

SVEUČILIŠTE U RIJECI
FAKULTET INFORMATIKE I DIGITALNIH TEHNOLOGIJA

Ive Botunac

**SUSTAV ZA AUTOMATSKO
TRGOVANJE DIONICAMA NA TRŽIŠTU
KAPITALA TEMELJEN NA DUBOKOM
PODRŽANOM UČENJU**

DOKTORSKI RAD

Rijeka, 2024.

SVEUČILIŠTE U RIJECI
FAKULTET INFORMATIKE I DIGITALNIH TEHNOLOGIJA

Ive Botunac

**SUSTAV ZA AUTOMATSKO
TRGOVANJE DIONICAMA NA TRŽIŠTU
KAPITALA TEMELJEN NA DUBOKOM
PODRŽANOM UČENJU**

DOKTORSKI RAD

Mentor: prof. dr. sc. Maja Matetić, Fakultet informatike i
digitalnih tehnologija

Rijeka, 2024.

UNIVERSITY OF RIJEKA
FACULTY OF INFORMATICS AND DIGITAL
TECHNOLOGIES

Ive Botunac

**AN AUTOMATED STOCK MARKET
TRADING SYSTEM BASED ON DEEP
REINFORCEMENT LEARNING**

DOCTORAL THESIS

Supervisor: Full Professor Maja Matetić, Faculty of informatics
and digital technologies

Rijeka, 2024

Mentor: prof. dr. sc. Maja Matetić, Fakultet informatike i digitalnih tehnologija

Doktorski rad obranjen je dana _____ u/na _____,

Pred povjerenstvom u sastavu:

1. _____
2. _____
3. _____
4. _____
5. _____

Sažetak

Ovaj rad predstavlja inovativni sustav za automatsko trgovanje dionicama na tržištu kapitala, koji integrira duboko podržano učenje i naprednu obradu prirodnog jezika. Istraživanje adresira izazove u automatiziranom trgovaju, uključujući volatilnost tržišta, kompleksnost finansijskih podataka i potrebu za kontinuiranom adaptacijom trgovačkih strategija.

Rad počinje sveobuhvatnim pregledom finansijskih tržišta i hipoteze efikasnog tržišta, postavljajući teorijski okvir za razumijevanje tržišne dinamike. Zatim se fokusira na evoluciju tehnika obrade prirodnog jezika, s posebnim naglaskom na Transformer arhitekturu i njenu primjenu u analizi finansijskih tekstova. Detaljno je istraženo duboko podržano učenje i njegova primjena u kontekstu finansijskog trgovanja.

Metodologija istraživanja obuhvaća razvoj dva modela: PrimoGPT, specijalizirani model za generiranje NLP značajki iz finansijskih tekstova, i PrimoRL, model dubokog podržanog učenja za donošenje trgovačkih odluka. PrimoGPT, temeljen na naprednoj Transformer arhitekturi, demonstrira sposobnost interpretacije kompleksnih finansijskih informacija, dok PrimoRL pokazuje izvanrednu adaptabilnost u dinamičnim tržišnim uvjetima.

Eksperimentalna evaluacija provedena je na dionicama vodećih tehnoloških kompanija u periodu od sedam mjeseci. Rezultati konzistentno pokazuju superiornost predloženog sustava nad tradicionalnim trgovačkim strategijama i drugim modelima strojnog učenja. Posebno su impresivne performanse na NFLX dionici s povratom od 41.19%, AAPL s povratom od 24.24% i AMZN dionici s 26.72% povrata, uz održavanje visokih Sharpe omjera.

Zaključno, rad unapređuje razumijevanje primjene umjetne inteligencije u finansijskom trgovaju i otvara perspektive za razvoj sofisticiranih automatiziranih trgovačkih sustava.

Ključne riječi: automatizirano trgovanje, strojno učenje, duboko podržano učenje, obrada prirodnog jezika, tržište kapitala, veliki jezični modeli, PrimoGPT, PrimoRL

Abstract

This paper presents an innovative system for automated stock trading in the stock market, integrating deep reinforcement learning and advanced natural language processing. The research addresses challenges in automated trading, including market volatility, the complexity of financial data, and the need to adapt trading strategies continuously.

The work begins with a comprehensive review of financial markets and the efficient market hypothesis, establishing a theoretical framework for understanding market dynamics. It then focuses on the evolution of natural language processing techniques, emphasizing the Transformer architecture and its application in financial text analysis. Deep reinforcement learning and its application in the context of financial trading are explored in detail.

The research methodology encompasses the development of two models: PrimoGPT, a specialized model for generating NLP features from financial texts, and PrimoRL, a deep reinforcement learning model for making trading decisions. PrimoGPT, based on advanced Transformer architecture, demonstrates the ability to interpret complex financial information, while PrimoRL exhibits exceptional adaptability in dynamic market conditions.

Experimental evaluation was conducted on stocks of leading technology companies over seven months. Results consistently show the proposed system's superiority over traditional trading strategies and other machine learning models. Particularly impressive performances were observed on NFLX stock, with a return of 41.19%, AAPL stock, with a return of 24.24%, and AMZN stock, with a 26.72% return, while maintaining high Sharpe ratios.

In conclusion, this work advances the understanding of artificial intelligence applications in financial trading and opens perspectives for developing more sophisticated automated trading systems.

Keywords: automated trading, machine learning, deep reinforcement learning, natural language processing, stock market, large language models, PrimoGPT, PrimoRL

Sadržaj

1 Uvod	1
1.1. Motivacija	4
1.2. Cilj, hipoteze i znanstveni doprinosi	4
1.3. Struktura rada	6
2 Pregled prethodnih istraživanja.....	7
2.1. Razvoj metoda predviđanja na tržištu kapitala	7
2.2. Primjena NLP-a u finansijskoj industriji	8
2.2.1. Razvoj i izazovi implementacije.....	9
2.2.2. Specijalizirani jezični modeli za financije.....	10
2.3. Sustavi dubokog podržanog učenja u trgovanim	12
2.3.1. Razvoj i implementacija	13
2.3.2. Specijalizirani sustavi i njihovi rezultati	14
3 Finansijska tržišta	16
3.1. Pregled finansijskih tržišta	16
3.2. Tržište kapitala	17
3.3. Hipoteza efikasnog tržišta	18
3.4. Vrste tržišnih analiza	20
3.4.1. Tehnička analiza.....	20
3.4.2. Fundamentalna analiza	22
3.4.3. Kvantitativna analiza	23
3.5. Upravljanje portfolijem	23
4 Obrada prirodnog jezika	25
4.1. Transformers arhitektura	26
4.1.1. Komponente Transformers arhitekture.....	27
4.1.2. Mehanizam pažnje u Transformers arhitekturi.....	29
4.1.3. Modeli temeljenih na Transformers arhitekturi.....	30
4.1.3.1. Modeli primarno bazirani na enkoderu	31
4.1.3.2. Modeli primarno bazirani na dekoderu	32
4.1.3.3. Modeli koji koriste enkoder-dekoder arhitekturu.....	33

4.1.3.4. Razvoj naprednih velikih jezičnih modela otvorenog koda	34
4.1.3.5. Prednosti Transformers arhitekture	35
4.2. Napredne tehnike treniranja i podešavanja.....	35
4.2.1. Treniranje modela instrukcijama	36
4.2.2. Tehnike optimizacije treniranih modela	38
4.2.3. Inženjering upita za modele.....	39
4.2.4. Generiranje pomoću pretraživanja.....	40
5 Duboko podržano učenje	43
5.1. Osnove podržanog učenja.....	44
5.1.1. Markovljev proces odlučivanja (MDP)	45
5.1.2. Nagrada i povrat	46
5.1.3. Funkcija vrijednosti i politika.....	47
5.2. Algoritmi podržanog učenja	48
5.2.1. Algoritmi bazirani na funkciji vrijednosti	50
5.2.1.1. Q-learning	50
5.2.1.2. Deep Q-networks (DQN).....	51
5.2.1.3. Double Deep Q-networks (DDQN).....	51
5.2.2. Algoritmi bazirani i na funkciji vrijednosti i politike.....	52
5.2.2.1. Proximal Policy Optimization (PPO)	53
5.2.2.2. Advantage Actor-Critic (A2C)	54
5.2.2.3. Soft Actor-Critic (SAC).....	54
6 Metodologija istraživanja	56
6.1. Dizajn arhitekture sustava	56
6.1.1. Pregled komponenti sustava	57
6.1.2. Modul za obradu i analizu teksta	58
6.1.3. Modul za donošenje odluka i trgovanje.....	59
6.1.4. Integracija modula i oblikovanje sustava	62
6.2. Prikupljanje i obrada podataka	63
6.2.1. Identifikacija izvora i prikupljanje podataka	63
6.2.2. Proces obrade i pohrane podataka	65
6.3. Metode generiranja značajki.....	69
6.3.1. Elementi upita za generiranje NLP značajki	69

6.3.2. Prilagodba i treniranje PrimoGPT modela	73
6.3.3. Generiranje značajki tehničkih indikatora	77
6.3.3.1. Jednostavan pomičan prosjek	77
6.3.3.2. Konvergencija/divergencija pomičnih prosjeka	78
6.3.3.3. Bollingerovi pojasevi.....	78
6.3.3.4. Indeks relativne jakosti.....	79
6.3.3.5. Indeks robnih kanala.....	80
6.3.3.6. Indeks usmjerenog kretanja.....	80
6.4. Oblikovanje okvira za duboko podržano učenje	81
6.4.1. Modeliranje sloja okruženja	82
6.4.2. Prilagodba i priprema za treniranje PrimoRL modela.....	84
7 Eksperiment i rezultati istraživanja	87
7.1. Postavka eksperimenta	87
7.1.1. Odabir skupa podataka	88
7.1.2. Mjerenje performansi modela.....	89
7.1.2.1. Standardne metrike za evaluaciju trgovачkih strategija	89
7.1.2.2. Evaluacija točnosti PrimoGPT modela.....	91
7.1.3. Usporedne strategije trgovanja	93
7.1.4. Implementacija značajki tehničkih indikatora.....	95
7.1.5. Tehničke specifikacije sustava	96
7.2. Izvršavanje i rezultati PrimoGPT modela	97
7.2.1. Provedba treniranja PrimoGPT modela.....	97
7.2.2. Prikaz rezultata PrimoGPT modela	99
7.3. Izvršavanje automatiziranog trgovanja koristeći PrimoRL	100
7.3.1. Provedba treniranja PrimoRL modela	101
7.3.2. Primjena sustava za automatizirano trgovanje	103
7.4. Rezultati i analiza performansi	103
7.4.1. Rezultati trgovanja za dionicu AAPL.....	104
7.4.2. Rezultati trgovanja za dionicu NFLX.....	106
7.4.3. Rezultati trgovanja za dionicu MSFT.....	109
7.4.4. Rezultati trgovanja za dionicu CRM	111
7.4.5. Rezultati trgovanja za dionicu AMZN	114

7.4.6. Rezultati trgovanja na razini portfolija.....	116
7.5. Diskusija rezultata	119
8 Zaključak.....	121
Literatura	125
Popis slika	138
Popis tablica	140
Pravitač	141

Poglavlje 1

Uvod

Finansijsko tržište igra važnu ulogu u oblikovanju globalnih ekonomija. Tržište kapitala kao dio finansijskog tržišta postaje sve važnije u ekonomskoj sferi, privlačeći time sve veću pažnju javnosti. Jedna teorija koja objašnjava cijene finansijskih sredstava i razloge iza volatilnosti tržišta dionica je hipoteza efikasnog tržišta (engl. Efficient Market Hypothesis, EMH) [1]. Ova hipoteza pretpostavlja da u zakonski uređenom, dobro funkcionalno reagirajućem, transparentnom i konkurentnom tržištu, investitori mogu brzo i racionalno odražavati sve tržišne informacije, zbog čega će cijene dionica točno, dovoljno i pravovremeno odražavati sve bitne činjenice, uključujući sadašnju i buduću vrijednost tvrtke [2]. Međutim, fluktuacije cijena dionica pod utjecajem su složenog niza faktora, uključujući izvještaje o zaradi tvrtki, nacionalne politike, utjecajne dioničare i stručna nagađanja o aktualnim događajima. Stoga postoji potreba za korištenjem raznih statističkih tehnika za zadatke kao što su predviđanje smjera kretanja dionica, predviđanje cijena dionica, upravljanje portfeljem i trgovačkim strategijama [3]. U kontekstu sve veće važnosti finansijskih tržišta, koja značajno utječe na različite sektore poput poslovanja i općenito ekonomije, analiza tržišta kapitala predstavlja stalni izazov upravo zbog te dinamične prirode. Tradicionalne teorije poput EMH-a, koje sugeriraju nepredvidljivost cijena dionica, temeljene su na zastarjelim informacijama i znanjima tog doba. Međutim, suvremena istraživanja [4] dovode u pitanje ove postavke, ukazujući na mogućnosti predviđanja tržišta kapitala. S napretkom istraživanja [5], nove empirijske studije izazivaju osnovne pretpostavke EMH-a, pružajući detaljniji uvid u dinamiku tržišnih cijena i informacijsku efikasnost. Daljnja istraživanja [6], [7] ističu ulogu tržišnih anomalija i psiholoških faktora, implicirajući potrebu za razvijanjem složenijih modela predviđanja koji mogu efikasno obrađivati i analizirati kompleksne tržišne podatke, proširujući tako razumijevanje dinamike finansijskih tržišta.

U istraživanjima predviđanja na tržištu kapitala općenito se koriste dvije poznate analitičke metode, fundamentalna analiza i tehnička analiza [8]. Fundamentalna analiza fokusira se na temeljne aspekte poslovanja određene tvrtke. Kada se pokušava predvidjeti cijena ili povrat dionice neke tvrtke, fundamentalni faktori obuhvaćaju prihode i rashode tvrtke, godišnju stopu rasta, njezinu poziciju na tržištu, te ostale informacije sadržane u finansijskim izvještajima [9], [10]. Kada se predviđa indeks dionica, što obuhvaća mnogo različitih dionica, moguće je koristiti iste informacije kao i informacije o općem

ekonomskom okruženju poput kretanja bruto društvenog proizvoda, stope zapošljavanja, valutnih tečajeva ili kamatnih stopa, što utječe na tvrtke uključene u taj indeks. S druge strane, tehnička analiza se temelji na proučavanju povijesnih podataka o cijenama i obujmu trgovine dionicama kako bi se predvidjela njihova buduća kretanja [11].

Većina tih prethodnih istraživanja primjenjivala je statističke metodologije analize vremenskih serija temeljene na povijesnim podacima za predviđanje cijena dionica i povrata. Među njima izdvajamo model auto-regresivne kondicionalne heteroskedastičnosti (engl. Auto-Regressive Conditional Heteroscedasticity), auto-regresivni pokretni prosjek (engl. Auto-Regressive Moving Average) i auto-regresivno integrirani pokretni prosjek (engl. Autoregressive Integrated Moving Average) [12]. Populariziranjem tehnika strojnog učenja nastaje sve veći interes znanstvene zajednice ka istraživanjima predviđanja na tržištu kapitala. Nasuprot tradicionalnim metodama vremenskih serija, ove tehnike su sposobne obraditi složene, nelinearne, bučne i kaotične podatke s finansijskih tržišta, što rezultira preciznijim predviđanjima [13]. Tehnike strojnog učenja koriste se u predviđanju cijena dionica kako bi se poboljšala točnost predviđanja i zaobišli problemi koji su mučili statističke metode koje su se koristile. Povjesno gledano, konvencionalni modeli poput modela temeljenih na stablima odlučivanja (engl. Decision Tree) [14], [15] i stroja s potpornim vektorima (engl. Support Vector Machine) [16] koristili su se upravo za predviđanja na ovim tržištima i prepoznavanju obrazaca kretanja dionica kako bi se odredio budući trend. Kako su se razvijali modeli dubokog učenja (engl. Deep Learning, DL), metode korištene za predviđanje tržišta dionica prešle su s tradicionalnih spomenutih tehnika na napredne tehnike dubokog učenja poput povratnih neuronskih mreža (engl. Recurrent Neural Network, RNN), mreža dugotrajne kratkoročne memorije (engl. Long Short-Term Memory, LSTM), ograđene povratne jedinice (engl. Gated Recurrent Unit, GRU) i konvolucijskih neuronskih mreža (engl. Convolutional Neural Network, CNN) [2]. Osim spomenutih metoda do izražaja dolaze metode iz područja obrade prirodnog jezika (engl. Natural Language Processing, NLP) koje se koriste za analize sentimenta. Analiza sentimenta predstavlja još jedan pristup koji se koristi na tržištima kapitala [17] koji označava proces predviđanja trendova putem analize tekstualnih korpusa poput vijesti ili objava na društvenim mrežama za specifičnu dionicu. Tehnike klasifikacije sentimenta uglavnom se dijele na pristup temeljen na metodama strojnog učenja i pristup temeljen na leksikonu, koji se dalje dijeli na pristup temeljen na rječniku ili pristup temeljen na korpusu [3], [18].

Nakon objave Transformers arhitekture neuronske mreže [19], područje obrade prirodnog jezika doživljava svoj uzlet pojmom brojnih novih modela od kojih ističemo one za generiranje teksta koje nazivamo generativni prethodno trenirani transformer (engl. Generative Pre-trained Transformer, GPT) [20] ili kolokvijalno veliki jezični modeli (engl. Large Language Model, LLM). Ovi modeli, specijalizirani za duboko razumijevanje i obradu prirodnog jezika, otvaraju nove mogućnosti za analizu i interpretaciju finansijskih podataka, pružajući detaljniji uvid u finansijske trendove i

informacije. Međutim, implementacija ovih modela u finansijsko tržište nosi sa sobom izazove kao što su prikupljanje relevantnih podataka, upravljanje kvalitetom podataka i njihovu ažurnost, što je ključno za precizno donošenje odluka u dinamičnom okruženju [21]. Trenutni trendovi u privatnom sektoru, poput razvoja BloombergGPT-a [22], pokazuju ekskluzivni pristup specijaliziranim finansijskim podacima, ali i potrebu za transparentnijim i otvorenijim pristupom u treniranju modela. Ovaj trend prema demokratizaciji finansijskih informacija i otvorenom kodu nagovještava novu eru u finansijskim istraživanjima, gdje šira dostupnost podataka i naprednih jezičnih modela potiče inovacije i istraživanja u finansijskom sektoru, pružajući nove perspektive i alate za analizu i predviđanje tržišta [21].

Uz razvoj NLP-a, posebno značajno mjesto zauzima primjena dubokog podržanog učenja (engl. Deep Reinforcement Learning, DRL) na finansijskom tržištu, posebno tržištu kapitala. DRL, koji balansira između istraživanja nepoznatog i iskorištavanja postojećeg znanja, prepoznat je kao efikasna metoda za automatsko trgovanje dionicama [23]. Ova tehnika je izrazito efikasna u rješavanju problema dinamičkog donošenja odluka kroz interakciju s nepoznatim okruženjem, pružajući dvostruku prednost, skalabilnost portfelja i neovisnost o tržišnom modelu [24]. DRL agenti razvijaju algoritamske trgovачke strategije koje uzimaju u obzir mnoge složene finansijske faktore, često previše kompleksne za ljudske trgovce [25]. Nedavno su se počele razvijati programske biblioteke poput FinRL [26], koje olakšavaju primjenu DRL-a u kvantitativnim financijama, pružajući jednostavno reproducibilne smjernice i mogućnost provođenja usporedbe s ostalim strategijama koje su tradicionalne za tržište kapitala. Kombiniranjem ovih naprednih tehnika DRL-a s NLP-om, posebno u kontekstu finansijskih tržišta, stvara se snažan hibridni pristup koji omogućava preciznije analize i predviđanja. Koristeći ovaj pristup otvaramo nove mogućnosti za istraživanje i primjenu složenih finansijskih modela, čime se unapređuju strategije trgovanja i upravljanje rizicima [27].

Ovaj rad predstavlja integraciju naprednih tehnika strojnog učenja, uključujući NLP i DRL, kako bi se simuliralo odlučivanje iskusnih finansijskih analitičara i donosile pouzdane te profitabilne odluke na finansijskim tržištima. Razvoj prilagođenih GPT modela, koji koriste Transformer arhitekturu za dubinsko razumijevanje i analizu finansijskih podataka, omogućit će stvaranje složenih DRL okruženja. Ova okruženja će replicirati stvarne tržišne uvjete, pružajući agentima mogućnost za treniranje kroz interakciju i optimizaciju trgovачkih strategija. U konačnici, ovaj pristup predstavlja ključnu inovaciju u automatiziranom trgovanju, kombinirajući tehnološki napredak i stručnost u finansijskom sektoru za postizanje optimalnih rezultata trgovanja.

1.1. Motivacija

Razvoj ovog istraživanja temelji se na ideji stvaranja inovativnog sustava koji bi investitorima na tržištu kapitala omogućio pametnije i sigurnije donošenje odluka. Motivacija upravo proizlazi iz težnje da se osiguraju inovativni alati koji će im pomoći u donošenju takvih odluka o trgovanju, čime bi se umanjili rizici i gubitci. Korištenjem naprednih tehnika strojnog učenja, poput NLP-a i DRL-a, ovaj rad teži simuliranju procesa odlučivanja iskusnih finansijskih analitičara, nudeći tako pristupačne i sofisticirane alate investitorima. Uključivanjem upravo tih tehniki iz domene NLP-a omogućava se detaljnija analiza i interpretacija finansijskih podataka, otvarajući nove perspektive u razumijevanju tržišnih trendova. Implementacija modela poput GPT-a u finansijskom sektoru donosi izazove u prikupljanju relevantnih podataka i upravljanju njihovom kvalitetom, no istovremeno pruža mogućnosti za dublje uvide i preciznije odluke.

Rad organizacije AI4Finance Foundation [21], [23], [26], [27], [28] u promicanju demokratizacije finansijskih informacija i otvorenog koda, ima značajan doprinos u ovom području, pružajući platformu za dijeljenje znanja i inovacije. Njihov rad omogućuje široj zajednicici pristup naprednim finansijskim alatima i metodama, potičući suradnju i istraživanje. U kontekstu kod primjerice robo-savjetovanja (engl. Robo-Advising), tehnologije poput NLP-a i DRL-a nude napredne metode za automatizirano investicijsko savjetovanje s minimalnom ljudskom intervencijom. Kroz primjenu ovih tehnologija, robo-savjetnici postaju sposobni za obradu raznovrsnih izvora podataka, uključujući društvene medije i finansijske izvještaje, pružajući pritom prilagođene i ažurne investicijske preporuke.

Osnovna motivacija je omogućiti simulaciju složenih procesa odlučivanja koje provode iskusni finansijski analitičari, koristeći moć velikih jezičnih modela i dubokog učenja. Cilj je razvoj sustava koji se ne ograničava samo na poboljšanje preciznosti predviđanja i efikasnosti trgovačkih odluka, već i na sofisticirano upravljanje rizikom. Takav pristup ima potencijal pružiti ključnu podršku investitorima, omogućujući im da ostvare optimalne rezultate na tržištu kapitala. Uspostavljanjem ovog sustava, teži se ka demokratizaciji složenih finansijskih analiza, čineći ih dostupnima široj populaciji investitora i time promičući transparentnije i pravednije finansijsko tržište.

1.2. Cilj, hipoteze i znanstveni doprinosi

Cilj ovog istraživanja je razvoj hibridnog sustava koji kombinira napredne tehnike strojnog učenja kako bi pružio podršku investitorima u donošenju informiranih trgovačkih odluka. Sustav ima za cilj minimizirati rizik i potencijalne gubitke, koristeći duboku analizu finansijskih tržišta i primjenjujući najnovije tehnologije u obradi

prirodnog jezika i dubokom podržanom učenju. Ključan element istraživanja je identifikacija karakteristika finansijskog tržišta i istraživanje kako se navedene tehnike mogu primijeniti za postizanje optimalnih trgovačkih strategija, čime se cilja na ostvarivanje značajnih poboljšanja u odnosu na tradicionalne pristupe trgovaniju na tržištu kapitala.

Znanstvene hipoteze rada:

H1: Predložen modularni sustav za trgovanje na tržištu kapitala može poboljšati povrat ulaganja u odnosu na referentne strategije.

H2: Koristeći sentiment analizu može se poboljšati predviđanje smjera kretanja vrijednosnica na tržištu kapitala.

H3: Korištenje mehanizma pozornosti u procesu prikupljanja i obrade podataka može se učinkovitije formirati relevantniji skup podataka.

H4: Koristeći duboko podržano učenje kao pristup za dinamičko donošenje odluka mogu se generirati profitabilne trgovačke akcije.

Očekivani znanstveni doprinosi su:

1. Model prikupljanja i obrade podataka potrebnih za predloženu metodu strojnog učenja.
2. Sustav za automatsko trgovanje dionica koji uključuje module za predviđanje smjera kretanje, odabir dionica, optimizaciju portfolija te donošenja odluka za trgovanje na tržištu kapitala.
3. Okvir za evaluaciju i usporedbu različitih trgovačkih strategija, uključujući tradicionalne metode i napredne pristupe temeljene na strojnom učenju.
4. Metodologija za fino podešavanje i optimizaciju modela za specifične zahtjeve finansijskih tržišta.

Navedeni znanstveni doprinosi ostvareni su kroz nekoliko komponenti ovog rada. Prvi doprinos realiziran je razvojem sustava za prikupljanje i obradu finansijskih podataka opisanog u poglavljju 6.2., koji obuhvaća automatizirano prikupljanje podataka s više izvora te njihovu naprednu obradu. Učinkovitost ovog modela potvrđena je kroz rezultate u poglavljju 7.2., gdje je demonstrirana točnost generiranih značajki na više odabranih dionica.

Drugi doprinos implementiran je kroz razvoj modularnog sustava koji integrira NLP i DRL komponente, što je detaljno prikazano u poglavljima 6.1., 6.3. i 6.4.. Sustav, koji se sastoji od PrimoGPT modula za obradu prirodnog jezika i PrimoRL modula za donošenje trgovačkih odluka, pokazao je značajnu učinkovitost kroz rezultate predstavljene u poglavljju 7.4., gdje su ostvareni prinosi koji nadmašuju tradicionalne trgovačke strategije.

Treći doprinos ostvaren je kroz razvoj evaluacijskog okvira opisanog u poglavlju 7.1., koji obuhvaća standardne metrike za procjenu trgovačkih strategija te posebno razvijenu metriku za evaluaciju PrimoGPT modela. Primjena ovog okvira demonstrirana je kroz detaljnu usporedbu različitih strategija u poglavlju 7.4..

Četvrti doprinos realiziran je kroz razvoj metodologije za fino podešavanje opisane u poglavljima 6.3.2. i 6.4.2., koja uključuje primjenu naprednih tehnika za efikasno treniranje jezičnih modela te optimizirane pristupe treniranju DRL agenata. Učinkovitost ove metodologije potvrđena je rezultatima predstavljenima u poglavljima 7.2. i 7.3..

1.3. Struktura rada

Ova doktorska disertacija sastoji se od ukupno osam poglavlja. Prvo poglavlje je uvod gdje se detaljno pruža osvrt na finansijska tržišta i korištenje metoda strojnog učenja na tom tržištu. Nakon uvoda, drugo poglavlje daje sveobuhvatan pregled prethodnih istraživanja, s posebnim naglaskom na razvoj metoda predviđanja na tržištu kapitala, primjenu NLP-a u finansijskoj industriji te sustave dubokog podržanog učenja u trgovanju. Treće poglavlje disertacije detaljno istražuje finansijska tržišta, počevši od temeljnih mehanizama i struktura, preko razvoja hipoteze efektivnog tržišta, pa sve do prikupljanja i obrade finansijskih podataka. U ovom poglavlju posebno se istražuju različiti pristupi tržišnoj analizi, uključujući tehničku, fundamentalnu i kvantitativnu analizu, s fokusom na njihovu primjenu u kontekstu modernih financija. U četvrtom poglavlju, fokus se prebacuje na obradu prirodnog jezika, gdje se proučavaju teorijski okviri NLP-a, specifičnosti finansijskog jezika, te izazovi njegove obrade u finansijskom sektoru. Posebna pažnja posvećuje se Transformer modelima, uključujući njihovu arhitekturu, funkcionalnost i specifične primjene u financijama. Peto poglavlje detaljno istražuje podržano učenje, od osnova podržanog učenja i Markovljevih procesa odlučivanja, do različitih metoda evaluacije i optimizacije politika. Ovo poglavlje također obuhvaća napredne algoritme podržanog učenja te njihovu primjenu u kontekstu financija. Šesto poglavlje usmjerava se na metodologiju istraživanja, od planiranja i odabira modela, preko arhitekture eksperimentalnog sustava i prikupljanja podataka, do testiranja i evaluacije hipoteza. Sedmo poglavlje disertacije posvećeno je eksperimentima i rezultatima istraživanja. U ovom poglavlju, postavlja se eksperimentalni okvir i analiziraju se rezultati, uključujući evaluaciju modela, upravljanje rizikom i prikaz dobivenih rezultata pomoću predloženog sustava automatiziranog trgovanja. Osmo poglavlje zaključuje disertaciju pružajući opsežan pregled cijelog istraživanja. U ovom završnom dijelu, sumiraju se rezultati, diskutiraju se implikacije i ograničenja istraživanja, te se nude smjernice za buduća istraživanja u području automatiziranog trgovanja koristeći napredne tehnike strojnog učenja. Ovo poglavlje također ističe doprinos istraživanja znanstvenoj zajednici i praktičnoj primjeni u finansijskom sektoru.

Poglavlje 2

Pregled prethodnih istraživanja

Sistematičan pregled postojećih rješenja i trenutnog stanja područja predstavlja temelj za razumijevanje mogućnosti i ograničenja suvremenih sustava za automatizirano trgovanje. Napredak u području strojnog učenja doveo je do značajnih promjena u načinu razvoja i implementaciji automatiziranih sustava za trgovanje, gdje algoritmi mogu prepoznati složene obrasce iz finansijskih podataka [2]. Tradicionalne tehnike analize zamjenjuju se naprednjim pristupima koji se mogu svrstati u četiri glavne kategorije: statističke metode, prepoznavanje uzoraka, strojno učenje i analiza sentimenta [3]. Posebno se ističu tri ključna područja razvoja: sustavi za automatizirano trgovanje, primjena naprednih jezičnih modela u finansijskoj analizi te implementacija sustava dubokog podržanog učenja.

Ova evolucija prema integriranim sustavima strojnog učenja obilježena je prelaskom s tradicionalnih tehnika na napredne pristupe poput povratnih neuronskih mreža, mreža dugotrajne kratkoročne memorije, konvolucijskih neuronskih mreža i Transformer-a [2], [29]. U narednim poglavljima detaljno se analizira razvoj i trenutno stanje svakog od ovih područja, s posebnim naglaskom na najnovija dostignuća i mogućnosti koje nude za unapređenje automatiziranog trgovanja.

2.1. Razvoj metoda predviđanja na tržištu kapitala

Razvoj metoda predviđanja na tržištu kapitala značajno je evoluirao posljednjih desetljeća, prateći napredak u računalnoj tehnologiji i metodama strojnog učenja. Rana istraživanja demonstrirala su superiornost LSTM mreža u dohvaćanju informacija iz finansijskih vremenskih serija, postižući impresivne dnevne prinose od 0,46% prije transakcijskih troškova na tržištu [30].

Značajan napredak postignut je kroz razvoj ModAugNet modela, koji donosi inovativni pristup augmentaciji podataka za predviđanje tržišnih indeksa. Ovaj pristup pokazao je značajno poboljšanje točnosti predviđanja na S&P500 i KOSPI200 indeksima, smanjujući srednju kvadratnu pogrešku za više od 50% [31]. Testiranja na portfeljima temeljenim na LSTM predviđanjima pokazala su bolje rezultate nad tradicionalnim pristupima, ostvarujući bolje prosječne dnevne prinose uz nižu volatilnost [32].

U području dubokog učenja, razvijen je okvir koji integrira više slojeva dubokih neuronskih mreža za predviđanje cijena dionica [33]. Ovaj pristup posebno je značajan jer demonstrira kako kombiniranje različitih tehnika dubokog učenja može poboljšati predviđanja u različitim tržišnim uvjetima. Paralelno, razvijen je hibridni pristup koji kombinira tehniku eliminacije unatrag s LSTM modelom, pokazujući kako pažljiv odabir značajki može značajno poboljšati performanse u predviđanju kretanja burzovnih indeksa [34].

Inovativni pristupi u integraciji LSTM-a s dinamičkim indikatorima rezultirali su stvaranjem sveobuhvatnog sustava predviđanja tržišta [35]. Posebno je značajna metodologija prilagodbe indikatora različitim tržišnim uvjetima. U području validacije trgovачkih strategija, razvijeni su novi pristupi testiranju koji uvode rigoroznu metodologiju za evaluaciju učinkovitosti strategija temeljenih na dubokom učenju [36].

Novija istraživanja fokusiraju se na razvoj sustava za trgovanje koji mogu učinkovito raditi s ograničenim računalnim resursima, istovremeno održavajući visoku preciznost predviđanja [37]. Ova dostignuća posebno su značajna jer pokazuju kako se napredne tehnike predviđanja mogu učinkovito implementirati i u okruženjima s ograničenim resursima.

Ovi razvojni trendovi pokazuju kontinuirano unapređenje metoda predviđanja na tržištu kapitala, s posebnim naglaskom na integraciju različitih pristupa i prilagodbu specifičnim tržišnim uvjetima. Razvoj ide u smjeru sve sofisticirajih modela koji mogu učinkovito obrađivati velike količine podataka i prilagodavati se dinamičnim tržišnim uvjetima.

2.2. Primjena NLP-a u financijskoj industriji

Razvoj obrade prirodnog jezika u financijskoj industriji, posebice na tržištu kapitala, označava značajnu promjenu u pristupu financijskim analizama i donošenju odluka. Popularizacija velikih jezičnih modela, predstavila je revolucionarne mogućnosti za analizu i interpretaciju velikih skupova podataka [38]. Početna istraživanja istaknula su potencijal financijskih vijesti za predviđanje kratkoročnih tržišnih povrata kroz analizu sentimenta [39], [40], [41], postavljajući temelje za širu primjenu NLP-a u analizi financijskih tržišta. Ova rana otkrića su pokazala kako NLP može obogatiti financijski sektor novim uvidima i poboljšati procese donošenja odluka. Također su ukazala na potrebu za dalnjim istraživanjem i razvojem specijaliziranih NLP rješenja.

S razvojem i implementacijom specifičnih financijskih LLM-ova [42], istraživači su započeli dubinsku analizu različitih izvora tekstualnih podataka, uključujući vijesti i izvještaje kompanija, kako bi potaknuli preciznije investicijske i trgovачke odluke [43]. Ovi modeli, trenirani na opsežnim skupovima podataka, pokazali su se sposobnima za obradu i tumačenje kompleksnih financijskih informacija, pružajući nove prilike za predviđanje tržišnih kretanja i automatizaciju trgovanja. Unatoč izazovima koje donosi razumijevanje specifičnog financijskog žargona i dinamičnosti tržišta, napredak u

tehnologiji NLP-a omogućio je stvaranje sofisticiranih alata za finansijsku analizu, ističući važnost kontinuiranog usavršavanja i prilagodbe modela sukladno promjenjivim tržišnim uvjetima [44].

Evolucija NLP tehnologija u finansijskom sektoru ilustrira kako se napredak u obradi prirodnog jezika može koristiti za transformaciju tradicionalnih pristupa analizi i trgovjanju, naglašavajući ključnu ulogu kontinuiranih istraživanja i inovacija. Razvoj NLP-a predstavlja važan element u razumijevanju tržišnih kretanja, nudeći nove mogućnosti za automatizaciju i poboljšanje finansijskih odluka i strategija. Ovaj kontinuirani napredak i specijalizacija tehnologija ostaju od suštinske važnosti za budućnost finansijskog sektora, posebno u kontekstu tržišta kapitala, gdje inovativna NLP rješenja obećavaju dodatno unapređenje efikasnosti i efektivnosti finansijskih operacija.

2.2.1. Razvoj i izazovi implementacije

Jedan od primarnih ciljeva u primjeni NLP unutar finansijske industrije leži u automatizaciji finansijskog izvještavanja, transformirajući velike skupove podataka u sažete i informativne izvještaje. Ovaj proces smanjuje vrijeme potrebno za analizu i omogućava brže donošenje odluka temeljenih na točnim i aktualnim informacijama. Uz automatizaciju, primjena NLP-a cilja na unaprjeđenje analitičkih procesa kroz interpretaciju emocionalnog tonusa vijesti i društvenih mreža, predviđajući kretanja na tržištu kroz analizu sentimenta. Ova sposobnost NLP modela otvara vrata za dublje razumijevanje tržišnih sentimenta, pružajući trgovcima vrijedne uvide koji mogu utjecati na razvoj njihovih trgovačkih strategija [45], [46].

Unatoč impresivnim mogućnostima, implementacija NLP-a u financije suočava se s izazovima koji proizlaze iz inherentne složenosti finansijskog sektora. Specifični finansijski žargon i kompleksnost terminologije zahtijevaju razvoj sofisticiranih NLP modela koji mogu precizno tumačiti i analizirati finansijski jezik [44]. Dinamičnost tržišta i stalni priljev novih informacija postavljaju visoke zahtjeve za ažurnost i točnost predviđanja, dok specifičnosti finansijskih izvještaja i potreba za domenskim znanjem tijekom treniranja modela dodatno komplikiraju proces razvoja. Izazovi se protežu i na tehničku stranu, gdje su značajni računalni resursi neophodni za treniranje i održavanje modela, zajedno s potrebom za strogošću u zaštiti privatnosti i sigurnosti osjetljivih finansijskih podataka.

Rane primjene NLP-a u finansijskoj industriji, poput sentiment analize, klasifikacije objava [46] i predviđanja vremenskih serija, demonstrirale su značajne prednosti koje tehnologija može pružiti [40], [41], [47]. Korištenje NLP-a za unaprjeđenje trgovačkih strategija temeljenih na analizi sentimenta vijesti i društvenih medija otvorilo je nove puteve za predviđanje kratkoročnih tržišnih povrata, dok su automatizirano izvještavanje i otkrivanje prijevara postavili temelje za efikasnije i sigurnije finansijske procese. Ove

rane implementacije naglašavaju ne samo praktičnu vrijednost NLP tehnologija u financijama, već i poticaj za kontinuirani razvoj i integraciju naprednijih NLP rješenja. Suočeni s izazovima specifičnog finansijskog jezika, dinamičnosti tržišta, i potrebom za detaljnim domenskim znanjem, ključno je usmjeriti napore na razvoj i prilagodbu specijaliziranih LLM-ova [22], [48], [49]. Takvi modeli trebaju biti dizajnirani s ciljem precizne interpretacije finansijskih podataka i brzog prilagođavanja tržišnim promjenama, osiguravajući time relevantnost i točnost u svakom trenutku. Kontinuirani napredak i inovacije u području NLP-a važne su za prevladavanje ovih izazova, omogućavajući finansijskom sektoru da u potpunosti iskoristi potencijale automatizacije, analize, i sigurnosti koje NLP nudi, te time oblikuje budućnost finansijskih analiza i odluka.

2.2.2. Specijalizirani jezični modeli za financije

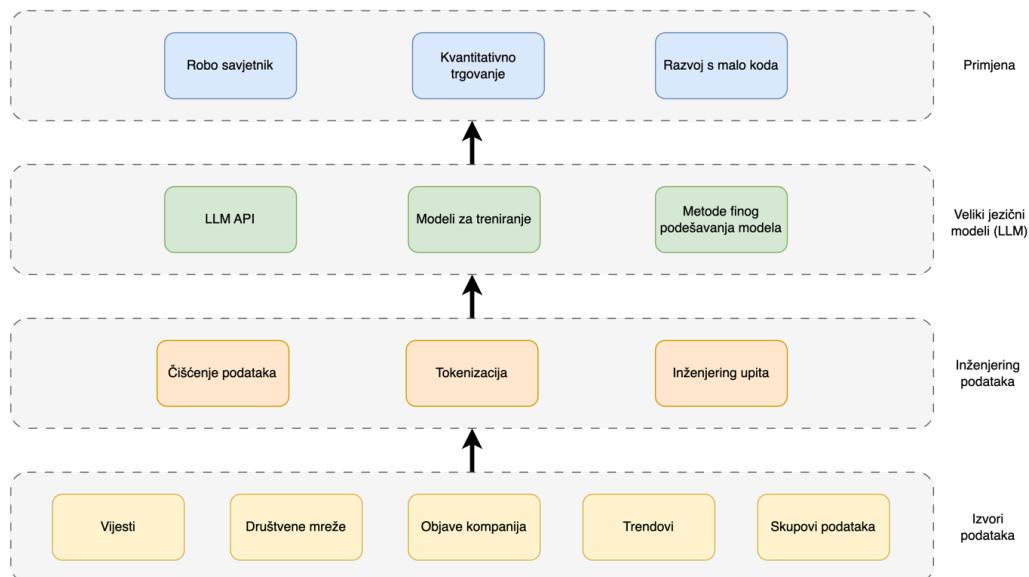
Razvoj specijaliziranih modela za finansijsku industriju doživljava svoj napredak korištenjem Transformers arhitekture, odgovarajući time na jedinstvene potrebe i izazove ove industrije. U svijetu gdje finansijski podaci igraju glavnu ulogu u donošenju odluka, precizna obrada i analiza teksta postaje imperativ. Unutar ovog konteksta, izdvajaju se modeli poput FinBERT-a [50], BloombergGPT-a [22] i FinGPT-a [48], donoseći napredak u polju finansijskog NLP-a i otvarajući prostor za bolje razumijevanje složenih finansijskih informacija.

FinBERT, predstavlja model specijaliziran za finansijsku industriju, koji se temelji na BERT modelu [51] i razvijen je kako bi se suočio s izazovima nedostatka označenih podataka karakterističnih za ovo područje. Kroz primjenu dubokog učenja i specifičnih tehniki obrade prirodnog jezika, model uspješno nadilazi ograničenja standardnih NLP modela, uvodeći treniranje na šest specifičnih zadataka (engl. Downstream Task) koji omogućavaju efikasnije hvatanje jezičnih značajki i semantičkih informacija iz finansijskih tekstova. FinBERT se posebno ističe u analizi sentimenta finansijskih vijesti i izvještaja, što dodatno doprinosi kod predviđanje tržišnih kretanja. Također, model pokazuje značajno poboljšanje u ekstrakciji relevantnih informacija iz složenih finansijskih dokumenata, što može znatno ubrzati i poboljšati proces donošenja investicijskih odluka. Rezultati pokazuju da FinBERT postavlja nove standarde u analizi finansijskih tekstova, pružajući izvanrednu učinkovitost i robusnost u različitim zadacima poput analize sentimenta i odgovaranja na pitanja, čime demonstrira svoj potencijal za transformaciju pristupa finansijskim informacijama i poticanje inovacija unutar finansijskog sektora [49].

S druge strane, BloombergGPT [22] također predstavlja novi pristup korištenja Transformers arhitekture u finansijskoj industriji. Kao model s 50 milijardi parametara, treniran na opsežnom skupu finansijskih podataka, BloombergGPT demonstrira značajnu prednost nad postojećim modelima u raznim finansijskim zadacima. Model se ističe

svojom sposobnošću da integrira i analizira ogromne količine finansijskih podataka iz različitih izvora, uključujući vijesti, tržišne podatke i finansijske izvještaje. Ova sposobnost omogućuje BloombergGPT-u da pruži sveobuhvatnije i preciznije analize tržišnih trendova i rizika, što je posebno važno za institucije koje se bave upravljanjem imovinom i trgovanjem na finansijskim tržištima. Ovaj model uspješno balansira između specijaliziranih finansijskih zadataka i održavanja konkurentnosti na općim NLP zadacima, čime postaje izuzetno vrijedan alat u finansijskoj industriji. Njegova sposobnost da pruži dublji uvid i preciznije analize finansijskih trendova čini ga dobrom resursom za donošenje informiranih investicijskih odluka.

FinGPT [48] unosi promjene kao jezični model otvorenog koda specifično dizajniran za potrebe finansijske industrije. Kao odgovor na ograničenja modela zatvorenog koda poput BloombergGPT-a, FinGPT promiče otvoreni pristup i transparentnost, ciljajući na stimulaciju inovacija i olakšavanje istraživanja i razvoja u domeni finansijskih LLM-ova. FinGPT se ističe svojom fleksibilnošću i prilagodljivošću različitim finansijskim zadacima. Model je posebno učinkovit u generiranju finansijskih izvještaja, sažimanju kompleksnih finansijskih dokumenata i pružanju personaliziranih finansijskih savjeta. Njegova arhitektura otvorenog koda omogućuje istraživačima i razvojnim timovima da ga prilagode specifičnim potrebama svojih organizacija, što otvara nove mogućnosti za inovacije u područjima kao što su upravljanje rizicima i otkrivanje prijevara u finansijskom sektoru. Ovaj model omogućava razvoj različitih aplikacija, od robotiziranog savjetovanja do algoritamskog trgovanja, time otvarajući nove mogućnosti i prilike unutar korištenja umjetne inteligencije u finansijskoj industriji [48]. Detaljan pregled arhitekture i potencijalne primjene FinGPT modela u finansijskom sektoru prikazan je na Slici 2.1., gdje se jasno može vidjeti kako se primjenjuju ključne komponente ovog modela za optimizaciju finansijskih operacija.



Slika 2.1: Arhitektura i primjena FinGPT modela u finansijskom sektoru [52]

Instruct-FinGPT [53], kao osnovni dio FinGPT platforme, istražuje kako prilagoditi LLM-ove za specifične potrebe analize financijskog sentimenta. Kroz posebnu metodu treninga s uputama, Instruct-FinGPT poboljšava razumijevanje konteksta i numeričkih podataka, otvarajući put za naprednije analize financijskog sentimenta. FinGPT-a ističe važnost demokratizacije pristupa financijskim podacima na globalnoj razini, koristeći automatizaciju za sakupljanje i obradu podataka u stvarnom vremenu [52].

Osim prethodno spomenutih modela, u financijskoj industriji nailazimo na još inovativnih pristupa koji koriste velike jezične modele za specifične potrebe tržišta. FinPT [54] je jedan takav model koji u predikciji financijskih rizika predstavlja značajan pomak, koristeći tehniku profilnog podešavanja na prethodno treniranim temeljnim modelima. Ovaj model transformira tabularne financijske podatke u detaljne jezične profile korisnika, zatim koristi te profile za fino podešavanje modela koji mogu predviđati različite financijske rizike poput kreditnog rizika, prijevare ili prekida suradnje [54].

FinVis-GPT [55], s druge strane, predstavlja inovativni multimodalni pristup, kombinirajući sposobnosti LLM-a s vizualnom analitikom za dubinsku analizu financijskih grafikona. Razvijen za interpretaciju složenih financijskih podataka koji se često prezentiraju u vizualnom obliku, ovaj model može generirati opise, odgovarati na pitanja te čak predviđati buduće tržišne trendove [55]. Kroz primjenu naprednih tehnika dubokog učenja i prirodne obrade jezika, modeli poput FinPT-a i FinVis-GPT-a šire spektar mogućnosti LLM-ova i pružaju nove perspektive za financijsku analizu i predviđanje.

Zaključno, razvoj specijaliziranih modela za financijsku industriju, od FinBERT-a i BloombergGPT-a do FinGPT-a, FinPT-a i FinVis-GPT-a, pokazuje napredak i širinu mogućnosti koje napredne tehnologije dubokog učenja i NLP-a nude. Ovi modeli pružaju naprednije alate za financijsku analizu i predikciju te naglašavaju važnost pristupa temeljenih na podacima, interdisciplinarnosti i inovacijama, otvarajući nove puteve u razumijevanju i primjeni financijskih informacija.

2.3. Sustavi dubokog podržanog učenja u trgovanju

U okviru brzorastuće industrije financijske tehnologije (engl. FinTech), algoritamsko trgovanje se ističe kao područje koje nosi brojne izazove i prilike za primjenu dubokog podržanog učenja. Prema podacima iz industrije, cilj je koristiti DRL za automatizaciju trgovačkih odluka i za unaprjeđenje analitičkih metoda koje temelje odluke na robustnoj kvantitativnoj analizi [56]. Ove analize obuhvaćaju široki spektar strategija, od temeljne analize do makro strategija i kvantitativnih pristupa, koje su ključne za razumijevanje i predviđanje tržišnih kretanja.

DRL se pokazao kao posebno koristan u rješavanju složenih, dinamičkih problema donošenja odluka u stohastičkim i djelomično opservabilnim tržišnim uvjetima, gdje tradicionalni pristupi i konvencionalne metode strojnog učenja često zakažu [27]. S

obzirom na to, nedavna istraživanja usmjerena su na unapređenje reproduktivnosti i razvoj robusnih tržišnih simulacija koje precizno oponašaju stvarne uvjete, čime se smanjuje jaz između simulacije i realnosti, što je ključno za pouzdanost DRL strategija [26], [57].

U ovom dijelu poglavlja detaljno se razmatra kako se DRL može efikasno primijeniti u različitim aspektima financijskog trgovanja, istražujući kako tehnološki napredak omogućuje razvoj sofisticiranih trgovačkih alata koji mogu doprinijeti inovacijama u financijskom sektoru. Daje se osvrt na ranu primjenu DRL-a u financijskim operacijama, izazove s kojima se susrećemo i kako se sučeljavamo s njima, uz fokus na izgradnju pouzdanih modela i algoritama koji mogu služiti kao temelj za buduće istraživanje i razvoj u području algoritamskog trgovanja.

2.3.1. Razvoj i implementacija

Primjena DRL-a u automatiziranom trgovaju usmjerena je na ostvarivanje prinosa i poboljšanje povrata ulaganja kroz sofisticirane algoritme. Osnovni cilj DRL-a u ovoj domeni je razvoj modela koji efikasno koriste multivarijantne podatke, uključujući tržišne podatke, tehničke indikatore, fundamentalne podatke i financijske novosti kako bi naučili dinamičke trgovačke strategije i postigli veće profite od klasičnih strategija trgovanja [58]. Primjena DRL-a omogućava integraciju različitih izvora podataka koji se potom koriste za formiranje stanja tržišta, što agentima omogućava da donose informirane trgovačke odluke temeljene na složenom i promjenjivom okruženju tržišta.

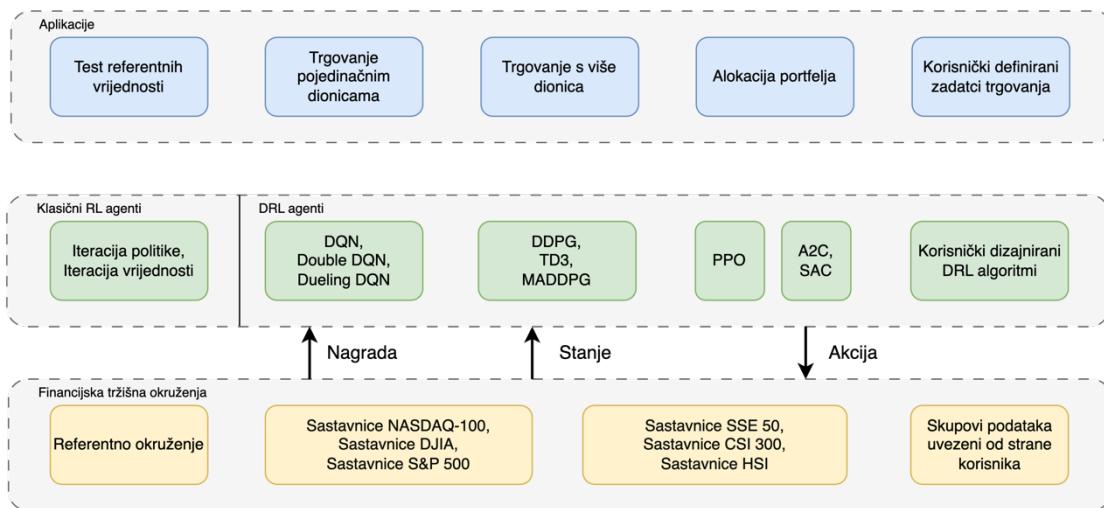
Glavni izazovi u korištenju DRL-a za automatizirano trgovanje obuhvaćaju premošćivanje razlika između simulacija i stvarnih uvjeta, kao i problemi s prekomjernim prilagođavanjem i kvalitetom podataka. Simulacijsko-okolišni jaz, niska razina odnosa signal-šum u financijskim podacima, te odgođeno nagrađivanje su faktori koji mogu umanjiti učinkovitost DRL strategija na tržištu. Često se događa da stvarna izvedba trgovačkih strategija ne odgovara simuliranoj zbog problema poput nedostataka, šuma i anomalija u financijskim podacima [27]. Dodatno, integracija troškova trgovanja, koji uključuju eksplicitne troškove poput transakcijskih troškova i poreza te implicitne troškove kao što su troškovi klizanja, predstavlja izazov u modeliranju. Ovi troškovi značajno utječu na realističnost rezultata simulacije, pogotovo kada je frekvencija trgovanja visoka [59].

Rane primjene DRL-a u automatiziranom trgovaju obuhvaćaju razvoj modela za generiranje trgovačkih signala temeljenih na povijesnim transakcijskim informacijama i financijskom statusu imovine. Jedan od primjera je razvoj modela optimizacije portfelja koji koristi poboljšani algoritam dubokog podržanog učenja [60], [61]. Osim toga, FinRL-
Podracer [62] predstavlja inovativni okvir koji ubrzava razvoj toka za DRL trgovačke strategije, obećavajući visoke performanse i skalabilnost na cloud platformama. Ovaj okvir omogućuje kontinuiranu obuku, integraciju i isporuku DRL vođenih trgovačkih

strategija, ističući potencijal za šire primjene DRL-a u različitim finansijskim zadacima poput alokacije portfelja, detekcije prijevara, i poboljšanja prinosa [63]. Kroz ovaj segment, razmatra se integracija modela i podataka, te nadzor nad kvalitetom podataka igraju ključnu ulogu u razvoju pouzdanih i efikasnih DRL aplikacija u finansijskom sektoru. Kontinuirana iteracija kroz razvoj modela i validacija u dinamičnim tržišnim uvjetima ostaje izazov, ali i prilika za daljnje unapređenje tehnologije podržanog učenja u finansijskom trgovanju.

2.3.2. Specijalizirani sustavi i njihovi rezultati

Posljednjih nekoliko godina, razvoj podržanog učenja omogućio je bolje iskorištavanje velikih skupova finansijskih podataka, prevladavajući prepostavke tradicionalnih modela i poboljšavajući proces donošenja finansijskih odluka. U svom radu, Hambly et al. [23] daju pregled novih razvoja i primjene RL pristupa u financijama, ističući kako se RL metode, uključujući metode temeljene na vrijednosti i politici koje ne zahtijevaju prepostavke o modelu, mogu primjenjivati u raznim finansijskim problemima kao što su optimalna izvedba, optimizacija portfelja, tržišno oblikovanje i robo-savjetovanje [64]. Istovremeno, posebno se ističu modeli poput FinRL-a [26] i TradeMaster-a [65], koji predstavljaju vrhunac primjene dubokog podržanog učenja u automatiziranom trgovanju. FinRL [26] predstavlja programsku biblioteku dizajniranu za razvoj prilagođenih strategija trgovanja dionicama, čija arhitektura i primjena u finansijskom sektoru detaljno su prikazani na Slici 2.2..



Slika 2.2: Pregled arhitekture i primjene FinRL modela u finansijskom sektoru [26]

Ova biblioteka opremljena je modularnom strukturu i nudi precizno podešene DRL algoritme, uključujući DQN, DDPG, PPO i druge, čime korisnicima omogućuje

učinkovito simuliranje trgovačkih okruženja u različitim vremenskim intervalima i na različitim tržištima. Osim toga, biblioteka integrira trgovačka ograničenja kao što su troškovi transakcija, tržišna likvidnost i stupanj izbjegavanja rizika ulagatelja, čineći je izuzetno relevantnom za realne trgovačke scenarije. Dodatno, FinRL-Meta [57], proširena verzija koju održava zajednica AI4Finance pruža brojna tržišnih okruženja, nudeći pri tome sveobuhvatnu dokumentaciju i resurse za testiranje te implementaciju svojih strategija.

Osim FinRL-a, značajan razvoj u ovom području ostvarila je biblioteka TradeMaster [65], koja predstavlja cjelovitu platformu za automatizirano trgovanje. Platforma pokriva četiri glavna financijska tržišta, šest trgovačkih scenarija te 15 algoritama podržanog učenja i niz alata za vizualnu evaluaciju. TradeMaster obuhvaća šest modula koji pokrivaju cijeli proces od dizajna, preko implementacije, do testiranja algoritama za kvantitativno trgovanje.

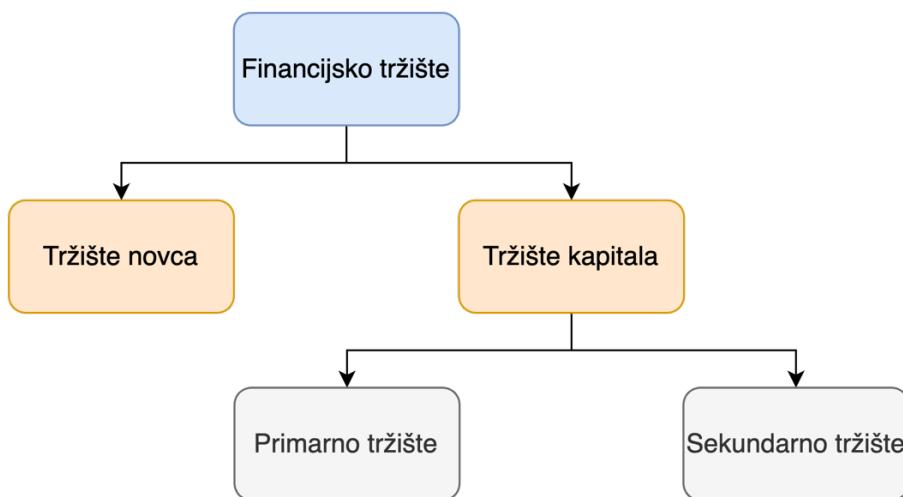
Od strane istraživača s istog instituta ističe se i nedavno objavljeno istraživanje koje predstavlja novi pristup u primjeni RL-a za automatizirano trgovanje pod nazivom EarnMore [66]. EarnMore je inovativni okvir podržanog učenja razvijen za upravljanje portfeljem, omogućuje optimizaciju kapitala u različite dionice za dugoročni profit uz jednokratni treniranje u globalnom skupu dionica. Također rješava izazove tradicionalnih RL metoda koje zahtijevaju ponovno treniranje pri svakoj promjeni skupa dionica, što dovodi do visokih operativnih troškova za računalne resurse. EarnMore koristi poseban mehanizam za maskiranje reprezentacija dionica izvan ciljanog skupa i treniranje reprezentacija kroz samonadzirani proces [66]. Ovime značajno nadmašuje referentne modele ostvarujući preko 40% poboljšanja u vidu povrata ulaganja.

Kroz analizu ovih modela vidljivo je da područje automatiziranog trgovanja kontinuirano napreduje i razvija se. Sve veći broj istraživača podržava koncepte otvorenog koda, što drugim znanstvenicima omogućuje korištenje postojećih razvoja i kreiranje novih metoda podržanog učenja. Ova inkluzivnost zajednice doprinosi većoj raznolikosti i prilagodljivosti, potičući daljnje inovacije u području automatiziranog trgovanja.

Poglavlje 3

Financijska tržišta

Financijska tržišta su vitalni dijelovi ekonomске strukture, koji omogućuju tok sredstava među različitim sudionicima. Prema Orsagu [67], financijska tržišta se dijele na tržište novca i tržište kapitala prikazano na Slici 3.1..



Slika 3.1: Prikaz podijele financijskih tržišta [67]

Saunders [68] nadalje razjašnjava da se financijska tržišta mogu razlikovati u dvije dimenzije: primarna naspram sekundarna tržišta i novčana naspram kapitalnih tržišta. Ova tržišta omogućuju različite ekonomске aktere, od pojedinaca do velikih korporacija, da financiraju svoje operacije, ulažu višak kapitala ili upravljaju rizikom.

3.1. Pregled financijskih tržišta

Kako je prethodno spomenuto mogu se razlikovati u dvije glavne dimenzije: primarna i sekundarna tržišta te novčana i kapitalna tržišta [68]. Primarna tržišta su ona na kojima se nove emisije vrijednosnih papira prodaju inicijalnim kupcima, dok sekundarna tržišta

omogućuju trgovinu već izdanim vrijednosnim papirima. Ova podjela omogućava dublje razumijevanje funkcija i procesa unutar finansijskih tržišta.

Na primarnim tržištima, novi finansijski instrumenti kao što su dionice i obveznice prvi put nalaze svoje kupce. Ova tržišta su ključna za inicijalno prikupljanje kapitala, što je neophodno za financiranje raznih operacija korporacija i vlada. S druge strane, sekundarna tržišta pružaju platformu za trgovinu već izdanim vrijednosnim papirima. Ovo omogućava investitorima da prilagode svoje portfelje u skladu s promjenjivim tržišnim uvjetima, čime se povećava likvidnost i omogućuje reevaluacija investicija. Paralelno s tim, novčana tržišta usmjerena su na kratkoročne finansijske instrumente poput trezorskih zapisa i komercijalnih papira. Ovi instrumenti su od ključne važnosti za kratkoročno financiranje i upravljanje likvidnošću, posebno za institucionalne investitore i novčane fondove. Pružanjem sigurnih opcija za kratkoročne investicije i efikasno upravljanje rizicima, novčana tržišta doprinose stabilnosti i fleksibilnosti finansijskog sustava.

U ovom kontekstu, finansijski posrednici, poput banaka i investičkih fondova, igraju ključnu ulogu u efikasnom funkcioniranju finansijskih tržišta omogućavajući protok sredstava od štediša do onih koji trebaju sredstva, čime se povećava produktivnost i efikasnost finansijskog sustava [69]. Fabozzi et al. [70] dalje naglašavaju da finansijska tržišta pružaju ključne ekonomske funkcije poput cjenovnog otkrivanja i likvidnosti. Proces cjenovnog otkrivanja signalizira kako bi sredstva unutar ekonomije trebala biti alocirana među različitim finansijskim imovinama, dok likvidnost omogućuje investitorima da prodaju finansijske imovine kada je to potrebno, čime se olakšava mobilizacija sredstava.

3.2. Tržište kapitala

Tržište kapitala, koje se razlikuje od tržišta novca po svojoj orientaciji na dugoročne finansijske transakcije i instrumente, predstavlja temeljni dio globalne finansijske strukture. Saunders ističe da tržište kapitala obuhvaća trgovinu dionicama i dugoročnim dužničkim instrumentima, poput obveznica, s rokom dospijeća većim od jedne godine [68]. Glavni dobavljači ovih vrijednosnih papira su korporacije i vlade, a glavni dobavljači sredstava su kućanstva odnosno građanstvo. Ovi instrumenti, zbog duljeg dospijeća, doživljavaju šire fluktuacije cijena na sekundarnim tržištima u odnosu na instrumente novčanog tržišta.

Mishkin i Eakins [69] nadalje razrađuju razliku između tržišta na temelju dospijeća vrijednosnih papira koji se na njima trguju. Dok se na novčanom tržištu trguje isključivo kratkoročnim dužničkim instrumentima, tržište kapitala uključuje dugoročne dugove i dioničke instrumente, što ga čini esencijalnim za dugoročne investicije i provedbe raznih finansijskih strategija. Prema Orsagu [67], tržište kapitala obuhvaća širok spektar

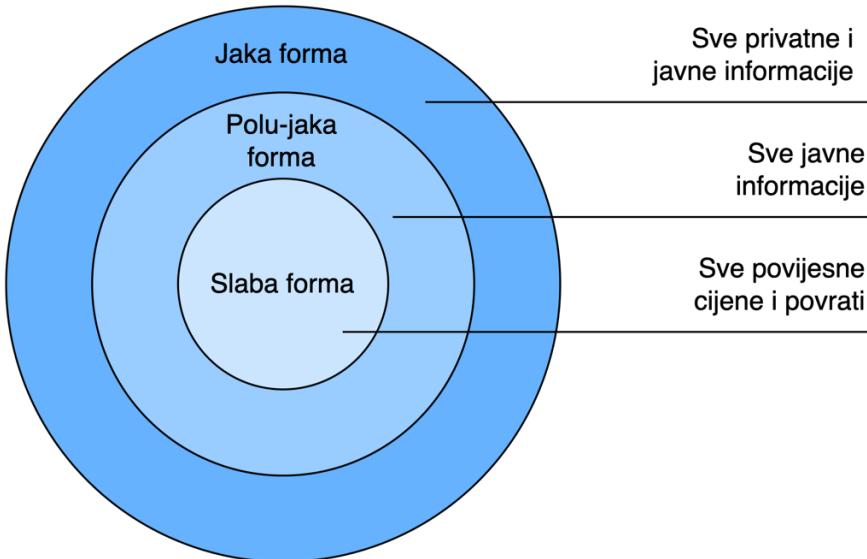
dugoročnih finansijskih proizvoda, uključujući dogovorno tržište dugoročnica i financiranje rizičnih poslova.

Investicijski bankari i specijalizirani finansijski posrednici igraju važnu ulogu u procesu emisije dugoročnih vrijednosnih papira na tržištu kapitala. Njihova funkcija u oblikovanju i održavanju tržišta kapitala je nezaobilazna, pružajući neophodnu infrastrukturu za efikasnu mobilizaciju kapitala i financiranje različitih ekonomskih aktivnosti. Ova dinamika tržišta kapitala ima izravan utjecaj na gospodarski razvoj i rast. Tržište kapitala pruža ključne izvore financiranja za poduzeća, potičući njihov rast i razvoj te omogućava šire fluktuacije cijena za dugoročne instrumente, čineći ih atraktivnim za investitore koji traže veće prinose uz prihvatanje većeg rizika [71]. Također, pruža likvidnost i omogućuje reevaluaciju investicija kroz trgovanje na tržištu. U kontekstu ove disertacije, tržište kapitala predstavlja važno područje istraživanja, posebno u razvoju i testiranju automatiziranih trgovačkih sustava koji se fokusiraju na dionice i druge dugoročne instrumente. Razumijevanje strukture i funkcija tržišta kapitala, stoga, ne samo da pruža temelj za ekonomski razvoj i finansijsku stabilnost, već je i neophodno za razvoj naprednih trgovačkih strategija i tehnologija u okviru ove disertacije. Dinamika tržišta kapitala, s njegovim kompleksnim strukturama i različitim instrumentima, pruža bogat izvor podataka i mogućnosti za inovacije u području dubokog učenja i automatiziranog trgovanja.

3.3. Hipoteza efikasnog tržišta

Hipoteza efikasnog tržišta predstavlja bitan koncept u finansijskoj teoriji koji objašnjava kako se informacije reflektiraju u cijenama dionica na tržištu. Razvoj EMH neodvojivo je povezan s radovima Eugenea F. Fama [1], [5], [72], čija su istraživanja postavila temelje za suvremeno razumijevanje tržišnih mehanizama. U svom pionirskom radu [72], Fama istražuje i argumentira da su promjene cijena dionica na burzi nepredvidive i rezultat slučajnih promjena, koje odražavaju sve dostupne informacije, što implicira nemogućnost sustavnog predviđanja budućih cijena na temelju povijesnih podataka. Nastavljajući istraživanje ove teme, Fama detaljno opisuje i definira tri razine tržišne efikasnosti: slabu, polu-jaku i jaku, kako je prikazano na Slici 3.2..

Slaba forma efikasnosti sugerira da povijesne cijene ne mogu biti pouzdan temelj za predviđanje budućih cijena, dok polu-jaka forma efikasnosti ukazuje na to da su sve javno dostupne informacije već uključene u trenutne cijene dionica. Jaka forma efikasnosti ide korak dalje, tvrdeći da su u cijenama dionica reflektirane sve informacije, uključujući i one koje nisu javno dostupne [1]. Fama naglašava važnost svake od ovih razina efikasnosti za razumijevanje kako tržišta obrađuju informacije i kako to utječe na cijene dionica. On predlaže da je sposobnost tržišta da učinkovito integrira različite vrste informacija ključna za investicijske strategije, te da razumijevanje ovih razina može pomoći investitorima u predviđanju tržišnih kretanja i upravljanju rizicima.



Slika 3.2: Razina tržišne efikasnosti prema hipotezi efikasnog tržišta [73]

Svojim trećim istraživanjem [5] produbljuje analizu EMH, fokusirajući se na izazove i anomalije koje su se pojavile unutar ove teorije. Rad istražuje kako određene tržišne anomalije, poput „efekta malih tvrtki“ i „siječanjskog efekta“, mogu koegzistirati unutar okvira EMH. Naglašava da, iako se pojavljuju odstupanja od očekivanih tržišnih ponašanja, ona često mogu biti objašnjena unutar postojećeg teorijskog okvira EMH, sugerirajući složenost i dinamičnost tržišnih uvjeta koji neprestano oblikuju i testiraju granice teorije efikasnog tržišta [5]. Ovi radovi Fame postavljaju temelje za razumijevanje tržišne efikasnosti i potiču kontinuirano istraživanje, debatu te kritičko preispitivanje unutar finansijske zajednice, čime doprinose razvoju i evoluciji finansijske teorije i prakse.

Razvoj EMH nadopunjjen je kasnijim istraživanjima koja su proširila razumijevanje složenosti tržišnih dinamika. Malkiel, u svom radu [6] ističe da, iako tržišta nisu savršena i postoje anomalije, rijetko pružaju sustavne prilike za ostvarivanje izvanrednih povrata. Ovaj rad naglašava da, unatoč postojanju tržišnih nepravilnosti, te anomalije ne stvaraju konzistentne prilike za arbitražu, što upućuje na to da tržišta uglavnom djeluju efikasno. Nakon što Malkiel u svom radu ističe da rijetko postoji sustavne prilike za ostvarivanje izvanrednih povrata unatoč tržišnim anomalijama, dolazimo do radova Timmermanna i Grangera [7] te Loa [74], koji dodatno istražuju dinamiku između efikasnosti tržišta i prognoziranja. Oni naglašavaju da postoji prostor za privremenu predvidljivost zbog neprestanog učenja i prilagođavanja tržišnih sudionika. Ovo je posebno relevantno u kontekstu dubokog učenja i razvoja automatiziranih sustava za trgovanje. Lo [74] predlaže adaptivnu prirodu tržišta, tvrdeći da su tržišta podložna promjenama i prilagodbama, što odražava složenost ljudskog ponašanja i evolucijskih procesa. Rad [75] pruža uvid u mehanizme koji dovode do tržišnih neefikasnosti, istražujući ulogu

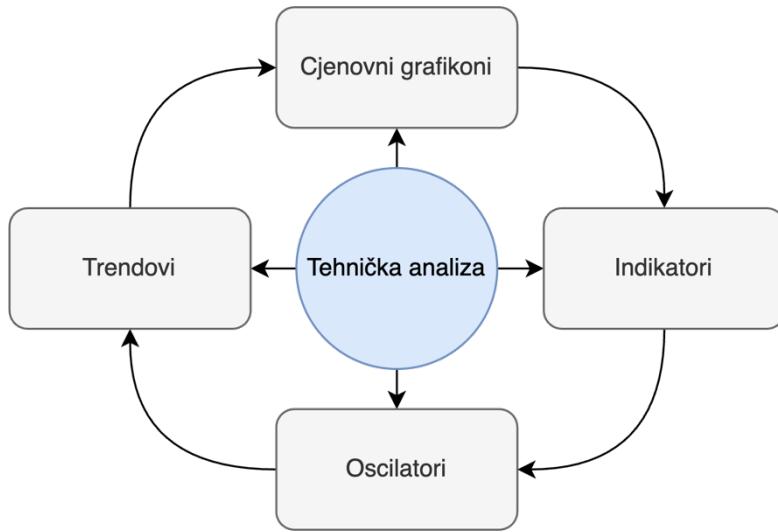
psiholoških faktora, asimetrija informacija i ograničenja u arbitraži. Zajedno, ovi radovi pružaju temeljit uvid u razvoj i trenutno stanje EMH, ističući kako se kontinuirano istraživanje i različite perspektive doprinose razumijevanju tržišne dinamike i uloge različitih čimbenika u oblikovanju tržišne efikasnosti.

3.4. Vrste tržišnih analiza

U kontekstu financijskih tržišta posebno tržišta kapitala, tržišna analiza predstavlja temeljni alat za informirano donošenje investicijskih odluka. Razlikujemo dvije osnovne vrste tržišnih analiza koje su ključne u procesu procjene i predviđanja ponašanja tržišta a to su tehnička i fundamentalna, te dodatno proširujemo za moderniju vrstu analize koju nazivamo kvantitativnom. U svrhu donošenja odluka, analitičari koriste koncept „signala“ kao stručni termin koji označava informaciju dobivenu kroz analizu, a koja investitoru sugerira da poduzme određenu akciju, bilo ulazak u poziciju ili izlazak iz nje [76]. Svaka od navedenih vrsta analiza pruža različite perspektive koje pomažu u donošenju odluka u investiranju. Detaljno razumijevanje i primjena ovih metoda omogućava bolju pripremu i prilagodbu tržišnim uvjetima te potencijalno dovodi do poboljšanja investicijskih rezultata.

3.4.1. Tehnička analiza

Tehnička analiza, kao jedna od temeljnih vrsta analize financijskih tržišta, usmjerava se na proučavanje povijesnih podataka o cijenama i volumenima trgovanja s ciljem predviđanja budućih kretanja cijena vrijednosnih papira [9]. Kao što je prikazano na Slici 3.3., tehnička analiza koristi razne alate kao što su cjenovni grafikoni, trendovi, indikatori i oscilatori, koji zajedno pružaju temelj za interpretaciju tržišnih signala. Osnovna premla tehničke analize je da tržišna aktivnost diskontira sve, od fundamentalnih do psiholoških utjecaja, čime se sugerira da je proučavanje kretanja tržišnih cijena dovoljno za procjenu budućih tržišnih trendova [77]. Tržišne cijene se kreću u trendovima, a sami trendovi su rezultat raznih varijabli koje utječu na njih. Tehnički indikatori dizajnirani su da identificiraju trendove i promjene u trendovima, neovisno o njihovim uzrocima [78]. Ovi trendovi traju sve dok ne dođe do promjene u ravnoteži ponude i potražnje za financijskim instrumentom na tržištu, a ključno je identificirati ove promjene na pravovremen način.



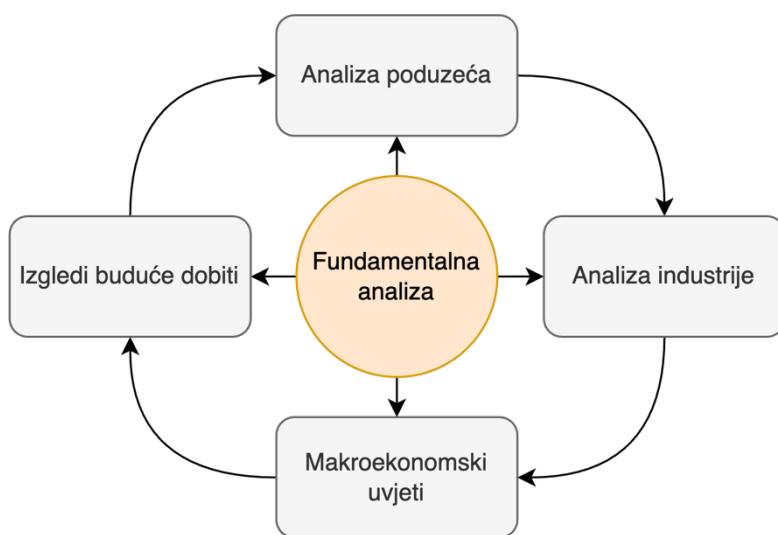
Slika 3.3: Elementi tehničke analize na financijskim tržištima [79]

Tehnička analiza koristi grafove kao neophodne alate za vizualizaciju tržišnih kretanja. Grafovi prikazuju različite vremenske okvire trendova, od dugoročnih koji traju godinama, do kratkotrajnih koji zanimaju trgovce na kratke staze. Svaki od ovih trendova zahtijeva specifične tehničke parametre za maksimiziranje nagrade i minimiziranje rizika [78]. Osim toga, tehnička analiza se bavi proučavanjem ponašanja cijena i promjena u volumenu trgovanja kako bi se predvidjela buduća kretanja cijena vrijednosnica. Prepostavka na kojoj se temelji tehnička analiza je da cijene imaju tendenciju ponavljanja svojih kretanja i promjena, stvarajući prepoznatljive obrasci. Ako se prepoznaaju ti obrasci, moguće je zauzeti povoljnu poziciju u dionici kako bi se profitiralo od budućih cijena koje ovi obrasci predviđaju [80].

Tehnička analiza otkriva trendove i pruža uvid u psihologiju tržišta. Ljudska psihologija i investicijska psihologija, odvojeno od svih racionalnih ekonomskih razmatranja, najvažniji su determinanti investicijskog odlučivanja i stoga aktualnog tržišnog ponašanja [78]. Grafikoni i tehnički indikatori odražavaju bikovsku (engl. Bullish) ili medvjedu (engl. Bearish) psihologiju tržišta, te su i odraz temeljnih ekonomskih uvjeta koji uzrokuju nastanak takvih tržišta. Jedna od prednosti tehničke analize je njen prilagodljivost gotovo svakom trgovačkom mediju i vremenskoj dimenziji. Tehnički analitičar može lako pratiti bilo koje tržište, što obično nije slučaj s analitičarima koji se oslanjaju na fundamentalnu analizu. Zbog ogromne količine podataka s kojima se fundamentalni analitičari moraju nositi, oni se često specijaliziraju. Tehnički trgovac, s druge strane, može usmjeriti svoj znanje i kapital na tržišta koja pokazuju snažne trendove da bi iskoristio rotacijsku prirodu tržišta [77].

3.4.2. Fundamentalna analiza

Fundamentalna analiza predstavlja temeljni aspekt u procjeni vrijednosti dionica i drugih financijskih instrumenata na tržištu kapitala, temeljeći se na detaljnom proučavanju dostupnih informacija kako bi se izvukli zaključci utemeljeni na utvrđenim principima i zdravoj logici. Kao što su Benjamin Graham i David Dodd [81] istaknuli, iako investicije nisu egzaktna znanost, analiza u ovom području je neizostavna i neophodna. Različite komponente koje se koriste u fundamentalnoj analizi prikazane su na Slici 3.4., a obuhvaćaju analizu poduzeća, analizu industrije i procjenu makroekonomskih uvjeta.



Slika 3.4: Komponente fundamentalne analize [79]

Proučavanje financijskih izvješća tvrtke, poput bilance, izvještaja o dobiti i gubitku te izvještaja o novčanom toku, omogućava analizi da ocijeni financijsko zdravlje tvrtke. Makroekonomski pokazatelji poput stope inflacije, kamatnih stopa, stope nezaposlenosti i bruto društvenog proizvoda (BDP) također igraju važnu ulogu u fundamentalnoj analizi, jer značajno utječu na tržišne uvjete i vrijednost dionica [10]. Osim toga, fundamentalna analiza usmjerena je na procjenu intrinzične vrijednosti dionice, koristeći se različitim modelima vrednovanja, poput modela diskontiranog novčanog toka (engl. Discounted Cash Flow) i analize temeljene na višestrukim omjerima. Ovaj pristup omogućava investitorima da odrede je li dionica podcijenjena ili precijenjena u odnosu na trenutnu tržišnu cijenu.

Važno je obratiti pozornost i na činjenicu da se fundamentalni podaci često objavljaju s određenim kašnjenjem. To znači da informacije iz regulatornih izvještaja i poslovne analitike, iako objavljene kvartalno, postaju javno dostupne tek nakon određenog vremenskog perioda. Stoga je ključno utvrditi točan trenutak kad su ti podaci postali

dostupni javnosti kako bi se izbjegle greške u analizi i donošenju odluka na temelju zastarjelih podataka. Osim toga, tržišni podaci koji uključuju sve trgovačke aktivnosti na burzi, pružaju dodatnu razinu informacija koje su korisne u fundamentalnoj analizi [82].

Daljnji razvoj u području strojnog učenja, posebice NLP-a, otvara nove mogućnosti u analizi ovih podataka. Korištenjem naprednih NLP tehnika, moguće je automatski obraditi velike količine teksta iz finansijskih izvještaja, regulatornih objava i novinskih članaka, omogućavajući tako brže i preciznije izvlačenje relevantnih informacija. Ovakav pristup unaprjeđuje proces fundamentalne analize i omogućuje integraciju ovih detaljnih podataka u razvoj sofisticiranih sustava za automatizirano trgovanje.

3.4.3. Kvantitativna analiza

Kvantitativna analiza u finansijskom trgovaju obuhvaća širok spektar tradicionalnih finansijskih informacija koje služe kao temelj za donošenje investicijskih odluka [4]. Ove informacije uključuju standardizirane finansijske izvještaje poput bilance, koja prikazuje imovinu i obveze tvrtke, računa dobiti i gubitka koji dokumentira prihode i rashode, te izvještaja o novčanom toku koji prati kretanje gotovine. Dodatno se prate i ključni finansijski pokazatelji kao što su pokazatelji likvidnosti, zaduženosti i profitabilnosti [82].

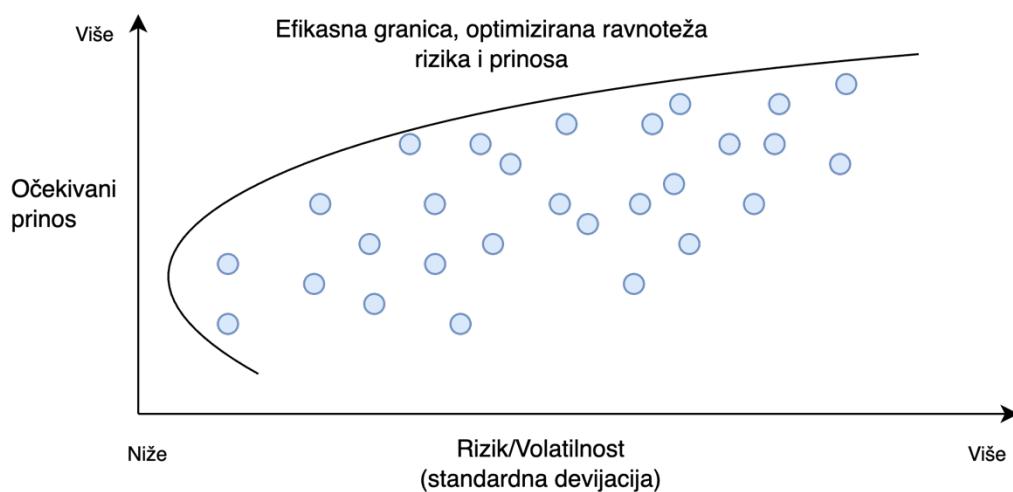
Poseban značaj u kvantitativnoj analizi imaju korporativne objave i priopćenja za javnost koja često sadrže informacije koje mogu značajno utjecati na tržišna kretanja [83]. Moderni pristup kvantitativnoj analizi nadilazi tradicionalne metode kroz integraciju alternativnih izvora podataka i naprednih tehnika obrade. Ovo uključuje analizu vijesti, društvenih mreža i drugih nestrukturiranih izvora podataka, što omogućava sveobuhvatniji uvid u tržišna kretanja [3].

U kontekstu automatiziranog trgovanja, kvantitativna analiza koristi se za razvoj algoritama koji automatiziraju trgovačke odluke. Primjena naprednih tehnika strojnog učenja, uključujući obradu prirodnog jezika, omogućava da se ti algoritmi brzo prilagode promjenama na tržištu [48]. Ovi modeli mogu analizirati velike količine podataka, što omogućava točnije predviđanje tržišnih kretanja i učinkovitije trgovanje [27].

3.5. Upravljanje portfolijem

Razvoj modernog pristupa upravljanju portfolijem započinje revolucionarnim radom Harryja Markowitza [84], koji postavlja temelje teorije prema kojoj investitori trebaju razmatrati ne samo očekivani prinos već i varijancu tih prinosa. Ova teorija kasnije je nadograđena kroz model određivanja cijena kapitalne imovine (engl. Capital Asset Pricing Model, CAPM) [85], koji uvodi koncept beta koeficijenta za mjerjenje osjetljivosti pojedinačne imovine na tržišni rizik. Kroz ove teorijske okvire uspostavljena je

fundamentalna veza između očekivanog prinosa i sistematskog rizika, što je omogućilo razvoj sofisticiranih pristupa upravljanju portfolijem. Kroz ove teorijske okvire uspostavljena je fundamentalna veza između očekivanog prinosa i sistematskog rizika, što je omogućilo razvoj sofisticiranih pristupa upravljanju portfolijem. Kao što je prikazano na Slici 3.5, svaka točka predstavlja pojedinačni portfelj, pri čemu oni koji se nalaze najbliže efikasnoj granici pružaju najveće prinose uz najmanji rizik. Ovakav odnos rizika i prinosa predstavlja temelj moderne teorije portfelja, gdje se kroz diverzifikaciju nastoji postići optimalna ravnoteža između očekivanih prinosa i prihvatljivih razina rizika [67].



Slika 3.5: Moderna teorija portfelja, efikasna granica [67]

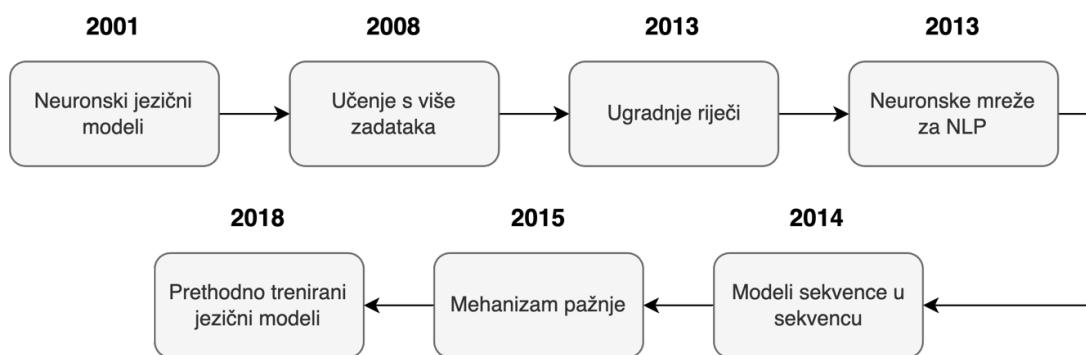
Suvremena istraživanja ukazuju na određena ograničenja tradicionalnih modela, posebice u kontekstu tržišne nesigurnosti i pretpostavki o racionalnosti investitora [86]. Kao odgovor na ove izazove, razvijeni su napredniji pristupi koji kombiniraju minimalizaciju varijance i maksimizaciju diverzifikacije. Ovi moderni pristupi prepoznaju da je portfolijski pristup superioran u odnosu na odabir pojedinačnih dionica jer značajno smanjuje specifični rizik investitora, istovremeno pružajući bolju zaštitu od nepredviđenih tržišnih šokova.

Najnoviji trendovi u području kvantitativnog upravljanja portfolijem usmjereni su na integraciju naprednih algoritama strojnog učenja s tradicionalnim metodama optimizacije [87]. Ovaj pristup omogućava razvoj sofisticiranih modela za predikciju i donošenje investicijskih odluka, čime se smanjuje ovisnost o konvencionalnim modelima koji često pokazuju nedostatke u nestabilnim tržišnim uvjetima. Upravo ova synergija tradicionalnih teorija i modernih tehnoloških rješenja predstavlja temelj za razvoj robusnih strategija upravljanja portfolijem koje se mogu učinkovito prilagoditi dinamičnim tržišnim uvjetima.

Poglavlje 4

Obrada prirodnog jezika

Obrada prirodnog jezika predstavlja presjek lingvistike i računalne znanosti, usmjeravajući se na interakciju između računalnih sustava i ljudskog jezika. Cilj NLP-a je razviti sustave sposobne za obradu ljudskog jezika, što uključuje razumijevanje konteksta i namjere iza prirodnog jezika [88]. Temeljni principi NLP-a leže upravo u kombinaciji računalne lingvistike, koja se bavi pravilima modeliranja ljudskog jezika, i strojnog učenja kao podskupa umjetne inteligencije (engl. Artificial Intelligence, AI) koje omogućava strojevima da uče iz iskustva. Dalnjim razvojem dubokog učenja, inspiriranog funkcioniranjem ljudskog mozga, odnosno neurona iz kojih proizlaze umjetne neuronske mreže (engl. Artificial Neural Network), došlo je do revolucionarne promjene u NLP-u. Time su omogućeni složeni zadaci obrade prirodnog jezika koji su prethodno bili ostvarivi samo u teoriji. Pojava prethodno treniranih modela, poput GPT modela, koji se mogu fino podešavati za različite zadatke, uštedjela je brojne računalne resurse i sate treniranja tih modela, predstavljajući drugu veliku promjenu u polju NLP-a [88]. Ključne komponente koje su doprinijele ovom napretku prikazane su na Slici 4.1..



Slika 4.1: Ključne komponente u razvoju NLP-a [89]

Do današnjeg napretka u NLP području trebala su proći desetljeća. U ranoj fazi razvoja tijekom 1990-ih, došlo je do postupne promjene od ručno pisanih pravila, ekspertnih sustava i lingvističkih teorija prema korpusom baziranim pristupima strojnog učenja. Skoro dva desetljeća, statističke metode strojnog učenja dominirale su mnogim zadacima

NLP-a, koristeći se obično visoko dimenzionalnim, ručno izrađenim značajkama. Međutim, posljednja desetljeća donijela su novu revoluciju s dubokim treniranjem koje je, proširujući svoju dominaciju na NLP, pokazalo visoku učinkovitost u hvatanju semantike riječi u odnosu na tradicionalne statističke tehnike [90]. Razvoj vektorskih reprezentacija teksta ključan je za napredak NLP-a, jer omogućava transformaciju teksta iz prirodnog oblika u format pogodan za računalnu obradu. Tehnike poput ugradnje riječi (engl. Word Embeddings) i primjena dubokih neuronskih mreža (engl. Deep Neural Networks) ključne su u stvaranju bogatih vektorskih reprezentacija koje efikasno hvataju semantiku, sintaksu i druge jezične karakteristike. Ove vektorske reprezentacije omogućuju modelima da razumiju značenje riječi i fraza unutar šireg konteksta te na taj način znatno poboljšavaju sposobnost modela da generaliziraju znanje na razne NLP zadatke [91]. Primjena ugradnji riječi, kao što su tehnike Word2Vec [92] i GloVe [93], revolucionirala je način na koji strojevi interpretiraju jezik, pretvarajući riječi u složene vektore koji odražavaju semantičke odnose među riječima. Na primjer, slične riječi imaju slične vektorske reprezentacije, što omogućuje modelima da razumiju sinonime, antonime i druge lingvističke nijanse.

Nastavljujući iz prethodnog razmatranja evolucije NLP-a, ključni trenutak u napretku predstavlja pojava takozvane Transformers arhitekture [19]. Prije pojave Transformersa, dominantne metode poput konvolucijskih neuronskih mreža i povratnih neuronskih mreža, uključujući varijante poput mreža dugotrajne kratkoročne memorije, suočavale su se s izazovima u obradi sekvenčijalnih podataka, posebno u kontekstu razumijevanja dugih ovisnosti unutar teksta. Međutim, u prosincu 2017. godine, Vaswani i suradnici objavili su revolucionarni rad "*Attention Is All You Need*" [19], predstavljajući originalnu Transformers arhitekturu koja je postavila nove standarde u obradi prirodnog jezika, koju detaljno obrađujemo u nastavku.

4.1. Transformers arhitektura

Razvoj arhitekture Transformera označio je značajan pomak u području NLP-a, prelazeći s tradicionalnih modela poput RNN i LSTM na modele koji se u potpunosti oslanjaju na mehanizme pažnje [19]. Ovaj pristup omogućio je modelima da efikasnije obrađuju sekvenčijalne podatke, eliminirajući potrebu za sekvenčijalnom obradom i omogućavajući paralelno izvršavanje procesa tijekom treniranja. Ključna inovacija unutar arhitekture Transformera, leži u njezinoj sposobnosti da modelira ovisnosti unutar sekvenci bez obzira na njihovu udaljenost, koristeći mehanizam samo-pažnje (engl. Self-Attention) za izračunavanje reprezentacija ulaza i izlaza.

Transformeri su se brzo uspostavili kao temelj za razvoj velikih jezičnih modela, kao što su GPT (Generative Pre-trained Transformer) [94] i BERT (Bidirectional Encoder Representations from Transformers) [51], koji su demonstrirali izvanredne sposobnosti u razumijevanju i generiranju prirodnog jezika [95]. Ovi modeli, koristeći arhitekturu

Transformera, ostvarili su značajne uspjehe u širokom spektru NLP zadataka, postavljajući nove standarde učinkovitosti i točnosti.

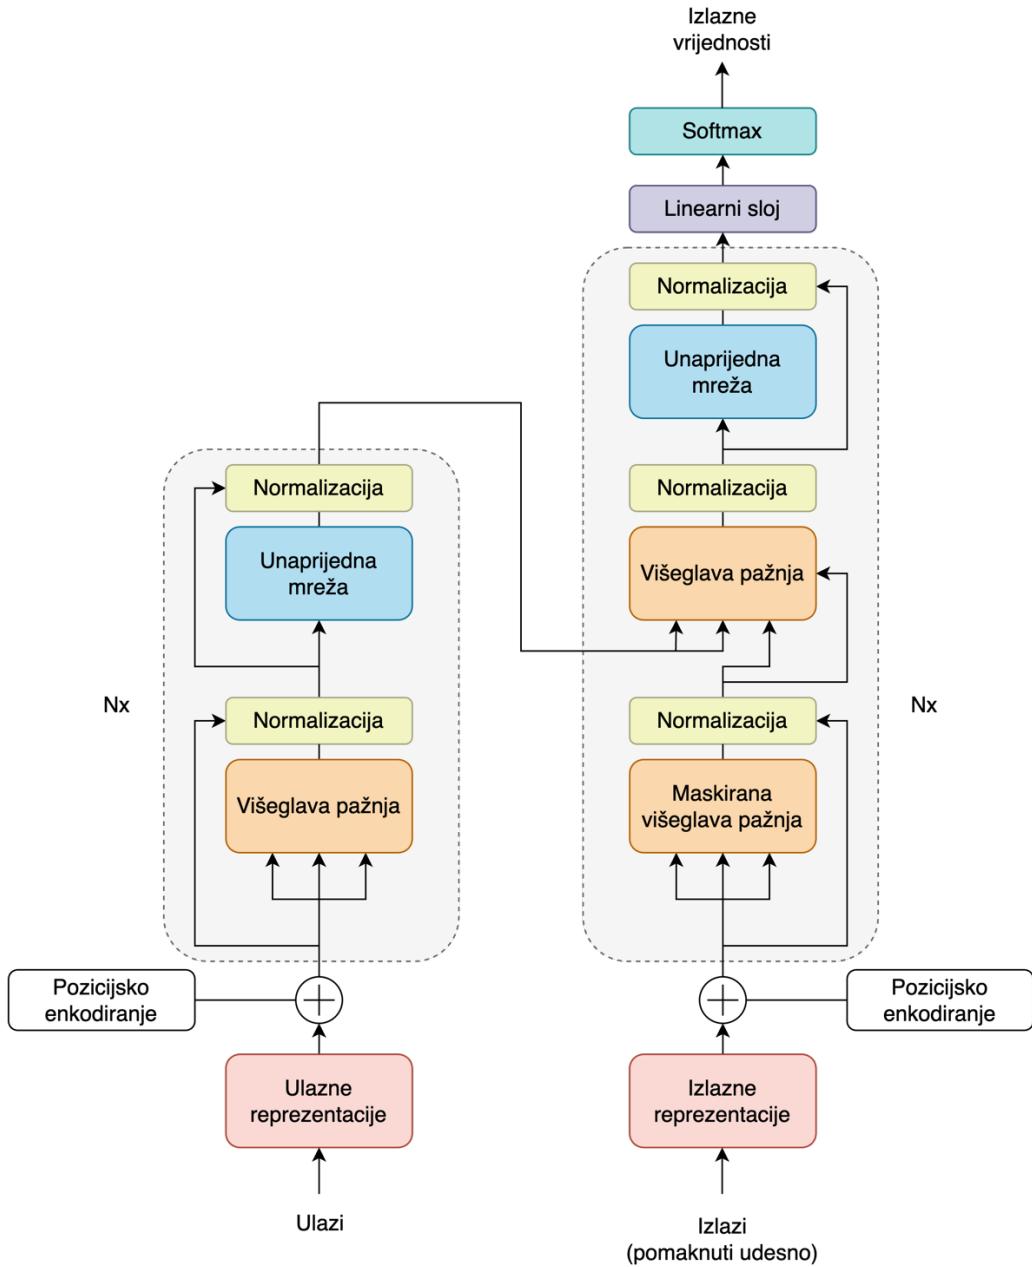
Uspjehu Transformer-a i LLM-ova može se pripisati nekoliko faktora. Prvo, eliminacija povrata i konvolucije u korist mehanizama pažnje omogućila je modelima da učinkovitije obrađuju i povezuju informacije kroz duge sekvence teksta. Drugo, sposobnost paralelne obrade znatno je ubrzala proces treniranja, omogućavajući razvoj modela s milijardama parametara sposobnih za obradu složenih jezičnih zadataka [96]. Naposljetu, primjena tehnika prijenosnog učenja (engl. Transfer Learning), kao što su fino podešavanje (engl. Fine-Tuning) i treniranje s malo primjera (engl. Few Shot Learning), omogućila je modelima da se prilagode specifičnim zadacima i domenama s relativno malo označenih podataka.

Kako se područje NLP-a nastavlja razvijati, arhitektura Transformer-a i temeljni modeli koji proizlaze iz te arhitekture ostaju u središtu inovacija, nudeći obećavajuće pristupe za rješavanje kako postojećih tako i novonastalih izazova u obradi i razumijevanju prirodnog jezika.

4.1.1. Komponente Transformers arhitekture

Arhitektura Transformer-a revolucionirala je obradu prirodnog jezika, uvodeći strukturu koja se temelji na enkoderu i dekoderu bez oslanjanja na povratne elemente. Enkoder transformira ulaznu sekvencu simbola u kontinuirane reprezentacije, dok dekoder koristi te reprezentacije za generiranje izlazne sekvence simbola [97]. Detaljna arhitektura enkodera i dekodera prikazana je na Slici 4.2. Ključna karakteristika Transformer-a je njegova sposobnost auto-regresivnog generiranja izlaza, koristeći prethodno generirane simbole kao dodatni ulaz za stvaranje sljedećeg simbola [96]. Ovaj pristup omogućuje održavanje koherentnosti i konteksta tijekom generiranja dugih sekvenci teksta, što je ključno za zadatke poput strojnog prevođenja i generiranja prirodnog jezika.

Transformeri efikasno obrađuju informacije bez potrebe za tradicionalnim sekvencijskim procesiranjem, što ih čini izuzetno brzima i skalabilnima. Uvođenje mehanizma pažnje omogućava modelu da se fokusira na određene dijelove ulaznih podataka koji su relevantni za zadatke koje izvršava, poboljšavajući time kvalitetu generiranih izlaza. Ova inovativna karakteristika ima važnu ulogu u povezivanju dijelova teksta koji su međusobno udaljeni, a koji sadrže bitne informacije ključne za razumijevanje konteksta izraza. Dodatno, mogućnost paralelnog procesiranja značajno ubrzava trening, što je dovelo do razvoja sve većih modela sposobnih za rješavanje složenih jezičnih zadataka s visokom preciznošću.



Slika 4.2: Detaljni prikaz Transformers arhitekture [19]

Enkoder je sastavljen od šest identičnih slojeva, pri čemu svaki sloj sadrži dva pod-sloja: višeglavni mehanizam samo-pažnje (engl. Multi-Head Self-Attention Mechanism) te jednostavnu, pozicijski potpuno povezanu unaprednu neuronsku mrežu (engl. Position-Wise Fully Connected Feedforward Network) [19]. Rezidualne veze oko svakog od pod-slojeva, praćene normalizacijom sloja, omogućuju očuvanje bitnih informacija i olakšavaju protok podataka kroz model. Svi pod-slojevi, uključujući slojeve za ugrađivanje, proizvode izlaze dimenzija $d_{model} = 512$, čime se osigurava uniformnost i efikasnost obrade [96].

Dekoderska komponenta također se sastoji od šest slojeva, dodajući treći pod-sloj za višestruku pažnju (engl. Multi-Head Attention) preko izlaza enkoderskog stoga na dva standardna pod-sloja. Kao i u enkoderu, rezidualne veze i normalizacija sloja koriste se za svaki pod-sloj. Kako bi se osiguralo da predikcije za određenu poziciju mogu ovisiti samo o prethodno poznatim izlazima, samo-pažnja u dekoderu modificirana je s ciljem sprečavanja pristupa naknadnim pozicijama [19].

Nakon dekoderske obrade, linearni sloj transformira dobiveni vektor u veći prostor za razlikovanje potencijalnih riječi u vokabularu. Softmax aktivacijska funkcija taj vektor pretvara u distribuciju vjerojatnosti za svaku riječ, s izborom najvjerojatnije riječi kao sljedećeg izlaza, omogućujući Transformeru auto-regresivno generiranje teksta [96].

Završno, mehanizam pažnje, koji mapira upite i setove parova ključ-vrijednost na izlaz, temelji se na vektorskim reprezentacijama. Izlaz se računa kao ponderirana suma vrijednosti, gdje se težina svake vrijednosti određuje funkcijom kompatibilnosti upita s odgovarajućim ključem. Ovaj mehanizam omogućava modelu da učinkovito obrađuje informacije bez obzira na njihovu udaljenost unutar sekvence [19], [96].

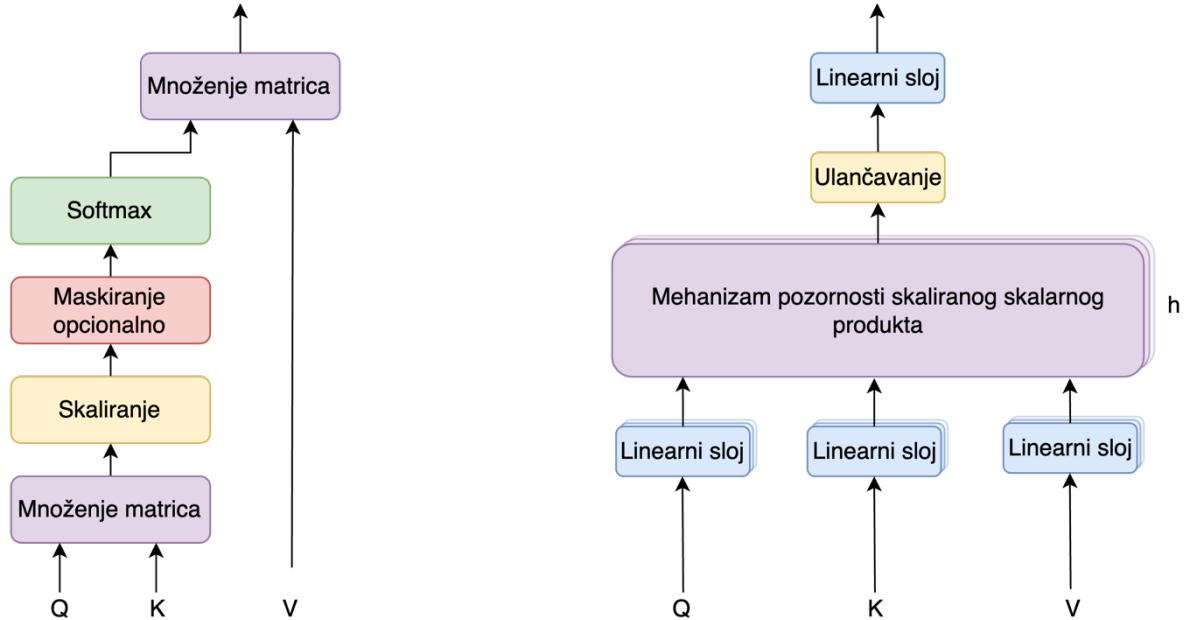
4.1.2. Mehanizam pažnje u Transformers arhitekturi

Mehanizam pažnje predstavlja ključnu komponentu unutar Transformers arhitekture. Osnovna ideja ovog mehanizma je omogućiti modelu da nauči gdje unutar ulaznih podataka treba usmjeriti pažnju. Prvotno korišten u strojnog prevođenju, mehanizam pažnje ubrzo je pronašao primjenu u širokom rasponu zadataka obrade prirodnog jezika zahvaljujući svojoj sposobnosti da poboljša razumijevanje i generiranje teksta.

Mehanizam pažnje uveden je kao odgovor na ograničenja fiksnih vektora u kodiranju dugih rečenica u modelima strojnog prevođenja zasnovanim na arhitekturi enkodera i dekodera. Tradicionalni pristupi zahtijevali su kodiranje cijele rečenice u jedan fiksni vektor, što je često dovodilo do gubitka informacija, osobito kod dužih rečenica. Mehanizam pažnje, prema radu Bahdanau et. al [98], omogućava modelu da kodira ulaznu rečenicu u niz vektora, gdje svaki odgovara jednoj riječi, te adaptivno odabire podskup tih vektora tijekom dekodiranja prijevoda. Ova metoda dinamičkog fokusiranja povećava preciznost prijevoda i omogućava modelima da efikasnije upravljaju informacijama iz dužih tekstova. Dodatno, poboljšava sposobnost modela da otkrije suptilne jezične nijanse, što rezultira prirodnijim i koherentnijim generiranim tekstom.

U središtu arhitekture leži mehanizam nazvan samo-pažnja (engl. Self-Attention), koji modelima omogućuje da procijene kako se svaka riječ u rečenici odnosi na svaku drugu riječ [19]. Detaljna struktura mehanizma pažnje prikazana je na Slici 4.3.. Za razliku od tradicionalnih mehanizama pažnje, samo-pažnja omogućava modelu da razumije kontekst i semantičku povezanost unutar iste sekvence bez potrebe za povratnim neuronским mrežama. Ova sposobnost posebno je važna za riječi s višestrukim

značenjima, gdje model koristi kontekst kako bi pravilno interpretirao značenje riječi [90].



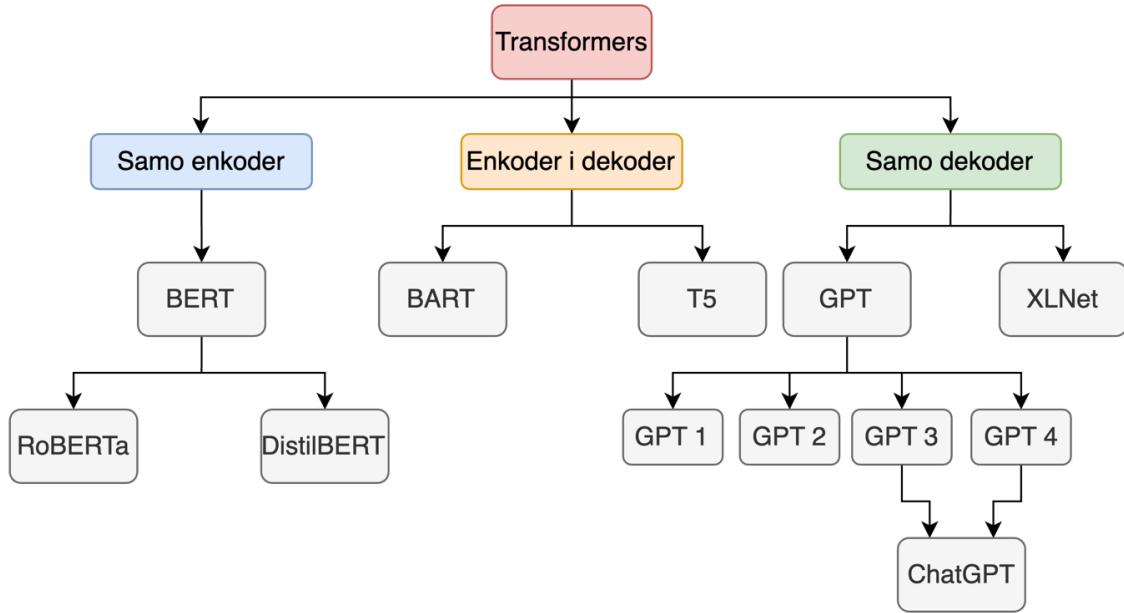
Slika 4.3: Struktura mehanizma pažnje unutar Transformers arhitekture [19]

Proces samo-pažnje uključuje stvaranje tri različita vektora za svaku ulaznu riječ: upita, ključa i vrijednosti. Ti vektori se zatim koriste za izračunavanje vrijednosti pažnje i zatim za generiranje izlaznih vektora koji odražavaju kontekstualne informacije unutar rečenice. Ovaj proces omogućava modelu da dinamički usmjerava fokus na relevantne dijelove ulaznih podataka tijekom generiranja izlaza [98].

Ovi modeli, zahvaljujući intenzivnoj primjeni mehanizma samo-pažnje, ostvarili su izvanredne uspjehe u obradi prirodnog jezika, uključujući strojno prevođenje i generiranje teksta. Ovaj napredak potvrđen je već više puta spomenutim radom "*Attention is all you need*" [19], koji naglašava kako je pažnja sama po sebi dovoljna za postizanje značajnih rezultata, eliminirajući potrebu za povratnim elementima.

4.1.3. Modeli temeljenih na Transformers arhitekturi

Razvoj modela temeljenih na Transformers arhitekturi obilježio je novu eru u polju obrade prirodnog jezika. Neki od popularnijih modela temeljenih na ovoj arhitekturi prikazani su na Slici 4.4..



Slika 4.4: Pregled modela temeljenih na Transformers arhitekturi [99]

Ovi modeli su postali temelj za mnoge napredne aplikacije, od strojnog prevođenja do automatskog sažimanja teksta. Od same pojave Transformers arhitekture pa sve do danas razvijeni su brojni modeli temeljeni na ovoj revolucionarnoj arhitekturi, počevši od onih baziranih na enkoderu, pa sve do kompleksnijih varijacija koje koriste enkoder-dekoder strukturu.

4.1.3.1. Modeli primarno bazirani na enkoderu

Prvi u nizu revolucionarnih modela bio je BERT [51] koji nakon objave Transformers arhitekture predstavlja također važan trenutak u povijesti NLP-a. BERT koristi inovativni pristup dvosmjernog učenja, što znači da model istovremeno uči kontekst riječi i s lijeve i s desne strane ciljane riječi unutar rečenice. Ova karakteristika omogućava BERT-u da dobije dublje razumijevanje jezičnih nijansi i konteksta, što je znatno poboljšalo performanse na širokom rasponu NLP zadataka poput razumijevanja jezika, prepoznavanja imenovanih entiteta, odgovaranja na pitanja i mnogih drugih.

Tehnički, BERT se oslanja na Transformers arhitekturu, posebno na njegov enkoderski dio. Model je predtreniran na ogromnom korpusu teksta koristeći dvije glavne metode: maskirano modeliranje jezika (engl. Masked-Language Modeling MLM) i predviđanje sljedeće rečenice (engl. Next Sentence Prediction, NSP) [51]. U MLM zadatači, određeni postotak riječi u rečenici se nasumično maskira, a cilj modela je predvidjeti te maskirane riječi na temelju konteksta koji imaju ostale riječi u rečenici. Ova tehnika omogućava modelu da bolje razumije značenje i upotrebu riječi. NSP zadatača uči model razumijevanju

veza između rečenica tako što model pokušava predvidjeti da li je određena rečenica logički nastavak prethodne rečenice u tekstu.

Jedna od najvažnijih tehničkih karakteristika BERT-a je njegova sposobnost da se fino podešava (engl. Fine-Tuning) za specifične zadatke (engl. Downstream) s relativno malom količinom podataka za treniranje. To znači da se nakon općeg predtreniranja na velikom korpusu teksta, BERT može brzo prilagoditi za različite specifične zadatke i domene, zadržavajući pritom visoku razinu performansi. Ova fleksibilnost i efikasnost u finom podešavanju omogućile su široku primjenu BERT-a u industriji i akademskoj zajednici.

BERT je postavio nove standarde u polju NLP-a, a njegov uspjeh potaknuo je razvoj mnogih drugih modela koji su nastojali poboljšati ili modificirati originalnu arhitekturu na različite načine. Modeli RoBERTa [100], ALBERT [101] i DistilBERT [102] su samo neki od primjera koji su direktno inspirirani BERT-om i koji su dodatno proširili granice mogućnosti u obradi prirodnog jezika, svaki na svoj način adresirajući specifične izazove ili nedostatke originalnog modela.

4.1.3.2. Modeli primarno bazirani na dekoderu

Serija GPT modela [94] predstavlja drugu važnu liniju razvoja u polju obrade prirodnog jezika, usredotočujući se na generativne sposobnosti i fleksibilnost u primjeni na različite NLP zadatke. Za razliku od BERT-a [51], koji koristi enkoderski dio arhitekture transformatora, GPT modeli se oslanjaju na dekoderski dio, omogućavajući im da generiraju tekst nastavljajući na ulazni niz riječi.

Prvi model u seriji, GPT-1 [94], uveo je koncept predtreniranja jezičnog modela na velikom korpusu teksta, nakon čega slijedi fino podešavanje modela za specifične zadatke. Tehnička inovacija GPT-1 leži u njegovoj sposobnosti da razumije i generira tekst na temelju naučenog konteksta, koristeći mehanizam pažnje za procjenu važnosti različitih dijelova ulaznog teksta.

Nasljednik GPT-1, GPT-2 [103], doveo je do znatnog napretka, povećavajući veličinu modela i količinu podataka za treniranje. Ova promjena je rezultirala modelom s daleko većom sposobnošću generiranja koherentnog i uvjerljivog teksta, čak i bez potrebe za specifičnim fino podešavanjem za mnoge zadatke. GPT-2 je također pokazao izvanredne sposobnosti u razumijevanju suptilnih jezičnih nijansi i generiranju teksta koji odgovara složenim upitim.

GPT-3 [104], najambiciozniji model do tog trenutka, dramatično je povećao veličinu modela, sadržavajući 175 milijardi parametara. GPT-3 je demonstrirao sposobnost obavljanja širokog spektra jezičnih zadataka izravno iz upita, koristeći samo nekoliko primjera za vođenje, poznato kao treniranje s nekoliko primjera (engl. Few Shot Learning). Ova sposobnost smanjuje potrebu za obimnim specifičnim setovima podataka za fino podešavanje, čineći GPT-3 iznimno fleksibilnim alatom za različite aplikacije.

Nakon GPT-3, očekivanja od GPT-4 [105] su bila visoka, iako specifični tehnički detalji i poboljšanja nisu javno objavljeni. GPT-4 nastavlja trend povećanja kompleksnosti i sposobnosti modela, dodatno poboljšavajući razumijevanje i generiranje teksta na još sofisticiranim razinama.

GPT serija modela pokazala je koliko daleko jezični modeli mogu ići u razumijevanju i generiranju prirodnog jezika, postavljajući temelje za razvoj aplikacija koje mogu voditi prirodne konverzacije, automatski generirati tekstove i pružati podršku u različitim oblicima digitalne interakcije. Kroz svoju evoluciju, GPT modeli su postali sinonim za napredak u NLP tehnologijama, omogućavajući razvoj novih i inovativnih aplikacija u obradi prirodnog jezika.

4.1.3.3. Modeli koji koriste enkoder-dekoder arhitekturu

Modeli BART [106] i T5 [107] predstavljaju unapređenja modela temeljenih na Transformers arhitekturi, dodatno proširujući granice mogućnosti u obradi i generiranju prirodnog jezika. Oba modela su zamišljena kao odgovor na potrebu za boljim razumijevanjem konteksta i generiranje koherentnog teksta, ali svaki pristupa ovom problemu na svoj jedinstven način.

BART (Bidirectional and Auto-Regressive Transformers) [106] kombinira dvosmjerno kodiranje s autoregresivnim dekodiranjem, omogućavajući sofisticirano razumijevanje ulaznog teksta i generiranje preciznih izlaza. Tehnički, BART predtrenira svoju enkodersko-dekodersku strukturu koristeći različite strategije, gdje model uči rekonstruirati originalni tekst koji je bio umjetno izmijenjen na različite načine, kao što su brisanje riječi ili permutacija rečenica. Ova metoda omogućava BART-u da razvije duboko razumijevanje jezičnih struktura i konteksta, što ga čini izuzetno snažnim u zadacima poput sažimanja teksta, odgovaranja na pitanja i prijevoda.

S druge strane, T5 (Text-to-Text Transfer Transformer) [107] pristupa problemu obrade prirodnog jezika pretvaranjem svakog NLP zadatka u zadatak generiranja teksta. T5 koristi enkodersko-dekodersku Transformers arhitekturu i trenira se na ogromnom setu podataka C4 [108], koristeći nenadzirano treniranje, gdje model uči iz konteksta bez eksplicitno označenih odgovora. T5 postavlja nove standarde u mnogim NLP zadacima, uključujući prepoznavanje entiteta, prijevod jezika, i mnoge druge, pokazujući izvanrednu sposobnost prilagodbe i generalizacije.

Oba modela, BART i T5, predstavljaju važne inovacije u korištenju Transformers arhitekture za obradu prirodnog jezika, svaki na svoj način proširujući mogućnosti modela u razumijevanju i generiranju teksta. Njihov razvoj nije samo tehnološko dostignuće, već i dokaz konstantnog napretka u polju NLP-a, gdje nove metode i arhitekture neprestano pomicu granice onoga što je moguće postići sa jezičnim modelima.

4.1.3.4. Razvoj naprednih velikih jezičnih modela otvorenog koda

Napredak u području jezičnih modela dosegao je novu razinu s razvojem Llama-2 [109] i Mistral [110], modela koji ne samo da guraju granice što je dalje moguće u obradi prirodnog jezika, već također upućuju na ključne izazove poput učinkovitosti i održivosti. Ovi modeli predstavljaju značajan napredak u pristupu razvoju velikih jezičnih modela, donoseći inovacije koje bi mogle promijeniti kako pristupamo treniranju i primjeni AI u različitim domenama.

Llama-2 [109] je izazvao posebno zanimanje zahvaljujući svom naglasku na efikasnosti, nudeći visokokvalitetno generiranje i razumijevanje teksta sa znatno manjim potrebama za računalnim resursima u odnosu na prethodne modele. Ovo je postignuto kroz optimizaciju arhitekture modela i procesa treniranja, što Llama-2 čini idealnim za širok raspon primjena, od mobilnih uređaja do velikih poslužiteljskih sustava, gdje je potrebno balansirati između performansi i potrošnje resursa. Njegova prilagodljivost i učinkovitost otvaraju nove mogućnosti za integraciju naprednih NLP funkcionalnosti u aplikacijama gdje su resursi ograničeni.

Najnoviji razvoj u ovom nizu, Llama 3 [111], nastavlja trend unapređenja, značajno poboljšavajući performanse i efikasnost. Dostupan u verzijama od 8, 70 i 405 milijardi parametara, ovaj model donosi znatna poboljšanja u razumijevanju konteksta i generiranju koherentnog teksta, pokazujući impresivne rezultate u složenim jezičnim zadacima poput zaključivanja, analize sentimenta i odgovaranja na pitanja. Posebno je značajno da Llama 3 održava visoku razinu performansi čak i u svojim manjim verzijama, istovremeno zadržavajući snažan fokus na optimizaciji resursa. Ova kombinacija naprednih jezičnih sposobnosti i računalne efikasnosti čini Llama 3 iznimno prikladnim za široku primjenu u različitim domenama, od istraživačkih projekata do komercijalnih aplikacija u obradi prirodnog jezika i kompleksnim analitičkim zadacima.

S druge strane, Mistral [110] predstavlja revolucionaran pristup treniranju jezičnih modela, s fokusom na minimiziranje ekološkog otiska. Razvojem Mistrala, istraživači su uspjeli značajno smanjiti potrebnu količinu energije i resursa potrebnih za treniranje velikih modela. Korištenjem naprednih tehnika optimizacije i efikasnijih algoritama, Mistral postavlja standarde u ekološki osviještenom razvoju te pruža put ka stvaranju moćnih modela koji su dostupniji zahvaljujući nižim troškovima treniranja.

Llama-2, Llama-3 i Mistral predstavljaju napredak u razvoju modela obrade prirodnog jezika, naglašavajući važnost ekološke i društvene odgovornosti. Njihov otvoreni pristup potiče zajednicu na suradnju i osigurava transparentnost, pokazujući da se tehnološki napredak može ostvariti uz očuvanje okoliša i etička razmatranja. Ovi modeli ističu kako je moguće razvijati snažne i učinkovite alate, a istovremeno uzimati u obzir važnost kreiranja tehnologija koje brinu o očuvanju planeta i promiču pravednost te ravnopravnost. Llama-2, Llama-3 i Mistral služe kao modeli za budući razvoj u polju obrade prirodnog jezika, usmjeravajući tehnološki napredak prema održivim i odgovornim rješenjima.

4.1.3.5. Prednosti Transformers arhitekture

Odabir Transformer arhitekture kao temelja za razvoj ovog sustava za automatizirano trgovanja proizlazi iz detaljne analize prednosti i nedostataka različitih pristupa u obradi prirodnog jezika. Tradicionalni pristupi temeljeni na RNN i LSTM arhitekturama pokazuju značajna ograničenja u kontekstu obrade dugih sekvenci finansijskih tekstova [2], [8]. Ova ograničenja posebno dolaze do izražaja kod analize finansijskih vijesti i izvještaja koji često zahtijevaju razumijevanje šireg konteksta i složenih vremenskih odnosa.

Transformer arhitektura pokazuje bolje performanse u obradi finansijskih tekstova zahvaljujući mehanizmu pažnje [19]. Ovaj mehanizam omogućava učinkovitije procesiranje dugih sekvenci i preciznije hvatanje kontekstualnih informacija, što je posebno važno za analizu finansijskih tekstova koji često sadrže složene međuvisnosti i reference na prethodne događaje. Dodatno, paralelna priroda obrade u Transformer arhitekturi omogućava značajno brže treniranje i inferenciju u usporedbi s povratnim arhitekturama, što je ključno za sustav koji mora obrađivati velike količine finansijskih podataka u realnom vremenu [48].

U kontekstu modela otvorenog koda, Llama 3 arhitektura odabrana je zbog nekoliko ključnih prednosti. Za razliku od zatvorenih modela poput BloombergGPT-a [22], Llama 3 pruža potpunu transparentnost i mogućnost prilagodbe specifičnim potrebama finansijske domene. Model demonstrira izvrsne performanse u razumijevanju konteksta i generiranju relevantnih značajki, što je potvrđeno kroz opsežna testiranja na finansijskim podacima [111]. Dodatno, njegova učinkovita arhitektura omogućava fino podešavanje s ograničenim računalnim resursima, što je posebno važno za praktičnu primjenu u razvoju sustava za automatsko trgovanje [112].

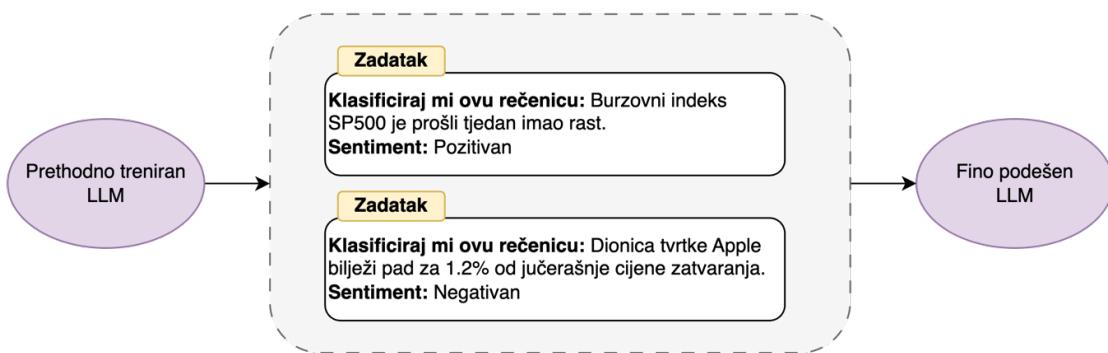
4.2. Napredne tehnike treniranja i podešavanja

Razvoj velikih jezičnih modela obilježen je značajnim promjenama u tehnikama treniranja, potaknutim evolucijom od modela poput GPT-2 do sofisticiranih verzija kao što su GPT-4 [105] i ChatGPT [113]. Napredak postignut je kroz fino podešavanje s instrukcijama [114], optimizaciju treniranih modela [115], [116], [117], [118], inženjeringu upita [119], [120], te generiranje pomoću pretraživanja [121], [122], odražavajući stalnu potragu za boljom prilagodljivošću, preciznošću i učinkovitošću u radu s LLM-ovima. Ove metode omogućuju modelima da bolje razumiju i izvršavaju korisničke upute, optimiziraju svoje performanse za specifične zadatke i domene, te generiraju kvalitetnije i relevantnije odgovore. U ovom kontekstu, fino podešavanje s instrukcijama omogućuje modelima da se brzo prilagode novim zadacima uz minimalne računalne resurse.

4.2.1. Treniranje modela instrukcijama

Uvođenje tehnike treniranja s instrukcijama značajno se unapređuju LLM modeli, poboljšavaju se njihove sposobnosti i kontrola. Ovaj pristup uključuje dodatno treniranje LLM-ova koristeći parove instrukcija s izlazom gdje instrukcija predstavlja korisničku naredbu modelu, a izlaz željeni rezultat te instrukcije [121], [123]. Prednosti ovog pristupa su višestruke i značajne. Prvo, fino podešavanje LLM-a na skupu podataka s instrukcijama smanjuje razliku između osnovnog cilja predviđanja sljedeće riječi modela, čime se omogućava preciznije usmjeravanje modela prema specifičnim zadacima korisnika. Drugo, omogućuje se kontrolirano i predvidljivo ponašanje modela u usporedbi sa standardnim pristupima, pružajući snažan mehanizam za usmjeravanje modela prema željenim odgovorima i domenskom znanju. Treće, treniranje s instrukcijama je računalno učinkovito, omogućavajući brzu adaptaciju modela na specifična područja bez potrebe za opsežnim ponovnim treniranjem ili promjenama arhitekture modela [121].

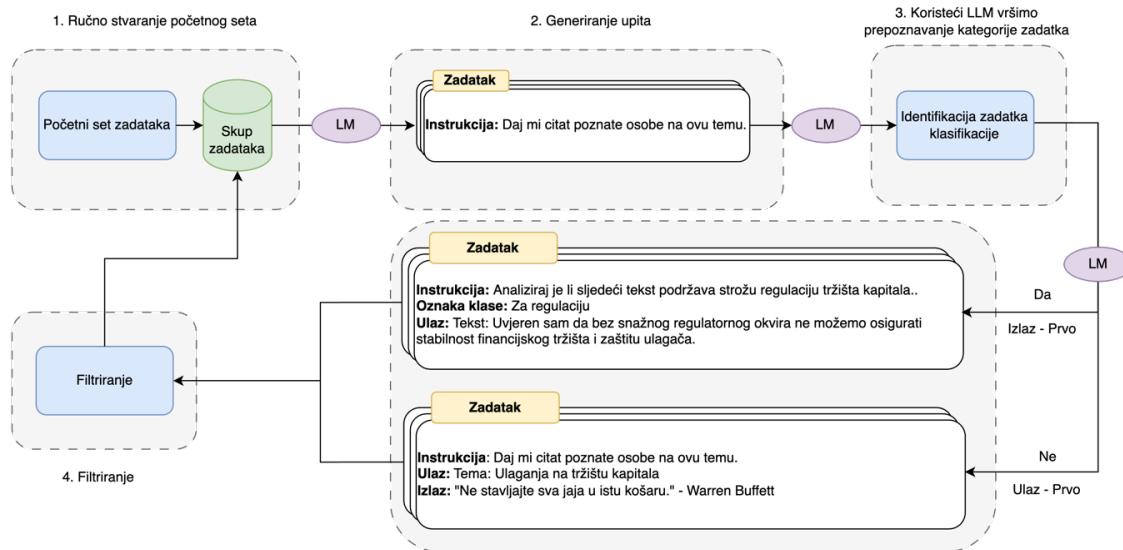
Za izradu skupova podataka s instrukcijama, postoje dva pristupa koja omogućuju efikasno prikupljanje i stvaranje bogatih raznolikih instrukcijskih parova potrebnih za treniranje modela instrukcijama. Proces kreiranja i korištenja instrukcijskih parova za treniranje prikazan je na Slici 4.5., gdje svaki zadatak uključuje specifičnu instrukciju za jezični model. Prva metoda temelji se na integraciji podataka iz postojećih označenih skupova podataka, gdje se parovi tekst-oznaka transformiraju u parove instrukcija-izlaz koristeći određene predloške. Ovaj pristup omogućava iskorištavanje već postojećih bogatih izvora podataka i njihovu adaptaciju u formatu koji je prikladan za treniranje modela instrukcijama.



Slika 4.5: Proces treniranja LLM-a s instrukcijama

Druga metoda koristi se za generiranje dodatnih instrukcijskih parova koristeći postojeće popularne modele poput GPT-3 ili GPT-4 [124]. Ovaj pristup uključuje dva glavna koraka: prvo, prikupljanje ili generiranje početnih setova uputa, koje mogu biti ručno prikupljene ili proširene korištenjem malog skupa početnih uputa. Zatim se te upute koriste kao ulazi u modele poput GPT-3 ili GPT-4 kako bi se generirali željeni izlazi

[125]. Proces koji ilustrira ovu metodu samostalno generiranih instrukcija prikazan je na Slici 4.6.. Takav pristup omogućuje brzo prikupljanje velikog i raznolikog skupa podataka s instrukcijama, koji su neophodni za treniranje modela instrukcijama.



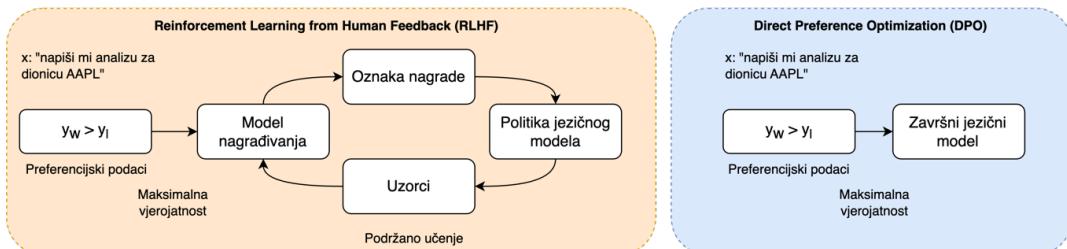
Slika 4.6: Treniranja LLM-a koristeći metodu samostalno generiranih instrukcija [125]

Na temelju prikupljenih ili generiranih skupova podataka za treniranje s instrukcijama, modeli se mogu fino podešavati na potpuno nadziran način. Modeli, uz danu instrukciju i ulaz, treniraju se predviđanjem svakog tokena u izlazu sekvencijalno. Primjer modela koji koristi ovaj pristup je Alpaca [126], koji je treniran kroz fino podešavanje na skupu podataka generiranom pomoću InstructGPT modela [114]. Alpaca demonstrira kako se može postići izvedba usporediva s najnaprednijim modelima poput InstructGPT-a, u smislu ljudske evaluacije. Ovo ističe potencijal i važnost treniranja s instrukcijama u razvoju efikasnih modela sposobnih za precizno izvršavanje zadataka prema ljudskim uputama, prilagođavajući se tako specifičnim zahtjevima i kontekstima koji proizlaze iz stvarnih primjena. Međutim, unatoč svojoj učinkovitosti, treniranje s instrukcijama predstavlja i određene izazove. Izrada kvalitetnih instrukcija koje adekvatno pokrivaju željena ponašanja modela nije jednostavan zadatak, a postojeći skupovi podataka s instrukcijama često su ograničeni u smislu količine, raznolikosti i kreativnosti. Postoji zabrinutost da treniranje s instrukcijama poboljšava performanse modela primarno na zadacima koji su dobro zastupljeni u skupu podataka za treniranje, dok se istovremeno kritizira da takav pristup može rezultirati modelima koji hvataju samo površinske obrasce i stilove umjesto da stvarno razumiju i uče zadatke [114]. Unatoč izazovima, treniranje s instrukcijama otvara nove mogućnosti za istraživanje i optimizaciju procesa, poboljšavajući usklađenost modela s ljudskim uputama te njihove izvedbene sposobnosti.

4.2.2. Tehnike optimizacije treniranih modela

Osim treniranja modela instrukcijama ili povećanja broja parametara modela kako bi poboljšali rezultate, možemo koristiti još neke od tehnika optimizacije treniranih modela. Naime, veći LLM-ovi mogu generirati odgovore koji su netočni, toksični ili jednostavno nisu korisni korisniku, što ukazuje na problem neusklađenosti modela s namjerama korisnika. Kako bi se riješio ovaj problem, istraživanje [117] pokazuje kako se finim podešavanjem modela uz pomoć povratne informacije od strane ljudi, tj. kroz proces ocjenjivanja modela na temelju ljudskih preferencija, može značajno poboljšati usklađenost modela s korisničkim namjerama na širokom spektru zadataka. Jedan od primjera takvog pristupa je razvoj modela InstructGPT [117] za kojeg bi mogli reći da je preteča popularnog ChatGPT modela, koji koristi tehniku podržanog učenja iz ljudske povratne informacije (engl. Reinforcement Learning from Human Feedback, RLHF), pokazujući poboljšanja u točnosti i smanjenje generiranja toksičnih odgovora. Osnovna ideja koja stoji iza InstructGPT-a naslijedena je iz tri koraka: prvo, stvaranje brojnih primjera razgovora između asistenta i čovjeka koji daje upute, što se koristi za treniranje postojećeg baznog LLM modela kroz nadzirano treniranje; drugo, prikupljanje podataka o rangiranju modela na temelju ljudskih preferencija, koje se zatim koriste za daljnje fino podešavanje modela kroz podržano učenje; i treće, optimizacija pomoću tehnika kao što su *Proximal Policy Optimization* (PPO) za poboljšanje kvalitete izlaza modela i njegovu prilagodbu korisničkim potrebama [117], [127].

U kontekstu težnje za preciznom kontrolom ponašanja modela, predstavljena je i tehnika direktnе optimizacije preferencija (engl. Direct Preference Optimization, DPO) [118], koja se razlikuje od RLHF-a po tome što optimizira model izravno prema ljudskim preferencijama koristeći jednostavan klasifikacijski gubitak, izbjegavajući složenost i nestabilnost povezanu s podržanim učenjem (engl. Reinforcement Learning, RL). Usporedba ove dvije tehnike prikazana je na Slici 4.7.. Osim RLHF-a i DPO-a, predložene su i druge tehnike kao što su pojačano samotreniranje (engl. Reinforced Self-Training, ReST) [116] i rangiranje odgovora za usklađivanje jezičnih modela s povratnim ljudskim informacijama (engl. Rank Responses to Align Language Models with Human Feedback, RRHF) [115], koje ciljaju na poboljšanje kvalitete izlaza LLM-ova usklađivanjem s ljudskim preferencijama.



Slika 4.7: Prikaz usporedbe RLHF i DPO tehnike [118]

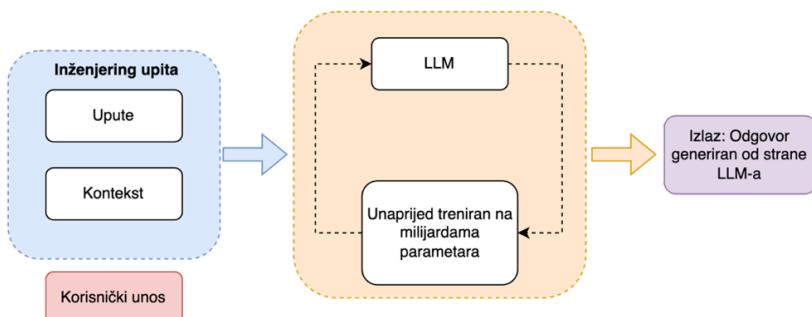
U kontekstu prilagodbe velikih modela specifičnim zadacima ili domenama, metode kao što su prilagodba niskog ranga (engl. Low-Rank Adaptation, LoRA) [112] i učinkovito fino podešavanje parametara (engl. Parameter-Efficient Fine-Tuning, PEFT) [128] nude rješenja za izazove povezane s velikim brojem parametara i zahtjevima za računalnim resursima. LoRA, na primjer, smanjuje broj parametara potrebnih za treniranje ubacivanjem rang-dekompozicijskih matrica u svaki sloj Transformer arhitekture, dok PEFT metode smanjuju broj parametara i potrošnju memorije potrebnih za fino podešavanje, omogućavajući usporedivu izvedbu s punim finim podešavanjem.

Kroz ove tehnike optimizacije, moguće je ostvariti precizniju kontrolu nad ponašanjem modela, uskladiti ih s ljudskim namjerama i poboljšati njihovu primjenjivost na specifične zadatke, dok istovremeno smanjujemo potrebu za velikim računalnim resursima, čineći ih pristupačnijima za širu primjenu.

4.2.3. Inženjering upita za modele

Inženjering upita (engl. Prompt Engineering) za prethodno trenirane jezične modele ključna je metoda u prilagođavanju ovih modela za specifične zadatke. Kroz različite pristupe, poput učenja u kontekstu (engl. In-Context Learning, ICL), učenja s malim brojem primjera (engl. Few-Shot Learning) i učenja bez primjera (engl. Zero-Shot Learning), omogućuje se modelima da s većom preciznošću interpretiraju i izvršavaju korisničke upute [129], [130].

Ovi metodološki pristupi su važni za razvoj fleksibilnosti modela, omogućavajući im da efikasno odgovaraju na raznovrsne izazove unutar širokog spektra zadataka iz domene obrade prirodnog jezika. Primjenom inženjeringu upita, modeli mogu prepoznati ključne elemente upita i konteksta, što im pomaže u generiranju preciznijih i relevantnijih odgovora [131]. Dodatno, inženjering upita omogućuje modelima da optimiziraju svoje performanse kroz bolje razumijevanje strukture i konteksta zadatka, čime se poboljšava njihova sposobnost da se prilagode specifičnim zahtjevima korisnika [119]. Komponente ovog procesa su detaljno prikazane na Slici 4.8., gdje je moguće vidjeti kako se upiti strukturiraju i implementiraju, pružajući temelj za precizniju obradu informacija [132].



Slika 4.8: Prikaz komponenata inženjeringu upita [132]

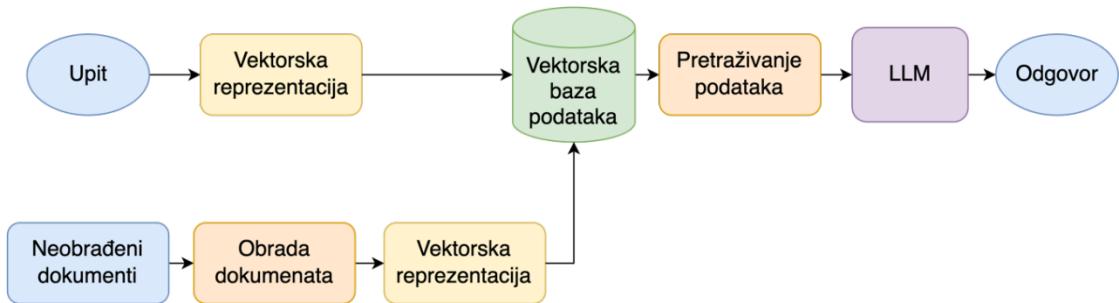
Jedan od temeljnih izazova u prilagodbi modela specifičnim zadacima je odabir između nadziranog finog podešavanja (engl. Supervised Fine-Tuning, SFT) o kojem je prethodno pisano i tehnika koje spadaju pod inženjeringu upita [133]. Dok učenje u kontekstu, zbog svoje jednostavnosti i poboljšane sposobnosti generalizacije izvan domene, postaje sve popularnije, nedavna istraživanja sugeriraju da fino podešavanje modela može podjednako dobro generalizirati izvan domene kada se kontrolira za veličinu modela i broj primjera. Takva usporedba ukazuje na to da je adaptacija zadataka robustan izazov, gdje niti jedan pristup nije univerzalno bolji, već rezultati ovise o faktorima poput veličine modela i broja primjera [131].

Učenje u kontekstu prilagođava model zadatku bez ažuriranja težina modela odnosno naknadnog treniranja modela, koristeći sekvencu demonstracija [129]. Ovaj pristup omogućuje modelima da izvršavaju zadatke bazirane na ograničenom broju kontekstualno relevantnih primjera, čime se smanjuju računalni troškovi i omogućava primjena modela na raznovrsne stvarne zadatke [134]. Sa druge strane, učenje s malim brojem primjera i učenje bez primjera omogućuju modelima izvršavanje zadataka uz minimalni broj ili bez prethodnih specifičnih primjera, oslanjajući se na opće znanje stečeno tijekom procesa prethodnog treniranja modela. Razlika između učenja u kontekstu i ovih tehnika leži u načinu prilagodbe novim zadacima, dok učenje s malim brojem primjera i učenje bez primjera primjenjuju prethodno stečeno znanje na nove situacije [129].

Iz aspekta inženjeringu upita, ovaj proces igra važnu ulogu u oblikovanju interakcija i izlaza modela, zahtijevajući detaljno osmišljavanje upita kako bi se osigurala točnost, relevantnost i koherencija generiranih odgovora [119]. Kroz različite pristupe, od jednostavnih do složenih, inženjeringu upita nudi metodički okvir za optimizaciju upita, čime se modelima pruža jasno usmjerenje i poboljšava njihova primjenjivost u različitim domenama. Ovi pristupi istražuju različite aspekte sposobnosti modela, od važnosti dobro strukturiranih upita do inherentne sposobnosti modela da primjenjuje svoje znanje na nove situacije, otvarajući put ka sve većoj fleksibilnosti i generalizacijskoj sposobnosti modela u obradi prirodnog jezika.

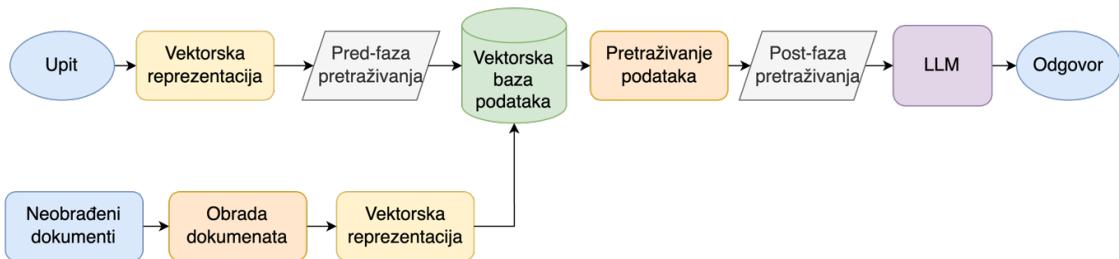
4.2.4. Generiranje pomoću pretraživanja

U kontekstu obrade prirodnog jezika, razvoj generiranja pomoću pretraživanja (engl. Retrieval-Augmented Generation, RAG) modela predstavlja značajnu inovaciju koja omogućava integraciju dinamičkih vanjskih izvora znanja s prethodno treniranim jezičnim modelima. Cjelokupni proces od unosa upita do generiranja odgovora, koji koristi jedinstveni set informacija u naivnom RAG pristupu, prikazan je na Slici 4.9.. RAG metoda uspješno spaja prednosti prethodno treniranih jezičnih modela s vanjskim resursima pohranjenim u primjerice vektorskim bazama podataka [122].



Slika 4.9: Naivni proces generiranja pomoću pretraživanja [121]

Ova integracija postiže se korištenjem sustava dohvaćanja (engl. Retriever), specijaliziranih algoritama koji omogućuju pretraživanje i dohvaćanje relevantnih informacija iz vektorskih baza. Dohvaćanje podataka se zasniva na pretvaranju upita u vektorske reprezentacije, koje se potom uspoređuju s vektorski indeksiranim sadržajima vektorskih baza podataka. Ovaj proces omogućava precizno i efikasno lociranje aktualnih informacija, obogaćujući generirani sadržaj relevantnim i ažuriranim podacima, dok se napredni RAG pristup, koji se poziva na različite izvore informacija za svaki token odgovora, detaljnije istražuje i prikazuje na Slici 4.10.. Ova sinergija omogućava generiranje sadržaja koji je precizniji, raznolikiji i aktualiziran, adresirajući na ključne izazove kao što su halucinacije (engl. Hallucinations) [135] i zastarjelo znanje koje su često ograničenja kod tradicionalnih jezičnih modela.



Slika 4.10: Napredni proces generiranja pomoću pretraživanja [121]

RAG modeli tako implementiraju dvije glavne formulacije: naivni i napredni RAG. Dok naivni RAG pruža osnovni okvir za povezivanje odgovora s dostupnim znanjem, napredni RAG pristup diverzificira izvore i pruža sofisticiranu prilagodbu na svakom koraku generiranja odgovora. Takva prilagodljivost omogućava LLM-ovima da učinkovito adresiraju specifične zahtjeve i kontekste upita, istovremeno smanjujući rizik od zastarjelih ili nepreciznih informacija [121].

Jedna od najvećih prednosti RAG-a u usporedbi s pristupima poput nadziranog finog podešavanja leži u njegovoj sposobnosti kontinuirane integracije ažuriranih informacija bez potrebe za ponovnim treniranjem. Dok SFT zahtijeva eksplicitno i redovito ponovno

treniranje modela kako bi se osvježilo njegovo znanje, RAG modeli dinamički pristupaju novim informacijama, omogućavajući im da ostanu relevantni i točni [136]. Uz to, razvoj naprednih RAG i modularnih RAG modela pokazuje težnju prema kreiranju sve složenijih sustava koji mogu neovisno optimizirati različite komponente za specifične zadatke [121]. Ovi pristupi otvaraju nove mogućnosti za povećanje prilagodljivosti i efikasnosti u rješavanju raznolikih zadataka, omogućavajući veću specijalizaciju i prilagođavanje specifičnim potrebama korisnika.

RAG pristup premošćuje jaz između statičnog znanja sadržanog u velikim jezičnim modelima i vanjskog svijeta informacija koji se stalno mijenja, pružajući temelj za budući razvoj NLP tehnologija koje će biti sposobne prilagoditi se i odgovoriti na širok spektar znanstvenih i praktičnih izazova. Razvojem i primjenom RAG modela, moguće je znatno poboljšati sposobnost jezičnih modela da generiraju relevantne, točne i aktualne informacije, otvarajući put prema razvoju inteligentnijih i prilagodljivijih NLP sustava.

Poglavlje 5

Duboko podržano učenje

Podržano učenje predstavlja jedan od pristupa u strojnom učenju u kojom se agent uči mapirati situacije u akcije kako bi maksimizirao nagradu. Ova metoda se temelji na konceptu učenja kroz pokušaj i pogrešku te se odlikuje sposobnošću agenta da samostalno otkriva koje akcije vode do najveće nagrade. Jedinstvenost podržanog učenja leži u njegovoj primjeni na kompleksne scenarije gdje odabrane akcije utječu ne samo na neposrednu nagradu već i na buduće situacije, oblikujući tako cijeli niz budućih nagrada [137]. Ovo zahtijeva razvijenu sposobnost predviđanja i planiranja, jer su posljedice akcija često odgođene i manifestiraju se kroz vremenski period [138].

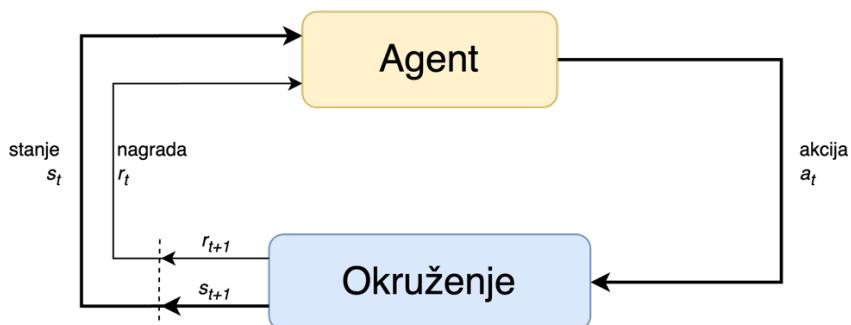
Podržano učenje razlikuje se od tradicionalnih pristupa strojnom učenju, poput nadziranog i nenadziranog učenja. Za razliku od nadziranog učenja, gdje sustav uči na temelju prethodno označenih primjera, u podržanom učenju agent mora eksperimentirati i učiti iz iskustva [139]. Ova metoda pokazuje svoju pravu snagu u scenarijima gdje je prikupljanje ili generiranje označenih podataka nepraktično ili nemoguće. Također, podržano učenje se razlikuje od nenadziranog učenja, čiji je cilj otkriti skrivenu strukturu unutar neoznačenih podataka. Dok nenadzirano treniranje teži otkrivanju strukture, podržano učenje teži optimizaciji akcija s ciljem maksimiziranja nagrade, čime se ističe kao zasebna paradigma strojnog učenja [138].

Razvojem dubokog učenja, podržano učenje je doživjelo svoj napredak, što je dovelo do nastanka dubokog podržanog učenja. Kombiniranjem modela dubokog učenja s metodama podržanog učenja, duboko podržano učenje omogućava efikasno rješavanje složenih problema sekvensijalnog odlučivanja [140]. Primjena dubokih neuronskih mreža u ovom kontekstu omogućava modelima da uče složene reprezentacije podataka, što rezultira snažnim i fleksibilnim sustavima sposobnim za treniranje iz iskustva. Duboke neuronske mreže, sa svojom sposobnošću da uče višeslojne reprezentacije podataka, predstavljaju ključnu komponentu u razvoju efikasnih metoda duboko podržanog učenja [141].

Duboko podržano učenje istražuje kako se kroz interakciju s okolinom i evaluacijom dobivenih rezultata mogu optimizirati akcije kako bi se maksimizirala ukupna nagrada. To uključuje razumijevanje i primjenu kompleksnih strategija učenja koje se mogu nositi s visokim stupnjem neizvjesnosti i dinamike, što je često prisutno u stvarnim aplikativnim primjenama, kao što su automatizirano trgovanje, robotika i računalne igre [142].

5.1. Osnove podržanog učenja

Podržano učenje oblikuje se oko interakcija između dva ključna entiteta: agenta i okruženja, kao što je ilustrirano na Slici 5.1.. Agent promatra stanje okruženja i na temelju toga bira akciju. Okruženje reagira na akciju tranzicijom u novo stanje i dodjeljuje agentu nagradu. Ovaj proces, u kojem agent prima stanje (s_t), poduzima akciju (a_t) i prima nagradu (r_t), predstavlja osnovni ciklus učenja koji se ponavlja kroz vremenske korake [143]. Agentova politika, koja određuje koje akcije će poduzeti u različitim stanjima, razvija se s vremenom kako bi se povećala ukupna nagrada. Ovaj proces učenja odvija se kroz seriju događaja ili epizoda, koje se mogu usporediti s nizom koraka ili odluka od početne točke do rješenja zadatka [137].



Slika 5.1: Dizajn sustava podržanog učenja [137]

Agent i okruženje su jasno definirani kako bi se osigurala nedvosmislenost razmjene informacija. Okruženje predstavlja sve što nije agent, nudeći različita stanja koja odražavaju moguće scenarije unutar zadatka. Nagrada koju agent prima nije samo rezultat njegove akcije, već je funkcija koja ovisi o akciji i trenutnom stanju okruženja [142]. Ova dinamika omogućava agentu da nauči razlikovati kvalitetu akcija unutar različitih konteksta, optimizirajući svoju politiku za različite situacije. Osim toga, razumijevanje kako različiti elementi okruženja utječu na rezultate akcija omogućava precizno podešavanje strategija koje agent primjenjuje.

Kroz iteracije, koje se tijekom učenja mogu smatrati eksperimentima, agent koristi povratne informacije u obliku nagrada da bi prilagodio svoje odluke i ponašanje. Kako se stanje okruženja mijenja od s_t do s_{t+1} , agent je potaknut da za novo stanje odabere akciju koja će maksimizirati nagradu r_{t+1} , a time i ukupni dugoročni dobitak [137]. Ovaj ciklički proces učenja je srž podržanog učenja i ključan je za razvoj inteligentnih sustava sposobnih za samostalno poboljšanje kroz interakciju sa svojim okruženjem.

5.1.1. Markovljev proces odlučivanja (MDP)

Markovljev proces odlučivanja (engl. Markov Decision Process, MDP) je matematički model za strukturiranje problema učenja kroz interakciju kako bi se postigao određeni cilj. MDP je sastavljen od agenta, koji uči i donosi odluke, i okoline koja uključuje sve izvan agenta. Njihova neprekidna interakcija obuhvaća selekciju akcija od strane agenta i odgovore okoline, koji prezentiraju agentu nove situacije i nagrade. Nagrade su specijalne numeričke vrijednosti koje agent teži maksimizirati kroz svoje odluke o akcijama. Ova prilagodba i treniranje temelje se na principu maksimizacije dugoročne koristi, što omogućava agentu da razvija složenije strategije odlučivanja s vremenom [142]. Ovaj proces će se primijeniti za modeliranje sloja okruženja ovog sustava automatskog trgovanja dionicama.

Interakcija između agenta i okoline događa se u nizu diskretnih vremenskih koraka $t = 0, 1, 2, 3, \dots$. Na svakom koraku vremena t , agent prima informaciju o stanju okoline S_t koje pripada skupu stanja S , te na temelju toga odabire akciju A_t , iz skupa akcija $A(S_t)$. Nakon jednog vremenskog koraka, kao djelomična posljedica svoje akcije, agent prima numeričku nagradu R_{t+1} i dolazi u novo stanje S_{t+1} . Iz ovoga proizlazi sekvenca koja započinje nizom: $S_0, A_0, R_1, S_1, A_1, R_2, S_2, A_2, R_3 \dots$ [138].

U kontekstu konačnog Markovljevog procesa odlučivanja, skupovi S , A i R , koji predstavljaju stanja, akcije i nagrade, sadrže ograničen broj elemenata. Vjerojatnosne distribucije slučajnih varijabli R_t i S_t su diskretne i jasno definirane, pri čemu njihove vrijednosti ovise isključivo o stanju i akciji iz prethodnog koraka. To jest, postoji definirana vjerojatnost za svaki par stanja s' i nagrade r u vremenu t , za dano prethodno stanje s i akciju a [138]:

$$p(s', r | s, a) \doteq P(S_t = s', R_t = r | S_{t-1} = s, A_{t-1} = a) \quad (5.1)$$

za sve $s' \in S$, $r \in R$, i $a \in A(s)$. Funkcija p definira dinamiku MPD-a u obliku funkcije. Dinamička funkcija p :

$$p: S \times R \times S \times A \rightarrow [0,1] \quad (5.2)$$

predstavlja običnu determinističku funkciju s četiri argumenta. Znak $|$ u funkciji predstavlja notaciju za uvjetnu vjerojatnost, a uvjetna distribucija mora zadovoljiti sljedeći uvjet:

$$\sum_{s' \in S} \sum_{r \in R} p(s', r | s, a) = 1 \quad (5.3)$$

Ovime se implicira da je vjerojatnost svake moguće vrijednosti za S_t i R_t uvjetovana isključivo prethodnim stanjem i akcijom, S_{t-1} i A_{t-1} , a ne ovisi o ranijim stanjima i akcijama. Ovo ograničenje nije na sam proces odlučivanja, već na definiciju stanja, koje mora uključivati sve relevantne informacije iz prošlosti o interakciji agenta i okoline koje su važne za budućnost. Ako stanje sadržava sve informacije relevantne za predviđanje budućih nagrada i stanja, tada kažemo da posjeduje Markovljevo svojstvo [138], [142].

5.1.2. Nagrada i povrat

U okviru podržanog učenja, cilj agenta je formaliziran kroz poseban signal zvan nagrada, koji prelazi iz okoline prema agentu. U svakom vremenskom korak t , nagrada je realni broj R_t . Neformalno, cilj agenta je maksimizirati ukupnu količinu nagrada koju prima, što znači da teži ne samo maksimiziranju neposredne nagrade, već i akumulativne nagrade kroz duži period. Da bi agent riješio problem koji mu postavimo, moramo konfigurirati nagrade na takav način da u maksimiziranju istih agent istovremeno ostvaruje i naše ciljeve. Od iznimne je važnosti da nagrade koje postavljamo zaista odražavaju ono što želimo postići. Formalnije, težimo maksimiziranju očekivanog povrata, gdje se povrat definira kao specifična funkcija sekvence nagrada. U najjednostavnijem slučaju, povrat se može definirati kao zbroj nagrada [137], [138]:

$$G_t = R_{t+1} + R_{t+2} + R_{t+3} + \dots + R_T \quad (5.4)$$

gdje je T , krajnji vremenski korak. Takav pristup ima smisla u primjenama gdje postoji prirodni krajnji vremenski korak T kada se interakcija agenta i okoline prirodno razdvaja u podsekvence, koje obično nazivamo epizodama. Svaka epizoda završava posebnim stanjem zvanim terminalno stanje S_T , nakon čega slijedi resetiranje u standardno početno stanje. Tada sljedeća epizoda počinje neovisno o tome kako je prethodna završila. Dakle, možemo smatrati da sve epizode završavaju u istom terminalnom stanju, s različitim nagradama za različite ishode. Zadaci takve vrste nazivaju se epizodični zadaci.

Međutim, u mnogim slučajevima interakcija agenta i okoline ne razdvaja se prirodno na prepoznatljive epizode, već se nastavlja kontinuirano bez ograničenja. U tom slučaju formulacija povrata postaje problematična za kontinuirane zadatke jer bi krajnji vremenski korak bio $T = \infty$, a povrat bi mogao biti beskonačan. Na primjer, prepostavimo da agent u svakom vremenskom koraku prima nagradu od $+1$. Da bi se riješio ovaj problem, uvodimo koncept diskontiranja, gdje agent pokušava odabratи akcije

tako da je maksimizirana suma diskontiranih nagrada koje prima u budućnosti. Posebno, bira A_t kako bi maksimizirao očekivani diskontirani povrat [137], [138]:

$$G_t = R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots = \sum_{k=0}^{\infty} \gamma^k R_{t+k+1} \quad (5.5)$$

gdje je γ parametar nazvan diskontna stopa, i vrijedi $0 \leq \gamma \leq 1$. Diskontna stopa određuje sadašnju vrijednost budućih nagrada: nagrada primljena u k vremenskih koraka u budućnosti vrijedi samo γ^k puta manje nego što bi vrijedila da je primljena odmah. Ako je $\gamma < 1$ beskonačni zbroj, ima konačnu vrijednost sve dok je sekvencija nagrada ograničena. Ako je $\gamma = 1$ agent je kratkovidan i brine se samo za maksimiziranje neposredne nagrade. Kako γ teži 1, cilj povrata sve više uzima u obzir buduće nagrade, agent postaje dugovidan [137], [138].

5.1.3. Funkcija vrijednosti i politika

Većina algoritama podržanog učenja fokusira se na procjenu funkcija vrijednosti, koje su presudne u određivanju kvalitete stanja ili parova stanje-akcija unutar okvira zadanog politikom. Funkcije vrijednosti temelje se na očekivanju budućih nagrada, čime daju uvid u prednosti određenih puteva koje agent može izabrati [144]. Ova očekivanja su ujedno i okosnica definiranja i prilagođavanja politika koje agent slijedi u procesu donošenja odluka.

Politika, označena kao π , predstavlja strategiju po kojoj agent određuje vjerojatnost odabira akcija u svakom stanju. Ako agent u vremenu t slijedi politiku π tada je $\pi(a | s)$ vjerojatnost da će A_t biti akcija a ako je trenutno stanje S_t , stanje s . Na temelju ovoga, vrijednosna funkcija stanja pod politikom π , označena kao $v_\pi(s)$, je očekivani povrat počevši od stanja s i prateći politiku π nadalje [138], [140]:

$$v_\pi(s) = E_\pi[G_t | S_t = s] = E_\pi[\sum_{k=0}^{\infty} \gamma^k R_{t+k+1} | S_t = s] \quad (5.6)$$

gdje E_π označava očekivanje pod uvjetom da agent slijedi politiku π , a γ je diskontna stopa koja reflektira manju važnost nagrada koje dolaze u daljoj budućnosti [138], [140].

Slično tome, vrijednosna funkcija akcije pod politikom π , označena kao $q_\pi(s, a)$, očekivani je povrat počevši od stanja s , izvršavanjem akcije a i zatim prateći politiku π [138], [140]:

$$q_\pi(s, a) = E_\pi[G_t | S_t = s, A_t = a] = E_\pi[\sum_{k=0}^{\infty} \gamma^k R_{t+k+1} | S_t = s, A_t = a] \quad (5.7)$$

Iz prakse se pokazalo da se funkcije vrijednosti v_π i q_π mogu pouzdano procijeniti na temelju iskustvenih podataka. Ukoliko agent neprestano prati politiku π i vodi evidenciju stvarnih povrata koji su uslijedili nakon svakog stanja, s vremenom će ovi prosjeci konvergirati prema vrijednostima $v_\pi(s)$. Ako se odvojeno prate prosjeci za svaku akciju unutar svakog stanja, ti će prosjeci konvergirati prema vrijednostima akcija $q_\pi(s, a)$. Metode koje koriste ove principe procjene poznate su kao Monte Carlo metode [138], [140].

Središnji koncept u primjeni ovih ideja je Bellmanova jednadžba, koju je formulirao Richard Bellman [145]. Ona predstavlja temeljni kamen teorije podržanog učenja, povezujući vrijednosti trenutnog stanja s očekivanim vrijednostima budućih stanja kroz rekurzivnu relaciju. Primjenjujući bilo koju politiku π i promatrajući bilo koje stanje s , vrijednost tog stanja može se precizno izraziti kroz sumu očekivanih vrijednosti svih mogućih sljedećih stanja i nagrada. Ova veza je formalno izražena kao [138], [142], [145]:

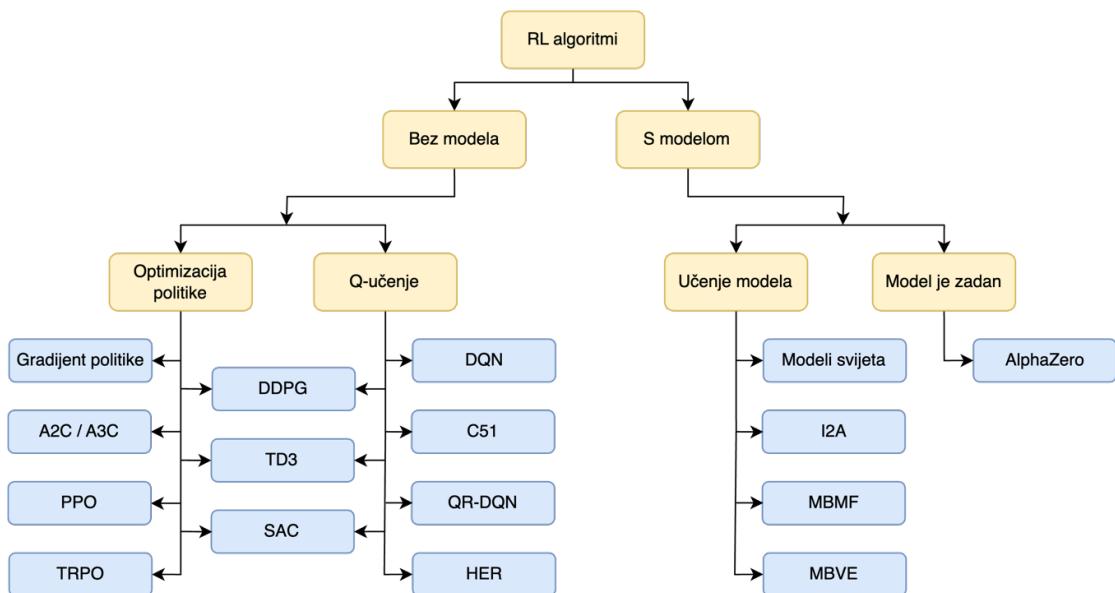
$$\begin{aligned} v_\pi(s) &= E_\pi[G_t | S_t = s] = E_\pi[R_{t+1} + \gamma G_{t+1} | S_t = s] \\ &= \sum_a \pi(a|s) \sum_{s', r} p(s', r|s, a) [r + \gamma E_\pi[G_{t+1} | S_{t+1} = s']] \\ &= \sum_a \pi(a|s) \sum_{s'} p(s', r|s, a) [r + \gamma v_\pi(s')] \end{aligned} \quad (5.8)$$

U ovoj jednadžbi, sumiramo preko svih potencijalnih akcija a koje se mogu odabrati u stanju s i svih mogućih ishoda s' i nagrada r koji proizlaze iz tih akcija. Svaki takav ishod teži se prema vjerojatnosti koju određuje politika π i model prijelaza p , čime se odražava koncept očekivanja. Očekivana vrijednost svakog potencijalnog nasljednog stanja uzima u obzir i trenutnu nagradu i diskontiranu vrijednost budućih stanja, što predstavlja strategiju agenta da teži ne samo trenutnom dobitku, već i optimalnim dugoročnim ishodima [138], [142], [145].

5.2. Algoritmi podržanog učenja

Algoritmi podržanog učenja klasificiraju se na temelju različitih pristupa agenta u procjeni i donošenju odluke unutar okoline. Dvije glavne kategorije su algoritmi bez modela (engl. Model-Free) i oni s modelom (engl. Model-Based) [142] što je dodatno prikazano na Slici 5.2.. Algoritmi bez modela, kao što to sugerira ime, djeluju bez eksplicitnog modela okoline, dok algoritmi s modelom uključuju neku formu modeliranja

kako bi se simulirali ishodi i unaprijedile odluke [146]. U ovom kontekstu, algoritmi bez modela ističu se kao središnji stupovi dubokog podržanog učenja bez potrebe za prethodnim znanjem o dinamici okoline. Ti pristupi se oslanjaju na direktno iskustveno treniranje, gdje agenti iterativno prilagođavaju svoje procjene i strategije temeljem povratnih informacija iz okoline.



Slika 5.2: Prikaz algoritama podržanog učenja [147]

Unutar algoritama bez modela fokus stavljam na: algoritme bazirane na funkciji vrijednosti (engl. Value-Based) i one koji kombiniraju treniranje funkcije vrijednosti s politikama (engl. Value and Policy Based). Algoritmi bazirani na funkciji vrijednosti, poput dubokih Q mreža (engl. Deep Q-Networks, DQN-a), temelj su za procjenu potencijalnih nagrada povezanih sa specifičnim akcijama i stanjima. Takvi algoritmi omogućuju agentima da prepoznaju i navigiraju putem koji maksimizira njihovu dugoročnu dobit. Kombinirani pristupi, kao što su metode *Actor-Critic*, kombiniraju procjenu funkcije vrijednosti s eksplisitnim optimiziranjem politike, čime se omogućuje agentu da procijeni potencijalne rezultate različitih akcija i istovremeno usmjerava politiku prema visoko vrijednim akcijama [137].

Iako je pristup baziran na modelima također relevantan, s obzirom na to da uključuje razumijevanje i modeliranje MDP-a radi anticipacije i planiranja akcija, u ovoj disertaciji se naglasak stavlja na algoritme bez modela, posebno one koje se temelje na funkciji vrijednosti i kombinaciji vrijednosti i politike.

5.2.1. Algoritmi bazirani na funkciji vrijednosti

Algoritmi bazirani na funkciji vrijednosti u središtu su pristupa dubokog podržanog učenja, gdje Q-učenje (engl. Q-learning) i njegove napredne forme poput DQN [148] koriste duboke neuronske mreže za aproksimaciju optimalnih politika odlučivanja. Kroz primjenu Bellmanove jednadžbe [145], ovi algoritmi procjenjuju vrijednost akcija u različitim stanjima, vodeći agente prema akcijama koje maksimiziraju očekivane dugoročne povrate [139].

5.2.1.1. Q-learning

Q učenje predstavlja jedan od osnovnih algoritama baziranih na funkciji vrijednosti, gdje je cilj naučiti optimalnu Q-vrijednost (engl. Q-values) za svaku kombinaciju stanja i akcija. Proces učenja se vodi putem Bellmanove jednadžbe, koja tvrdi da je optimalna Q-vrijednost $Q^*(s, a)$ jednakosti između Q-vrijednosti i očekivane maksimalne sume trenutne nagrade $R(s, a, s')$ diskontirane vrijednosti sljedećeg stanja, kako je izraženo formulom [139], [149]:

$$Q^*(s, a) = (\mathcal{B}Q^*)(s, a) \quad (5.9)$$

gdje je \mathcal{B} Bellmanov operator koji se formalno definira kao:

$$(\mathcal{B}K)(s, a) = \sum_{s' \in S} T(s, a, s') \left(R(s, a, s') + \gamma \max_{a' \in A} K(s', a') \right) \quad (5.10)$$

što implicira da se optimalne odluke donose razmatrajući sve moguće ishode i birajući one koji maksimiziraju dugoročnu korist.

Algoritam Q-učenje ažurira procjene vrijednosti koristeći razliku između procijenjene Q-vrijednosti i onoga što se stvarno dogodi, stvarne nagrade plus diskontiranu procjenu najbolje sljedeće akcije. Ažuriranje se vrši pomoću jednostavnog algoritma iterativne aproksimacije, koji u konačnici konvergira prema optimalnim Q-vrijednostima. Ta se ideja izražava kroz ciljanu vrijednost Y_k^Q [139]:

$$Y_k^Q = r + \gamma \max_{a' \in A} Q(s', a'; \bar{\theta}_k) \quad (5.11)$$

gdje γ predstavlja faktor diskontiranja, a $\bar{\theta}_k$ u parametri funkcije vrijednosti na k -toj iteraciji. Ova jednadžba omogućuje algoritmu da uči o optimalnoj politici djelovanja kroz iskustvo, bez potrebe za modelom prijelaza stanja [139].

5.2.1.2. Deep Q-networks (DQN)

DQN je inovacija koja je proširila mogućnosti tradicionalnog Q-učenja korištenjem dubokih neuronskih mreža za aproksimaciju Q-funkcije. Uveden od strane Mnih et al. [148], DQN koristi moć dubokog učenja da bi omogućio agentima uspješno treniranje izravno iz vizualnih ulaza, poput piksela u video igram. Element DQN algoritma je upotreba dviju heuristika: ciljnih Q-mreža koje stabiliziraju treniranje ograničavajući ažuriranje parametara na svakih C iteracija i tehnike ponovne memorije koja omogućava treniranje iz širokog spektra akumuliranih iskustava [139], [142].

DQN se oslanja na ideje prilagođenog Q-učenja, gdje se ciljana funkcija Q-vrijednosti prikazana na formuli 11 koristi za oblikovanje ciljnih vrijednosti koje vode proces ažuriranja neuronske mreže. Ciljne Q-vrijednosti, označene s $\bar{\theta}_k$ koriste se za izračunavanje gubitka tijekom učenja, uz ažuriranje svakih C koraka kako bi se izbjegle velike promjene u procijenjenim vrijednostima, što pomaže održavanju stabilnosti učenja [139], [149].

Osim toga, DQN algoritam koristi nekoliko drugih heuristika, kao što je normaliziranje nagrada između -1 i $+1$ kako bi se osiguralo da ciljne vrijednosti ostanu unutar razumnih granica te kako bi se olakšalo treniranje s istom stopom učenja. Osim toga, upotreba konvolucijskih slojeva u dubokim neuronskim mrežama omogućuje efikasnije prepoznavanje značajki iz vizualnih podataka, što je naročito korisno pri obradi slika ili video sadržaja [139].

5.2.1.3. Double Deep Q-networks (DDQN)

DDQN razvijaju koncept DQN-a rješavajući problem prekomjerne procjene Q-vrijednosti koje su česte u standardnim DQN algoritmima. DDQN uvodi korištenje dvostrukih mreža da bi razdvojio evaluaciju najbolje akcije od njenog ažuriranja. To se postiže tako da jedna mreža, tzv. online mreža, odabire akciju, dok druga, tzv. ciljana mreža (engl. Target Network), procjenjuje vrijednost te akcije [150]. Takav pristup smanjuje pristranost koja može dovesti do precijenjenih Q-vrijednosti i bolje generalizira treniranje agenta.

Formalno, ciljna vrijednost u DDQN-u definirana je kao:

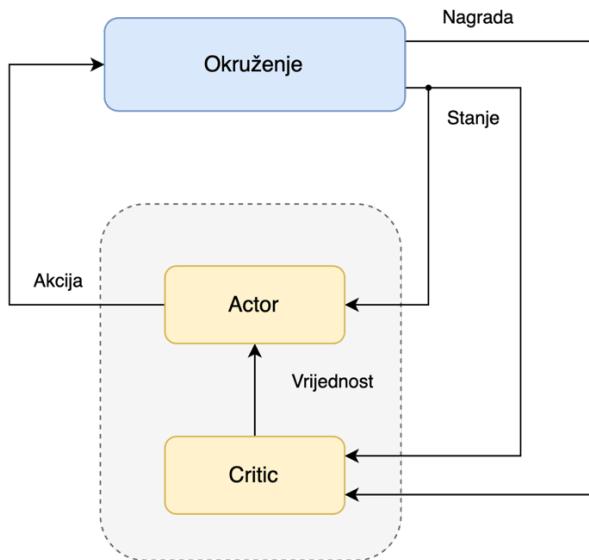
$$Y_k^{DDQN} = r + \gamma Q \left(s', \arg \max_{a \in A} Q(s', a; \theta_k); \theta_k^- \right) \quad (5.12)$$

gdje je θ_k skup parametara online Q-mreže na trenutnoj iteraciji k , a θ_{k-1} skup parametara ciljane Q-mreže koji se ažurira svakih iteracija. Ovime se omogućuje stabilnije treniranje, jer se ciljane vrijednosti ne mijenjaju sa svakim korakom, što pomaže agenciju da izbjegne kratkoročne varijacije u procjeni i fokusira se na dugoročniju konzistentnost [139].

DDQN metodologija pokazala se uspješnom u različitim okruženjima, poboljšavajući performanse u odnosu na standardni DQN i pružajući stabilniji put ka optimalnoj politici. Ova poboljšanja omogućuju da se duboko podržano učenje još snažnije usidri kao efikasan alat u kreiranju autonomnih sustava koji djeluju na temelju složenih odluka.

5.2.2. Algoritmi bazirani i na funkciji vrijednosti i politike

U naprednim sustavima podržanog učenja, algoritmi koji uče više funkcija istovremeno poput politike djelovanja i funkcije vrijednosti te su često sposobni za kompleksnije zadatke i ostvaruju bolje performanse. *Actor-Critic* metode, predstavljajući hibridne algoritme u podržanom učenju, kombiniraju dvije ključne komponente: *Actor* koji donosi odluke i djeluje unutar okoline, i *Critic*, koji procjenjuje te akcije temeljem funkcije vrijednosti [137]. Arhitektura ove metode se prikazuje na Slici 5.3..



Slika 5.3: Prikaz *Actor-Critic* arhitekture [142]

Actor u ovom kontekstu označava dio algoritma zadužen za selekciju akcija. Glavni zadatak *Actora* je usvajati znanje i birati najoptimalnije akcije na temelju ocjena koje dobiva od *Critic-a*. S druge strane, *Critic* analizira i ocjenjuje izvedbu *Actora*, uzimajući u obzir predviđene vrijednosti i moguće rezultate tih akcija [146].

Među značajnim algoritmima temeljenim na ovom pristupu ističu se *Proximal Policy Optimization* (PPO) koji je trenutno najrašireniji i *Soft Actor-Critic* (SAC). PPO posebno, koristi se zbog svoje sposobnosti da stabilno izvršava iterativno poboljšanje politika uz ograničene promjene, što pomaže u održavanju konzistentnih performansi tokom učenja [137].

5.2.2.1. Proximal Policy Optimization (PPO)

PPO kojeg su predstavili Schulman et. al. [151] iz OpenAI-a 2017. godine, donosi revoluciju u stabilnosti i napredovanju metoda učenja politike u dubokom podržanom učenju. Ova tehnika je naročito izražena u rješavanju izazova povezanih s metodama *Vanilla Policy Gradient* i *Trust Region Policy Optimization*. PPO odlikuje se time što efikasno trenira politike akcija u visokodimenzionalnim kontinuiranim akcijskim prostorima, koristeći pritom jednostavne, ali učinkovite strategije optimizacije prvog reda [152].

PPO unapređuje efikasnost i robusnost *Trust Region Policy Optimization* (TRPO), eliminirajući potrebu za složenom drugostepenom optimizacijom. Ključna inovacija PPO-a je uvođenje ograničenog ciljnog objektiva, poznatog kao *clipped* funkcija gubitka, koji se optimizira kroz formulu:

$$L^{\text{CLIP}}(\theta) = \widehat{\mathbb{E}}_t[\min(r_t(\theta)\widehat{A}_t, \text{clip}(r_t(\theta), 1 - \epsilon, 1 + \epsilon)\widehat{A}_t)] \quad (5.13)$$

U ovoj formuli računa se očekivanje minimuma između dva izraza. Prvi izraz unutar minimuma $r_t(\theta)\widehat{A}_t$ predstavlja standardni objektiv gradijenta politike, gdje je $r_t(\theta)$ omjer vjerojatnosti između trenutne i stare politike. Drugi izraz ograničava ovaj omjer vjerojatnosti, osiguravajući da se ne udalji previše izvan intervala $[1-\epsilon, 1+\epsilon]$, gdje je ϵ hiperparametar. Ograničeni objektiv sprečava pretjerani odmak od trenutne politike, posebno u slučajevima kada je prednost pozitivna, odnosno kada odabrana akcija ima pozitivan učinak na ishod. Kada je prednost negativna, funkcija gubitka postaje ravna kako bi se izbjeglo predaleko odmagnuti od politike koja dovodi do manje vjerojatne akcije [151].

PPO se pokazao posebno korisnim u okruženjima s kontinuiranim prostorom akcija, gdje metode temeljene na vrednovanju, poput DQN-a, ne mogu izračunati beskonačan broj Q-vrijednosti za svaku akciju. Direktno treniranje politike kroz PPO time pruža prednost u takvim scenarijima, omogućujući razvoj preciznih i adaptivnih modela koji učinkovito upravljaju kontinuiranim akcijama [141].

5.2.2.2. Advantage Actor-Critic (A2C)

A2C algoritmi učinkovito kombiniraju politiku izbora akcija i procjenu vrijednosti stanja kroz dva glavna elementa: *Actor* koji bira akcije i *Critic* koji ih procjenjuje. Osnovna formula koja se koristi u A2C algoritmima je [153]:

$$A(s, a) = Q(s, a) - V(s) \quad (5.14)$$

gdje $Q(s, a)$ predstavlja vrijednost poduzimanja akcije a u stanju s , a $V(s)$ je vrijednost procjene trenutnog stanja bez specifične akcije. Funkcija prednosti $A(s, a)$, informira aktora koliko je neka akcija bolja ili lošija od prosječne očekivane akcije u danom stanju. *Actor* koristi ovu funkciju za ažuriranje svoje politike akcija kako bi maksimizirao ukupnu očekivanu nagradu, dok *Critic* ažurira procjenu funkcije vrijednosti pomoću dobivenih rezultata [137].

A2C pristup omogućava efikasnije treniranje politika akcija u kontinuiranim prostorima akcija, što je osobito važno u složenim okruženjima poput finansijskih tržišta gdje akcije i njihove posljedice nisu jasno definirane i gdje je potrebno brzo prilagođavanje strategija.

5.2.2.3. Soft Actor-Critic (SAC)

SAC je napredna tehnika dubokog podržanog učenja koja cilja na maksimiziranje očekivane nagrade i entropije politike, vodeći ka balansiranju između efikasnosti i istraživanja u kontinuiranim akcijskim prostorima [154]. SAC postiže to kombinirajući dvije neuronske mreže, jednu za *Actora*, koji određuje politiku, i drugu za *Criticu*, koji procjenjuje vrijednost akcija. Upotrebom funkcionalnih aproksimatora, SAC procjenjuje tzv. meku Q-funkciju $Q_\theta(s_t, a_t)$, stanje vrijednosti funkcije $V_\psi(s_t)$, te prilagodljivu politiku $\pi_\phi(a_t | s_t)$ [146].

Centralni dio SAC algoritma je optimizacija objektivne funkcije koja nije samo usmjerena na nagrade, već i na entropiju, što se vidi u formuli:

$$J(\pi) = \sum_{t=1}^T E_{s_t \sim p^\pi, a_t \sim \pi} [r(s_t, a_t) + \alpha H(\pi(\cdot | s_t))] \quad (5.15)$$

gdje α kontrolira važnost entropijskog člana i time stupanj nasumičnosti optimalne politike. Ovaj pristup ne samo da promiče istraživanje, nego omogućuje i bolje treniranje politika u prostorima gdje postoje mnoge gotovo optimalne akcije [146].

Rezultati pokazuju da SAC postiže vrhunske performanse na zadacima kontinuirane kontrole, nadmašujući druge metode, uključujući i one koje koriste politiku izvan strategije i one koje se baziraju na strategiji optimizacije politike. Stabilnost i pouzdanost koje SAC pruža, zajedno sa sposobnošću maksimiziranja entropije, čine ga obećavajućim pristupom za daljnje istraživanje i primjenu u složenim, stvarnim okruženjima gdje su prostori akcija kontinuirani i visokodimenzionalni [154].

Poglavlje 6

Metodologija istraživanja

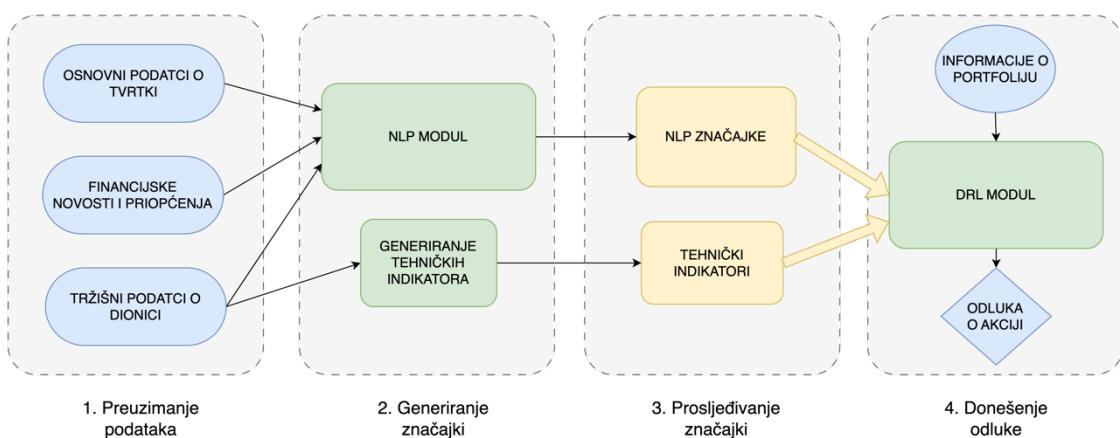
U ovom poglavlju temeljito se obrađuje metodologija primijenjena u kreiranju prototipa sustava za automatsko trgovanje na tržištu kapitala. Ovaj znanstveni pristup u metodologiji omogućuje razvijanje i detaljno testiranje prototipa kroz cikličke faze dizajna, implementacije i evaluacije, osiguravajući da konačni prototip sustava efikasno rješava postavljene probleme [155]. Razrađuje se sveobuhvatan pristup, od inicijalnog prikupljanja i obrade podataka, preko razvoja i treniranja modela za obradu prirodnog jezika i modela za duboko podržano učenje, do finalizacije prototipa sustava. Ovaj proces se dijeli u module, razvoj modula za obradu prirodnog jezika i razvoj modula za duboko podržano učenje, čiji je cilj optimizacija i automatizacija trgovačkih odluka na temelju analize tržišnih podataka i finansijskih vijesti. Detaljno se istražuje kako su specifični izazovi povezani s obradom prirodnog jezika i prilagodbom modela na finansijskom tržištu prevladani, naglašavajući značaj takve integracije za napredak u automatiziranom trgovaju. Pristup prikazan u ovom poglavlju ističe ulogu strojnog učenja u procesu poboljšanja finansijskih analiza i donošenja odluka, time pokazujući kako se ovaj metodološki okvir može primijeniti za razvoj sofisticiranih i efikasnijih trgovačkih alata.

6.1. Dizajn arhitekture sustava

Prvi korak u provedbi metodologije istraživanja je dizajn arhitekture sustava kako bi se osiguralo da sve potrebne komponente sustava mogu ispravno funkcionirati. Dizajn arhitekture sustava prethodi procesu razvoja pojedine komponente i daje uvid u relacije i međuovisne povezanosti istih. Ova faza je ključna ne samo za utvrđivanje kako pojedine komponente komuniciraju međusobno, već i za osiguravanje da arhitektura može podržati skalabilnost, pouzdanost i performanse koje su neophodne za efikasno trgovanje na tržištu kapitala [27], [62]. U ovom kontekstu, poseban naglasak stavlja se na modularni pristup, koji omogućava fleksibilnost u integraciji novih komponenti i prilagodbi na promjene. Stvaranjem robusne i fleksibilne arhitekture, postavljaju se čvrsti temelji za sustav sposoban za precizno izvršavanje trgovanja, istovremeno osiguravajući njegovu adaptabilnost i uspjeh na tržištu kapitala.

6.1.1. Pregled komponenti sustava

Arhitektura predloženog sustava za automatsko trgovanje oslanja se na nekoliko komponenti, od kojih svaka ima određeni zadatak unutar ukupne funkcionalnosti. Sustavne komponente moraju se besprijekorno izvršavati, pri čemu svaka od njih završava svoj segment zadatka i šalje podatke dalje u sljedeću komponentu sustava. Kako bi se vizualizirao ovaj proces, Slika 6.1. ilustrira arhitekturu sustava s jasno definiranim podjelama među pojedinim komponentama.



Slika 6.1: Prikaz arhitekture sustava

Prva skupina funkcionalnosti sustava odnosi se na preuzimanje i obradu podataka, čime se osigurava da su svi potrebni podaci skupljeni s odgovarajućih servisa, obradom prilagođeni i pripremljeni za daljnju analizu. Na temelju prikupljenih i obrađenih podataka, slijedi generiranje značajki koristeći NLP modul, a u procesu se koristi i dodatni modul za generiranje tehničkih indikatora.

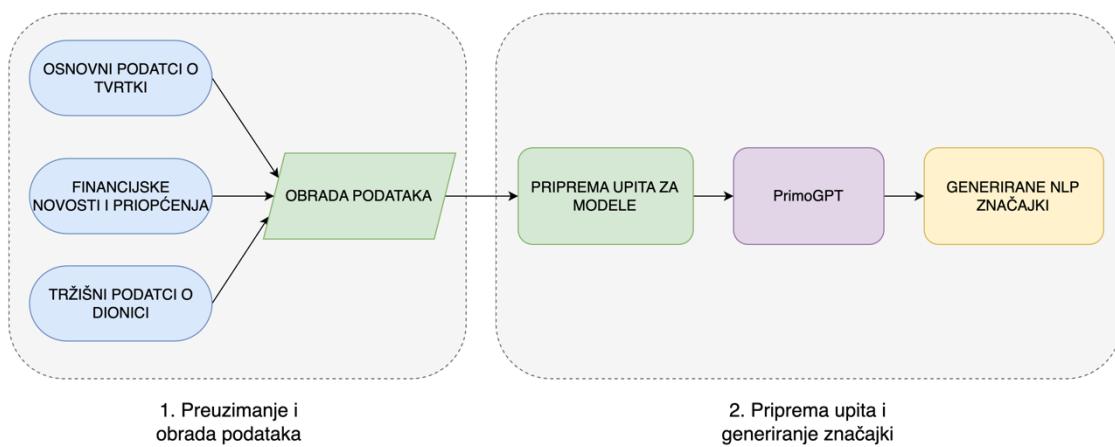
Nakon faze generiranja značajki, podaci se proslijeđuju modulu zaduženom za donošenje odluka i provedbu trgovanja, odnosno DRL modul. Ovaj modul zahtijeva sveobuhvatne informacije, ne samo o generiranim značajkama već i o portfelju s kojim će se trgovati, kako bi mogao valjano obavljati svoju funkciju. Krajnji ishod ovog integriranog procesa je generiranje trgovačkih odluka ili akcija koje će modul izvršiti.

Svaki dan trgovanja podrazumijeva ponavljanje navedenog procesa, gdje sustav, na temelju najnovijih podataka i prethodno treniranog modela, donosi odluke o trgovačkim akcijama. Odluke koje model donosi su temeljene na skupu generiranih značajki i istreniranog modela dubokog podržanog učenja, omogućujući tako sustavu da djeluje konzistentno unutar odabranog intervala trgovanja.

6.1.2. Modul za obradu i analizu teksta

Modul za obradu i analizu teksta, ili NLP modul, zadužen je za generiranje značajki temeljenih na informacijama o pojedinoj tvrtki, kretanju cijene njezine dionice te relevantnim financijskim medijskim objavama. Cilj ovoga modula jest omogućiti dubinsku obradu tekstualnoga sadržaja i pretvoriti ga u numeričke vrijednosti koje potom predstavljaju ulaz za DRL modul te služe kao temelj za donošenje trgovačkih odluka.

Kao što je prikazano na Slici 6.2., izvedba ovoga modula započinje prikupljanjem podataka iz različitih eksternih izvora, među kojima su povijesne i trenutačne cijene dionica, financijski izvještaji te niz relevantnih novosti, uključujući i korporativna priopćenja. Nakon početnoga prikupljanja, slijedi njihovo filtriranje prema vremenu objave kako bi se zadržale samo one vijesti čija je objava uskladena s odabranim intervalom trgovanja, čime se isključuju informacije koje ne mogu utjecati na sljedeći trgovački dan [156], [157]. Ovako pripremljeni podatci zatim se sistematiziraju i formatiraju u obliku odgovarajućeg skupa ulaznih značajki za model strojnog učenja.



Slika 6.2: Procesa obrade i analize teksta u NLP modulu

U središtu NLP modula nalazi se PrimoGPT, prilagođeni jezični model baziran na Llama 3 arhitekturi [111], posebno izrađen za potrebe ove disertacije. Kako bi model mogao učinkovito obraditi financijske vijesti i stvarati numeričke pokazatelje korisne za daljnju analizu, provedena je faza finog podešavanja na skupu podataka koji obuhvaća različite dionice, prateće temeljne informacije o tvrtkama te pripadajuće tekstualne objave. U toj je fazi, radi učenja uzročno-posljedičnih veza, modelu povremeno bio dostupan i ishod budućega kretanja cijene sljedeće trgovačke sesije, no isključivo tijekom treniranja, a ne pri stvarnoj kasnijoj primjeni sustava. Takva metodologija omogućila je PrimoGPT-u da prepozna nijanse u financijskim objavama.

Sastavni dio procesa rada ovoga modula odnosi se na generiranje upita za PrimoGPT, pri čemu se u jedan upit, uz kratak opis tvrtke i aktualne tržišne parametre, uključuju sve

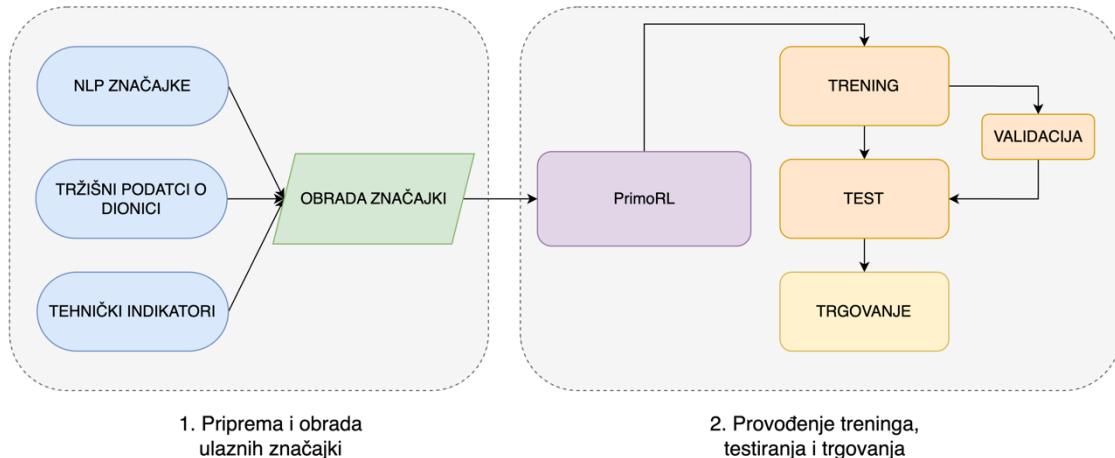
relevantne vijesti izvan radnoga vremena. Na temelju takve strukturirane analize, PrimoGPT generira jedinstveni skup značajki u kojemu se, uz sentiment i potencijalni utjecaj na cijenu, bilježe i vrijednosti poput promjene profila rizika te indikacije o razini povjerenja investitora. Svaka od tih značajki standardizirana je i prilagođena formatu koji može biti jednostavno integriran s ostalim numeričkim podacima u dalnjim fazama obrade.

Generiranjem ovako usklađenoga i cjelovitoga skupa značajki ostvaruje se niz pogodnosti za DRL modul. Ponajprije, omogućuje se preciznije praćenje stvarnoga utjecaja novosti objavljenih izvan radnoga vremena burze, što je osobito važno u razdobljima povećane tržišne volatilnosti. Nadalje, unificiran skup tekstualnih i tržišnih pokazatelja omogućuje lakše mjerjenje učinkovitosti cijelog sustava kroz testne primjere, u kojima se prepoznaju situacije gdje su negativno intonirane vijesti stvarno dovele do pada cijene i obrnuto. Sposobnost PrimoGPT modela da izdvoji ključne aspekte sadržaja i generira numeričke pokazatelje posebno je značajna jer time otvara mogućnost detaljne procjene performansi automatiziranoga trgovanja u korelaciji s objektivnim pokazateljima o sentimentu ili očekivanom trendu cijene.

Na taj način, NLP modul, sa svojim središnjim PrimoGPT modelom, omogućuje stvaranje dubljega i sveobuhvatnijeg skupa informacija koji će DRL modulu pružiti sofisticirani uvid u kompleksne obrasce na tržištu kapitala. Takav pristup, koji se temelji na poveznici između računalne analize teksta i finansijskih metrika, nadilazi uobičajene tehnike usredotočene samo na numeričke indikatore te znatno unapređuje kvalitetu i preciznost procesa donošenja trgovačkih odluka.

6.1.3. Modul za donošenje odluka i trgovanje

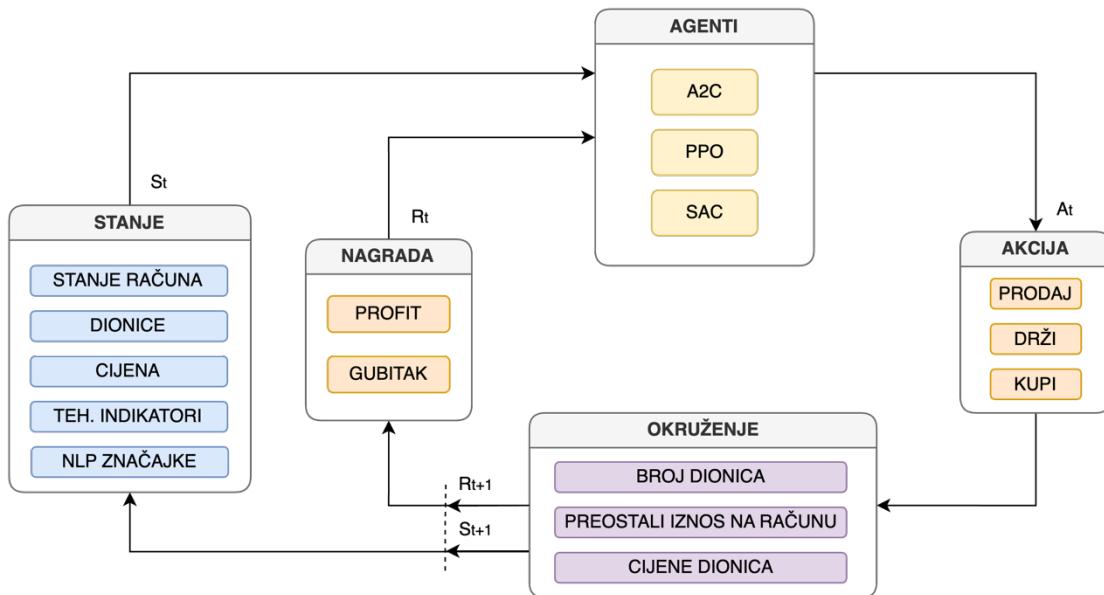
Modul za donošenje odluka i trgovanje, ili DRL modul, predstavlja središnju komponentu sustava za automatsko trgovanje, temeljenu na algoritmima dubokog podržanog učenja. Primarna zadaća ovoga modula jest interpretirati ulazne podatke, koji uključuju NLP značajke, tržišne podatke o dionici i tehničke indikatore, te na temelju njih generirati odgovarajuće trgovačke akcije usmjerene na maksimiziranje povrata ulaganja. Cjelokupni postupak, od obrade početnih značajki do konačnoga izvršavanja trgovačkih odluka, prikazan je na Slici 6.3. Implementacija modula slijedi standarde OpenAI Gymnasium [158] i načela FinRL modela [26], a unutar ovoga rada nazvan je PrimoRL.



Slika 6.3: Prikaz arhitekture modula za donošenje odluke i trgovanje

Prvi dio ovoga modula usmjeren je na obradu i pripremu značajki koje dolaze iz prethodnih komponenti sustava. U toj se fazi ujedinjuju numerički podaci iz tržišta, tehnički indikatori i NLP značajke dobivene iz analize NLP modula, što rezultira jedinstvenim skupom ulaznih veličina. Takav skup omogućuje dublje sagledavanje tržišnih prilika, budući da uključuje kako tradicionalne tehničke indikatore tako i podatke o sentimentu te potencijalnom riziku proizašli iz podataka obrađenih u NLP modulu. U ovome dijelu definiraju se i svi potrebni parametri za simulaciju, poput razdoblja koji će se promatrati tijekom treninga i testiranja, te se inicijalno postavlja struktura stanja koja opisuje raspoloživu imovinu i pozicije u dionicama.

Središnja funkcionalnost drugoga dijela DRL modula sastoji se u kreiranju simulacijskoga tržišnog okruženja, čime se postiže realistična imitacija burzovnih uvjeta unutar kojih se agenti uče optimalno reagirati na različite tržišne scenarije. U ovoj se fazi definira niz elemenata: prostor stanja (engl. state space), prostor akcija (engl. action space) te funkcija nagrade (engl. reward function) prikazano na Slici 6.4.. Na taj se način postiže uvjerljiva replikacija tržišne dinamike, pri čemu se agentima omogućuje donošenje odluka o kupnji, prodaji ili zadržavanju dionica, a svaka takva odluka ažurira stanje sustava ovisno o tome je li dobit ostvarena ili izgubljena [27]. Kontinuirano prilagođavanje funkcije nagrade omogućuje dugoročno očuvanje stabilnosti i profitabilnosti strategije, s obzirom na to da se pritom uzimaju u obzir i tržišna volatilnost te ostali rizici povezani s donošenjem trgovačkih odluka.



Slika 6.4: Interakcija stanja, nagrada i akcija unutar PrimoRL modela [159]

Tijekom samog treninga, modul za donošenje odluka koristi paralelno treniranje, što znači da se u jednom trenutku može generirati više različitih instanci tržišnoga okruženja. Time se znatno ubrzava postupak optimizacije jer agent istodobno iskušava različite scenarije i akumulira iskustvo iz svakoga od njih [57]. Nakon što agent doneše pojedinu odluku i ostvari nagradu, ažurira se odgovarajući skup parametara u modelu dubokog podržanog učenja. Ovaj se proces ponavlja kroz više epizoda, sve dok strategija ne dosege zadovoljavajuću razinu performansi.

Konačni sloj u ovome modulu odnosi se na samu implementaciju algoritama dubokog podržanog učenja, kao što su A2C, PPO i SAC. Ovi algoritmi predstavljaju mehanizme učenja kroz interakciju s okruženjem: agent, vođen trenutačnim stanjem i nagradama, rafinira vlastitu politiku trgovanja i prilagođava je različitim tržišnim uvjetima. Na taj način modul nije ograničen samo na jedno pravilo, nego se njegova strategija oblikuje kontinuirano, prikupljanjem iskustva iz izravne simulacije realnih tržišnih zbivanja. Pritom se pokazuje da spoj analitičkih značajki (dobivenih integracijom finansijskih novosti, tehničkih pokazatelja i informacija o portfelju) i slojevite arhitekture DRL-a omogućuje preciznije donošenje trgovačkih odluka u stvarnome vremenu.

Na opisani način, svaki sloj unutar modula ima definiranu svrhu: u prvoj se fazi objedinjuju i pripremaju značajke, u drugoj se kreira tržišno okruženje i generiraju nagrade, dok se u trećoj provodi sam algoritam treninga koji vodi do konačnih trgovinskih akcija. Takva je podjela presudna za postizanje veće jasnoće i fleksibilnosti pri razvoju te za osiguravanje modularnosti cijelog sustava. Spomenuti složeni pristup konačno omogućava efikasnu primjenu prikupljenih i obrađenih podataka, a agenti se mogu kontinuirano usavršavati, što dovodi do povećane otpornosti i profitabilnosti strategije trgovanja. Upravo ta sposobnost autonomne i neprekinute prilagodbe tržišnim

promjenama označava glavnu prednost ovoga modula u kontekstu automatiziranoga trgovanja na tržištu kapitala.

6.1.4. Integracija modula i oblikovanje sustava

Nakon razrade predstavljenih komponenti sustava i pružanja detaljnog uvida u arhitekturu modula koji obrađuju i analiziraju podatke te modula za donošenje odluka, dolazimo do integracijske faze. Ovdje se konvergiraju svi prethodni procesi u sinergiji, stvarajući robustan i koordiniran sustav koji je u stanju izvršavati trgovačke akcije temeljene na informiranim i automatiziranim odlukama [62].

Integracija modula u sustavu za automatsko trgovanje obuhvaća tehničku sinergiju među različitim komponentama te njihovo strateško usklađivanje, temeljeno na dubokom razumijevanju tržišta i ciljevima trgovanja. Ovaj pristup je važan za formulaciju sofisticiranih strategija koje podržavaju raznovrsne primjene u trgovaju dionicama, gdje je pravilno upravljanje rizicima jednako važno kao i izbor pravog trenutka za kupnju ili prodaju odabrane dionice. Ova integracija također omogućuje stvaranje adaptivnih mehanizama koji kontinuirano procjenjuju učinkovitost sustava i prilagođavaju parametre prema trenutnim tržišnim uvjetima, osiguravajući optimalnu performansu u različitim tržišnim scenarijima.

Kako bi bolje razumjeli proces, integraciju možemo promatrati kroz tri razine:

Operativna razina - na kojoj se podaci pretvaraju u značajke spremne za analizu, osiguravajući da su svi relevantni podaci pravilno obrađeni i spremni za sljedeću fazu procesa.

Funkcionalna razina - gdje se generirane značajke i tehnički indikatori koriste za stvaranje pouzdane slike tržišta koja će informirati trgovačke odluke.

Strategijska razina - na kojoj se definiraju parametri i postavke modula za donošenje odluka i trgovanja koji će djelovati na temelju pripremljenih podataka, dovodeći do realizacije trgovačkih akcija usmjerenih na ostvarenje profita i minimalizaciju rizika.

Kroz ovaj pristup slojevite arhitekture, modul za donošenje odluka je proaktivna komponenta koja reagira na trenutne tržišne signale i anticipira buduće prilike. To omogućuje sustavu da se prilagođava, uči iz trenutnih tržišnih stanja te da razvija prediktivnu sposobnost, postavljajući temelje za proaktivno trgovanje koje je korak ispred tržišnih kretanja [57]. Ova sposobnost brze prilagodbe važna je za održavanje konkurentnosti i optimizaciju povrata investicija u nepredvidivom tržišnom okruženju. Primjena ovakvog integriranog pristupa omogućava sustavu da efikasno koristi prikupljene podatke i trenirane modele za automatsko izvršavanje trgovačkih strategija, što rezultira boljom preciznošću u trgovaju. Integracija također omogućuje sofisticirano upravljanje rizicima kroz dinamičku alokaciju resursa i prilagodbu strategija u realnom vremenu, što je bitno za dugoročnu održivost i profitabilnost u volatilnom tržišnom okruženju. Sustav postaje sposoban za samostalno donošenje odluka, koristeći duboko

podržano učenje kao osnovu za trgovanje, što predstavlja ostvarenje cilja u automatiziranom trgovaju na tržištu kapitala.

6.2. Prikupljanje i obrada podataka

U razvoju sustava temeljenih na strojnom učenju, podaci su najvažnija komponenta, a njihova kvaliteta i količina značajno utječe na učinkovitost i točnost modela. Odabir izvora podataka vrši se s ciljem osiguranja pouzdanosti, točnosti i aktualnosti informacija, koje uključuju povijesne cijene dionica, informacije o tvrtkama, tržišne volumene te druge relevantne novosti i podatke. Često se kroz literaturu pronađi naziv alternativni podaci kad je riječ o finansijskim novostima, objavama na društvenim mrežama i raznim izvještajima o događajima [83].

Metodologija za prikupljanje podataka uključuje konfiguriranje skripti za automatsko preuzimanje i osiguranje pravovremenosti podataka. Nakon prikupljanja, podaci se obrađuju kako bi se eliminirali nepotpuni ili nekonzistentni zapisi i normalizirali različiti formati, te se izvlače informacije relevantne za daljnju obradu u procesu generiranja značajki te treniranje modela. Konačno, obrađeni podaci se pohranjuju u odgovarajuće formate, pripremajući ih za upotrebu u modelima strojnog učenja koji se kasnije koriste [82].

6.2.1. Identifikacija izvora i prikupljanje podataka

Odabir izvora podataka je prvi korak u izradi ove komponente sustava za automatizirano trgovanje. U današnje vrijeme, napredak informacijskih tehnologija omogućuje pristup različitim pružateljima usluga za dohvatanje podataka, stoga je od izuzetne važnosti pažljivo odabrati izvore koji mogu osigurati pouzdanost, točnost i aktualnost informacija [160]. Također, troškovna efikasnost je bitna komponenta u ovom odabiru, posebice za istraživačke svrhe kao što je izrada prototipa sustava u sklopu ove disertacije. Pri odabiru izvora podataka, važno je uzeti u obzir i brzinu kojom se podaci osvježavaju te mogućnosti integracije s razvojnim okruženjima, kako bi se osigurala maksimalna korist i agilnost u primjeni sustava.

Za te potrebe odabrani su Finnhub [161] i Yahoo Finance [162] kao primarni izvori podataka. Finnhub se koristi za prikupljanje osnovnih podataka o tvrtkama i takozvanih alternativnih podataka [83] što uključuje razne finansijske novosti, te zbog svoje sposobnosti da pruža besplatno aplikacijsko programsko sučelje (engl. Application Programming interface, API) za privatne korisnike i istraživače. Detalji o podacima prikupljenim s Finnhub-a prikazani su u Tablici 6.1.. Yahoo Finance je izabran za dohvaćanje tržišnih podataka o cijenama dionica i drugih tržišnih parametara poput volumena trgovanja, temeljnih za generiranje tehničkih indikatora.

Tablica 6.1: Prikaz podataka prikupljenih s Finnhub

Naziv značajke	Opis	
Datum	Datum i vrijeme objave novosti	
Osnovne informacije o tvrtki	Ime tvrtke	Burzovna oznaka dionice
	Simbol	Burzovna oznaka dionice
	Industrija	Sektor industrije kojem tvrtka pripada
	Tržišna kapitalizacija	Trenutna tržišna vrijednost tvrtke
	Broj zaposlenika	Ukupan broj zaposlenih u tvrtki
	Cijena zatvaranja	Zadnja cijena dionice na kraju trgovačkog dana
	Promjena cijene zatvaranja	Postotna promjena cijene u odnosu na prethodni dan
Financijske novosti	Naslov	Glavni naslov finansijske vijesti
	Sažetak	Kratak pregled vijesti
	Izvor	Naziv medija ili platforme koja je objavila vijest
Priopćenja za javnost	Naslov	Glavni naslov službenog priopćenja tvrtke
	Opis	Detaljniji sadržaj priopćenja informacijama

Tržišni podaci o dionicama obuhvaćaju informacije kao što su otvorena, najviša, najniža, i zatvorena cijena dionica na dnevnoj bazi, kao i prilagodene zatvorene cijene koje uzimaju u obzir korporativne akcije poput podijele dionica i dividendi. Također, podaci o volumenu trgovanja omogućuju uvid u likvidnost i interes tržišta za određene dionice, što je neophodno za izvođenje preciznih tržišnih analiza. Detaljan prikaz ovih podataka nalazi se u Tablici 6.2..

Tablica 6.2: Prikaz podataka prikupljenih s Yahoo Finance

Naziv značajke	Opis
Datum	Datum trgovanja
Cijena otvaranja	Otvorena cijena dionice
Najviša cijena	Najviša cijena dionice tijekom trgovanja
Najniža cijena	Najniža cijena dionice tijekom trgovanja
Cijena zatvaranja	Zatvorena cijena dionice na kraju trgovačkog dana
Pril. Cijena zatvaranja	Prilagođena zatvorena cijena
Volumen	Volumen trgovanja
Simbol	Burzovna oznaka dionice

Za preuzimanje podataka s prethodno navedenih servisa koristi se programski jezik Python [163], koji je iznimno jednostavan u rukovanju s podacima i omogućuje brzu

integraciju s različitim API-jima. Unutar Python skripte definirane su funkcije koje se spajaju na navedene servise koristeći njihove API-je i preuzimaju potrebne podatke za proslijedjeni vremenski interval. Podaci se prvo preuzimaju i pohranjuju u privremene varijable unutar Python skripte što omogućava brzu i efikasnu obradu podataka prije konačnog spremanja.

6.2.2. Proces obrade i pohrane podataka

Proces obrade podataka odvija se odmah po preuzimanju i smještanju istih u privremene varijable. Povrat ulaganja na dionicama s Yahoo Finance servisa izračunava se temeljem prilagođene zatvorene cijene za svaki dan. Izračun povrata je osnovna operacija koja se obavlja koristeći odgovarajuću formulu za izračun dnevnih povrata, uzimajući pritom u obzir prilagođene zatvorene cijene za trenutni i prethodni dan [164]:

$$R = \left(\frac{P_t - P_{t-1}}{P_{t-1}} \right) \quad (6.1)$$

gdje je P_t prilagođena cijena zatvaranja na kraju trenutnog dana, a P_{t-1} prilagođena cijena zatvaranja na kraju prethodnog dana.

Nakon izračuna dnevnih povrata, podaci se obrađuju kroz Algoritam 5.1. koji kategorizira povrate u različite kategorije. Ove kategorizirane vrijednosti koriste se za daljnju analizu i kao dio upita prilikom korištenja naprednih jezičnih modela. Kroz algoritam se povrat pretvara u tekstualne oznake koje opisuju smjer i veličinu promjene.

Algoritam 6.1: Mapiranje povrata ulaganja

Ulaz: vrijednost_povrata ulaganja vrijednost_povrata
Izlaz: tekstualna oznaka rezultat

```
1  ako je vrijednost_povrata >= 0 tada
2      | postavi smjer ← 'U'
3  inače
4      | postavi smjer ← 'D'
5  kraj ako
6  absolutna_vrijednost ← 100 * izracun_absolutna_vrijednost(vrijednost_povrata)
7  zaokruzeno_gore ← zaokruži_na_vise(absolute_vrijednost)
8  ako zaokruzeno_gore <= 5 onda
9      | rezultat ← smjer + pretvoriti_u_broj(zaokruzeno_gore)
10 inače
11     | rezultat ← smjer + '5+'
12 kraj ako
13 vrati rezultat
```

Nakon računanja povrata, pažnja se posvećuje filtriranju i obradi finansijskih novosti. Konkretno, biraju se samo one vijesti koje su objavljene izvan radnog vremena New York Stock Exchange-a (NYSE) [165], odnosno nakon njenog zatvaranja do sljedećeg otvaranja. Sukladno tome nad prikupljenim finansijskim novostima provodi se filtriranje kako bi se odabrali oni izvori koji objavljaju novosti u istoj vremenskoj zoni NYSE prikazani na Tablici 6.3..

Tablica 6.3: Filtrirani izvori finansijskih novosti

Izvor	Opis podatka	Linkovi
Fintel	Analize i podaci za dubinsko istraživanje tržišta	https://fintel.io/
InvestorPlace	Vijesti i analize o dionicama	https://investorplace.com/
Seeking Alpha	Članci, predviđanja i analize stručnjaka	https://seekingalpha.com/
Yahoo	Globalne finansijske vijesti i podaci o tržištu	https://finance.yahoo.com/
CNBC	Najnovije finansijske vijesti i analize tržišta	https://www.cnbc.com/
TipRanks	Analize dionica i ocjene stručnjaka	https://www.tipranks.com/
MarketWatch	Tržišne informacije i finansijske vijesti	https://www.marketwatch.com/
The Fly	Vijesti o tržištima i finansijskim transakcijama	https://thefly.com/
Benzinga	Brze finansijske vijesti, analize i predviđanja	https://www.benzinga.com/
TalkMarkets	Finansijski sadržaj i analize dionica	https://talkmarkets.com/
Stock Options Channel	Podaci o opcijama i trgovanju	https://www.stockoptionschannel.com/

Ovaj pristup je značajan jer korporativni događaji, objave o zaradama i druge ključne informacije koje se objavljaju van radnog vremena burze često imaju veliki utjecaj na tržište. S obzirom na to da postoji trgovanje izvan uobičajenog radnog vremena (engl. After Hours Trading), većina značajnog trgovanja ipak se odvija tijekom službenih sati burze, što objašnjava važnost takvog pristupa filtriranju [156]. Posebna pažnja u procesu obrade posvećena je pravilnoj klasifikaciji vijesti koje su objavljene tijekom vikenda. Premda su nedavna istraživanja [157] ukazala na smanjenje ili nestanak tzv. efekta vikenda (engl. Weekend Effect), vikendom se često objavljaju važne korporativne informacije koje mogu imati značajan utjecaj na tržišne aktivnosti prvoga trgovačkog

dana koji slijedi. Procesom obrade osigurava se da su podaci iz različitih izvora odgovarajuće vremenski usklađeni i povezani.

Podaci prikupljeni kroz ove faze obrade koriste se dalje u procesima pripreme za treniranje modela PrimoGPT i PrimoRL, koji se koriste unutar NLP i DRL modula. Za svaku dionicu prikupljaju se osnovne informacije o tvrtki koje pružaju kontekst za razumijevanje pozicije tvrtke na tržištu. Primjer takvih informacija prikazan je u Tablici 6.4.

Tablica 6.4: Primjer osnovnih informacija o tvrtki

Naziv značajke	Sadržaj
Ime tvrtke	Apple Inc
Simbol	AAPL
Industrija	Technology
Tržišna kapitalizacija	\$3,434,462
Broj zaposlenika	161,000
Cijena zatvaranja	\$183.55
Promjena cijene zatvaranja	Down by 0-1% compared to the previous closing price.

Važan izvor informacija za razumijevanje najnovijih razvoja i strategija tvrtke su priopćenja za javnost. Ovi podaci su kritični jer često sadrže ključne informacije o poslovnim aktivnostima i rezultatima tvrtke. Priopćenja za javnost mogu uključivati najave novih proizvoda, financijske rezultate, promjene u vodstvu tvrtke ili strateške inicijative, pružajući investitorima i analitičarima vrijedan uvid u smjer i performanse tvrtke. Primjer priopćenja za javnost prikazan je u Tablici 6.5.

Tablica 6.5: Primjer priopćenja za javnost

Datum	Simbol	Naslov	Opis
2024-01-08	AAPL	Apple Vision Pro available in the U.S. on February 2	Apple announces Apple Vision Pro will be available beginning Friday, February 2, at all U.S. Apple Store...
2024-01-11	AAPL	Wanda Austin to join Apple's board of directors	Dr. Austin, former CEO of The Aerospace Corporation, brings expertise in cutting-edge technology...
2024-01-11	AAPL	Shareholder Statement on Al Gore's Departure from Board	Apple announced Al Gore won't seek reelection to the board, citing age limit...

Tržišni podaci o dionicama, koji obuhvaćaju detaljne informacije o cijenama i volumenima trgovanja, prikazani su u Tablici 6.6. Ovaj set podataka pruža sveobuhvatan uvid u dnevne performanse dionica na tržištu i služi kao temelj za brojne analitičke i prediktivne procese sustava automatiziranog trgovanja. Svaki zapis sadrži informacije o

cijeni otvaranja, zatvaranja, najvišoj i najnižoj cijeni tijekom dana, kao i ukupnom volumenu trgovanja. Na osnovi ovih podataka izračunavaju se razni tehnički indikatori, neophodni za analizu trendova i obrazaca u kretanju cijena dionica. Ovi podaci se također izravno unose u DRL modul, omogućujući modelu učenje i optimizaciju trgovačkih strategija temeljenih na povijesnim tržišnim kretanjima. U NLP modulu, ovi podaci se koriste za generiranje kontekstualnih informacija i preciznih predikcija tržišnih kretanja.

Tablica 6.6: Primjer tržišnih podataka o dionici

Datum	Simbol	Cijena otvaranja	Najviša cijena	Najniža cijena	Pril. cijena zatvaranja	Volumen
2021-09-01	AAPL	152.830002	154.979996	152.339996	149.998184	80313700.0
2021-09-02	AAPL	153.869995	154.720001	152.399994	151.119431	71115500.0
2021-09-03	AAPL	153.759995	154.630005	153.089996	151.758713	57808700.0

Tablica 6.7. nadopunjuje ovaj set podataka kroz prikaz filtriranih finansijskih novosti, uključujući naslove i sažetke, koji su također za razumijevanje tržišnih kretanja, posebno van standardnih sati trgovanja. Izvor ovih novosti omogućava daljnje istraživanje i dubinsku analizu specifičnih događaja koji utječu na tržišne cijene.

Tablica 6.7: Primjer finansijskih novosti

Datum	Simbol	Naslov	Sažetak	Izvor
2024-01-03	AAPL	Apple Stock Is Dropping Again. How It Can Get 'Unstuck.'	The iPhone maker is under pressure to show it is ready to compete in the field of artificial intelligence...	Yahoo
2024-01-03	AAPL	How To Earn \$500 A Month From Apple Stock Following Tuesday's Slide	Apple shares settled lower after Barclays downgraded its rating on the stock. Analyst cites weakness....	Yahoo
2024-01-03	AAPL	PC demand presents opportunities for Apple in 2024	Despite Barclays downgrade, Goldman Sachs analysts note potential upside...	Yahoo

Završni korak u procesu je integracija podataka iz obje tablice kako bi se osigurala njihova pohrana u CSV format. Ovaj format omogućava efikasno rukovanje s podacima i njihovu spremnost za daljnju obradu. Svi relevantni podaci spojeni su zajedno kako bi se formirao konsolidirani skup podataka koji je potreban za treniranje i testiranje modela. Ovim pristupom, osigurava se da modeli imaju pristup detaljnim i sveobuhvatnim informacijama potrebnim za analizu tržišnih trendova i donošenje informiranih trgovačkih odluka.

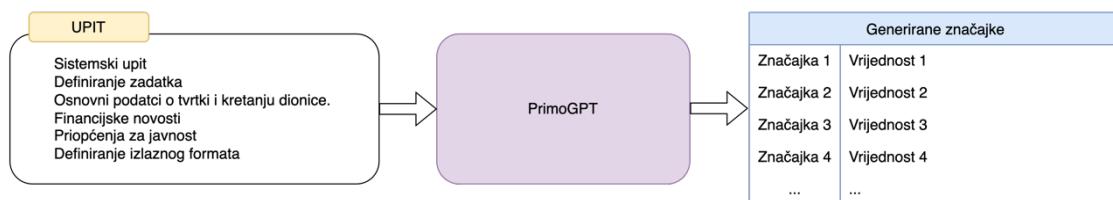
6.3. Metode generiranja značajki

U okviru ove disertacije, posebna pažnja posvećena je procesu generiranja značajki, koji se ističe kao jedna od inovacija u treniranju modela dubokog podržanog učenja. Značajke, kao temeljne komponente modela, pažljivo su osmišljene i generirane kako bi se osigurala njihova relevantnost i time pridonijele uspješnosti modela. U tom kontekstu, značajke su podijeljene u dva primarna skupa: one derivirane iz tržišnih podataka o dionicima i one koje proizlaze iz osnovnih informacija o tvrtki i finansijskim novostima.

Značajke koje se generiraju iz tržišnih podataka o dionicama su standardne i dobro uspostavljeni unutar domene tehničke analize što se ogleda u primjeru tehničkih indikatora [78]. Međutim, inovativnost dolazi do izražaja kroz drugi skup značajki. Ovaj skup, koji integrira informacije iz finansijskih novosti, zahtijeva napredne metode za kvantifikaciju i transformaciju kvalitativnih informacija u numeričke vrijednosti koje mogu biti efikasno iskorištene unutar modela dubokog podržanog učenja. Ove značajke, generirane primjenom metoda obrade prirodnog jezika na finansijske tekstove, u okviru ove disertacije nazivamo NLP značajke.

6.3.1. Elementi upita za generiranje NLP značajki

Osnova korištenja velikih jezičnih modела su detaljno osmišljeni tekstualni unosi, poznatiji kao upiti (engl. Prompt), koji usmjeravaju izlaz modela [120]. Upiti variraju od jednostavnih pitanja do detaljnih opisa specifičnih zadataka, uključujući upute, pitanja i primjere podataka. Osnovni upiti mogu biti jednostavni kao direktna pitanja ili specifične instrukcije za zadatke, dok napredniji upiti mogu uključivati kompleksnije strukture poput lanca misli, gdje se model vodi logičkim procesom razmišljanja kako bi se došlo do odgovora [119]. Ovi upiti su osnova za usmjeravanje modela PrimoGPT-a prema generiranju relevantnih i kontekstualno primjerenih odgovora. Kao što je prikazano na Slici 6.5., pravilno dizajnirani upiti omogućuju optimalno generiranje značajki, osiguravajući precizne i korisne izlaze iz PrimoGPT-a [43].



Slika 6.5: Proces generiranja NLP značajki koristeći upite

Kako bi se generirale značajke koje sadrže kvantificirane informacije proizašle iz osnovnih informacija o tvrtki i finansijskih novosti, koristi se pristup kreiranja upita koji se sastoji od instrukcije i ulaza [119]. U ovom kontekstu upit je strukturiran kako bi model izvršio analizu za specifičnu tvrtku, procijenio utjecaj novosti i objava na cijenu dionice, te kvantificirao taj utjecaj kroz seriju značajki poput sentimenta, relevantnosti, i potencijalnog utjecaja na trend. Te značajke su predstavljene na numeričkoj skali, pružajući precizne i lako obradive podatke za daljnje korištenje u modelima, što je detaljno prikazano i opisano u Tablici 6.8.. Istraživanje Callana et. al. [166] navodi da GPT-4 model ostvaruje odlične performanse u rješavanju CFA [167] ispita uz adekvatno kreirane upite. Ovo pokazuje da modeli poput GPT-4 mogu djelovati kao finansijski analitičar, što daje potporu ideji njegove primjene u analizi osnovnih informacija o tvrtki i finansijskih novosti.

Tablica 6.8: Opis NLP značajki

Naziv značajke	Opis	Skala
Relevantnost novosti	Ocjena koliko je vijest izravno relevantna za performanse dionice.	0: nije relevantno; 1: donekle relevantno; 2: vrlo relevantno
Sentiment	Ocjena emocionalnog stava vijesti prema dionici.	-1: negativan; 0: neutralan; 1: pozitivan
Potencijalni utjecaj na cijenu	Očekivani utjecaj vijesti na cijenu dionice u sljedećoj trgovinskoj sesiji.	-3: jak negativan; -2: umjeren negativan; -1: blagi negativan; 0: bez utjecaja; 1: blagi pozitivan; 2: umjeren pozitivan; 3: jak pozitivan
Smjer trenda	Vjerojatni smjer trenda cijene dionice na temelju vijesti.	-1: silazni; 0: neutralan; 1: uzlazni
Utjecaj na zaradu	Potencijalni utjecaj vijesti na buduću zaradu tvrtke.	-2: značajan negativan; -1: blagi negativan; 0: neutralan ili nejasan; 1: blagi pozitivan; 2: značajan pozitivan
Povjerenje investitora	Kako bi vijesti mogle utjecati na povjerenje investitora u tvrtku.	-3: veliko smanjenje; -2: umjerno smanjenje; -1: blago smanjenje; 0: bez promjene; 1: blago povećanje; 2: umjerno povećanje; 3: veliko povećanje
Promjena profila rizika	Kako bi vijesti mogle promijeniti percipirani profil rizika tvrtke.	-2: značajno povećan rizik; -1: blago povećan rizik; 0: bez značajne promjene; 1: blago smanjen rizik; 2: značajno smanjen rizik

Osnovni element korištenog upita je instrukcija, koja se koristi u pozivu prema PrimoGPT modelu. Ovaj dio upita precizno određuje ulogu modela i jasno definira zadatak koji model treba izvršiti. Za konstrukciju instrukcije korištena je biblioteka LangChain [168],

koja omogućuje fleksibilno i učinkovito strukturiranje upita. Ovakav pristup omogućuje modelu da razumije specifične zahtjeve zadatka i generira odgovarajuće odgovore. Primjer takve instrukcije prikazan je u Tablici 6.9..

Tablica 6.9: Primjer instrukcije

Dijelovi instrukcije	Sadržaj
Sistemski upit	You are a senior quantitative analyst specializing in stock market analysis. Your task is to analyze the provided company recent news and press releases to generate key features that could influence the stock's price movement in the next trading session. Focus on interpreting the given data to provide insights for algorithmic trading models.
Zadatak analize	<p>Based primarily on the provided news and press releases (if available) generate the following features defined in the output format. When analyzing, pay special attention to:</p> <ol style="list-style-type: none"> 1. Potential negative impacts or risks, even if they're subtle or not the main focus of the news. 2. Market saturation signs, increased competition, or regulatory challenges. 3. Discrepancies between the tone of the news and the actual content. 4. Possible overoptimism in positive news that might lead to unrealistic expectations. 5. Short-term versus long-term implications of the news, especially potential short-term negative reactions. <p>Be cautious of overly positive sentiment and ensure you're giving appropriate weight to any negative indicators.</p>
Izlazni format	news_relevance
	sentiment
	price_impact_potential
	trend_direction
	earnings_impact
	investor_confidence
	risk_profile_change

Nakon instrukcije, slijedi konstrukcija ulaznih podataka, također implementirana pomoću LangChaina. Ova konstrukcija obuhvaća sveobuhvatne informacije potrebne za analizu, uključujući osnovne informacije o tvrtki, relevantne dnevne podatke o dionici, ključne financijske pokazatelje, te pregled važnih novosti objavljenih nakon zatvaranja tržišta prethodnog dana. Ovakav ulaz omogućuje modelu da analizira sve bitne informacije i time generira značajke koje su definirane u instrukciji. Primjer ulaznih podataka prikazan je u Tablici 6.10..

Tablica 6.10: Primjer ulaznih podataka

Dijelovi ulaza	Sadržaj	
Informacije o tvrtki	Apple Inc is a company trading under the ticker AAPL. The company operates in the Technology industry with a market capitalization of \$3,434,462. It has 161,000 employees. The current stock price is \$183.55, with today's price change down by 0-1% compared to the previous closing price.	
Financijske novosti	Uputa	Here are the recent news articles related to AAPL:
	Naslov	Apple Stock Is Dropping Again. How It Can Get 'Unstuck.'
	Sažetak	The iPhone maker is under pressure to show it is ready to compete in the field of artificial intelligence...
	Naslov	How To Earn \$500 A Month From Apple Stock Following Tuesday's Slide
	Sažetak	Apple shares settled lower after Barclays downgraded its rating on the stock. Analyst cites weakness....
Priopćenja za javnost	Uputa	Here is the most recent press release from AAPL:
	Naslov	Apple Vision Pro available in the U.S. on February 2
	Opis	Apple announces Apple Vision Pro will be available beginning Friday, February 2, at all U.S. Apple Store...
	Naslov	Wanda Austin to join Apple's board of directors
	Opis	Dr. Austin, former CEO of The Aerospace Corporation, brings expertise in cutting-edge technology...

Nakon obrade upita, model generira izlazne podatke u strogo definiranom formatu, prethodno prikazanom u Tablici 5.10. Ovaj proces koristi LangChain za strukturiranje i formatiranje podataka. Važno je napomenuti da je instrukcija modelu uvijek ista, dok je ulaz dinamičan i prilagođava se specifičnostima svakog pojedinačnog upita. LangChain omogućuje učinkovito spajanje statične instrukcije s dinamičnim ulazom, stvarajući jedinstveni upit koji se zatim šalje modelu na obradu.

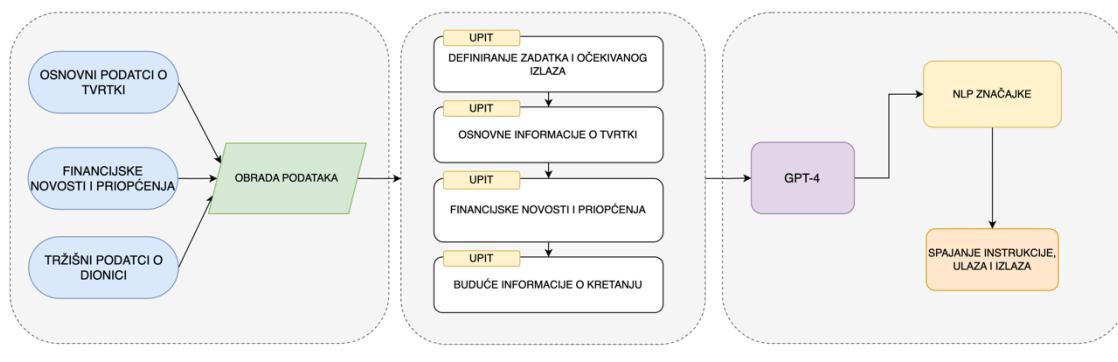
Ovako strukturirani izlazni podaci, koji uključuju različite numeričke vrijednosti predstavljajući NLP značajke, omogućuju daljnju obradu unutar DRL modula. Ovaj pristup osigurava dosljednost u formatu podataka, visoku kvalitetu informacija za daljnju

analizu, te fleksibilnost u prilagodbi različitim scenarijima upita, što je važno za učinkovito donošenje odluka u dinamičnom okruženju.

6.3.2. Prilagodba i treniranje PrimoGPT modela

Prije nego što možemo pristupiti generiranju NLP značajki, ključno je prvo razviti i trenirati PrimoGPT model koji će biti u središtu ovog procesa. Za razvoj PrimoGPT-a uspostavljen je napredni pristup treniranja s instrukcijama, gdje se setovi podataka koji se sastoje od instrukcija, ulaza i odgovora [133] generiraju isključivo pomoću GPT-4 [124]. Svaka instrukcija u procesu treniranja obogaćena je dodatnim kontekstom koji uključuje informaciju o kretanju cijene dionice sljedećeg trgovačkog dana. Ovaj jedinstveni pristup omogućava modelu da tijekom treninga uspostavi veze između trenutnih finansijskih podataka i budućih tržišnih kretanja. Važno je naglasiti da se ove informacije o budućim cijenama koriste isključivo tijekom faze treniranja PrimoGPT modela.

Cilj ovog pristupa je razviti model koji može generirati preciznije značajke, posebno one vezane za trendove na tržištu. Uključivanjem budućih informacija u trening set, model uči prepoznavati suptilne obrasce i indikatore u trenutnim podacima koji mogu biti prediktivni za buduća kretanja. Međutim, ključno je istaknuti da se pri stvarnoj primjeni, odnosno kada PrimoGPT generira značajke za sustav automatskog trgovanja, modelu ne pružaju nikakve buduće informacije. U operativnoj fazi, model se oslanja isključivo na trenutno dostupne podatke za generiranje značajki, primjenjujući znanje stečeno tijekom treninga za prepoznavanje potencijalno prediktivnih obrazaca. Proces generiranja instrukcija za treniranje, uključujući način na koji se integriraju buduće informacije, prikazan je na Slici 6.6..

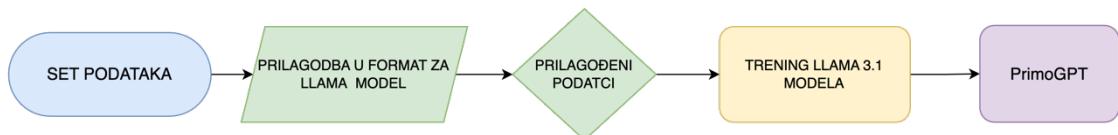


Slika 6.6: Procedura pripreme podataka za treniranje modela

Kao prvi korak u razvoju ovoga modela, podaci se prikupljaju i obrađuju na način koji je detaljno opisan u prethodnim poglavljima. Pritom se vodi računa o jasnoj podjeli između

skupova za treniranje i onih za testiranje samog sustava za automatizirano trgovanje, čime se osigurava sprječavanje curenja podataka te maksimalno realistični uvjeti za naknadnu procjenu preformansi predloženog sustava. Pošto je primarni cilj razviti PrimoGPT koji će moći iz teksta izdvojiti relevantne značajke za finansijsku analizu, iznimno je važna faza oblikovanje posebnog skupa u kojem se, uz osnovne podatke o tvrtki i njezinu trenutačnom stanju, nalaze filtrirane vijesti i pripadajućoj informaciji o budućem kretanju cijena.

Specifični upiti za GPT-4 model generiraju se uz jasno definiranu ulogu i zadatak modela, što omogućuje kontrolirano usmjeravanje generiranih odgovora prema traženim NLP značajkama. Nakon što se prikupi dostatna količina takvih upita i pripadnih odgovora, oni se prilagođavaju u formatu prikladnom za treniranje Llama 3 arhitekture, kako je prikazano na Slici 6.7. Temeljni koncept pritom podrazumijeva kombiniranje tekstualnih izvještaja, detalja o cijeni i dodatnih uputa o budućem kretanju dionice. Na taj se način, tijekom treniranja, postiže dublje povezivanje trenutačnih finansijskih novosti i potencijalnih tržišnih ishoda, što rezultira boljom sposobnošću modela da prepozna obrasce značajne za donošenje automatiziranih trgovačkih odluka.



Slika 6.7: Procedura treniranja PrimoGPT modela

U Tablici 6.11. prikazan je primjer kako izgleda jedna stavka iz skupa za treniranje, uključujući instrukciju koja definira ulogu modela, ulazne podatke o tvrtki i novostima, te ciljani izlaz. Takav pristup omogućuje da PrimoGPT u fazi treniranja stječe uvid u različite oblike tekstualnih informacija, istodobno imajući pristup i ograničenim podatcima o budućem kretanju cijene. Važno je napomenuti da se ove buduće vrijednosti, premda mogu znatno olakšati uspostavljanje uzročno-posljedičnih veza prilikom treniranja, ne koriste u stvarnoj primjeni modela.

Tablica 6.11: Primjer skupa podatka za trening PrimoGPT modela

Skup podataka	Sadržaj
Instrukcija	
Sistemski upit	You are a senior quantitative analyst specializing in stock market analysis. Your task is to analyze the provided company recent news and press releases to generate key features that could influence the stock's price movement in the next trading session. Focus on interpreting the given data to provide insights for algorithmic trading models.

	Informacije o tvrtki		Alphabet Inc is a company trading under the ticker GOOGL. The company operates in the Media industry with a market capitalization of \$2,048,326. It has 180,895 employees. The current stock price is \$86.87, with today's price change down by 3-4% compared to the previous closing price.
Ulag	Financijske novosti	Uputa	Here are the recent news articles related to GOOGL:
		Naslov	Breaking Down the Earnings Picture as Estimates Fade
		Sažetak	Overall corporate profitability isn't great, but it isn't bad either. That said, estimates for the coming periods are steadily coming down, with the revisions trend accelerating in recent days.
		Naslov	Alphabet Inc. Cl A stock underperforms Wednesday when compared to competitors
		Sažetak	Shares of Alphabet Inc. Cl A slipped 3.87% to \$86.97 Wednesday, on what proved to be an all-around dismal trading session for the stock market, with the S&P
Priopćenja za javnost		Uputa	Here is the most recent press release from GOOGL (if available):
		Naslov	South Florida Agency Turns to Google Public Sector to Help Manage Critical Water Programs
		Opis	Google Public Sector is partnering with the South Florida Water Management District to help the agency enable visualization and trend analysis for water quality to inform water management decisions across the district.
	Zadatak analize	<p>Based primarily on the provided news and press releases (if available) generate the following features defined in the output format. When analyzing, pay special attention to:</p> <ol style="list-style-type: none"> 1. Potential negative impacts or risks, even if they're subtle or not the main focus of the news. 2. Market saturation signs, increased competition, or regulatory challenges. 3. Discrepancies between the tone of the news and the actual content. 4. Possible overoptimism in positive news that might lead to unrealistic expectations. 5. Short-term versus long-term implications of the news, especially potential short-term negative reactions. <p>Be cautious of overly positive sentiment and ensure you're giving appropriate weight to any negative indicators.</p>	

	Izlazni format	news_relevance	How directly relevant the provided news and press releases are to the stock's performance (0: not relevant, 1: somewhat relevant, 2: highly relevant)
		sentiment	Overall sentiment towards the stock based on the news and press releases (-1: negative, 0: neutral, 1: positive)
		price_impact_potential	Potential impact of the news and press releases on the stock's price in the next trading session (-3: strong negative, -2: moderate negative, -1: slight negative, 0: no impact, 1: slight positive, 2: moderate positive, 3: strong positive)
		trend_direction	Likely direction of the stock's price trend based on the news and press releases (-1: downward, 0: neutral, 1: upward)
		earnings_impact	Potential impact of the news on the company's future earnings (-2: significant negative, -1: slight negative, 0: neutral or unclear, 1: slight positive, 2: significant positive)
		investor_confidence	How the news might affect investor confidence in the company (-3: major decrease, -2: moderate decrease, -1: slight decrease, 0: no change, 1: slight increase, 2: moderate increase, 3: major increase)
		risk_profile_change	How the news might change the perceived risk profile of the company (-2: significantly increased risk, -1: slightly increased risk, 0: no significant change, 1: slightly decreased risk, 2: significantly decreased risk)
	Buduća informacija		From today's trading day (2022-11-02) to the next trading day (2022-11-03), the stock price will be down by 4-5% to \$83.33 from \$86.87. Keep this information in mind when generating features, and try to identify patterns or factors in the news and press releases that might explain or correlate with this price movement. Use this future price information as context, but base your feature generation primarily on the content and implications of the news and press releases.
Odgovor	news_relevance	2	
	sentiment	0	
	price_impact_potential	-2	
	trend_direction	-1	
	earnings_impact	-1	

	investor_confidence	-2
	risk_profile_change	-1

Ova metoda omogućava PrimoGPT-u da stvori značajke koje ne samo da odražavaju trenutne informacije već i pružaju uvid u očekivane financijske trendove. To doprinosi stvaranju modela koji može generirati detaljne i relevantne analitičke uvide, premošćujući jaz između trenutnih događaja i njihovih potencijalnih budućih utjecaja. Proces treniranja provodi se s ciljem razvoja optimiziranog modela za analizu i predviđanje tržišnih trendova. Testiranje novonastalog modela provodi se kako bi se evaluirale njegove performanse u generiranju NLP značajki.

6.3.3. Generiranje značajki tehničkih indikatora

Ovdje prikazujemo proces generiranja značajki tehničkih indikatora, koje zajedno s osnovnim informacijama o tvrtki i analizom financijskih vijesti, služe kao ulazni podaci za modul dubokog učenja. Cilj je iskoristiti ove značajke za razvoj modela koji će testirati strategije automatiziranog trgovanja i njihovu sposobnost predviđanja budućih tržišnih kretanja [169].

6.3.3.1. Jednostavan pomičan prosjek

Jednostavan pomičan prosjek (engl. Simple Moving Average, SMA) je tehnički indikator koji se koristi za izračunavanje prosječne vrijednosti skupa cijena unutar određenog vremenskog perioda. Obično se primjenjuje na zatvarajuće cijene dionica tijekom n perioda. Prosječna vrijednost izračunava se kao aritmetička sredina n posljednjih cijena, čime se omogućuje glađenje kratkotrajnih fluktuacija cijena i isticanje dugotrajnijih trendova na tržištu [170].

Za izračunavanje SMA koristi se sljedeća formula:

$$SMA_t(n) = \frac{1}{n} \sum_{i=0}^{n-1} P_{t-i} \quad (6.2)$$

U kojoj P_{t-i} predstavlja cijenu u trenutku $t-i$, a n ukupan broj perioda uzetih u obzir za izračun prosjeka.

Korištenje SMA indikatora pruža investitorima mogućnost analize tržišnih trendova. Primjerice, dugoročni SMA, kao što je 200-dnevni SMA, može se koristiti za

identifikaciju dugoročnih trendova, sugerirajući opću tržišnu klimu. S druge strane, kratkoročni SMA može se koristiti za praćenje i predviđanje kratkoročnih kretanja cijena, omogućujući brzu reakciju na tržišne promjene.

6.3.3.2. Konvergencija/divergencija pomičnih prosjeka

Konvergencija/divergencija pomičnih prosjeka (engl. Moving Average Convergence/Divergence, MACD) predstavlja tehnički indikator koji se koristi za praćenje impulsa i mogućih trendova na tržištu. MACD je izведен iz razlike između dvije eksponencijalne pomične vrijednosti (EMA) različitih vremenskih perioda, tipično se koristi kombinacija kratkoročne i dugoročne EMA [170].

Izračunava se prema formuli:

$$MACD_t = EMA_m(t) - EMA_n(t) \quad (6.3)$$

gdje $EMA_m(t)$ predstavlja kratkoročnu eksponencijalnu pomičnu prosječnu vrijednost, dok $EMA_n(t)$ označava dugoročnu eksponencijalnu pomičnu prosječnu vrijednost. Uobičajeni vremenski periodi koji se koriste za ove EMA vrijednosti su 12 i 26 dana.

Signalna linija MACD-a, koja se koristi za generiranje trgovačkih signala, izračunava se kao EMA od MACD vrijednosti, najčešće koristeći period od 9 dana:

$$Signal_t = EMA_p(t) \cdot MACD_t \quad (6.4)$$

gdje $EMA_p(t)$ predstavlja eksponencijalnu pomičnu prosječnu vrijednost MACD vrijednosti preko p perioda, gdje je p obično 9.

Primjena MACD-a omogućuje investitorima da identificiraju moguće točke ulaska ili izlaska s tržišta, kao i da uoče potencijalne preokrete trendova. Na primjer, kada MACD linija preseže signalnu liniju, to može ukazivati na uzlazni trend i potencijalni signal za kupnju. Obrnuto, kada MACD linija padne ispod signalne linije, to se može tumačiti kao signal za prodaju.

6.3.3.3. Bollingerovi pojasevi

Bollingerovi pojasevi (engl. Bollinger Bands, BB) predstavljaju tehnički indikator koji je razvio John A. Bollinger s ciljem pružanja uvida u razinu volatilnosti i relativne cijene imovine. Za razliku od tradicionalnog omotača pomičnog prosjeka, Bollingerovi pojasevi

koriste standardnu devijaciju kako bi se prilagodili tržišnim promjenama, čime omogućavaju dinamičnije praćenje tržišnih kretanja [78].

Ovi pojasevi konstruiraju se oko 20-dnevnog jednostavnog pomičnog prosjeka (SMA), s gornjom granicom koja je definirana kao dvostruka standardna devijacija iznad SMA i donjom granicom koja je dvostruka standardna devijacija ispod SMA. Time se formiraju tri linije koje čine Bollingerove pojaseve: srednja linija odgovara SMA, dok gornja i donja linija predstavljaju nivoe otpora, odnosno podrške.

Bollingerovi pojasevi koriste se i kao sredstvo za identifikaciju prekupljenih ili prezasićenih tržišnih uvjeta, gdje se signali kupnje i prodaje generiraju na osnovu interakcije cijena s pojasevima u kombinaciji s drugim indikatorima, poput bilance volumena ili tokova novca. Signali koji se temelje samo na doticanju ili prelasku pojaseva obično se ne smatraju dovoljnim za pouzdane trgovačke odluke, već se koriste za potvrđivanje drugih indikacija koje ukazuju na potencijalne promjene u tržišnom trendu.

6.3.3.4. Indeks relativne jakosti

Indeks relativne jakosti (engl. Relative Strength Indeks, RSI) koncipiran je kao alat za kvantifikaciju brzine i promjena u cjenovnim pokretima finansijskih instrumenata. Ovaj indikator određuje se kao omjer eksponencijalno izglađenih prosječnih dobitaka nasuprot eksponencijalno izglađenim prosječnim gubicima unutar definiranog vremenskog okvira [78]. Za izračun RSI-a koristi se formula:

$$RSI = 100 - \left(\frac{100}{1 + RS} \right) \quad (6.5)$$

gdje je RS omjer eksponencijalno izglađenog prosječnog broja perioda sa porastom cijena prema eksponencijalno izglađenom prosječnom broju perioda sa padom cijena. Preporučena duljina n-periode za RSI je 14 dana, mada se mogu koristiti i druge duljine ovisno o željenoj osjetljivosti i analiziranom vremenskom okviru. Indikator varira od 0 do 100, gdje vrijednosti iznad 70 ukazuju na potencijalno prekupljeno stanje (engl. Overbought), a vrijednosti ispod 30 na potencijalno prezasićeno stanje (engl. Oversold) tržišta.

RSI kao oscilator mjeri brzinu i promjene smjera cijene, čime investitorima pruža mogućnost prepoznavanja trendova i signaliziranja mogućih obrata. S obzirom na svoju osjetljivost na brze promjene cijena, RSI se često koristi u kombinaciji s drugim indikatorima kako bi se potvrdili signali i izbjegle lažne indikacije koje mogu nastati zbog kratkotrajnih fluktuacija.

6.3.3.5. Indeks robnih kanala

Indeks robnih kanala (engl. Commodity Channel Indeks, CCI) je oscilacijski indikator za identifikaciju cikličnih trendova u robi, dionicama i valutama. CCI mjeri razliku između tipične cijene i njenog jednostavnog pomicnog prosjeka (SMA), standardiziranu prema srednjoj apsolutnoj devijaciji od tipične cijene [78].

Tipična cijena se izračunava kao prosjek najviše, najniže i zatvarajuće cijene unutar perioda, a indikator se matematički izražava kao:

$$CCI = \frac{1}{0.015} \left(\frac{p_t - SMA(p_t)}{\sigma(p_t)} \right) \quad (6.6)$$

gdje je p_t tipična cijena u periodu t , $SMA(p_t)$ je jednostavni pomicni prosjek tipičnih cijena, a $\sigma(p_t)$ predstavlja srednju apsolutnu devijaciju tipičnih cijena.

Konstanta 0.015 u nazivniku se koristi kako bi većina vrijednosti CCI oscilirala u opsegu od -100 do +100, što olakšava interpretaciju indikatora. Fluktuacije CCI iznad i ispod nule sugeriraju promjene u tržišnoj dinamici, a ekstremne vrijednosti izvan ovih granica mogu ukazivati na potencijalne trgovačke prilike.

CCI se u praksi koristi za identifikaciju situacija kada je roba ili finansijska imovina prekupljena ili prezasićena, što može ukazivati na nadolazeću promjenu trenda. Osim toga, CCI se može prilagoditi različitim vremenskim okvirima tržišta mijenjajući period prosječnog izračuna, čime postaje prilagodljiv različitim trgovačkim stilovima i strategijama.

6.3.3.6. Indeks usmjerenog kretanja

Indeks usmjerenog kretanja (engl. Directional Movement Indeks, DX) je tehnički indikator koji mjeri snagu trenda cijene bez obzira na njegov smjer. Razvijen je kao alat za procjenu jačine uzlaznih ili silaznih trendova na tržištu. DX se izračunava korištenjem dva ključna pod-indikatora: pozitivnog indeksa smjera (+DI) i negativnog indeksa smjera (-DI) [171].

Izračun DX-a temelji se na sljedećoj formuli:

$$DX = \frac{|+DI - (-DI)|}{|+DI + (-DI)|} \times 100 \quad (6.7)$$

gdje su $+DI$ i $-DI$ izračunati korištenjem izglađenog usmjerenog kretanja (eng. smoothed directional movement) i prosječnog stvarnog raspona (eng. average true range, ATR) vrijednosti.

DX varira od 0 do 100, gdje više vrijednosti ukazuju na jači trend, bez obzira je li on uzlazni ili silazni. Vrijednosti iznad 25 općenito se smatraju indikacijom snažnog trenda, dok vrijednosti ispod 25 sugeriraju slabiji trend ili njegovo odsustvo.

Kada se koristi u trgovcu, DX se često kombinira s $+DI$ i $-DI$ linijama za stvaranje cjelovitijeg indikatora poznatog kao *Average Directional Movement Index* (ADX). Trgovci koriste ove indikatore za identificiranje početka novih trendova, procjenu snage postojećih trendova i prepoznavanje potencijalnih obrata na tržištu.

DX i njegovi povezani indikatori posebno su korisni u volatilnim tržišnim uvjetima, pomažući trgovcima da razlikuju snažne trendove od nasumičnih cjenovnih kretanja. Međutim, kao i kod drugih tehničkih indikatora, DX se često koristi u kombinaciji s drugim alatima tehničke analize za potvrdu trgovačkih signala i smanjenje rizika od lažnih signala.

6.4. Oblikovanje okvira za duboko podržano učenje

U ovom dijelu metodologije prikazan je razvoj okvira za duboko podržano učenje, koristeći biblioteke OpenAI Gymnasium i FinRL [26], koje su ključne za simulaciju tržišnih okruženja i evaluaciju trgovačkih strategija. OpenAI Gymnasium nudi standardizirana okruženja koja omogućavaju treniranje DRL agenata, dok FinRL pruža specifična okruženja usmjerena na simulaciju realnih finansijskih tržišta. Kroz korištenje ovih biblioteka razvijaju se vjerne simulacije tržišta koje su neophodne za razvoj i testiranje DRL strategija. Dodatno se koristi Stable Baselines 3 [172] biblioteka, koja sadrži skup poboljšanih implementacija DRL algoritama, jednostavnih za korištenje unutar Python razvojnog okruženja [27]. Ova biblioteka je odabrana zbog svoje transparentnosti i dobro dokumentirane podrške koja olakšava snalaženje u složenostima DRL-a.

Ovaj metodološki pristup omogućava sistematično testiranje i evaluaciju različitih DRL strategija, što je ključno kod razvoja efikasnih trgovačkih algoritama. U nastavku, kroz poglavje o modeliranju sloja okruženja, detaljnije se opisuje kako su konfigurirani specifični parametri okruženja, akcije koje agenti mogu poduzimati i kako se definiraju nagrade koje motiviraju treniranje agenata.

6.4.1. Modeliranje sloja okruženja

U svrhu automatskog trgovanja dionicama, finansijski zadatak modelira se kao problem Markovljevog proces odlučivanja. Proces treniranja uključuje promatranje promjena cijena dionica, poduzimanje akcije te izračunavanje nagrade kako bi se agentu omogućilo prilagođavanje strategije. Interakcijom s okruženjem, trgovački agent razvija strategiju trgovanja koja maksimizira nagrade tijekom vremena [160].

Trgovačka okruženja, zasnovana na OpenAI Gymnasium okviru, simuliraju stvarna tržišta dionica koristeći stvarne tržišne podatke prema principu vremenski vođene simulacije. MDP je dobro formiran matematički model za zadatke sekvencijalnog odlučivanja u kojem donositelj odluka može djelomično ili potpuno utjecati na ishod. Stanje (S) i akcija (A) definiraju ulaz i izlaz za zadatke donošenja odluka, a funkcija nagrade (R) omogućuje modelu treniranje putem optimizacije usmjerene na cilj. Vjerojatnost prijelaza (P) omogućuje da ciljni problem bude stohastički, što je obično bliže stvarnosti. Diskontni faktor (γ) čini da model uzima u obzir buduću nagradu prilikom donošenja odluka [23]. Detaljniji prikaz ključnih komponenti i odabralih parametara trgovačkog okruženja može se naći u Tablici 6.12..

Tablica 6.12: Ključne komponente okružena

Ključna komponenta	Parametri
Stanje	Stanje računa (saldo) $b_t \in \mathbb{R}_+$
	Dionice u vlasništvu $h_t \in \mathbb{Z}_+^n$
	Vrijednost dionica u vlasništvu $v_t \in \mathbb{R}_+^n$
	Cijena zatvaranja $c_t \in \mathbb{R}_+^n$
	Tehnički indikatori
	NLP značajke
Akcije	Kupi/Prodaj/Zadrži (kontinuirane vrijednosti između -1 i 1)
	Maksimalni broj dionica za trgovanje $h_{max} \in \mathbb{Z}_+$
Nagrade	Promjena vrijednosti (izračunato na temelju promjene ukupne vrijednosti imovine)
	Uključuje komponentu Sharpeovog omjera
Okruženje	Podržava trgovanje s jednom ili više dionica istovremeno
	Koristi stvarne tržišne podatke
	Mogućnost simulacije troškova trgovanja

Prostor stanja, akcije i funkcija nagrada definiraju se na sljedeći način:

Prostor stanja (S) opisuje promatranja koja agent prima iz okruženja. Kao što trgovac analizira različite informacije prije izvršenja trgovine, tako i RL agent promatra različite značajke kako bi bolje učio u interaktivnom okruženju [26]:

- Stanje računa (saldo) $b_t \in \mathbb{R}_+$: iznos novca koji je ostao na računu u trenutnom vremenskom koraku t .
- Dionice u vlasništvu $h_t \in \mathbb{Z}_+^n$: trenutne pojedinačne dionice za svaku dionicu tvrtke, gdje n predstavlja broj pojedinačnih dionica.
- Cijena zatvaranja $c_t \in \mathbb{R}_+^n$: cijena zatvaranja dionice tog dana.
- Tehnički indikatori: RSI $R_t \in \mathbb{R}_+^n$, MACD $M_t \in \mathbb{R}_+^n$, i svi ostali.
- Generirane NLP značajke: $NLP_t \in \mathbb{R}_+^n$

Prostor akcija (A) opisuje dozvoljene akcije kojima agent vrši interakciju s okruženjem [26]:

- Akcije su kontinuirane vrijednosti između -1 i 1, gdje negativne vrijednosti predstavljaju prodaju, pozitivne kupnju, a vrijednosti blizu nule držanje.
- Definirano je $h_{max} \in \mathbb{Z}_+$ kao maksimalni broj dionica koji je dopušten za trgovanje u jednoj transakciji [173].
- Konačna akcija se dobiva množenjem kontinuirane vrijednosti s h_{max} i zaokruživanjem na najbliži cijeli broj.

Funkcija nagrada ($r(s, a, s')$) je mehanizam poticaja za treniranje agenta bolje akcije. Postoji mnogo oblika funkcija nagrada. A implementirana je sljedeća [26]:

- promjena vrijednosti kada se poduzme akcija a u stanju s i dolazi do novog stanja s' , $r(s, a, s') = v' - v$, gdje v' i v predstavljaju vrijednosti portfelja u stanju s' i s , respektivno
- Sharpe ratio za razdoblja $t = \{1, \dots, T\}$, $S_T = \frac{\text{mean}(R_t)}{\text{std}(R_t)}$, gdje je $R_t = v_t - v_{t-1}$

Detaljan sustav nagrađivanja, koji obuhvaća implementaciju i primjenu ovih funkcija nagrada, prikazan je u Algoritmu 6.2..

Algoritam 6.2: Izračun nagrade u PrimoRL modelu

Ulaz: početna_imovina, završna_imovina, povijest, faktor_skaliranja
Izlaz: nagrada

```

1  Funkcija 1: izračunaj_nagradu(početna_imovina, završna_imovina, povijest, faktor_skaliranja)
2      profit ← završna_imovina - početna_imovina
3      stopa_povrata ← profit / početna_imovina
4      sharpe_omjer ← izračunaj_sharpe_omjer(povijest)
5      vrati nagrada * faktor_skaliranja
6

7  Funkcija 2: izračunaj_sharpe_omjer(povijest)
8      | ako je duljina(povijest) < 2 tada
9          | vrati 0
10     | dnevni_povrati ← izračunaj_dnevne_povrate(povijest)
11     | ako je duljina(dnevni_povrati) < 2 tada
12         | vrati 0
13     | prosječni_povrat ← srednja_vrijednost(dnevni_povrati)
14     | std_devijacija ← standardna_devijacija(dnevni_povrati)
15     | ako je std_devijacija = 0 tada
16         | vrati 0
17     | godišnji_faktor ← korijen(252)
18     | sharpe_omjer ← godišnji_faktor * (prosječni_povrat / std_devijacija)
19     | vrati sharpe_omjer
20

21 Funkcija 3: izračunaj_dnevne_povrate(povijest)
22     | dnevni_povrati ← prazna lista
23     | za i od 1 do duljina(povijest) - 1 radi
24         |     povrat ← (povijest[i] - povijest[i-1]) / povijest[i-1]
25         |     dodaj povrat u dnevni_povrati
26     | vrati dnevni_povrati
27
28 nagrada ← izračunaj_nagradu(početna_imovina, završna_imovina, povijest, faktor_skaliranja)
29 vrati nagrada

```

Definiranjem preciznih prostora stanja, akcija i funkcija nagrada stvara se čvrsta osnova za treniranje i evaluaciju agenata podržanog učenja. Ove komponente omogućuju agentima da donose informirane odluke u realnim i simuliranim tržišnim uvjetima. Prostor akcija i dobro definirane funkcije nagrada potiču agente na optimizaciju njihovih trgovačkih strategija, čime se osigurava njihova efikasnost i prilagodljivost na promjene na tržištu.

6.4.2. Prilagodba i priprema za treniranje PrimoRL modela

Treniranje agenata DRL-a započinje postavljanjem i inicijalizacijom specijaliziranog trgovackog okruženja, prilagođenog za simulaciju realnih tržišnih uvjeta. Ovo je okruženje konstruirano na temelju povijesnih podataka i dinamički se prilagođava kroz interakciju u realnom vremenu, čime se osigurava realistično trgovacko iskustvo. Implementacija okruženja uključuje praćenje različitih tržišnih pokazatelja i tehničkih indikatora, što agentima omogućuje donošenje informiranih odluka utemeljenih na stvarnim tržišnim podacima. Okruženje je opremljeno zadanim parametrima koji

definiraju početna stanja portfelja, raspon dopuštenih akcija koje agenti mogu izvoditi, te metrike koje se koriste za izračun nagrada. Time se mjeri uspješnost pojedinačnih akcija agenata [57].

Agenti se treniraju kroz iterativni ciklus eksperimentiranja s različitim trgovačkim strategijama, ovisno o setovima ulaznih značajki, u nizu epizoda. Svaka se epizoda sastoji od niza koraka u kojima agenti donose odluke na temelju trenutnih tržišnih uvjeta. Primijenjena akcija rezultira odgovarajućim promjenama unutar okruženja, uključujući i ažuriranje tržišnoga stanja. Tijekom toga se izvršava funkcija izračuna nagrade, koja uključuje profit ili gubitak te mjere rizika. Na taj način, nagrada reflektiraju financijski rezultat akcija kao što su profiti ili gubici, te mogu uključivati dodatne parametre poput troškova transakcija i procjene rizika. Modeli nagradivanja također uzimaju u obzir dugoročne performanse, koristeći metrike poput Sharpeovog omjera, što potiče razvoj strategija koje razmatraju i kratkoročne dobitke i dugoročnu stabilnost portfelja [173].

Nakon uspostave okruženja i procesa treniranja, Algoritam 6.3. prikazuje kako se sve funkcije međusobno povezuju za uspješno izvršavanje treninga.

Algoritam 6.3: Okruženje za trgovanje dionicama

Ulaz: df, početni_iznos, maksimalni_broj_dionica, tehnički_indikatori, nlp_znacajke
Izlaz: konačno stanje nakon izvršenja algoritma

1	Funkcija 1: Inicijalizacija
2	inicijaliziraj sve ulazne parametre i postavi početne vrijednosti
3	kreiraj prostore za akcije i opservacije
4	postavi početno stanje
5	
6	Funkcija 2: Resetiranje okruženja
7	ako je nasumicni_pocetak = istina onda
8	odaberi nasumični početak
9	inače
10	postavi početak na prvi datum
11	vratи početno stanje s_0
12	
13	Funkcija 3: Izvršavanje akcije
14	akcija ← izvrši odabranu akciju baziranu na trenutnom stanju
15	novo_stanje, nagrada, završeno ← ažuriraj stanje portfelja, izračunaj nagradu i provjeri kraj
16	vratи novo_stanje, nagrada, završeno
17	
18	Funkcija 4: Izračun nagrade
19	nagrada ← izračunaj nagradu prema trenutnom stanju i pravilima
20	vratи nagrada
21	
22	Funkcija 5: Simulacija trgovanja
23	dok nije završeno
24	akcija ← odaberi akciju temeljenu na trenutnom stanju
25	stanje, nagrada, završeno ← izvrši(akcija)
26	ažuriraj strategiju trgovanja temeljem dobivene nagrade
27	vratи konacno_stanje

Cjelokupan se proces treniranja organizira kroz nekoliko međusobno povezanih funkcija:

Funkcija 1 (Inicijalizacija) provodi postavljanje svih ulaznih parametara (npr. *početni_iznos, maksimalni_broj_dionica, tehnički_indikatori, nlp_znacajke*) i priprema okolinu, uključujući kreiranje prostora stanja i akcija te postavljanje početne točke u vremenskim serijama.

Funkcija 2 (Resetiranje okruženja) poziva se početkom svake epizode, čime se portfelj i tržišno stanje vraćaju na definiranu početnu razinu. Time se osigurava da svaka epizoda kreće iz poznatoga ili slučajnog stanja, ovisno o postavljenim eksperimentalnim uvjetima.

Nakon što je epizoda započela, u svakoj iteraciji (koraku) poziva se **Funkcija 3 (Izvršavanje akcije)**. Ova je funkcija zadužena za prihvatanje odluke agenta (kupnja, prodaja, zadržavanje) i njezinu primjenu na trenutačno tržišno stanje, pri čemu se ažuriraju podaci o portfelju i novom stanju sustava.

Unutar iste funkcije obavlja se i poziv **Funkcije 4 (Izračun nagrade)**, koja procjenjuje financijski ishod poduzete radnje te određuje je li epizoda završena (npr. ako se dosegne zadnji dan dostupnih podataka ili agent iscrpi raspoloživa sredstva). Zatim se agentu vraćaju *novo_stanje, iznos nagrade i informacija o završetku epizode*, omogućujući mu da prilagodi svoju strategiju u skladu s dobivenim rezultatom.

Kad je epizoda završena, agent može prijeći na novu epizodu ili, ako je ispunjen uvjet prekida, proces treniranja završava. U sklopu istoga algoritma, **Funkcija 5 (Simulacija trgovanja)** obuhvaća glavnu petlju koja se izvršava sve dok se ne ispuni uvjet za završetak. U njoj agent u svakom koraku odabire akciju na temelju trenutačnoga stanja, poziva Funkciju 3 kako bi se ta akcija izvršila, te na temelju dobivene nagrade kontinuirano prilagođava svoju trgovačku strategiju. Konačno se vraća *konacno_stanje*, nakon čega je epizoda dovršena.

U posljednjoj fazi obavlja se vrednovanje treniranog modela na nezavisnom validacijskom skupu. Za procjenu uspješnosti koriste se metrike ukupnoga ostvarenog prinosa, Sharpeovog omjera i maksimalnoga pada. Te metrike omogućuju usporedbu različitih strategija i preciznu optimizaciju finalnoga modela.

Ovakva iterativna arhitektura treninga, utemeljena na ciklusu inicijalizacije, resetiranja, akcije, izračuna nagrade i simulacije, omogućuje uspješno učenje i prilagodbu DRL agenata u simuliranome tržišnom okruženju. Pritom svaki korak jasno odražava logiku stvarnoga trgovanja: definira se pojam početnoga stanja (saldo, dionice u vlasništvu), odabire se akcija u skladu s ulaznim značajkama, ažurira se tržišno stanje te se agenata nagrađuje ili penalizira na temelju financijskih učinaka njegova poteza. Kroz višestruko ponavljanje epizoda agent stječe sve bolje razumijevanje tržišnih obrazaca, čime se osigurava dostatna priprema za rad u stvarnim uvjetima i dugoročno održiva trgovačka strategija.

Poglavlje 7

Eksperiment i rezultati istraživanja

U ovom poglavlju detaljno su opisani provedeni eksperimenti i analiza rezultata kako bi se evaluirala učinkovitost i validnost predloženog sustava za automatsko trgovanje dionicama. Sustav, temeljen na integraciji modula obrade prirodnog jezika i dubokog podržanog učenja, što uključuje specifično razvijene modele PrimoGPT i PrimoRL, je testiran unutar Google Colab [174] okruženja, čime je omogućena upotreba naprednih GPU jedinica za brzu i efikasnu simulaciju tržišnih uvjeta i procesa trgovanja.

Faze eksperimenta obuhvaćaju uspostavu eksperimentalnog okruženja, prikupljanje i obradu podataka, generiranje NLP značajki putem PrimoGPT modela, te implementaciju i monitoring modula za duboko podržano učenje kroz PrimoRL model. Sve faze eksperimenta su dizajnirane s ciljem osiguranja da tehnički aspekti eksperimenta budu usklađeni s postavljenim istraživačkim hipotezama i znanstvenim ciljevima.

Analiza rezultata izvedena je nakon završetka eksperimentalnih testiranja, s posebnim fokusom na evaluaciju performansi trgovackog sustava pod varijabilnim tržišnim uvjetima. Rezultati su kvantificirani i uspoređeni s rezultatima dobivenim iz postojećih modela, koristeći definirane metrike za ocjenu efikasnosti i uspješnosti. Kroz ovu analizu, dobiveni su uvidi o prednostima i ograničenjima predloženog sustava, posebice u kontekstu sinergije PrimoGPT i PrimoRL modela, omogućujući detaljnu evaluaciju njegove relevantnosti u kontekstu finansijskih tržišta. Ovako strukturirani eksperimenti i dubinska analiza rezultata pridonose širem razumijevanju potencijala primjene naprednih tehnoloških rješenja u finansijskoj industriji, potvrđujući značajan znanstveni doprinos u području automatiziranog trgovanja.

7.1. Postavka eksperimenta

Prije provedbe eksperimenta, nužno je pažljivo planiranje i postavljanje parametara koji će kasnije omogućiti objektivno mjerjenje performansi i vrednovanje rezultata. U kontekstu razvoja ovog automatiziranog sustava trgovanja postavke eksperimenta određuju okvire unutar kojih će se testirati hipoteze disertacije. Pritom treba uzeti u obzir niz faktora koji mogu utjecati na valjanost i pouzdanost izvedenih zaključaka, uključujući

odabir podataka, mjere performanse i usporedne strategije. Eksperiment je osmišljen tako da testira postavljene hipoteze i pruži uvide u realne trgovačke scenarije.

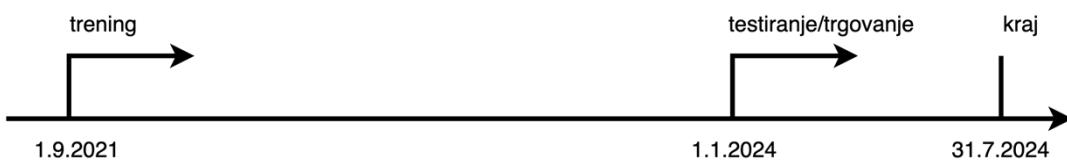
7.1.1. Odabir skupa podataka

Temelj eksperimenta čini odabir skupa podataka koji će biti korišten u testiranju i trgovanju. Izbor odgovarajućih podataka zahtijeva strategijski pristup s obzirom na diverzifikaciju i reprezentativnost unutar tržišnog spektra. Stoga su za eksperiment odabrane dionice eminentnih tehnoloških kompanija koje su prepoznate po svojoj tržišnoj volatilnosti i likvidnosti prikazano u Tablici 7.1.. Ove karakteristike čine odabrane dionice idealnim kandidatima za procjenu sposobnosti modela da interpretira kompleksne tržišne signale i izvršava trgovačke odluke [175].

Tablica 7.1: Prikaz odabranih dionica za provođenje eksperimenta

Oznaka dionice	Naziv tvrtke
AAPL	Apple Inc.
NFLX	Netflix Inc.
MSFT	Microsoft Corporation
CRM	Salesforce, Inc.
AMZN	Amazon.com, Inc.

Odabrani vremenski interval za prikupljanje podataka proteže se od 1. rujna 2021. do 31. srpnja 2024. godine, čime su pokriveni različiti tržišni uvjeti i pružena mogućnost za sveobuhvatnu analizu performansi modela. Kao što je prikazano na Slici 7.1., ovaj period je podijeljen u dvije ključne faze: fazu treniranja i fazu testiranja/trgovanja. Faza treniranja obuhvaća razdoblje od 1. rujna 2021. do 31. prosinca 2023., pružajući modelu priliku da uči iz širokog spektra tržišnih scenarija i razvije robustne strategije trgovanja. Faza testiranja/trgovanja započinje 1. siječnja 2024. i traje do 31. srpnja 2024., omogućujući evaluaciju modela na novim, prethodno neviđenim podacima. Ova struktura omogućuje temeljito testiranje i potvrđivanje sposobnosti modela u realnim i varirajućim tržišnim uvjetima, simulirajući stvarnu primjenu u trgovaju.



Slika 7.1: Prikaz podjele podataka

U procesu treniranja PrimoGPT modela korišteni su podaci izvan skupa dionica namijenjenih trgovanjima. Ova metoda osigurava da model ima solidnu osnovu u razumijevanju raznovrsnih tržišnih kretanja bez prethodnog uvida u specifične dionice koje će se koristiti za treniranje i testiranje sustava za automatizirano trgovanje. Podaci za treniranje ovog modela izabrani su također iz skupa dionica tvrtki koje posluju s visokim profilom, prikazanih u Tablici 7.2., kako bi se konstruirale instrukcije koje će obuhvatiti širok dijapazon tržišnih informacija i strategija.

Tablica 7.2: Prikaz odabralih dionica treniranje PrimoGPT modela

Oznaka dionice	Naziv tvrtke
GOOGL	Alphabet Inc.
META	Meta Platforms, Inc.
AMD	Advanced Micro Devices, Inc.
TSLA	Tesla, Inc.

7.1.2. Mjerenje performansi modela

Za sveobuhvatnu procjenu performansi razvijenog sustava za automatizirano trgovanje, primjenjuje se niz standardnih metrika performansi te posebno razvijena metrika za evaluaciju PrimoGPT modela. Ove metrike pružaju temelj za objektivno vrednovanje sustava i omogućavaju usporedbu s drugim modelima i strategijama trgovanja, čime se potvrđuje pouzdanost predloženog pristupa. Analiza obuhvaća dvije ključne kategorije mjerenja: standardne metrike za evaluaciju trgovačkih strategija i specifičnu metriku za procjenu točnosti PrimoGPT modela u generiranju prediktivni značajki.

7.1.2.1. Standardne metrike za evaluaciju trgovačkih strategija

Ovdje se detaljno prikazuju standardne metrike performansi koje se koriste za procjenu učinkovitosti i rizika povezanih s sustavom za automatizirano trgovanje. Ove metrike uključuju kumulativni povrat, Sharpeov omjer, volatilnost i maksimalni pad vrijednosti. Svaka od ovih metrika pruža jedinstveni uvid u različite aspekte performansi trgovačke strategije, od ukupne profitabilnosti do izloženosti riziku.

Kumulativni povrat (engl. Comulative Return, CR) je osnovna metrika koja mjeri ukupan rast ili pad vrijednosti investicije tijekom određenog perioda. Koristi se za ocjenu dugoročne uspješnosti investicijske strategije, akumulirajući dnevne povrate kroz vremenski period, čime se omogućava uvid u konačni finansijski ishod investicije ili strategije trgovanja. Ova metrika je posebno važna za strategije koje se fokusiraju na

dugoročni rast te se često smatra osnovnim pokazateljem uspješnosti investitora. Kumulativni prikaz je dan u [164]:

$$CR = \frac{P_t - P_i}{P_i} \quad (7.1)$$

gdje R_t označava ukupan povrat, P_t je cijena na kraju promatranog perioda, a P_i je početna cijena.

Sharpeov omjer (engl. Sharpe Ratio, SR) pruža ocjenu uspješnosti investicijske strategije prilagođene riziku, uspoređujući prekomjerni povrat portfelja u odnosu na povrat bezrizične kamatne stope s volatilnosti strategije. Ovaj omjer je iznimno koristan za procjenu strategija trgovanja s obzirom na preuzeti rizik i omogućuje investorima da usporedi različite portfelje na temelju njihove sposobnosti generiranja viška povrata uzimajući u obzir varijabilnost povrata. Sharpeov omjer je prikazan kao [176]:

$$SR = \frac{R_p - R_f}{\sigma_p} \quad (7.2)$$

gdje R_p označava očekivani povrat portfelja, R_f je bezrizična kamatna stopa, a σ_p standardna devijacija povrata portfelja.

Godišnja volatilnost (engl. Annualized Volatility, AV) i dnevna volatilnost (engl. Daily Volatility) su metrike koje kvantificiraju varijabilnost ili rizik povezan s povratima portfelja. Dnevna volatilnost predstavlja standardnu devijaciju dnevnih povrata portfelja, reflektirajući kratkoročne fluktuacije vrijednosti, dok godišnja volatilnost izražava ove fluktuacije na godišnjem nivou, normalizirajući dnevnu volatilnost prema broju trgovačkih dana u godini što prikazujemo [177]:

$$AV = \sigma_{\text{daily}} \times \sqrt{252} \quad (7.3)$$

gdje je σ_{daily} standardna devijacija dnevnih povrata. Kvadratni korijen broja trgovačkih dana (u ovom slučaju 252) koristi se za skaliranje dnevne volatilnosti na godišnju, što daje uvid u moguću varijabilnost portfelja na godišnjoj razini.

Maksimalni pad vrijednosti portfelja (engl. Max Drawdown, MDD) je statistička mjera koja predstavlja najveći zabilježeni pad između najviše točke (engl. Peak) i najniže

točke (engl. Trough) vrijednosti investicijskog portfelja ili trgovacke strategije tijekom određenog perioda promatranja. Ovaj pokazatelj je ključan za razumijevanje potencijalnog rizika gubitka koji investitori mogu doživjeti. Maksimalni pad se često koristi kao pokazatelj rizika koji je investitor izložen tijekom vremena i pruža uvid u izdržljivost portfelja u periodima tržišnih padova. Formula za izračunavanje je [177]:

$$MDD = \max \left(\frac{P_{\text{peak}} - P_{\text{trough}}}{P_{\text{peak}}} \right) \quad (7.4)$$

gdje je P_{peak} najviša vrijednost portfelja prije početka pada, a P_{trough} najniža vrijednost portfelja nakon početka pada.

7.1.2.2. Evaluacija točnosti PrimoGPT modela

Za potrebe evaluacije učinkovitosti PrimoGPT modela u generiranju značajki i predviđanju tržišnih trendova razvijena je posebna metrika. Ova metrika dizajnirana je kako bi se procijenila sposobnost modela da generira relevantne i prediktivne značajke koje će se koristiti u sustavu automatiziranog trgovanja.

Pri razvoju ove metrike, posebna pažnja posvećena je sentimentu i trendu kao ključnim indikatorima tržišnih kretanja. Odluka da se ove dvije značajke koriste kao direktni pokazatelji utjecaja na trend temelji se na opsežnim istraživanjima i empirijskim dokazima koji ukazuju na njihovu snažnu prediktivnu moć u kontekstu financijskih tržišta. Sentiment, koji odražava općenito raspoloženje tržišta i investitora, često može predvidjeti kratkoročne fluktuacije cijena [178]. S druge strane, trend pruža uvid u dugoročnije kretanje tržišta, omogućujući identifikaciju potencijalnih zaokreta ili nastavka postojećih obrazaca.

Međutim, važno je naglasiti da, iako se sentiment i trend koriste kao primarni indikatori u ovoj metrići, evaluacija modela ne ograničava se samo na ove dvije značajke. U sklopu sveobuhvatne analize, razmatra se prediktivna točnost svih generiranih značajki u odnosu na buduća tržišna kretanja. Ovaj pristup omogućuje detaljniju procjenu doprinosa svake pojedine značajke ukupnoj prediktivnoj moći modela.

Za procjenu prediktivne točnosti generiranih značajki koriste se standardne statističke metode. Ove metode uspoređuju vrijednosti značajki s stvarnim smjerom kretanja cijene dionice sljedećeg trgovackog dana. Analiza uključuje izračun točnosti predviđanja za svaku značajku, gdje se pozitivna vrijednost značajke interpretira kao predikcija rasta cijene, negativna kao predikcija pada, a neutralna vrijednost kao predikcija zadržavanja prethodnog trenda.

Kroz prikaz na Algoritmu 7.1. i objašnjenje njegovog funkcioniranja, demonstrira se kako se mjeri točnost PrimoGPT modela u procjeni budućih tržišnih kretanja. Ovaj algoritam

predstavlja srž evaluacijskog procesa, fokusirajući se na sentiment i trend, ali također pruža osnovu za širu analizu svih generiranih značajki.

Algoritam 7.1: Evaluacijski algoritam za PrimoGPT model

Ulaz: podaci \leftarrow DataFrame s kolonama [News Relevance, Sentiment, Trend Direction, Bin Label]
Izlaz: točnost

```
1  Funkcija 1: predvidi_kretanje(redak, prethodni_smjer)
2      | ako je redak[News Relevance] = 0 ili (redak[Sentiment] + redak[Trend Direction] = 0) tada
3          | vratи prethodni_smjer
4      | inače
5          |   rezultat  $\leftarrow$  redak[Sentiment] + redak[Trend Direction]
6          |   ako je rezultat > 0 tada
7              |       | vratи 'U'
8          |   inače
9              |       | vratи 'D'
10     | kraj
11
12 Funkcija 2: klasificiraj_stvarno_kretanje(oznaka_bina)
13    | ako je oznaka_bina prazna ili počinje s 'U' tada
14        | vratи 'U'
15    | inače
16        | vratи 'D'
17    | kraj
18
19 Funkcija 3: izračunaj_točnost
20     | stvarno_trenutni_dan  $\leftarrow$  primjeni klasificiraj_stvarno_kretanje na podaci[Bin Label]
21     | predviđanja  $\leftarrow$  prazna lista
22     | prethodni_smjer  $\leftarrow$  'U'
23     | za svaki redak u podaci izvršavaj
24         |     predikcija  $\leftarrow$  predvidi_kretanje(redak, prethodni_smjer)
25         |     dodaj predikcija u predviđanja
26         |     prethodni_smjer  $\leftarrow$  redak[stvarno_trenutni_dan]
27     | kraj
28
29     | podaci[predviđeno_sljedeći_dan]  $\leftarrow$  predviđanja
30     | podaci[stvarno_sljedeći_dan]  $\leftarrow$  pomakni stvarno_trenutni_dan za 1 dan unaprijed
31     | ukloni zadnji redak iz podaci
32     | točnost  $\leftarrow$  usporedi(podaci[stvarno_sljedeći_dan], podaci[predviđeno_sljedeći_dan])
33     | vratи točnost
34
35     točnost  $\leftarrow$  izračunaj_točnost(podaci)
36     vratи točnost
```

Rezultati ove sveobuhvatne evaluacije potvrditi učinkovitost PrimoGPT modela u generiranju relevantnih značajki te će također pružiti vrijedne uvide u relativnu važnost različitih tipova informacija za predviđanje tržišnih kretanja. Ovi uvidi mogu se dalje koristiti za fino podešavanje modela i optimizaciju strategija trgovanja, osiguravajući kontinuirano poboljšanje sustava automatiziranog trgovanja.

7.1.3. Usporedne strategije trgovanja

Kako bi se napravila objektivna usporedba performansi svih varijacija koje će se koristiti unutar modela za automatizirano trgovanje nužno je odabrati usporedne trgovačke strategije koje služe kao referenca. Svaka od odabranih strategija ima jedinstvenu logiku i metodologiju koja se koristi kao standard za usporedbu u industriji:

Kupi i drži strategija (engl. Buy and Hold, B&H) temelji se na dugoročnom pristupu ulaganju gdje investitor kupuje dionice i zadržava ih bez obzira na kratkoročne fluktuacije cijena. Ova strategija obično iskorištava dugoročni rast tržišta i smanjuje troškove transakcija, čineći je popularnom zbog svoje jednostavnosti i pasivnog pristupa.

Momentum (MOM) strategija koristi jednostavan pristup uspoređivanjem trenutne zatvarajuće cijene s cijenom zatvaranja iz odabranog prethodnog perioda. Pretpostavka je da će se trenutni trend, bilo rastući ili padajući, nastaviti. Ako trenutna cijena P_t premašuje cijenu P_{t-n+1} , to se smatra signalom za mogući nastavak uzlaznog trenda i stvara priliku za kupnju. Suprotno, ako je trenutna cijena niža od cijene iz prethodnog perioda, mogući nastavak silaznog trenda indicira signal za prodaju [29].

Cijena minus pomični prosjek (engl. Price Minus Moving Average, P-MA) strategija koja koristi pokretni prosjek MA od cijene P , temelji se na prepostavci da će, u trendovskom tržištu, cijena dionice obično biti iznad svog pokretnog prosjeka tijekom uzlaznih trendova, a ispod tijekom silaznih trendova. Strategija definira signal za kupnju kada trenutna cijena dionice P_t premašuje pokretni prosjek $MA_{t(n)}$ i signal za prodaju kada je trenutna cijena ispod pokretnog prosjeka. Ovaj pristup koristi jednostavni pokretni prosjek (SMA) ili eksponencijalni pokretni prosjek (EMA) kako bi se uhvatile promjene u trendu cijena dionice [29].

MACD strategija temelji se na tehničkom indikatoru koji mjeri razliku između dvije eksponencijalno pomične srednje vrijednosti (EMA). Ova strategija koristi odnos između MACD linije i signalne linije za identificiranje potencijalnih trgovačkih prilika. MACD linija se izračunava kao razlika između kratkoročne i dugoročne EMA, dok signalna linija predstavlja EMA same MACD linije. Strategija definira signal za kupnju kada MACD linija prelazi iznad signalne linije $MACD_t > Signal_t$, što se smatra indikacijom potencijalnog uzlaznog trenda. Suprotno tome, signal za prodaju generira se kada MACD linija pada ispod signalne linije $MACD_t < Signal_t$, što može ukazivati na mogući silazni trend. Ovaj pristup omogućuje trgovcima da identificiraju promjene u trendovima i momentumu na tržištu, pružajući dodatni alat za donošenje odluka o ulasku i izlasku iz trgovačkih pozicija [29].

FinRL strategija predstavlja napredni pristup automatiziranom trgovanju koji se temelji na dubokom podržanom učenju. Ova strategija koristi modularnu strukturu i precizno podešene DRL algoritme za simuliranje kompleksnih trgovačkih scenarija. FinRL strategija omogućuje agenciju da uči optimalne trgovačke akcije kroz interakciju s tržišnim okruženjem, uzimajući u obzir višestruke faktore poput cijena dionica, volumena trgovanja i tehničkih indikatora. Za razliku od tradicionalnih strategija koje se oslanjaju na fiksna pravila, FinRL prilagođava svoje odluke dinamički, bazirajući se na trenutno stanje tržišta i prethodna iskustva [57]. Strategija integrira važne tržišne faktore poput troškova transakcija i likvidnosti, što je čini posebno relevantnom za realne trgovačke uvjete. FinRL strategija se može primjeniti na različite vremenske okvire i tržišta, pružajući fleksibilnost u razvoju sofisticiranih trgovačkih pristupa [26].

Dow Jones Industrial Average (DJI) burzovni indeks koristi se za procjenu kako pojedinačna strategija stoji naspram ukupne performanse tržišta. Indeks predstavlja prosječnu vrijednost odabranih dionica i često se koristi kao mjerilo za zdravlje tržišta te kao usporedbe (engl. Benchmark) za različite investicijske strategije [179].

Metoda srednje varijance (engl. Mean-Variance) koju je razvio Harry Markowitz [84], temelji se na optimizaciji odnosa između očekivanog povrata i rizika u portfelju. Ova strategija polazi od pretpostavke da investitori preferiraju veće povrate uz manji rizik. Koncept je efikasna granica, koja predstavlja skup optimalnih portfelja koji nude najviši očekivani povrat za danu razinu rizika ili najniži rizik za dani očekivani povrat.

Strategija koristi povijesne podatke za izračun očekivanih povrata μ i kovarijance Σ između dionica. Optimalni portfelj w se određuje rješavanjem optimizacijskog problema:

$$\max w' \mu - \lambda w' \Sigma w \quad (7.5)$$

gdje je w vektor težina dionica u portfelju, a λ faktor averzije prema riziku.

Ova strategija pruža sistematski pristup balansiranju rizika i povrata, uzimajući individualne karakteristike dionica i njihove međusobne odnose [67].

Ove strategije odabранe su zbog njihove prepoznatljivosti i široke primjene u finansijskoj industriji, pružajući jasan okvir za evaluaciju i usporedbu učinkovitosti modela. Svaka od strategija predstavlja drugačiji pristup trgovanstvu i omogućuje nam da testiramo kako naš model stoji protiv raznolikih i vremenski provjerjenih metoda ulaganja.

7.1.4. Implementacija značajki tehničkih indikatora

Za potrebe eksperimenta, odabran je set tehničkih indikatora koji obuhvaćaju različite aspekte tržišnih kretanja. Ovaj set uključuje MACD, BB, RSI, DX s periodom od 30 dana, te SMA za periode od 30 i 60 dana. Izbor ovih specifičnih indikatora i njihovih parametara temeljen je na prethodnim istraživanjima i sličnim eksperimentima [26], [29], [180], s ciljem obuhvaćanja različitih aspekata tržišnih trendova i dinamika.

Proces implementacije započeo je pripremom tržišnih podataka o cijenama dionica, koji su organizirani u strukturirani format pogodan za daljnju analizu. Za svaki od odabranih tehničkih indikatora, implementirane su posebne funkcije koristeći Python programski jezik kako bi formule pretvorili u funkcionalan kod. Ove funkcije su zatim primijenjene na pripremljene podatke kako bi se generirale značajke za svaki trgovački dan u promatranom razdoblju.

Posebna pažnja posvećena je obradi nedostajućih vrijednosti, koje se mogu pojaviti na početku vremenskih serija zbog prirode izračuna nekih indikatora. Ove nedostajuće vrijednosti su tretirane metodama interpolacije ili popunjavanja, ovisno o specifičnostima svakog indikatora, osiguravajući kontinuitet i konzistentnost u setovima podataka.

Implementirane značajke tehničkih indikatora integrirane su s ostalim ulaznim podacima za model, stvarajući sveobuhvatan set informacija za donošenje trgovačkih odluka. Ovaj pristup omogućuje sustavu da razmatra širok spektar tržišnih signala, od kratkoročnih fluktuacija do dugoročnih trendova, pružajući robusnu osnovu za analizu i predviđanje tržišnih kretanja.

U Tablici 7.3. prikazan je primjer izračunatih vrijednosti nekih od implementiranih tehničkih indikatora za dionicu tvrtke Apple Inc. Ovaj prikaz ilustrira kako različiti indikatori pružaju raznolike poglede na tržišna kretanja, što je ključno za sveobuhvatnu analizu i donošenje informiranih trgovačkih odluka.

Tablica 7.3: Primjer generiranih tehničkih indikatora

Datum	MACD	BB UB	BB LB	RSI30	CCI30	DX30	SMA30	SMA60
2021-09-08	0.134	154.999	148.816	71.415	59.342	72.225	151.908	151.908
2021-09-09	0.080	154.627	149.063	59.780	15.067	70.433	151.845	151.845
2021-09-10	-0.182	155.846	146.322	32.728	-166.643	40.887	151.084	151.084

7.1.5. Tehničke specifikacije sustava

Razvijeni sustav za automatsko trgovanje implementiran je kroz nekoliko međusobno povezanih komponenti, gdje svaka komponenta koristi specifične tehnologije i biblioteke za izvršavanje svojih zadataka. Sustav je razvijen i testiran unutar Google Colab [174] okruženja, koristeći dostupne GPU resurse (A100) za učinkovito treniranje modela.

Komponenta za prikupljanje podataka implementirana je u Python programskom jeziku [163], koristeći API integracije s Finnhub [161] i Yahoo Finance [162] servisima. Finnhub API korišten je za dohvat novosti, priopćenja za javnost i fundamentalnih podataka, dok je Yahoo Finance API korišten za prikupljanje povijesnih podataka o cijenama dionica. Implementirane su posebne funkcije za automatizaciju procesa prikupljanja i početne obrade podataka.

Za trening PrimoGPT modela korištena je Llama 3.1 8B Instruct arhitektura [111], implementirana kroz Unslloth biblioteku [181] koja omogućuje efikasno fino podešavanje modela. Trening je proveden na Google Colab platformi koristeći A100 GPU. Za generiranje značajki implementiran je sustav temeljen na LangChain biblioteci [168], koji omogućuje kreiranje i upravljanje upitima za različite scenarije korištenja. Dodatno su generirani tehnički indikatori koristeći Pandas biblioteku [182], gdje su svi indikatori implementirani prema formulama definiranim u prethodnim poglavljima.

Trgovačko okruženje razvijeno je koristeći OpenAI Gymnasium [158] i FinRL [26] okvire, s prilagođenim sustavom nagrađivanja koji integrira generirane NLP značajke. Implementacija je uključivala definiranje prostora stanja, akcija i funkcije nagrade, uz postavljanje parametara okruženja poput maksimalnog broja dionica za trgovanje i početnog kapitala. Za implementaciju algoritama dubokog podržanog učenja korištena je Stable Baselines3 biblioteka [172].

Simulacija i evaluacija provedene su kroz Jupyter bilježnice [183], gdje su definirani vremenski intervali za trening i trgovanje. Za vizualizaciju rezultata korištena je Matplotlib biblioteka [184].

Komunikacija između komponenti sustava realizirana je kroz standardizirane DataFrame strukture, osiguravajući konzistentnu integraciju različitih izvora podataka i generiranih značajki. Svi podaci su organizirani u vremenski uskladene serije, omogućujući preciznu simulaciju trgovačkih scenarija.

Ovakva arhitektura sustava omogućuje fleksibilno eksperimentiranje s različitim konfiguracijama i strategijama trgovanja, uz mogućnost jednostavne prilagodbe i proširenja pojedinih komponenti prema specifičnim potrebama.

7.2. Izvršavanje i rezultati PrimoGPT modela

U procesu razvoja sustava za automatsko trgovanje dionicama, treniranje i evaluacija PrimoGPT modela zauzimaju važno mjesto. PrimoGPT se razvija kao specijalizirani model za obradu prirodnog jezika, s fokusom na finansijsku domenu. Njegova osnovna namjena je generiranje značajki iz tekstualnih podataka vezanih uz tržište kapitala.

U ovom poglavlju prikazuju se detalji implementacije PrimoGPT modela, uključujući njegovo treniranje i prikaz rezultata. Posebno se razmatra proces transformacije kvalitativnih finansijskih informacija u kvantitativne značajke, koje se koriste kao ulazi za PrimoRL model koji je sastavni dio DRL modula.

Namjera je prikazati primjenu naprednih tehnika obrade prirodnog jezika u analizi finansijskih tržišta. Predstavljaju se rezultati procesa generiranja značajki, od sirovih tekstualnih podataka do strukturiranih, numeričkih vrijednosti primjenjivih u modelima podržanog učenja. Ovim se nastoji demonstrirati tehnička izvedivost predložene metodologije i njen potencijal u području automatiziranog trgovanja na tržištu kapitala.

7.2.1. Provedba treniranja PrimoGPT modela

Proces treniranja PrimoGPT modela obuhvaća fino podešavanje (engl. fine-tuning) Llama 3 modela, s ciljem prilagodbe njegovog znanja i sposobnosti specifičnom zadatku analize finansijskih tekstova i generiranja relevantnih značajki za trgovanje. Za realizaciju ovog procesa, koristi se Unslotr biblioteku [181], koja omogućuje efikasno fino podešavanje velikih jezičnih modela. Trening je proveden na Google Colab platformi, koristeći A100 GPU, što je osiguralo potrebnu računalnu snagu za obradu velikog jezičnog modela poput Llama 3.

Kako bi se osiguralo treniranje ovako velikog modela primijenjena je QLoRA (Quantization-aware Low-Rank Adaptation) metoda finog podešavanja čime su omogućene značajne uštede memorije uz minimalan gubitak performansi. Ova tehnika pokazala se posebno korisnom pri radu s velikim modelima na ograničenim računalnim resursima. Za razliku od standardne LoRA metode, koja koristi niskodimenzionalne adaptore za fino podešavanje, u QLoRA pristupu dodatno je primijenjena kvantizacija na težine modela [185]. Ovim pristupom smanjena je preciznost reprezentacije parametara s 32 ili 16 bita na 4 ili 8 bita, čime su značajno reducirani memorijski zahtjevi. Time je omogućeno fino podešavanje modela s milijardama parametara na standardnim GPU jedinicama, što bi inače zahtijevalo specijalizirani hardver. Unatoč smanjenoj preciznosti, primjenom QLoRA metode održana je visoka kvaliteta rezultata, čime je postignut balans između efikasnosti resursa i performansi modela [186].

Za sam proces treninga korišten je posebno pripremljen set podataka koji se sastoji od 2973 trening setova, gdje svaki set sadrži instrukciju, input i očekivani output. Podaci su

pripremljeni u Alpaca formatu [126], što osigurava konzistentnost i efikasnost tijekom procesa treniranja. Priprema podataka provedena je kroz nekoliko važnih koraka. Prvo, svi podatci formatirani su u Alpaca upitnu strukturu, koja omogućava jasno definiranje instrukcije, ulaznih podataka i očekivanog izlaza. Zatim je na kraj svakog primjera dodan EOS (End of Sequence) token, čime je označen završetak sekvence i olakšano učenje modela. Konačno, provedena je tokenizacija pripremljenih podataka, čime su tekstualni podatci pretvoreni u numeričke vrijednosti pogodne za unos u model. Proces tokenizacije predstavlja važan korak u pripremi podataka, omogućujući modelu efikasnu obradu i učenje iz tekstualnih informacija. Ova transformacija pretvara riječi u numeričke reprezentacije te održava semantičke veze između riječi, što je posebno značajno u kontekstu financijskih tekstova gdje specifični termini i fraze nose bogat informacijski sadržaj. Pažljiva tokenizacija također pomaže u rješavanju problema rijetkih riječi i specijaliziranih financijskih termina, osiguravajući da model može adekvatno razumjeti i generirati relevantne financijske značajke [187]. Ovim procesom osigurana je optimalna priprema podataka za trening, što značajno doprinosi uspješnom finom podešavanju modela.

Prije samog procesa treniranja, odabrani su hiperparametri koji utječu na performanse i efikasnost modela. Ovi parametri uključuju veličinu modela, metodu finog podešavanja, stopu učenja, veličinu grupe (engl. batch size) i druge relevantne postavke. Pri odabiru hiperparametara korištene su standardne vrijednosti preporučene od strane Unslloθ biblioteke, koja je primijenjena u ovom istraživanju [188]. Ovaj pristup eliminirao je potrebu za opsežnim eksperimentiranjem s različitim kombinacijama parametara, osiguravajući pritom optimalne postavke za proces treniranja. Odabrani hiperparametri korišteni tijekom treniranja prikazani su u Tablici 7.4..

Tablica 7.4: Prikaz odabralih hiperparametara

Hiperparametar	Vrijednost
Tip modela	Llama 3.1 8B Instruct
Veličina skupa za treniranje	2973
Metoda finog podešavanja	QLoRA
Rank (r)	16
LoRA alpha	16
Learning rate	2e-4
Batch size	2
Gradient accumulation steps	4
Max sequence length	8192
Epoch	1
Optimizer	AdamW 8-bit
Weight decay	0.01

S ovom QLoRA konfiguracijom, trenirali smo samo 42 milijuna od ukupno 8 milijardi parametara modela, što čini samo 0.5196% svih parametara. Ovaj pristup značajno smanjuje računalne zahtjeve i vrijeme treniranja, istovremeno održavajući visoku kvalitetu rezultata. Nakon završetka treninga, model je postavljen na privatni Hugging Face profil, čime je omogućena njegova daljnja upotreba i integracija u ostatak sustava za automatsko trgovanje. Ovaj korak osigurava da je prilagođeni model lako dostupan za generiranje značajki u kasnijim fazama procesa, posebice pri integraciji s PrimoRL modulom.

7.2.2. Prikaz rezultata PrimoGPT modela

Nakon treniranja PrimoGPT modela, pristupilo se fazi evaluacije i primjene modela za generiranje NLP značajki. Ovaj proces usmjeren je na transformaciju kvalitativnih finansijskih informacija u kvantitativne inpute pogodne za sustav automatskog trgovanja. Za generiranje značajki korištene su prethodno pripremljene skripte koje implementiraju LangChain biblioteku. Ove skripte su dizajnirane za učitavanje treniranog PrimoGPT modela s privatnog Hugging Face repozitorija i njegovu primjenu na odabrani set finansijskih podataka vezanih uz ciljane dionice.

Proces generiranja značajki proveden je nad skupom podataka koji je detaljno prethodno opisan. Cilj ovog procesa je ekstrahirati važne informacije iz ovih tekstova i pretvoriti ih u numeričke vrijednosti koje mogu poslužiti kao input za sustav trgovanja. Važno je napomenuti da su ovi rezultati primarno namijenjeni mjerenu pouzdanosti generiranih značajki i njihove potencijalne korelacije s budućim kretanjima cijena dionica. Ovaj korak ne predstavlja direktno trgovanje ili donošenje trgovačkih odluka, već služi kao poveznica između nestrukturiranih tekstualnih podataka i strukturiranih inputa potrebnih za sofisticirane trgovačke algoritme. Tablica 7.5. prikazuje primjer generiranih NLP značajki za odabране dionice:

Tablica 7.5: Primjer generiranih NLP značajki

Datum	News Relevance	Sent.	Price Impact Potential	Trend Direct.	Earnings Impact	Investor Confidence	Risk Profile Change
2024-01-05	2	-1	-2	1	-1	-2	-1
2024-01-08	2	1	2	-1	1	2	0
2024-01-09	2	0	-1	1	-1	-1	0

Nakon generiranja značajki, provedena je evaluacija točnosti modela koristeći prethodno definirani evaluacijski algoritam za mjerjenje performansi. Ovaj algoritam uspoređuje generirane značajke sa stvarnim tržišnim kretanjima u narednom periodu, pružajući uvid u prediktivnu snagu modela. Poseban naglasak stavljen je na kombinaciju sentimenta i

trenda kao ključnih indikatora, ali algoritam također omogućuje analizu pojedinačnih značajki i njihovog kolektivnog utjecaja. Evaluacija je provedena na skupu odabralih dionica u periodu od 1. siječnja 2024. do 31. srpnja 2024., što odgovara fazi testiranja/trgovanja definiranoj za provođenje simulacijskog trgovanja sa PrimoRL modelom. Za svaku dionicu, izračunata je točnost predviđanja koristeći evaluacijski algoritam te sve ostale značajke pojedinačno. Rezultati ove evaluacije, prikazani u Tablici 7.6, pružaju uvide u učinkovitost modela i potencijalne područja za daljnje poboljšanje.

Tablica 7.6: Rezultati PrimoGPT modela

Dionica	Evaluacijski algoritam	Sent.	Price Impact Potential	Trend Direct.	Earnings Impact	Investor Confidence	Risk Profile Change
AAPL	58%	66%	55%	58%	59%	55%	55%
NFLX	48%	46%	45%	48%	46%	43%	50%
MSFT	50%	45%	53%	50%	48%	52%	50%
CRM	45%	45%	44%	45%	43%	45%	45%
AMZN	54%	47%	56%	54%	47%	56%	48%

Ovi rezultati pokazuju sposobnost PrimoGPT modela da generira relevantne i potencijalno prediktivne značajke iz finansijskih tekstova. Važno je naglasiti da ove značajke same po sebi ne predstavljaju trgovačke signale, već služe kao ulaz u DRL modul, koji će ih koristiti u kombinaciji s drugim pripremljenim podatcima za donošenje trgovačkih odluka.

7.3. Izvršavanje automatiziranog trgovanja koristeći PrimoRL

Proces izvršavanja automatiziranog trgovanja korištenjem PrimoRL modela predstavlja središnji dio razvijenog sustava. Nastavlja se na prethodno opisanu metodologiju i arhitekturu sustava, s fokusom na praktičnu implementaciju i primjenu PrimoRL modela u simuliranom trgovačkom okruženju. Izvršavanje je podijeljeno u dvije glavne faze. Prva faza obuhvaća trening PrimoRL modela, gdje se model prilagođava specifičnostima zadanog trgovačkog problema koristeći definirane značajke i povijesne podatke. Druga faza uključuje primjenu treniranog modela u simuliranom trgovačkom okruženju, gdje se testira njegova sposobnost donošenja trgovačkih odluka u uvjetima bliskim stvarnom tržištu.

Prikazani su tehnički aspekti treninga modela, uključujući odabir hiperparametara i konfiguraciju okruženja za učenje. Zatim je opisan proces integracije modela u simulirano trgovačko okruženje, demonstrirajući kako PrimoRL koristi generirane značajke za donošenje trgovačkih odluka. Cilj je pružiti jasnu sliku o tome kako teorijski koncepti i razvijeni modeli funkcioniraju u praktičnoj primjeni automatiziranog trgovanja.

7.3.1. Provedba treniranja PrimoRL modela

U procesu razvoja PrimoRL modela, nakon testiranja različitih agenata dubokog podržanog učenja, za trgovanje pojedinačnim dionicama odabran je *Proximal Policy Optimization* (PPO). Odluka o korištenju PPO-a donešena je na temelju njegove superiorne stabilnosti i efikasnosti u kontekstu trgovanja pojedinačnim dionicama. PPO je pokazao značajno bolje performanse u usporedbi s drugim testiranim algoritmima, posebice u aspektima brzine konvergencije i stabilnosti učenja tijekom dugotrajnih sesija treninga za pojedinačne dionice [57].

Ključan faktor u odabiru PPO-a za trgovanje pojedinačnim dionicama bila je njegova robusnost u odnosu na ostale agente. Tijekom evaluacije, agenti poput A2C i SAC pokazali su visoku osjetljivost na izbor hiperparametara i nestabilnost pri obradi kompleksnih ulaznih podataka karakterističnih za tržište dionica. Ovi agenti često su rezultirali nekonzistentnim performansama ili potpunim neuspjehom u procesu treninga, posebno pri suočavanju s volatilnošću tržišta i raznolikošću ulaznih podataka koji uključuju tehničke indikatore i NLP značajke. Važno je naglasiti da nastavak rada s drugim agentima nije bio održiv pristup kad je riječ o trgovaju pojedinačnim dionicama. Unatoč brojnim pokušajima podešavanja parametara, ovi agenti nisu davali smislene rezultate, a proces njihovog fino podešavanja pokazao se izuzetno zahtjevnim i neproduktivnim. S obzirom na ograničene resurse i vrijeme, odlučeno je fokusirati se isključivo na PPO agenta koji je od početka pokazivao obećavajuće rezultate. PPO je, s druge strane, demonstrirao iznimnu stabilnost i adaptabilnost [23]. Njegova sposobnost da efikasno balansira između istraživanja novih strategija i iskorištavanja već naučenih obrazaca pokazala se ključnom u kontekstu trgovanja dionicama. Ova karakteristika PPO-a bila je posebno važna s obzirom na kompleksnost i dinamičnost tržišta dionica, gdje je potrebno kontinuirano prilagođavanje strategija u skladu s promjenjivim tržišnim uvjetima. Međutim, za trgovanje na razini portfolija, koje predstavlja kompleksnije okruženje s većim brojem parametara, uključeni su i A2C i SAC agenti uz PPO. Ova odluka donešena je na temelju činjenice da u složenijim okruženjima s više parametara, različiti agenti mogu pokazati dobre rezultate u različitim aspektima trgovanja. A2C, SAC i PPO su odabrani jer su pokazali obećavajuće performanse u preliminarnim testovima na razini portfolija [57].

Proces optimizacije hiperparametara proveden je sustavno koristeći metodu pretraživanja mreže (engl. grid search), gdje su sve prikazane kombinacije hiperparametara u Tablici 7.7. testirane međusobno [189]. Ovaj pristup omogućio je temeljitu evaluaciju utjecaja različitih konfiguracija na performanse modela. Za svaku kombinaciju hiperparametara, model je treniran i evaluiran, pri čemu su praćeni pokazatelji poput ukupnog prinosa, stabilnosti učenja i sposobnosti generalizacije na različite tržišne uvjete. Važno je napomenuti da su određene kombinacije hiperparametara rezultirale modelima s nezadovoljavajućim performansama ili nestabilnim učenjem, što je bilo ključno za proces eliminacije neodgovarajućih konfiguracija.

Za A2C i SAC agente u kontekstu trgovanja na razini portfolija, parametri su odabrani prema preporukama FinRL biblioteke [26]. Ovi parametri su se pokazali kao dobar polazni temelj za treniranje modela u složenijim okruženjima portfolija, gdje je potrebna veća fleksibilnost i raznolikost strategija trgovanja.

Tablica 7.7: Testirani i odabrani hiperparametri za PPO algoritam

Hiperparametar	Testirane vrijednosti	Odabрана vrijednost
Broj koraka učenja (n_steps)	1024, 2048, 4096	2048
Veličina grupe (batch_size)	64, 128, 256	128
Stopa učenja	0.0001, 0.00025, 0.0005	0.00025
Entropijski koeficijent	0.005, 0.01, 0.02	0.01
Ukupan broj vremenskih koraka	200000, 400000, 600000	400000

Odabране vrijednosti hiperparametara pokazale su najbolji balans između brzine učenja, stabilnosti i kvalitete naučene politike trgovanja. Broj koraka učenja od 2048 omogućio je agentu da uči iz dovoljno dugih sekvenci tržišnih podataka, dok je veličina grupe od 128 osigurala efikasno ažuriranje modela bez prekomjernog memorijskog opterećenja. Stopa učenja od 0.00025 pokazala se optimalnom za postupno i stabilno poboljšanje politike, a entropijski koeficijent od 0.01 potaknuo je adekvatno istraživanje novih strategija.

Za konfiguraciju okruženja trgovanja, definirani su dodatni parametri koji simuliraju realne uvjete tržišta. Maksimalni broj dionica kojima se može trgovati u jednoj transakciji (hmax) postavljen je na 1000, što omogućuje modelu fleksibilnost u trgovaju, istovremeno ograničavajući preveliku izloženost riziku. Početni kapital za trgovanje određen je na 100,000 USD, pružajući realističnu osnovu za simulaciju trgovanja.

Proces treninga modela odvijao se kroz 400,000 vremenskih koraka, što je omogućilo modelu da nauči iz širokog spektra tržišnih scenarija. U kontekstu troškova transakcija, odlučeno je da se oni postave na 0 za potrebe ovog istraživanja. Ova odluka reflektira trend na tržištu gdje neki moderni brokeri, poput Alpaca Markets, nude besplatno trgovanje putem API-ja za algoritamsko trgovanje [190]. Iako ovo pojednostavljenje omogućuje fokus na evaluaciju čiste strategije trgovanja, u stvarnoj primjeni bilo bi nužno uključiti i ove troškove za preciznije predviđanje stvarnih prinosa.

7.3.2. Primjena sustava za automatizirano trgovanje

Nakon treniranja, PrimoRL model implementiran je u simulirano trgovacko okruzenje koje vjerno replicira uvjete stvarnog tržišta. Ovo okruženje omogućuje modelu donošenje trgovackih odluka na temelju trenutnih tržišnih podataka, uključujući cijene dionica, tehničke indikatore i NLP značajke generirane PrimoGPT modelom.

Proces donošenja odluka odvija se u diskretnim vremenskim koracima, na dnevnoj bazi. U svakom koraku, model analizira trenutno stanje tržišta i generira akciju (kupnja, prodaja ili držanje dionica). Odluke se donose uzimajući u obzir trenutno stanje tržišta i prethodne akcije te njihove posljedice, omogućujući razvoj dugoročne strategije trgovanja. Performanse modela kontinuirano su praćene tijekom simulacije trgovanja. Pokazatelji uključuju ukupnu vrijednost portfelja odnosno kumulativni prinos, realizirane dobitke i gubitke, te broj i vrstu izvršenih transakcija. Posebna pažnja posvećena je praćenju Sharpeovog omjera, koji mjeri odnos između prinosa i rizika.

Za praćenje performansi korišten je posebno razvijen sustav ispisivanja podataka koji bilježi sve relevantne informacije u realnom vremenu. Ovi podaci uključuju vrijednost portfelja na kraju svakog trgovackog dana, detalje o svakoj izvršenoj transakciji, trenutne pozicije u pojedinim dionicama, te vrijednost nagrade. Implementiran je i sustav za upravljanje rizicima koji je primijenjen kroz sustav nagrađivanja agenta. Ovaj sustav prati izloženost portfelja i po potrebi ograničava veličinu pojedinačnih transakcija, osiguravajući da model ne preuzima prekomjerne rizike i održava stabilnost portfelja.

Rezultati dobiveni tijekom ove simulacije trgovanja služe kao indikatori uspješnosti razvijenog sustava za automatizirano trgovanje, pružajući osnovu za evaluaciju i daljnje unapređenje modela.

7.4. Rezultati i analiza performansi

Detaljni rezultati i analiza performansi razvijenog sustava za automatizirano trgovanje predstavljeni su s ciljem pružanja sveobuhvatnog uvida u učinkovitost PrimoRL modela koji koristi NLP generirane značajke PrimoGPT modela u usporedbi s drugim trgovackim strategijama, uključujući tradicionalnu „kupi i drži“ (B&H) strategiju. Rezultati su prikazani kroz kombinaciju numeričkih podataka u tablicama i vizualnih reprezentacija putem grafova, što omogućuje jasnu prezentaciju performansi različitih strategija. Za svaku promatrano dionicu i portfolio, prikazani su pokazatelji uspješnosti poput kumulativnih prinosa, Sharpeovog omjera, maksimalnog pada vrijednosti i volatilnosti.

Analiza je strukturirana po pojedinim dionicama i na kraju s prikazom portfolija, pružajući detaljan osvrt na performanse modela. Grafički prikazi uključuju linijski graf koji pokazuje kumulativni prihod po strategiji kroz vrijeme, omogućujući direktnu usporedbu PrimoRL modela s drugim pristupima. Dodatno, poseban graf prikazuje

performanse PrimoRL modela s označenim točkama kupnje i prodaje te volumenom akcija, pružajući uvid u specifične trgovačke odluke modela. Ovaj pristup omogućuje detaljno razumijevanje kako PrimoRL model donosi odluke u različitim tržišnim situacijama i kako se njegova učinkovitost mijenja tijekom promatranog perioda.

Provedena je analiza ostvarenih prinosa i kontrole rizika, pružajući uvid u učinkovitost modela u maksimiziranju prinosa uz održavanje prihvatljive razine rizika. Dodatno, analizirana je vremenska dinamika performansi različitih strategija, istražujući razdoblja kada je određena strategija nadmašivala druge. Sveobuhvatnim pristupom omogućeno je dublje razumijevanje prednosti i nedostataka PrimoRL modela u različitim tržišnim uvjetima te identificiranje područja za potencijalna poboljšanja.

7.4.1. Rezultati trgovanja za dionicu AAPL

Rezultati trgovanja za dionicu tvrtke Apple Inc. (AAPL) obuhvaćaju period od 1. siječnja 2024. do 31. srpnja 2024. Analiza uključuje usporedbu performansi PrimoRL modela s drugim trgovačkim strategijama, uključujući tradicionalnu B&H strategiju, te nekoliko strategija temeljenih na tehničkim indikatorima poput MOM, P-MA, MACD te model FinRL.

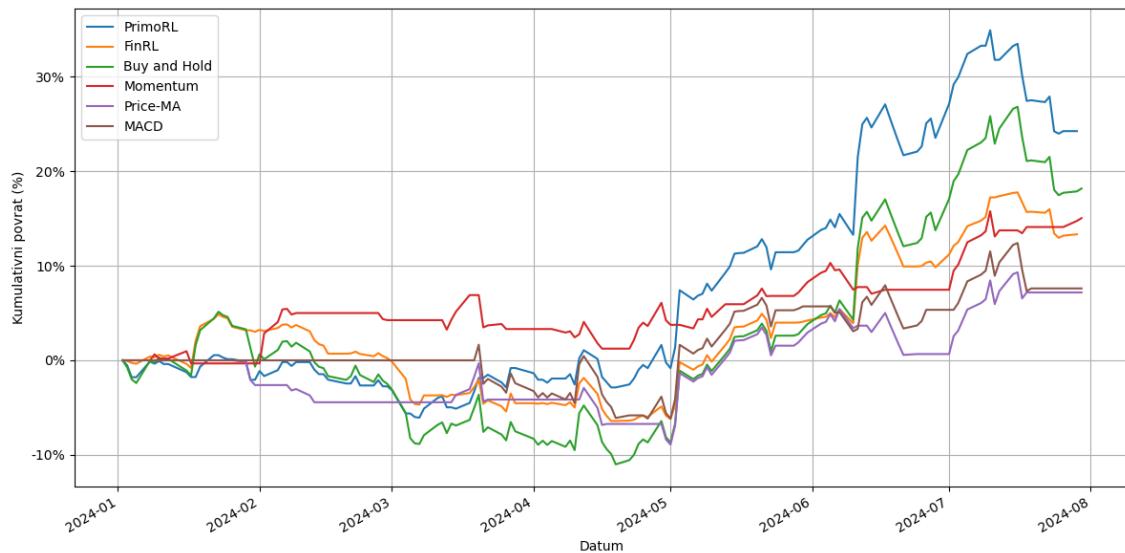
Tablica 7.8. prikazuje standardne metrike za evaluaciju trgovačkih strategija za sve promatrane modele. PrimoRL model ostvario je najveći kumulativni povrat od 24.24%, značajno nadmašujući B&H strategiju koja je ostvarila povrat od 18.17%. PrimoRL je također pokazao drugi najbolji Sharpeov omjer od 1.91, što ukazuje na dobar balans između prinosa i rizika. MOM strategija je imala najviši Sharpeov omjer od 2.09, ali uz niži ukupni povrat od 15.04%.

Tablica 7.8: Usporedba performansi trgovačkih strategija za dionicu AAPL

Model	Kumulativni povrat	Sharpe omjer	Godišnja volatilnost	Maksimalni pad
B&H	18.17%	1.32	24.22%	-15.35%
MOM	15.04%	2.09	12.02%	-5.29%
P-MA	7.18%	0.84	12.80%	-8.91%
MACD	7.60%	0.80	13.58%	-7.68%
FinRL	13.33%	1.36	17.10%	-10.76%
PrimoRL	24.24%	1.91	21.03%	-8.10%

Slika 7.2. prikazuje graf kumulativnih povrata svih strategija kroz promatrano razdoblje. Graf jasno pokazuje da je PrimoRL model konzistentno održavao prednost nad većinom drugih strategija, posebno u drugoj polovici promatranog perioda. Međutim, vidljivo je

da su druge strategije u određenim trenucima imale bolje performanse, što ukazuje na volatilnost tržišta i izazove s kojima se suočavaju aktivne trgovačke strategije.



Slika 7.2: Kumulativni povrati različitih trgovačkih strategija za dionicu AAPL

Slika 7.3. detaljnije prikazuje performanse PrimoRL modela, uključujući točke kupnje i prodaje. Ovaj graf otkriva da je model uspješno identificirao nekoliko važnih točaka za ulazak i izlazak iz pozicija, što je doprinijelo njegovom ukupnom uspjehu.



Slika 7.3: Performanse PrimoRL modela za dionicu AAPL

Analiza performansi PrimoRL modela kroz vrijeme pokazuje nekoliko važnih aspekata. U pogledu prinosa, model je pokazao sposobnost ostvarivanja konzistentnih pozitivnih rezultata. Graf prikazuje da je PrimoRL uspijevaо održavati stabilne prinose čak i u periodima kada su druge strategije bilježile padove, što ukazuje na njegovu sposobnost prilagodbe različitim tržišnim uvjetima.

U aspektu upravljanja rizikom, PrimoRL model demonstrira godišnju volatilnost od 21.03%, što je niže od B&H strategije (24.22%), ali više od ostalih aktivnih strategija. Ovo sugerira da model balansira između agresivnijeg pristupa za postizanje viših prinosa i upravljanja rizikom. Maksimalni pad od -8.10% za PrimoRL je niži od B&H i FinRL strategija, što ukazuje na dobro upravljanje rizikom u nepovoljnim tržišnim uvjetima.

Promatrajući trgovačke aktivnosti prikazane na Slici 6.3., vidljivo je da PrimoRL model primjenjuje dinamičnu strategiju trgovanja. Model pokazuje sposobnost brzog reagiranja na tržišne promjene, što se očituje u čestim, ali preciznim trgovačkim akcijama. Zanimljivo je primijetiti kako model balansira između agresivnih kupnji tijekom uzlaznih trendova i pravovremenih prodaja pri naznakama tržišnih korekcija.

FinRL model, također baziran na dubokom podržanom učenju, pokazao je solidne performanse s povratom od 13.33% i Sharpeovim omjerom od 1.36, ali nije uspio nadmašiti PrimoRL model. Ova razlika u performansama naglašava potencijalnu prednost integracije NLP značajki u proces donošenja trgovačkih odluka, što je značajna karakteristika PrimoRL modela. PrimoRL model pokazao je obećavajuće rezultate u trgovajuju AAAP dionicom, kombinirajući visok povrat s umjerenom volatilnošću. Njegova sposobnost prilagodbe različitim tržišnim uvjetima i efikasno upravljanje rizikom čine ga robusnim alatom za automatizirano trgovanje.

7.4.2. Rezultati trgovanja za dionicu NFLX

Analiza trgovanja dionicom Netflix Inc. (NFLX) provedena je za razdoblje od 1. siječnja 2024. do 31. srpnja 2024. U ovom periodu, uspoređene su performanse PrimoRL modela s drugim trgovačkim strategijama, uključujući pasivnu strategiju kupi i drži (B&H) te aktivne strategije temeljene na tehničkim indikatorima (MOM, P-MA, MACD) i model dubokog podržanog učenja FinRL. NFLX dionica odabrana je zbog svoje volatilnosti i osjetljivosti na tržišne trendove, što je čini zanimljivim slučajem za proučavanje u kontekstu automatiziranog trgovanja. Ova analiza ima za cilj usporediti različite strategije i procijeniti sposobnost PrimoRL modela da se prilagodi dinamičnim uvjetima na tržištu tehničkih dionica. Posebna pažnja posvećena je evaluaciji kako model koristi generirane NLP značajke u kombinaciji s tehničkim indikatorima za donošenje trgovačkih odluka.

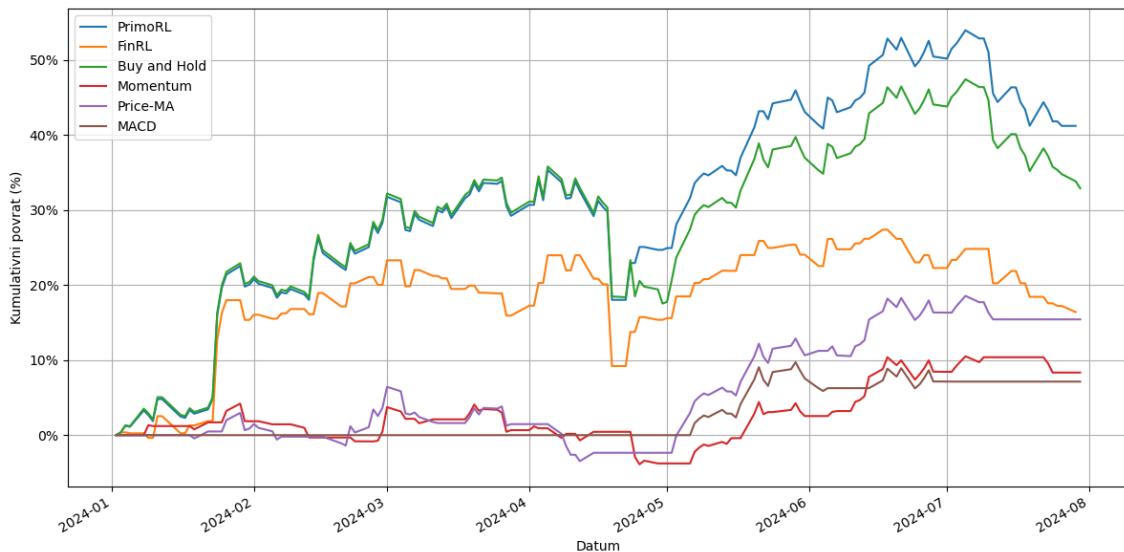
Tablica 7.9. pruža sveobuhvatan pregled performansi različitih trgovačkih strategija primjenjenih na NFLX dionicu:

Tablica 7.9: Prikaz rezultata za dionicu NFLX

Model	Kumulativni povrat	Sharpe omjer	Godišnja volatilnost	Maksimalni pad
B&H	32.88%	1.80	30.16%	-13.44%
MOM	8.33%	1.12	12.24%	-7.76%
P-MA	15.42%	1.72	15.15%	-9.30%
MACD	7.13%	1.40	8.86%	-3.50%
FinRL	16.39%	1.15	25.97%	-11.89%
PrimoRL	41.19%	2.22	28.99%	-12.79

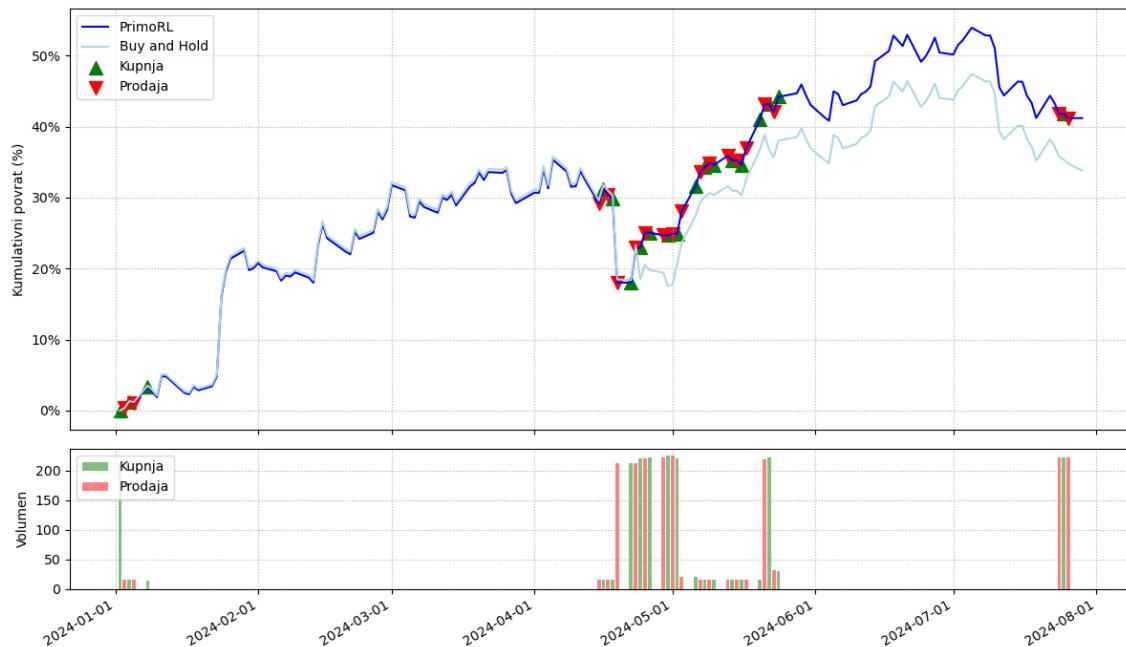
PrimoRL model se istaknuo s impresivnim kumulativnim povratom od 41.19%, značajno nadmašujući sve ostale strategije, uključujući i B&H strategiju koja je ostvarila povrat od 32.88%. Osim toga, PrimoRL je pokazao najviši Sharpe omjer od 2.22, što ukazuje na izvanredan omjer prinosa i rizika.

Slika 7.4. vizualno prikazuje kumulativne povrate svih promatranih strategija tijekom analiziranog perioda. Graf jasno ilustrira dominantnu performansu PrimoRL modela, koji je od samog početka održavao prednost nad ostalim strategijama. Posebno je zanimljivo primjetiti kako je PrimoRL uspješno prošao kroz nekoliko volatilnih perioda, posebice tijekom travnja i svibnja, kada su druge strategije doživjele značajne padove.

**Slika 7.4:** Kumulativni povrati različitih trgovачkih strategija za dionicu NFLX

Detaljniji uvid u performanse PrimoRL modela pruža Slika 7.5., koja prikazuje točke kupnje i prodaje uz kretanje cijene dionice. Ovaj graf otkriva sofisticiranu strategiju

trgovanja koju PrimoRL primjenjuje. Model pokazuje sposobnost pravovremenog ulaska u pozicije tijekom uzlaznih trendova, kao i brzo zatvaranje pozicija pri naznakama pada tržišta. Posebno je impresivna serija trgovanja u drugoj polovici promatranog perioda, gdje model uspješno kapitalizira na volatilnosti tržišta.



Slika 7.5: Performanse PrimoRL modela za dionicu NFLX

Usprkos visokom povratu, PrimoRL model pokazuje relativno visoku godišnju volatilnost od 28.99%, što je blizu volatilnosti B&H strategije (30.16%). Međutim, ova volatilnost se pokazala opravdanom s obzirom na ostvarene prinose. Maksimalni pad od -12.79% za PrimoRL je nešto viši od nekih konzervativnijih strategija, ali i dalje niži od B&H strategije, što sugerira da model uspješno balansira između agresivnog pristupa za postizanje visokih prinosa i upravljanja rizicima.

Usporedba s FinRL modelom, koji je ostvario povrat od 16.39% uz Sharpe omjer od 1.15, dodatno naglašava PrimoRL pristup u donošenju odluka. Ova značajna razlika u performansama sugerira da integracija NLP značajki u proces odlučivanja, što je distinkтивna karakteristika PrimoRL modela, pruža značajnu prednost u trgovaju NFLX dionicom.

Ukupno gledano, PrimoRL model je demonstrirao izvanrednu sposobnost u trgovaju NFLX dionicom, kombinirajući visok povrat s dobrim upravljanjem rizikom. Njegova sposobnost da nadmaši i pasivne i aktivne strategije trgovanja, posebno u volatilnim tržišnim uvjetima, čini ga iznimno vrijednim alatom za automatizirano trgovanje.

7.4.3. Rezultati trgovanja za dionicu MSFT

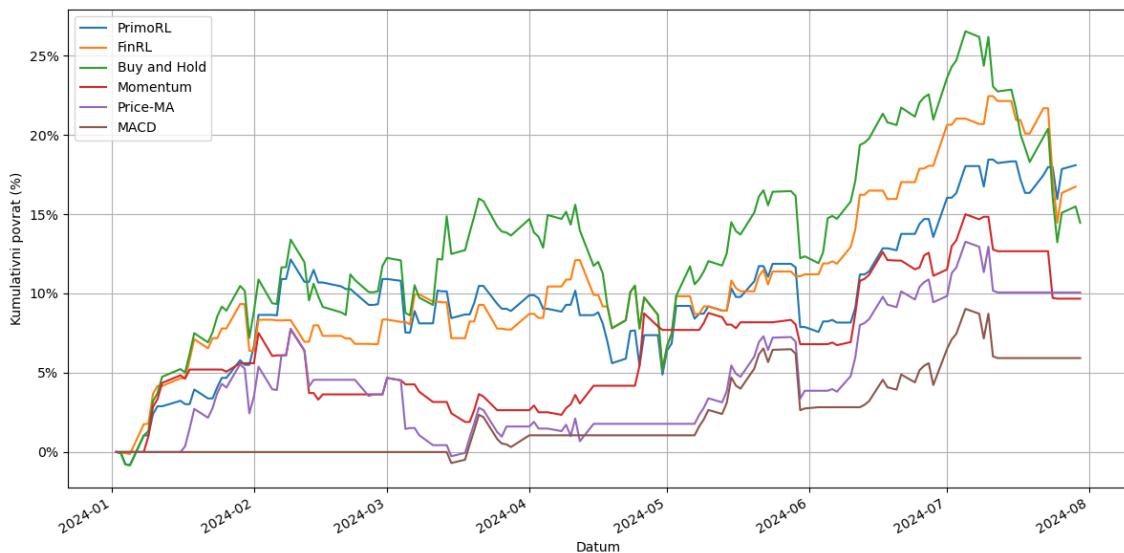
Analiza trgovanja dionicom Microsoft Corporation (MSFT) provedena je za razdoblje od 1. siječnja 2024. do 31. srpnja 2024. Ovo razdoblje karakteriziraju značajne fluktuacije na tržištu tehnoloških dionica, što MSFT kao i ostale obrađene dionice tehnoloških tvrtki čini zanimljivim slučajem za proučavanje. Microsoft, kao jedna od vodećih tehnoloških kompanija s diversificiranim poslovnim modelom, predstavlja jedinstveni izazov za trgovačke strategije. Njegova dionica često odražava šire trendove u tehnološkom sektoru, ali također pokazuje specifične obrasce kretanja vezane uz inovacije i poslovne rezultate kompanije. Ova analiza posebno je usmjerena na procjenu kako različite strategije, a posebno PrimoRL model, reagiraju na kompleksne tržišne signale povezane s MSFT dionicom, uključujući utjecaj korporativnih vijesti i tehnoloških inovacija na tržišne performanse.

Tablica 7.10. pruža pregled performansi različitih trgovačkih strategija primijenjenih na MSFT dionicu. Zanimljivo je primijetiti da je PrimoRL model, unatoč izazovima, ostvario najbolji kumulativni povrat od 18.08% i najviši Sharpe omjer od 2.10. Ovo je posebno značajno u usporedbi s tradicionalnom strategijom kupi i drži (B&H), koja je ostvarila povrat od 14.45%, kao i s FinRL modelom koji je pokazao solidan rezultat s povratom od 16.73%.

Tablica 7.10: Prikaz rezultata za dionicu MSFT

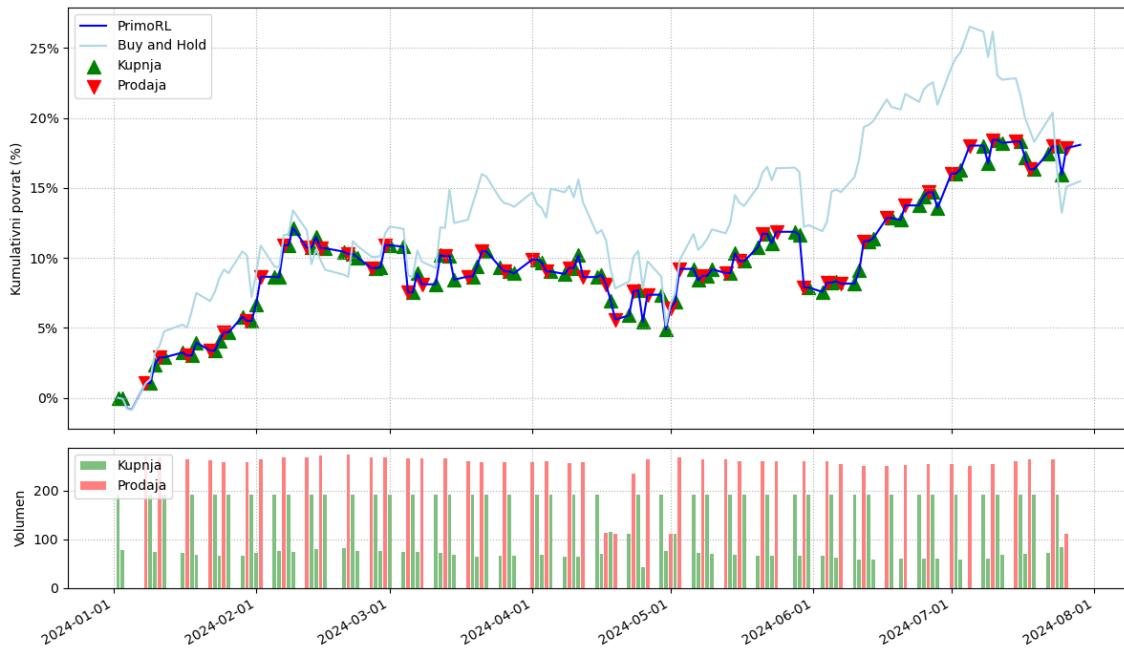
Model	Kumulativni povrat	Sharpe omjer	Godišnja volatilnost	Maksimalni pad
B&H	14.45%	1.29	19.78%	-10.51%
MOM	9.67%	1.53	10.86%	-5.42%
P-MA	10.06%	1.33	13.19%	-7.45%
MACD	5.92%	1.14	9.12%	-3.36%
FinRL	16.73%	1.88	14.97%	-6.52%
PrimoRL	18.08%	2.10	14.33%	-6.47%

Slika 7.6. vizualno prikazuje kumulativne povrate svih promatranih strategija tijekom analiziranog perioda. Ovaj graf otkriva zanimljivu dinamiku PrimoRL modela. Za razliku od prethodnih slučajeva, PrimoRL strategija nije dominirala tijekom većeg dijela promatranog razdoblja. Zapravo, model je pokazivao ispodprosječne performanse sve do samog kraja perioda.



Slika 7.6: Kumulativni povrati različitih trgovачkih strategija za dionicu MSFT

Detaljniji uvid u performanse PrimoRL modela pruža grafički prikaz na Slici 6.7., koji prikazuje točke kupnje i prodaje uz kretanje cijene dionice.



Slika 7.7: Performanse PrimoRL modela za dionicu MSFT

Početni period karakterizira relativno niska aktivnost PrimoRL modela, što objašnjava njegove niže performanse u tom razdoblju. Međutim, krajem promatranog perioda, model

je poduzeo niz preciznih trgovačkih akcija koje su rezultirale značajnim rastom performansi.

Usprkos nižoj godišnjoj volatilnosti od 14.33% u usporedbi s B&H strategijom (19.78%), PrimoRL model je uspio ostvariti veći povrat. Ovo ukazuje na efikasno upravljanje rizikom, posebno vidljivo u manjem maksimalnom padu od -6.47% u usporedbi s -10.51% za B&H strategiju.

FinRL model pokazao je impresivne rezultate s povratom od 16.73% i Sharpe omjerom od 1.88, demonstrirajući snagu pristupa dubokog ojačanog učenja. Međutim, PrimoRL je i dalje uspio nadmašiti FinRL, iako s manjom razlikom nego u slučaju drugih dionica.

Trgovanje MSFT dionicom predstavilo je jedinstvene izazove za PrimoRL model. Unatoč početnim poteškoćama, model je pokazao sposobnost prilagodbe i optimiziranog trgovanja. Ova strategija, iako rizična, na kraju se isplatila, rezultirajući najboljim ukupnim performansama. Ovakav pristup naglašava važnost dugoročne perspektive u trgovaju i sposobnost modela da uči i prilagođava se kompleksnim tržišnim uvjetima.

7.4.4. Rezultati trgovanja za dionicu CRM

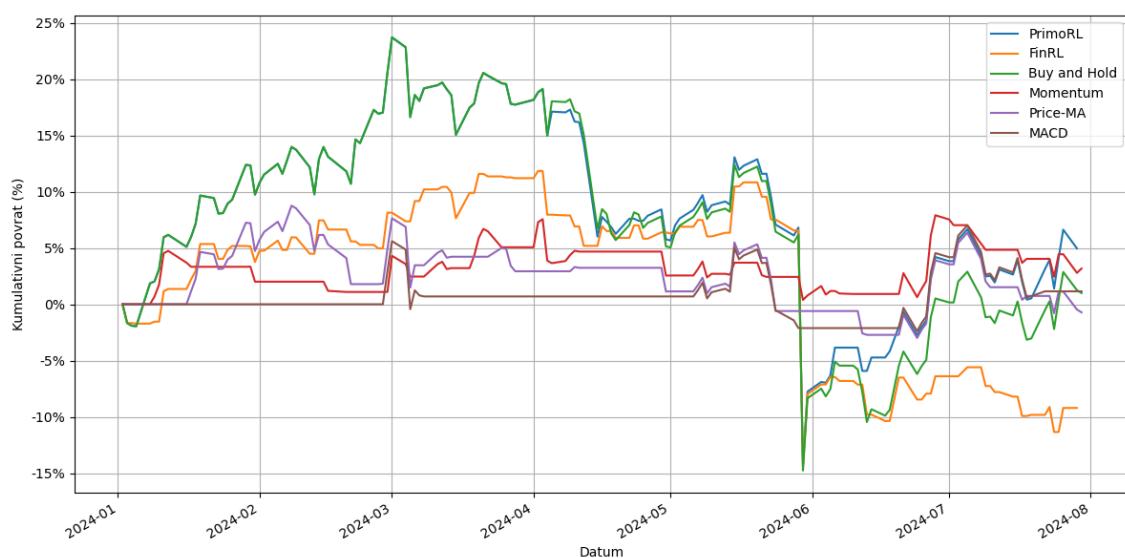
Analiza trgovanja dionicom Salesforce (CRM) za razdoblje od 1. siječnja 2024. do 31. srpnja 2024. pruža uvid u performanse različitih trgovačkih strategija u izazovnom tržišnom okruženju. Unatoč općem trendu rasta u tehnološkom sektoru tijekom ovog perioda, dionica CRM pokazala je znatno drugačiju tržišnu dinamik.

Tablica 7.11. prikazuje rezultate različitih trgovačkih strategija primijenjenih na CRM dionicu. Uočljivo je da je većina strategija ostvarila skromne ili čak negativne povrate, što odražava težak period za ovu dionicu. PrimoRL model se istaknuo s najvišim kumulativnim povratom od 4.95%, što je značajno bolje od tradicionalne B&H strategije koja je ostvarila nizak povrat od 0.99%. Zanimljivo je primjetiti da je FinRL model zabilježio značajan gubitak od -9.21%, što dodatno naglašava izazov trgovanja ovom dionicom u promatranom periodu.

Tablica 7.11: Prikaz rezultata za dionicu CRM

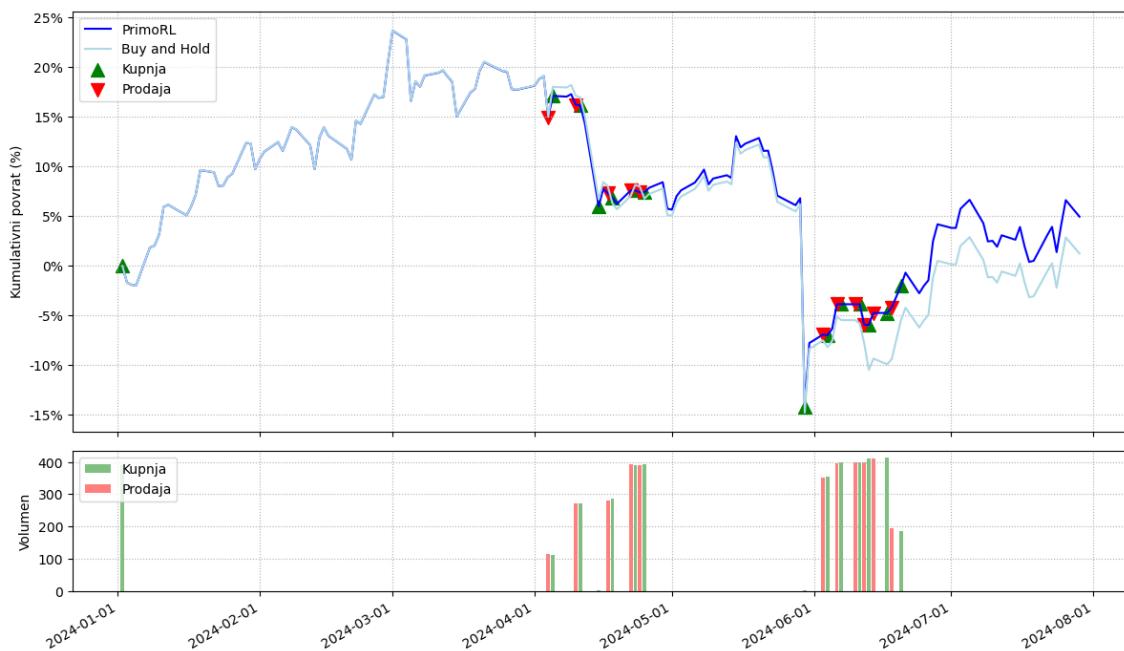
Model	Kumulativni povrat	Sharpe omjer	Godišnja volatilnost	Maksimalni pad
B&H	0.99%	0.25	38.69%	-31.11%
MOM	3.17%	0.47%	13.45%	-6.67%
P-MA	-0.72%	0.02	17.93%	-10.80%
MACD	1.14%	0.21	14.72%	-7.56%
FinRL	-9.21%	-0.33	32.69%	-23.48%
PrimoRL	4.95%	0.42	37.90%	-30.64\$

Slika 7.8. na grafu prikazuje kumulativne povrate svih promatranih strategija. Graf pokazuje nestabilno kretanje cijene dionice, s izraženim padom u svibnju. Ovaj pad predstavlja izazov za sve trgovačke strategije. PrimoRL model, iako je također osjetio utjecaj ovog pada, pokazao je sposobnost bržeg oporavka u usporedbi s ostalim strategijama. Ova sposobnost PrimoRL modela može se pripisati njegovoj mogućnosti brze prilagodbe strategije na temelju novih tržišnih informacija i NLP značajki. Također može se primijetiti kako su se druge strategije, posebno one temeljene na tehničkim indikatorima, teže nosile s ovom naglom promjenom trenda. Ova situacija ističe prednosti prilagodljivih strategija u nestabilnim tržišnim uvjetima, posebno za dionice poput CRM koje su osjetljive na brze promjene u tehnološkom sektoru i raspoloženje investitora.



Slika 7.8: Kumulativni povrati različitih trgovačkih strategija za dionicu CRM

Detaljniji uvid u performanse PrimoRL modela pruža grafički prikaz na Slici 7.9.. Ovaj prikaz otkriva da je model bio relativno neaktivan tijekom većeg dijela promatranog perioda, s tek nekoliko značajnijih trgovačkih akcija. Posebno je zanimljivo primijetiti nedostatak značajnijih kupnji tijekom većeg dijela razdoblja, što sugerira da je model prepoznao rizike i postupao prema tome. Ova opreznost modela ukazuje na njegovu sposobnost da procijeni nepovoljne tržišne uvjete i izbjegne nepotrebne rizike. Međutim, model je pokazao spremnost za akciju kada je prepoznao povoljne prilike, što se vidi iz nekoliko važnih transakcija koje je izvršio. Ova strategija u kojoj model čeka pravi trenutak mogla bi objasniti zašto je PrimoRL uspio ostvariti pozitivan povrat u okolnostima gdje su druge strategije zabilježile gubitke.



Slika 7.9: Performanse PrimoRL modela za dionicu CRM

Kako je već spomenuto važan trenutak za PrimoRL strategiju dogodio se nakon značajnog pada u svibnju. Model je pokazao sposobnost brze prilagodbe novonastaloj situaciji, izvršavajući niz kupnji na nižim razinama cijene. Usprkos relativno visokoj godišnjoj volatilnosti od 37.90%, koja je blizu volatilnosti B&H strategije (38.69%), PrimoRL je uspio ostvariti bolji povrat uz nešto manji maksimalni pad (-30.64% naspram -31.11% za B&H). Ovo ukazuje na određenu razinu uspješnosti u upravljanju rizicima u vrlo volatilnim uvjetima.

Ovaj primjer trgovanja CRM dionicom ističe važnu karakteristiku PrimoRL modela, sposobnost prilagodbe različitim tržišnim uvjetima, uključujući i one nepovoljne. Dok je većina strategija zabilježila gubitke, PrimoRL je uspio ostvariti pozitivan povrat, demonstrirajući robusnost modela u izazovnim situacijama.

Činjenica da je PrimoRL nadmašio B&H strategiju u ovako teškom periodu za dionicu naglašava potencijalnu vrijednost aktivnog upravljanja portfeljem, čak i kada su tržišni uvjeti nepovoljni. Model je pokazao sposobnost minimiziranja gubitaka u padajućem tržištu i iskorištavanja prilika za oporavak, što je ključno za dugoročni uspjeh u trgovanju. Trgovanje CRM dionicom pružilo je vrijedan uvid u performanse PrimoRL modela u nepovoljnim tržišnim uvjetima. Unatoč skromnom kumulativnom povratu, relativna uspješnost modela u ovom scenariju dodatno potvrđuje njegovu robusnost i adaptabilnost različitim tržišnim situacijama.

7.4.5. Rezultati trgovanja za dionicu AMZN

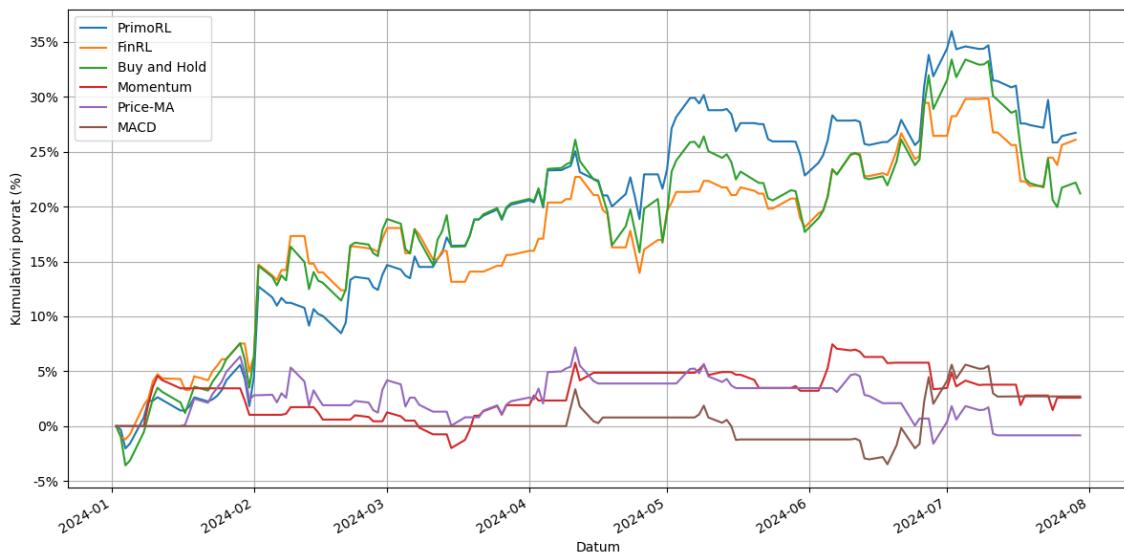
Analiza trgovanja dionicom Amazon.com Inc. (AMZN) za razdoblje od 1. siječnja 2024. do 31. srpnja 2024. pruža zanimljiv uvid u performanse različitih trgovачkih strategija na jednoj od vodećih tehnoloških dionica. Dionica AMZN često pokazuje visoku volatilnost i osjetljivost na tržišne trendove, tehnološke inovacije i promjene u potrošačkim navikama, što je čini idealnim kandidatom za testiranje robusnosti različitih trgovачkih pristupa.

Tablica 7.12. prikazuje rezultate različitih trgovачkih strategija primijenjenih na AMZN dionicu. PrimoRL model ostvario je najviši kumulativni povrat od 26.72%, neznatno nadmašujući FinRL model koji je postigao 26.09%. Obje ove strategije značajno su nadmašile tradicionalnu strategiju kupi i drži (B&H), koja je ostvarila solidan, ali ipak niži povrat od 21.19%. Zanimljivo je primjetiti da su ostale aktivne strategije trgovanja (MOM, P-MA, MACD) ostvarile znatno niže povrate, što naglašava prednost pristupa temeljenih na strojnom učenju u ovom slučaju.

Tablica 7.12: Prikaz rezultata za dionicu AMZN

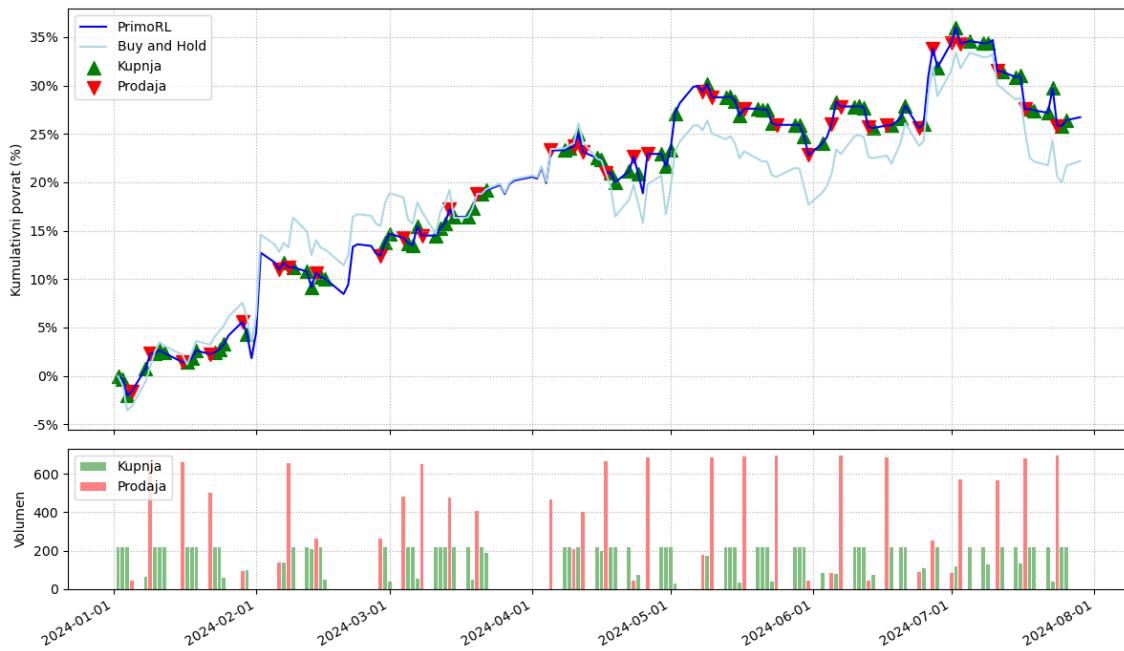
Modeli	Kumulativni povrat	Sharpe omjer	Godišnja volatilnost	Maksimalni pad
B&H	21.19%	1.47	24.86%	-10.07%
MOM	2.58%	0.50	9.73%	-6.28%
P-MA	-0.83%	-0.05	13.14%	-8.18%
MACD	2.78%	0.48	10.82%	-6.16%
FinRL	26.09%	2.06	20.63%	-7.13%
PrimoRL	26.72%	2.08	20.95%	-7.45%

Slika 7.10. vizualno prikazuje kumulativne povrate svih promatranih strategija. Graf otkriva dinamiku gdje PrimoRL model preuzima vodstvo u drugoj polovici promatranog perioda, posebno od travnja nadalje. Do tog trenutka, performanse PrimoRL-a bile su bliske drugim strategijama, ali nakon toga model pokazuje konzistentnu prednost.



Slika 7.10: Kumulativni povrati različitih trgovalnih strategija za dionicu AMZN

Detaljniji uvid u performanse PrimoRL modela pruža Slika 7.11.. Ova slika otkriva sofisticiranu strategiju trgovanja koju PrimoRL primjenjuje. Uočljivo je da model često kupuje manje količine dionica, a zatim zatvara gotovo cijelu poziciju kada procijeni da je dostignut optimalan profit. Ovaj pristup postupnog ulaska i brzog izlaska pokazao se posebno učinkovitim u hvatanju kratkoročnih trendova rasta.



Slika 7.11: Performanse PrimoRL modela za dionicu AMZN

Zanimljivo primjetiti obrazac trgovanja u drugoj polovici promatranoog perioda. PrimoRL model pokazuje povećanu aktivnost, s češćim, ali manjim kupnjama, praćenim

pravovremenim prodajama. Ovaj pristup omogućio je modelu da iskoristi pozitivne trendove, istovremeno minimizirajući rizik držanja velikih pozicija tijekom dužih perioda.

Usprkos aktivnom trgovanju, PrimoRL je uspio održati godišnju volatilnost na 20.95%, što je značajno niže od B&H strategije (24.86%). Ovo ukazuje na učinkovito upravljanje rizicima. Maksimalni pad od -7.45% za PrimoRL je također povoljniji u usporedbi s B&H strategijom (-10.07%), što dodatno potvrđuje sposobnost modela da ograniči gubitke u nepovoljnim tržišnim uvjetima.

Usporedba s FinRL modelom posebno je zanimljiva. Oba modela pokazala su izvanredne rezultate, s vrlo sličnim performansama. PrimoRL je ostvario neznatno bolji povrat (26.72% naspram 26.09%) i Sharpe omjer (2.08 naspram 2.06), ali ove razlike su minimalne. Ovako slični rezultati između dva napredna modela strojnog učenja naglašavaju potencijal primjene AI-a u razvoju algoritama za automatizirano trgovanje. Trgovanje AMZN dionicom demonstriralo je snagu PrimoRL modela u hvatanju i iskorištavanju tržišnih trendova. Model je pokazao sposobnost prilagodbe različitim tržišnim fazama, posebno se ističući u drugoj polovici promatranog perioda. Strategija čestih, manjih trgovanja s brzim uzimanjem profita pokazala se učinkovitom u maksimiziranju povrata uz istovremeno ograničavanje rizika. Ovi rezultati dodatno potvrđuju robusnost PrimoRL pristupa u trgovaju vodećim tehnološkim dionicama u dinamičnim tržišnim uvjetima.

7.4.6. Rezultati trgovanja na razini portfolija

Analiza trgovanja na razini portfolija, koji uključuje dionice AAPL, NFLX, MSFT, CRM i AMZN, pruža sveobuhvatan uvid u sposobnost različitih modela da upravljaju diversificiranim skupom imovine. Ova analiza je posebno značajna jer demonstrira kako modeli balansiraju rizike i povrate različitih dionica, optimizirajući performanse cijelog portfolija. Rezultati pokazuju sposobnost naprednih modela strojnog učenja da nadmaše tradicionalne strategije trgovanja u kompleksnim tržišnim uvjetima.

Tablica 7.13. prikazuje rezultate različitih strategija primjenjenih na portfolio razini. PrimoRL model, posebno u svojoj PPO (Proximal Policy Optimization) varijanti, značajno nadmašuje ostale strategije s impresivnim kumulativnim povratom od 32.29% i Sharpe omjerom od 2.19. Ovo je znatno bolje od tradicionalnih usporednih strategija poput metode srednje vrijednosti (engl. Mean-Variance) i burzovnog indeksa DJI (Dow Jones Industrial Average).

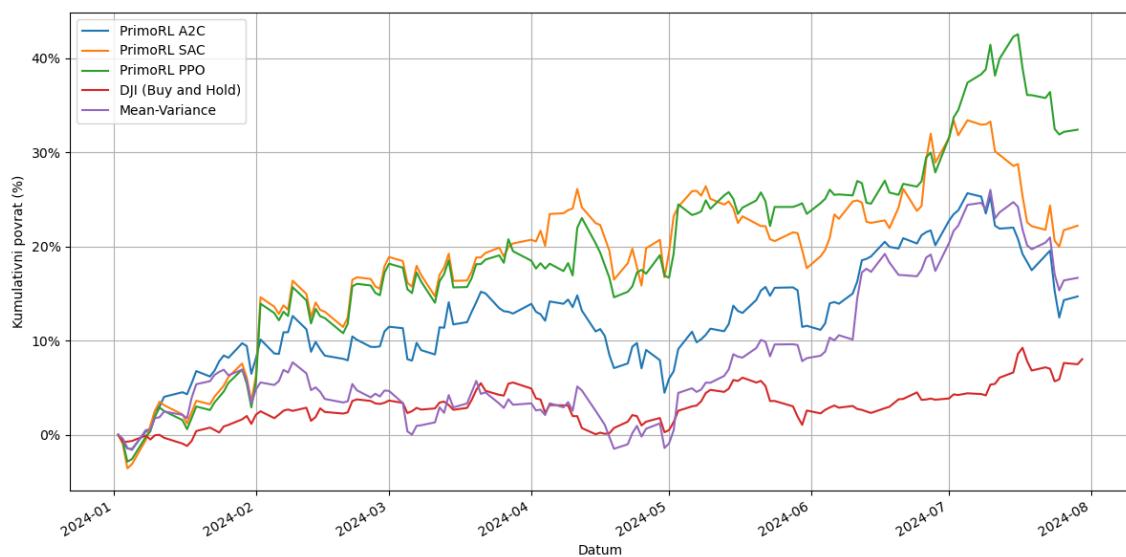
Tablica 7.13: Prikaz rezultata na razini portfolija

Modeli	Kumulativni povrat	Sharpe omjer	Godišnja volatilnost	Maksimalni pad
Mean-Variance	16.66%	1.55	18.48%	-8.52%
DJI (B&H)	8.02%	1.40	10.00%	-5.20%
FinRL (A2C)	17.84%	1.30	24.18%	-15.33%
FinRL (SAC)	25.53%	1.74	24.54%	-10.49%
FinRL (PPO)	16.34%	1.36	21.03%	-10.50%
PrimoRL (A2C)	14.68%	1.31	19.75%	-10.50%
PrimoRL (SAC)	22.19%	1.53	24.83%	-10.07%
PrimoRL (PPO)	32.29%	2.19	23.60%	-7.47%

Slika 7.12. vizualno prikazuje kumulativne povrate za različite varijante FinRL modela, kao i usporednjih strategija. Graf prikazuje dinamiku trgovanja tijekom promatranog perioda. FinRL SAC (Soft Actor-Critic) strategija pokazuje najbolje performanse među FinRL varijantama, održavajući konzistentan uzlazni trend s povremenim periodima izrazitog rasta. FinRL PPO (Proximal Policy Optimization) također pokazuje snažne rezultate, posebno u drugoj polovici promatranog perioda. Zanimljivo je primjetiti kako FinRL A2C (Advantage Actor-Critic) strategija, iako započinje s negativnim trendom, uspijeva se oporaviti i završiti s pozitivnim prinosom. Sve FinRL strategije nadmašuju tradicionalne usporedne strategije, demonstrirajući prednosti pristupa temeljenog na dubokom podržanom učenju.

**Slika 7.12:** Kumulativni povrati za FinRL modele

Slika 7.13 prikazuje kumulativne povrate za PrimoRL modele i usporedne strategije. PrimoRL PPO strategija se ističe s izvanrednim performansama, pokazujući konzistentan i snažan rast tijekom cijelog promatranog perioda. Posebno je značajan nagli uzlazni trend u posljednjoj trećini perioda, gdje PrimoRL PPO značajno nadmašuje sve ostale strategije. PrimoRL SAC također pokazuje snažne rezultate, iako s nešto većom volatilnošću. Zanimljivo je primijetiti kako PrimoRL A2C, nakon početnog zaostajanja, uspijeva sustići i preći usporedne strategije u drugoj polovici perioda. Sve PrimoRL strategije demonstriraju sposobnost prilagodbe promjenjivim tržišnim uvjetima, održavajući pozitivan trend kroz većinu promatranog perioda i učinkovito upravljući rizicima na razini portfolija.



Slika 7.13: Kumulativni povrati za PrimoRL modele

Kad promatramo dionice u skupu portfolija ističe se sposobnost modela da minimiziraju razine rizika. Iako su neke pojedinačne dionice, poput CRM, imale negativne prinose u određenim periodima, portfolio pristup uspješno je ublažio ove negativne učinke. Ovo se očituje u relativno niskim maksimalnim padovima za većinu strategija, s PrimoRL PPO strategijom koja ostvaruje najniži maksimalni pad od samo -7.47%.

S obzirom na usporedne strategije dodatno se naglašavaju prednosti naprednih modela strojnog učenja. Dok metoda srednje vrijednosti pruža solidne rezultate, ona značajno zaostaje za najboljim strategijama temeljenim na dubokom podržanom učenju. Indeks, iako pokazuje najnižu volatilnost, ostvaruje najniži povrat, što naglašava potencijalne prednosti aktivnog upravljanja portfolijom u dinamičnim tržišnim uvjetima. Ova razlika u performansama ilustrira kako napredni algoritmi mogu iskoristiti tržišne neučinkovitosti koje tradicionalne strategije možda propuštaju.

Rezultati trgovanja na razini portfolija demonstriraju snagu i fleksibilnost PrimoRL i FinRL modela u upravljanju diversificiranim skupom imovine. PrimoRL PPO se ističe

kao najuspješnija strategija, kombinirajući visok povrat s učinkovitim upravljanjem rizicima, što sugerira da ovaj pristup može biti posebno koristan za investitore koji traže optimalan balans između rasta i stabilnosti.

Ovi rezultati naglašavaju ogroman potencijal naprednih tehnika strojnog učenja u kontekstu upravljanja portfolijom, pružajući investitorima moćne alate za trgovanje na kompleksnim i dinamičnim financijskim tržištima. Sposobnost ovih modela da nadmaše tradicionalne strategije, uz istovremeno održavanje prihvatljivih razina rizika, otvara nove mogućnosti za učinkovito upravljanje investicijama.

7.5. Diskusija rezultata

Rezultati provedenih testiranja sustava za automatsko trgovanje pružaju sveobuhvatan uvid u performanse PrimoRL modela u usporedbi s drugim trgovačkim strategijama na različitim tehnološkim dionicama i na razini portfolija. PrimoRL model pokazao je konzistentnost u nadmašivanju drugih strategija na većini promatranih dionica. Model je ostvario najviše kumulativne povrate na dionicama AAPL (24.24%), NFLX (41.19%), MSFT (18.08%), i AMZN (26.72%). U slučaju CRM dionice, gdje su tržišni uvjeti bili nepovoljni, PrimoRL je uspio ostvariti pozitivan povrat (4.95%) dok su neke druge strategije bilježile gubitke. Ova konzistentnost ukazuje na robusnost PrimoRL modela i njegovu sposobnost prilagodbe različitim tržišnim uvjetima. Značajna je njegova sposobnost da nadmaši tradicionalnu B&H strategiju, što sugerira da model uspješno identificira i iskorištava kratkoročne tržišne prilike.

Uz visoke povrate, PrimoRL model pokazao je i dobru sposobnost upravljanja rizicima. U većini slučajeva, model je ostvario niže ili usporedive razine volatilnosti u odnosu na B&H strategiju, uz istovremeno postizanje viših povrata. Ovo je vidljivo u slučaju MSFT dionice, gdje je PrimoRL ostvario godišnju volatilnost od 14.33% u usporedbi s 19.78% za B&H strategiju. Maksimalni padovi za PrimoRL model bili su generalno niži ili usporedivi s drugim strategijama, što ukazuje na učinkovito upravljanje gubicima u nepovoljnim tržišnim uvjetima. Ova sposobnost balansiranja između visokih povrata i kontroliranog rizika reflektira se u konzistentno visokim Sharpe omjerima koje je model ostvario.

Rezultati pokazuju da PrimoRL model posjeduje adaptabilnost na različite tržišne uvjete. U slučaju NFLX dionice, model je pokazao sposobnost održavanja prednosti tijekom volatilni perioda. Za MSFT dionicu, iako je počeo s lošijim performansama, model je uspio prilagoditi svoju strategiju i završiti kao najbolji u kumulativnom prinosu. U izazovnom scenaruju CRM dionice, PrimoRL je uspio ostvariti pozitivan povrat u okruženju gdje su neke druge strategije zabilježile gubitke. Ova adaptabilnost sugerira da model uči iz tržišnih podataka i prilagođava svoju strategiju u realnom vremenu, što je prednost u dinamičnom tržišnom okruženju.

Usporedba PrimoRL modela s FinRL modelom, koja predstavlja jedno od vodećih rješenja otvorenog koda u području automatiziranog trgovanja, pruža važne uvide u učinkovitost različitih pristupa dubokog podržanog učenja. Kroz repliciranje FinRL implementacije i testiranje na identičnom skupu dionica, omogućena je direktna usporedba performansi. Dok su oba modela uspješno nadmašila tradicionalne strategije, PrimoRL je pokazao određenu prednost u većini testnih slučajeva. Ovo je posebno vidljivo kod NFLX dionice, gdje je PrimoRL ostvario povrat od 41.19% u usporedbi s 16.39% za FinRL. Međutim, u slučaju AMZN dionice, modeli su pokazali vrlo slične performanse, gdje je PrimoRL ostvario povrat od 26.72% u usporedbi s 26.09% za FinRL, što potvrđuje robusnost pristupa temeljenog na dubokom podržanom učenju. Ključna razlika između ova dva modela leži u PrimoRL-ovom korištenju NLP generiranih značajki, koje su omogućile sofisticiraniju interpretaciju tržišnih signala. Ove značajke, integrirane u procesu donošenja odluka, pokazale su se posebno vrijednima u volatilnim tržišnim uvjetima, doprinoseći boljim ukupnim performansama PrimoRL modela.

Rezultati na razini portfolija pokazuju dobre performanse. PrimoRL PPO strategija ostvarila je najviši kumulativni povrat od 32.29% i najviši Sharpe omjer od 2.19, nadmašujući druge strategije. Ovo demonstrira sposobnost modela da upravlja diversificiranim portfolijom, balansirajući rizike i povrate različitih dionica. PrimoRL PPO ostvario je najniži maksimalni pad od -7.47% na razini portfolija, što ukazuje na dobru sposobnost upravljanja rizicima u kontekstu cijelog portfolija. Ova kombinacija visokih povrata i učinkovitog upravljanja rizicima čini PrimoRL PPO potencijalno atraktivnom strategijom za praktičnu primjenu. Uspjeh PrimoRL modela na razini portfolija dodatno naglašava vrijednost NLP generiranih značajki u kontekstu upravljanja diversificiranim skupom imovine.

Važno je razmotriti i potencijalna ograničenja ovih testiranja. Promatrani period od sedam mjeseci, iako informativan, možda ne obuhvaća puni raspon tržišnih uvjeta. Buduća istraživanja mogla bi se fokusirati na duže vremenske periode i različite tržišne cikluse. Također, iako je PrimoRL pokazao dobre performanse na odabranim tehnološkim dionicama, bilo bi korisno istražiti njegove performanse na širem rasponu dionica iz različitih sektora. Ovo bi pružilo uvid u generalnu primjenjivost modela nad različitim tržišnim segmenata. Isto tako, važno je napomenuti da prošle performanse ne garantiraju buduće rezultate. Potrebno je daljnje testiranje i validacija u stvarnim tržišnim uvjetima kako bi se potvrdila robusnost i pouzdanost PrimoRL modela. Posebno bi bilo zanimljivo istražiti kako se NLP generirane značajke ponašaju u različitim tržišnim sektorima i tijekom dužih vremenskih perioda.

Rezultati ovog testiranja podupiru potencijal PrimoRL modela kao alata za automatizirano trgovanje dionicama. Njegova sposobnost da nadmašuje druge strategije, upravlja rizicima i adaptira se različitim tržišnim uvjetima čini ga kandidatom za praktičnu primjenu u upravljanju investicijama. Ovi rezultati naglašavaju potencijal naprednih tehnika strojnog učenja u kontekstu financijskog trgovanja i otvaraju put za daljnja istraživanja i razvoj u ovom području.

Poglavlje 8

Zaključak

Ova doktorska disertacija predstavlja sveobuhvatno istraživanje i razvoj inovativnog sustava za automatsko trgovanje dionicama na tržištu kapitala, integrirajući napredne tehnike dubokog podržanog učenja i metode obrade prirodnog jezika. Kroz detaljnu analizu, implementaciju i eksperimentalnu evaluaciju, rad pruža značajan doprinos razumijevanju i primjeni umjetne inteligencije u kontekstu finansijskih tržišta, adresira ključne izazove u automatiziranom trgovovanju i otvara nove perspektive za buduća istraživanja.

Temeljita analiza finansijskih tržišta i hipoteze efikasnog tržišta, predstavljena u trećem poglavlju, postavila je čvrst teorijski okvir za razumijevanje kompleksnosti tržišta kapitala. Osvrt na evoluciju EMH-a, od ranih radova Fama do suvremenih interpretacija, naglasio je važnost kontinuiranog preispitivanja tradicionalnih modela u svijetu naprednih tehnologija i industrijske tranzicije. Ova analiza je važna početna točka za razumijevanje potencijala i ograničenja automatiziranih sustava trgovanja, posebno u kontekstu tržišnih anomalija i psiholoških faktora koji utječu na tržišna kretanja.

Kroz četvrto poglavlje, fokus je stavljen na obradu prirodnog jezika. Detaljno je prikazan napredak područja NLP-a, s posebnim naglaskom na revolucionarnu Transformer arhitekturu. Analiza modela poput BERT-a, GPT serije i drugih derivata, pružila je dubinski uvid u mogućnosti i ograničenja trenutnih takozvani SOTA (State of the art) NLP tehnologija. Ovo poglavlje je uvod u pripremu za razvoj PrimoGPT modela, demonstrirajući kako napredne NLP tehnike mogu biti prilagođene za analizu finansijskih tekstova. Posebno je značajna diskusija o primjeni tehnika kao što su učenje iz konteksta i trening s instrukcijama, koje su direktno utjecale na dizajn i implementaciju našeg modela.

Peto poglavlje pružilo je sveobuhvatan pregled dubokog podržanog učenja, detaljno analizirajući algoritme poput DQN, A2C, PPO i SAC. Ovo poglavlje stvorilo je temelje za razvoj PrimoRL modela, omogućujući informirani odabir i prilagodbu algoritama za specifične izazove trgovanja dionicama. Posebno je značajna diskusija o balansiranju istraživanja i iskorištavanja u kontekstu volatilnih finansijskih tržišta, što je direktno utjecalo na dizajn našeg trgovackog agenta.

Metodologija istraživanja, predstavljena u šestom poglavlju, detaljno je opisala inovativan pristup integraciji NLP-a i dubokog podržanog učenja. Razvoj PrimoGPT

modela za generiranje NLP značajki demonstrirao je napredan pristup analizi finansijskih tekstova, uključujući vijesti, izvještaje i druge relevantne izvore. PrimoRL model, s druge strane, pokazao je kako se napredni algoritmi dubokog podržanog učenja mogu prilagoditi za donošenje trgovačkih odluka u realnom vremenu.

Eksperimentalni rezultati, prezentirani u sedmom poglavlju, pružili su opsežne dokaze u prilog postavljenim hipotezama:

H1: Predložen modularni sustav za trgovanje na tržištu kapitala može poboljšati povrat ulaganja u odnosu na referentne strategije.

H2: Koristeći sentiment analizu može se poboljšati predviđanje smjera kretanja vrijednosnica na tržištu kapitala.

H3: Korištenje mehanizma pozornosti u procesu prikupljanja i obrade podataka može se učinkovitije formirati relevantniji skup podataka.

H4: Koristeći duboko podržano učenje kao pristup za dinamičko donošenje odluka mogu se generirati profitabilne trgovačke akcije.

Rezultati su konzistentno pokazali superiornost PrimoRL modela nad tradicionalnim strategijama i drugim modelima strojnog učenja. Posebno impresivne performanse na NFLX (41.19% povrata), AAPL (24.24% povrata) i AMZN (26.72% povrata) dionicama demonstriraju robusnost i adaptabilnost sustava u različitim tržišnim uvjetima. Važno je naglasiti da je sustav pokazao sposobnost održavanja visokih performansi i u volatilnim periodima, što je bitno kad je riječ o praktičnoj primjeni u realnim tržišnim uvjetima.

S druge strane PrimoGPT model pokazao je sposobnost generiranja relevantnih NLP značajki. Analiza performansi pokazala je da su ove značajke značajno doprinijele preciznosti trgovačkih odluka, omogućujući sustavu da efikasno interpretira kompleksne tržišne signale sadržane u finansijskim tekstovima. Ovo je vidljivo u sposobnosti sustava da reagira na suptilne tržišne indikacije koje tradicionalne metode često previde.

Implementacija PrimoGPT modela, temeljenog na naprednoj Transformer arhitekturi, demonstrirala je značajno unapređenje u obradi finansijskih tekstova. Sposobnost modela da generira kontekstualno bogate i tržišno relevantne značajke ključna je za performanse cjelokupnog sustava. Ovo potvrđuje hipotezu da Transformer arhitektura omogućuje sofisticiraniju analizu finansijskih podataka, što doprinosi informiranom donošenju trgovačkih odluka.

PrimoRL model, baziran na PPO algoritmu, pokazao je sposobnost adaptacije na različite tržišne uvjete. Konzistentno visoki povrati i Sharpe omjeri na različitim dionicama potvrđuju sposobnost modela da generira profitabilne trgovačke strategije. Impresivna je sposobnost modela da balansira između kratkoročnih prilika i dugoročnih trendova, što je ključno za održivu profitabilnost u dinamičnom tržišnom okruženju.

Znanstveni doprinosi ovog rada su višestruki i značajni:

1. Razvijen je model prikupljanja i obrade podataka potrebnih za predloženu metodu strojnog učenja.
2. Implementiran je sustav za automatsko trgovanje dionica koji uključuje module za predviđanje smjera kretanja, odabir dionica, optimizaciju portfolija te donošenja odluka za trgovanje na tržištu kapitala.
3. Razvijen je okvir za evaluaciju i usporedbu različitih trgovačkih strategija, uključujući tradicionalne metode i napredne pristupe temeljene na strojnom učenju.
4. Stvorena je metodologija za fino podešavanje i optimizaciju modela za specifične zahtjeve finansijskih tržišta.

Ovaj integrirani pristup predstavlja novi standard u automatiziranom donošenju trgovačkih odluka, demonstrirajući kako sinergija različitih modela strojnog učenja može rezultirati iznadprosječnim performansama. Razvijeni okvir pruža vrijedan alat za buduća istraživanja i razvoj u području automatiziranog trgovanja, dok metodologija za fino podešavanje adresira jedinstvene izazove poput visoke volatilnosti i potrebe za brzim donošenjem odluka.

Rad je također identificirao nekoliko izazova u primjeni dubokog podržanog učenja na finansijskim tržištima. Volatilnost tržišta i nepredvidljivost ostaju područja koja zahtijevaju daljnje istraživanje, iako je PrimoRL model pokazao obećavajuće rezultate kroz svoju adaptivnu prirodu. Kompleksnost finansijskih podataka i optimalna integracija različitih izvora informacija predstavljaju kontinuirani izazov. Potreba za kontinuiranom adaptacijom modela i razvoj metoda za efikasno online učenje ostaju važna područja za buduća istraživanja.

Metodologija korištena u ovom radu otvara brojne mogućnosti za buduća istraživanja. Daljnja eksploracija i optimizacija algoritama dubokog podržanog učenja za specifične tržišne uvjete i različite klase imovine predstavlja izazovno područje za istraživanje. Proširenje NLP komponente za obradu još šireg spektra finansijskih tekstova, uključujući analizu objava na društvenim mrežama, moglo bi dodatno unaprijediti preciznost predviđanja. Razvoj hibridnih modela koji kombiniraju uvide iz tehničke, fundamentalne i kvantitativne analize s naprednim tehnikama strojnog učenja predstavlja obećavajući smjer za buduća istraživanja. Razvoj robusnih metoda za upravljanje rizicima, uključujući strategije za ublažavanje utjecaja ekstremnih tržišnih događaja i sistemskih rizika, ostaje kritično područje za daljnje istraživanje.

Zaključno, ovaj doktorski rad predstavlja značajan korak naprijed u primjeni umjetne inteligencije u automatiziranom trgovaju na tržištu kapitala. Razvijeni sustav demonstrira superiornu sposobnost u nadmašivanju tradicionalnih trgovačkih strategija te otvara nove perspektive za razumijevanje i navigaciju kompleksnih finansijskih tržišta. Rezultati ovog istraživanja potvrđuju potencijal AI-a da transformira finansijsku industriju, pružajući alate za sofisticiranije analize tržišta i preciznije donošenje odluka.

Dok izazovi i dalje postoje, posebno u kontekstu volatilnih tržišnih uvjeta i potrebe za kontinuiranom adaptacijom, ovaj rad pruža čvrstu osnovu za daljnji razvoj i unapređenje automatiziranih sustava trgovanja temeljenih na umjetnoj inteligenciji. Budućnost ovog područja leži u daljnjoj integraciji različitih AI tehnologija, kontinuiranom unapređenju modela za obradu i interpretaciju finansijskih podataka, te razvoju etički odgovornih i regulatorno usklađenih sustava.

Ovaj rad da doprinosi akademskom razumijevanju primjene AI-a u financijama i pruža praktične uvide koji mogu informirati razvoj nove generacije trgovačkih alata i strategija. Time se otvara put ka stvaranju inteligentnijih, efikasnijih i potencijalno pravednijih finansijskih tržišta, što ima dalekosežne implikacije za globalnu ekonomiju i društvo u cjelini.

Literatura

- [1] E. F. Fama, “Efficient Capital Markets A Review of Theory and Empirical Work,” 1970.
- [2] J. Zou *et al.*, “Stock Market Prediction via Deep Learning Techniques: A Survey,” Dec. 2022, [Online]. Available: <http://arxiv.org/abs/2212.12717>
- [3] D. Shah, H. Isah, and F. Zulkernine, “Stock market analysis: A review and taxonomy of prediction techniques,” 2019, *MDPI Multidisciplinary Digital Publishing Institute*. doi: 10.3390/ijfs7020026.
- [4] S. K. Sahu, A. Mokhade, and N. D. Bokde, “An Overview of Machine Learning, Deep Learning, and Reinforcement Learning-Based Techniques in Quantitative Finance: Recent Progress and Challenges,” Feb. 01, 2023, *MDPI*. doi: 10.3390/app13031956.
- [5] E. F. Fama, “Efficient Capital Markets: II,” 1991.
- [6] B. G. Malkiel, “The Efficient Market Hypothesis and Its Critics,” 2003.
- [7] A. Timmermann and C. W. J. Granger, “Efficient market hypothesis and forecasting,” *Int J Forecast*, vol. 20, no. 1, pp. 15–27, Jan. 2004, doi: 10.1016/S0169-2070(03)00012-8.
- [8] M. Lam, “Neural network techniques for financial performance prediction: integrating fundamental and technical analysis,” *Decis Support Syst*, vol. 37, no. 4, pp. 567–581, Sep. 2004, doi: 10.1016/S0167-9236(03)00088-5.
- [9] J. J. Murphy, *Technical analysis of the financial markets*. 1999. [Online]. Available: www.Fxborssa.com
- [10] B. Graham, *The intelligent investor*. 2006.
- [11] C. Lohrmann and P. Luukka, “Classification of intraday S&P500 returns with a Random Forest,” *Int J Forecast*, vol. 35, no. 1, pp. 390–407, Jan. 2019, doi: 10.1016/j.ijforecast.2018.08.004.
- [12] M.-Y. Chen and B.-T. Chen, “A hybrid fuzzy time series model based on granular computing for stock price forecasting,” *Inf Sci (N Y)*, vol. 294, pp. 227–241, Feb. 2015, doi: 10.1016/j.ins.2014.09.038.
- [13] Y. Chen and Y. Hao, “A feature weighted support vector machine and K-nearest neighbor algorithm for stock market indices prediction,” *Expert Syst Appl*, vol. 80, pp. 340–355, Sep. 2017, doi: 10.1016/j.eswa.2017.02.044.
- [14] F. X. S. D. Nugroho, T. B. Adji, and S. Fauziati, “Decision support system for stock trading using multiple indicators decision tree,” in *2014 The 1st International Conference on Information Technology, Computer, and Electrical Engineering*, IEEE, Nov. 2014, pp. 291–296. doi: 10.1109/ICITACEE.2014.7065759.

- [15] R. A. Kamble, “Short and long term stock trend prediction using decision tree,” in *2017 International Conference on Intelligent Computing and Control Systems (ICICCS)*, IEEE, Jun. 2017, pp. 1371–1375. doi: 10.1109/ICCONS.2017.8250694.
- [16] B. Xie, R. J. Passonneau, L. Wu, and G. G. Creamer, “Semantic Frames to Predict Stock Price Movement.” [Online]. Available: <https://ssrn.com/abstract=2314133>
- [17] J. Bollen, H. Mao, and X. Zeng, “Twitter mood predicts the stock market,” *J Comput Sci*, vol. 2, no. 1, pp. 1–8, Mar. 2011, doi: 10.1016/j.jocs.2010.12.007.
- [18] A. Bhardwaj, Y. Narayan, Vanraj, Pawan, and M. Dutta, “Sentiment Analysis for Indian Stock Market Prediction Using Sensex and Nifty,” *Procedia Comput Sci*, vol. 70, pp. 85–91, 2015, doi: 10.1016/j.procs.2015.10.043.
- [19] A. Vaswani *et al.*, “Attention Is All You Need,” Jun. 2017, [Online]. Available: <http://arxiv.org/abs/1706.03762>
- [20] A. R. Openai, K. N. Openai, T. S. Openai, and I. S. Openai, “Improving Language Understanding by Generative Pre-Training.” [Online]. Available: <https://gluebenchmark.com/leaderboard>
- [21] H. Yang, X.-Y. Liu, and C. D. Wang, “FinGPT: Open-Source Financial Large Language Models,” Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2306.06031>
- [22] S. Wu *et al.*, “BloombergGPT: A Large Language Model for Finance,” Mar. 2023, [Online]. Available: <http://arxiv.org/abs/2303.17564>
- [23] B. Hambly, R. Xu, and H. Yang, “Recent Advances in Reinforcement Learning in Finance,” Dec. 2021, doi: 10.13140/RG.2.2.30278.40002.
- [24] H. Buehler, L. Gonon, J. Teichmann, B. Wood, B. Mohan, and J. Kochems, “Deep Hedging: Hedging Derivatives Under Generic Market Frictions Using Reinforcement Learning,” *SSRN Electronic Journal*, 2019, doi: 10.2139/ssrn.3355706.
- [25] Z. Jiang, D. Xu, and J. Liang, “A Deep Reinforcement Learning Framework for the Financial Portfolio Management Problem,” Jun. 2017, [Online]. Available: <http://arxiv.org/abs/1706.10059>
- [26] X.-Y. Liu *et al.*, “FinRL: A Deep Reinforcement Learning Library for Automated Stock Trading in Quantitative Finance,” Nov. 2020, [Online]. Available: <http://arxiv.org/abs/2011.09607>
- [27] X.-Y. Liu *et al.*, “Dynamic Datasets and Market Environments for Financial Reinforcement Learning,” Apr. 2023, [Online]. Available: <http://arxiv.org/abs/2304.13174>
- [28] N. Wang, H. Yang, and C. D. Wang, “FinGPT: Instruction Tuning Benchmark for Open-Source Large Language Models in Financial Datasets,” Oct. 2023, [Online]. Available: <http://arxiv.org/abs/2310.04793>

- [29] I. Botunac, J. Bosna, and M. Matetić, “Optimization of Traditional Stock Market Strategies Using the LSTM Hybrid Approach,” *Information (Switzerland)*, vol. 15, no. 3, Mar. 2024, doi: 10.3390/info15030136.
- [30] T. Fischer and C. Krauss, “Deep learning with long short-term memory networks for financial market predictions,” *Eur J Oper Res*, vol. 270, no. 2, pp. 654–669, Oct. 2018, doi: 10.1016/j.ejor.2017.11.054.
- [31] Y. Baek and H. Y. Kim, “ModAugNet: A new forecasting framework for stock market index value with an overfitting prevention LSTM module and a prediction LSTM module,” *Expert Syst Appl*, vol. 113, pp. 457–480, Dec. 2018, doi: 10.1016/j.eswa.2018.07.019.
- [32] V. D. Ta, C. M. Liu, and D. A. Tadesse, “Portfolio optimization-based stock prediction using long-short term memory network in quantitative trading,” *Applied Sciences (Switzerland)*, vol. 10, no. 2, Jan. 2020, doi: 10.3390/app10020437.
- [33] T. H. H. Aldhyani and A. Alzahrani, “Framework for Predicting and Modeling Stock Market Prices Based on Deep Learning Algorithms,” *Electronics (Switzerland)*, vol. 11, no. 19, Oct. 2022, doi: 10.3390/electronics11193149.
- [34] S. H. Jafar, S. Akhtar, H. El-Chaarani, P. A. Khan, and R. Binsaddig, “Forecasting of NIFTY 50 Index Price by Using Backward Elimination with an LSTM Model,” *Journal of Risk and Financial Management*, vol. 16, no. 10, Oct. 2023, doi: 10.3390/jrfm16100423.
- [35] C. S. Ku, J. Xiong, Y. L. Chen, S. D. Cheah, H. C. Soong, and L. Y. Por, “Improving Stock Market Predictions: An Equity Forecasting Scanner Using Long Short-Term Memory Method with Dynamic Indicators for Malaysia Stock Market,” *Mathematics*, vol. 11, no. 11, Jun. 2023, doi: 10.3390/math11112470.
- [36] I. Letteri, G. Della Penna, G. De Gasperis, and A. Dyoub, “DNN-ForwardTesting: A New Trading Strategy Validation using Statistical Timeseries Analysis and Deep Neural Networks,” Oct. 2022, [Online]. Available: <http://arxiv.org/abs/2210.11532>
- [37] S. J. Yu, S. B. Yang, and S. H. Yoon, “The Design of an Intelligent Lightweight Stock Trading System Using Deep Learning Models: Employing Technical Analysis Methods,” *Systems*, vol. 11, no. 9, Sep. 2023, doi: 10.3390/systems11090470.
- [38] P. Glasserman and C. Lin, “Assessing Look-Ahead Bias in Stock Return Predictions Generated By GPT Sentiment Analysis,” Sep. 2023, [Online]. Available: <http://arxiv.org/abs/2309.17322>
- [39] D. Garcia, X. Hu, and M. Rohrer, “The colour of finance words,” *J financ econ*, vol. 147, no. 3, pp. 525–549, Mar. 2023, doi: 10.1016/j.jfineco.2022.11.006.
- [40] C. W. Calomiris and H. Mamaysky, “How news and its context drive risk and returns around the world,” *J financ econ*, vol. 133, no. 2, pp. 299–336, Aug. 2019, doi: 10.1016/j.jfineco.2018.11.009.

- [41] P. C. Tetlock, “Giving Content to Investor Sentiment: The Role of Media in the Stock Market,” *J Finance*, vol. 62, no. 3, pp. 1139–1168, Jun. 2007, doi: 10.1111/j.1540-6261.2007.01232.x.
- [42] H. Zhao *et al.*, “Revolutionizing Finance with LLMs: An Overview of Applications and Insights,” Jan. 2024, [Online]. Available: <http://arxiv.org/abs/2401.11641>
- [43] A. Lopez-Lira and Y. Tang, “Can ChatGPT Forecast Stock Price Movements? Return Predictability and Large Language Models,” Apr. 2023, [Online]. Available: <http://arxiv.org/abs/2304.07619>
- [44] Z. Chu *et al.*, “Data-Centric Financial Large Language Models,” Oct. 2023, [Online]. Available: <http://arxiv.org/abs/2310.17784>
- [45] U. Gupta, “GPT-InvestAR: Enhancing Stock Investment Strategies through Annual Report Analysis with Large Language Models,” Sep. 2023, [Online]. Available: <http://arxiv.org/abs/2309.03079>
- [46] Z. Zhou, L. Ma, and H. Liu, “Trade the Event: Corporate Events Detection for News-Based Event-Driven Trading,” May 2021, [Online]. Available: <http://arxiv.org/abs/2105.12825>
- [47] K. Mishev, A. Gjorgjevikj, I. Vodenska, L. T. Chitkushev, and D. Trajanov, “Evaluation of Sentiment Analysis in Finance: From Lexicons to Transformers,” *IEEE Access*, vol. 8, pp. 131662–131682, 2020, doi: 10.1109/ACCESS.2020.3009626.
- [48] H. Yang, X.-Y. Liu, and C. D. Wang, “FinGPT: Open-Source Financial Large Language Models,” Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2306.06031>
- [49] A. H. Huang, H. Wang, and Y. Yang, “FinBERT: A Large Language Model for Extracting Information from Financial Text*,” *Contemporary Accounting Research*, vol. 40, no. 2, pp. 806–841, May 2023, doi: 10.1111/1911-3846.12832.
- [50] Z. Liu, D. Huang, K. Huang, Z. Li, and J. Zhao, “FinBERT: A Pre-trained Financial Language Representation Model for Financial Text Mining,” 2020. [Online]. Available: <http://commoncrawl.org/>
- [51] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding,” Oct. 2018, [Online]. Available: <http://arxiv.org/abs/1810.04805>
- [52] X.-Y. Liu, G. Wang, H. Yang, and D. Zha, “FinGPT: Democratizing Internet-scale Data for Financial Large Language Models,” Jul. 2023, [Online]. Available: <http://arxiv.org/abs/2307.10485>
- [53] B. Zhang, H. Yang, and X.-Y. Liu, “Instruct-FinGPT: Financial Sentiment Analysis by Instruction Tuning of General-Purpose Large Language Models,” Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2306.12659>

- [54] Y. Yin, Y. Yang, J. Yang, and Q. Liu, “FinPT: Financial Risk Prediction with Profile Tuning on Pretrained Foundation Models,” Jul. 2023, [Online]. Available: <http://arxiv.org/abs/2308.00065>
- [55] Z. Wang, Y. Li, J. Wu, J. Soon, and X. Zhang, “FinVis-GPT: A Multimodal Large Language Model for Financial Chart Analysis,” Jul. 2023, [Online]. Available: <http://arxiv.org/abs/2308.01430>
- [56] T.-V. Pricope, “Deep Reinforcement Learning in Quantitative Algorithmic Trading: A Review,” May 2021, [Online]. Available: <http://arxiv.org/abs/2106.00123>
- [57] X.-Y. Liu *et al.*, “FinRL-Meta: Market Environments and Benchmarks for Data-Driven Financial Reinforcement Learning,” Nov. 2022, [Online]. Available: <http://arxiv.org/abs/2211.03107>
- [58] Y. Li, P. Liu, and Z. Wang, “Stock Trading Strategies Based on Deep Reinforcement Learning,” *Sci Program*, vol. 2022, 2022, doi: 10.1155/2022/4698656.
- [59] T. Théate and D. Ernst, “An application of deep reinforcement learning to algorithmic trading,” *Expert Syst Appl*, vol. 173, Jul. 2021, doi: 10.1016/j.eswa.2021.114632.
- [60] E. C. Garrido-Merchán, S. Mora-Figueroa-Cruz-Guzmán, and M. Coronado-Vaca, “Deep Reinforcement Learning for ESG financial portfolio management,” Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2307.09631>
- [61] B. Jin, “An intelligent algorithmic trading based on a risk-return reinforcement learning algorithm,” Aug. 2022, [Online]. Available: <http://arxiv.org/abs/2208.10707>
- [62] Z. Li, X.-Y. Liu, J. Zheng, Z. Wang, A. Walid, and J. Guo, “FinRL-Podracer: High Performance and Scalable Deep Reinforcement Learning for Quantitative Finance,” Nov. 2021, doi: 10.1145/3490354.3494413.
- [63] N. Malibari, I. Katib, and R. Mehmood, “Smart Robotic Strategies and Advice for Stock Trading Using Deep Transformer Reinforcement Learning,” *Applied Sciences (Switzerland)*, vol. 12, no. 24, Dec. 2022, doi: 10.3390/app122412526.
- [64] H. Wang and S. Yu, “Robo-Advising: Enhancing Investment with Inverse Optimization and Deep Reinforcement Learning,” May 2021, [Online]. Available: <http://arxiv.org/abs/2105.09264>
- [65] S. Sun *et al.*, “TradeMaster: A Holistic Quantitative Trading Platform Empowered by Reinforcement Learning.” [Online]. Available: <https://github.com/TradeMaster-NTU/TradeMaster>
- [66] W. Zhang *et al.*, “Reinforcement Learning with Maskable Stock Representation for Portfolio Management in Customizable Stock Pools,” Nov. 2023, [Online]. Available: <http://arxiv.org/abs/2311.10801>
- [67] S. Orsag, *Investicijska analiza*. 2015.

- [68] A. Saunders, M. M. Cornett, and O. Erhemjamts, *Financial Markets and Institutions*. 2022.
- [69] F. S. Mishkin and S. Eakins, “Financial Markets and Institutions,” 2018. [Online]. Available: www.myfinancelab.com
- [70] F. J. Fabozzi, F. J. Jones, F. A. Fabozzi, and S. V. Mann, *Foundations of global financial markets and institutions*. 2019.
- [71] R. Mohan, “Stock Markets: An Overview and A Literature Review,” 2019, doi: 10.13140/RG.2.2.22639.05289.
- [72] E. F. Fama, “The behavior of stock-market prices,” 1965.
- [73] IG Analyst, “What is the efficient market hypothesis (EMH)?” Accessed: Sep. 21, 2024. [Online]. Available: <https://www.ig.com/en/trading-strategies/what-is-the-efficient-market-hypothesis--emh---191217>
- [74] A. W. Lo, “The Adaptive Markets Hypothesis,” 2004. [Online]. Available: www.ijjournals.com
- [75] L. A. Stout, “The Mechanisms Of Market Inefficiency: An Introduction To The New Finance,” 2003. [Online]. Available: <http://ssrn.com/abstract=470161>
- [76] I. Andrijanić and N. Vidaković, *Poslovanje na burzama*. 2015.
- [77] J. Murphy, *Technical Analysis of the Futures Markets*. 1999. [Online]. Available: www.Fxborssa.com
- [78] R. W. Colby, *The Encyclopedia of Technical Market Indicators*. McGraw-Hill Education, 2002.
- [79] Stock Phoenix Blog, “What is Fundamental and Technical Analysis?” Accessed: Sep. 21, 2024. [Online]. Available: <https://stockphoenix.com/blog/what-is-fundamental-and-technical-analysis/>
- [80] R. Romeu and U. Serajuddin, *Technical Analysis for Direct access Trading*. 2001.
- [81] B. Grahan, “Security Analysis,” *Doodd, David L.*, 2009.
- [82] L. de Prado, “Advances in Financial Machine Learning,” 2018.
- [83] T. Guida, “Big Data and Machine Learning in Quantitative Investment,” 2018. [Online]. Available: www.WileyFinance.com.
- [84] H. Markowitz, “Portfolio Selection,” 1952.
- [85] W. F. Sharpe, “CAPITAL ASSET PRICES: A THEORY OF MARKET EQUILIBRIUM UNDER CONDITIONS OF RISK,” *J Finance*, vol. 19, no. 3, pp. 425–442, 1964, doi: 10.1111/j.1540-6261.1964.tb02865.x.
- [86] M. De Jong, “Portfolio optimization in an uncertain world,” 2016.
- [87] M. Senescall and R. K. Y. Low, “Quantitative Portfolio Management: Review and Outlook,” Sep. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/math12182897.

- [88] S. Kublik and S. Saboo, *Building Innovative NLP Products Using Large Language Models*. O'Reilly Media, 2023.
- [89] A. Louis, "A Brief History of Natural Language Processing." Accessed: Sep. 21, 2024. [Online]. Available: <https://medium.com/@antoine.louis/a-brief-history-of-natural-language-processing-part-1-ffbc937ebce>
- [90] M. T. Pilehva and J. Camacho-Collados, *Embeddings in Natural Language Processing: Theory and Advances in Vector Representations of Meaning*. 2021.
- [91] K. Babić, S. Martinčić-Ipšić, and A. Meštrović, "Survey of neural text representation models," Nov. 01, 2020, *MDPI AG*. doi: 10.3390/info11110511.
- [92] T. Mikolov, K. Chen, G. Corrado, and J. Dean, "Efficient Estimation of Word Representations in Vector Space," Jan. 2013, [Online]. Available: <http://arxiv.org/abs/1301.3781>
- [93] J. Pennington, R. Socher, and C. D. Manning, "GloVe: Global Vectors for Word Representation," 2014. [Online]. Available: <http://nlp>.
- [94] A. R. Openai, K. N. Openai, T. S. Openai, and I. S. Openai, "Improving Language Understanding by Generative Pre-Training," 2018. [Online]. Available: <https://gluebenchmark.com/leaderboard>
- [95] S. Ravichandiran, *Getting started with Google BERT : build and train state-of-the-art natural language processing models using BERT*. 2021.
- [96] Denis Rothman, *Transformers for Natural Language Processing Build Innovative Deep Neural Network Architectures for NLP with Python, Pytorch, TensorFlow, BERT, RoBERTa, and More*. Packt Publishing, Limited, 2021.
- [97] L. Tunstall, L. von Werra, and T. Wolf, *Natural Language Processing with Transformers*. 2022.
- [98] D. Bahdanau, K. Cho, and Y. Bengio, "Neural Machine Translation by Jointly Learning to Align and Translate," Sep. 2024. [Online]. Available: <http://arxiv.org/abs/1409.0473>
- [99] Y. Wang, "An In-Depth Look at the Transformer Based Models." Accessed: Sep. 21, 2024. [Online]. Available: <https://medium.com/the-modern-scientist/an-in-depth-look-at-the-transformer-based-models-22e5f5d17b6b>
- [100] Y. Liu *et al.*, "RoBERTa: A Robustly Optimized BERT Pretraining Approach," Jul. 2019, [Online]. Available: <http://arxiv.org/abs/1907.11692>
- [101] Z. Lan, M. Chen, S. Goodman, K. Gimpel, P. Sharma, and R. Soricut, "ALBERT: A Lite BERT for Self-supervised Learning of Language Representations," Sep. 2019, [Online]. Available: <http://arxiv.org/abs/1909.11942>
- [102] V. Sanh, L. Debut, J. Chaumond, and T. Wolf, "DistilBERT, a distilled version of BERT: smaller, faster, cheaper and lighter," Oct. 2019, [Online]. Available: <http://arxiv.org/abs/1910.01108>

- [103] A. Radford, J. Wu, R. Child, D. Luan, D. Amodei, and I. Sutskever, “Language Models are Unsupervised Multitask Learners,” 2018. [Online]. Available: <https://github.com/codelucas/newspaper>
- [104] T. B. Brown *et al.*, “Language Models are Few-Shot Learners,” 2020.
- [105] OpenAI, “GPT-4 Technical Report,” 2023.
- [106] M. Lewis *et al.*, “BART: Denoising Sequence-to-Sequence Pre-training for Natural Language Generation, Translation, and Comprehension,” Oct. 2019, [Online]. Available: <http://arxiv.org/abs/1910.13461>
- [107] C. Raffel *et al.*, “Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer,” Oct. 2019, [Online]. Available: <http://arxiv.org/abs/1910.10683>
- [108] “Colossal Clean Crawled Corpus (C4).” Accessed: Jul. 10, 2024. [Online]. Available: <https://www.tensorflow.org/datasets/catalog/c4>
- [109] H. Touvron *et al.*, “Llama 2: Open Foundation and Fine-Tuned Chat Models,” Jul. 2023, [Online]. Available: <http://arxiv.org/abs/2307.09288>
- [110] A. Q. Jiang *et al.*, “Mixtral of Experts,” Jan. 2024, [Online]. Available: <http://arxiv.org/abs/2401.04088>
- [111] A. Dubey *et al.*, “The Llama 3 Herd of Models,” Jul. 2024, [Online]. Available: <http://arxiv.org/abs/2407.21783>
- [112] E. Hu *et al.*, “LoRA: Low-Rank Adaptation of Large Language Models,” 2021. [Online]. Available: <https://github.com/microsoft/LoRA>.
- [113] OpenAI, “ChatGPT: Optimizing Language Models for Dialogue.” Accessed: Jul. 10, 2024. [Online]. Available: <https://openai.com/chatgpt/>
- [114] S. Zhang *et al.*, “Instruction Tuning for Large Language Models: A Survey,” 2023. [Online]. Available: <https://github.com/xiaoya-li/>
- [115] Z. Yuan, H. Yuan, C. Tan, W. Wang, S. Huang, and F. Huang, “RRHF: Rank Responses to Align Language Models with Human Feedback without tears,” 2023. [Online]. Available: <https://github.com/GanjinZero/RRHF>.
- [116] C. Gulcehre *et al.*, “Reinforced Self-Training (ReST) for Language Modeling,” 2023.
- [117] L. Ouyang *et al.*, “Training language models to follow instructions with human feedback,” 2022.
- [118] R. Rafailov, A. Sharma, E. Mitchell, S. Ermon, C. D. Manning, and C. Finn, “Direct Preference Optimization: Your Language Model is Secretly a Reward Model,” 2023.
- [119] X. Amatriain, “Prompt Design and Engineering: Introduction and Advanced Methods,” 2024.
- [120] B. Chen, Z. Zhang, N. Langrené, and S. Zhu, “Unleashing the potential of prompt engineering in Large Language Models: a comprehensive review,” 2023.

- [121] Y. Gao *et al.*, “Retrieval-Augmented Generation for Large Language Models: A Survey,” 2024. [Online]. Available: <https://github.com/Tongji-KGLLM/>
- [122] P. Lewis *et al.*, “Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks,” 2021. [Online]. Available: <https://github.com/huggingface/transformers/blob/master/>
- [123] H. Won Chung, L. Hou, S. Longpre, B. Zoph, Y. Tay, and W. Fedus, “Scaling Instruction-Finetuned Language Models,” 2022.
- [124] B. Peng, C. Li, P. He, M. Galley, and J. Gao, “Instruction Tuning with GPT-4,” 2023. [Online]. Available: <https://instruction-tuning-with-gpt-4.github.io/>
- [125] Y. Wang *et al.*, “Self-Instruct: Aligning Language Models with Self-Generated Instructions,” Dec. 2022, [Online]. Available: <http://arxiv.org/abs/2212.10560>
- [126] R. Taori *et al.*, “Alpaca - A strong, replicable instruction-following model,” 2023.
- [127] H. Sun, “Reinforcement Learning in the Era of LLMs: What is Essential? What is needed? An RL Perspective on RLHF, Prompting, and Beyond,” 2023.
- [128] L. Xu, H. Xie, S.-Z. J. Qin, X. Tao, and F. L. Wang, “Parameter-Efficient Fine-Tuning Methods for Pretrained Language Models: A Critical Review and Assessment,” 2023. [Online]. Available: <https://huggingface.co/blog/falcon-180b#hardware-requirements>
- [129] M. Mosbach, T. Pimentel, S. Ravfogel, D. Klakow, and Y. Elazar, “Few-shot Fine-tuning vs. In-context Learning: A Fair Comparison and Evaluation,” 2023. [Online]. Available: <https://github.com/uds-lsv/llmft>.
- [130] A. G. Møller, J. A. Dalsgaard, A. Pera, and L. M. Aiello, “Is a prompt and a few samples all you need? Using GPT-4 for data augmentation in low-resource classification tasks,” Apr. 2023, [Online]. Available: <http://arxiv.org/abs/2304.13861>
- [131] I. Botunac, M. Brkić Bakarić, and M. Matetić, “Comparing Fine-Tuning and Prompt Engineering for Multi-Class Classification in Hospitality Review Analysis,” *Applied Sciences*, vol. 14, no. 14, p. 6254, Jul. 2024, doi: 10.3390/app14146254.
- [132] P. Sahoo, A. K. Singh, S. Saha, V. Jain, S. Mondal, and A. Chadha, “A Systematic Survey of Prompt Engineering in Large Language Models: Techniques and Applications,” Feb. 2024, [Online]. Available: <http://arxiv.org/abs/2402.07927>
- [133] M. Huerta-Enochian, “Instruction Fine-Tuning: Does Prompt Loss Matter?,” 2024.
- [134] Q. Dong *et al.*, “A Survey on In-context Learning,” 2023.
- [135] L. Huang *et al.*, “A Survey on Hallucination in Large Language Models: Principles, Taxonomy, Challenges, and Open Questions,” 2023. [Online]. Available: <https://github.com/>
- [136] O. Ovadia, M. Brief, M. Mishaeli, and O. Elisha, “Fine-Tuning or Retrieval? Comparing Knowledge Injection in LLMs,” 2024.

- [137] L. Graesser and W. L. Keng, “Foundations of Deep Reinforcement Learning,” 2020.
- [138] R. S. Sutton and A. G. Barto, *Reinforcement learning: An introduction*. 2018.
- [139] V. François-Lavet, P. Henderson, R. Islam, M. G. Bellemare, and J. Pineau, “An introduction to deep reinforcement learning,” *Foundations and Trends in Machine Learning*, vol. 11, no. 3–4, pp. 219–354, Dec. 2018, doi: 10.1561/2200000071.
- [140] F. Agostinelli, G. Hocquet, S. Singh, and P. Baldi, “From Reinforcement Learning to Deep Reinforcement Learning: An Overview,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Springer Verlag, 2018, pp. 298–328. doi: 10.1007/978-3-319-99492-5_13.
- [141] A. Zai and B. Brown, “Deep Reinforcement Learning in Action,” 2020.
- [142] M. Sewak, “Deep Reinforcement Learning,” 2019.
- [143] Y. Li, “Deep Reinforcement Learning: An Overview,” Jan. 2018, [Online]. Available: <http://arxiv.org/abs/1701.07274>
- [144] C. Szepesvári, “Algorithms for Reinforcement Learning,” 2009.
- [145] R. E. Bellman, *Dynamic Programming*. Princeton University Press, 1957.
- [146] F. AlMahamid and K. Grolinger, “Reinforcement Learning Algorithms: An Overview and Classification,” Sep. 2022, doi: 10.1109/CCECE53047.2021.9569056.
- [147] OpenAI, “Part 2: Kinds of RL Algorithms.” Accessed: Sep. 21, 2024. [Online]. Available: https://spinningup.openai.com/en/latest/spinningup/rl_intro2.html
- [148] V. Mnih *et al.*, “Human-level control through deep reinforcement learning,” *Nature*, vol. 518, no. 7540, pp. 529–533, Feb. 2015, doi: 10.1038/nature14236.
- [149] A. Mosavi *et al.*, “Comprehensive review of deep reinforcement learning methods and applications in economics,” *Mathematics*, vol. 8, no. 10, Oct. 2020, doi: 10.3390/MATH8101640.
- [150] H. van Hasselt, A. Guez, and D. Silver, “Deep Reinforcement Learning with Double Q-learning,” Sep. 2015, [Online]. Available: <http://arxiv.org/abs/1509.06461>
- [151] J. Schulman, F. Wolski, P. Dhariwal, A. Radford, and O. Klimov, “Proximal Policy Optimization Algorithms,” Jul. 2017, [Online]. Available: <http://arxiv.org/abs/1707.06347>
- [152] R. Kozlica, S. Wegenkittl, and S. Hirländer, “Deep Q-Learning versus Proximal Policy Optimization: Performance Comparison in a Material Sorting Task,” Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2306.01451>
- [153] V. Mnih *et al.*, “Asynchronous Methods for Deep Reinforcement Learning,” Feb. 2016, [Online]. Available: <http://arxiv.org/abs/1602.01783>

- [154] T. Haarnoja, A. Zhou, P. Abbeel, and S. Levine, “Soft Actor-Critic: Off-Policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor,” Jan. 2018, [Online]. Available: <http://arxiv.org/abs/1801.01290>
- [155] R. J. Wieringa, “Design Science Methodology for Information Systems and Software Engineering,” 2015.
- [156] B. Cui and A. E. Gozluklu, “News and Trading After Hours,” 2021. [Online]. Available: <https://ssrn.com/abstract=3796812>
- [157] D. Olson, C. Mossman, and N. T. Chou, “The evolution of the weekend effect in US markets,” *Quarterly Review of Economics and Finance*, vol. 58, pp. 56–63, Nov. 2015, doi: 10.1016/j.qref.2015.01.005.
- [158] OpenAI, “Gymnasium: A toolkit for developing and comparing reinforcement learning algorithms.” Accessed: Jul. 10, 2024. [Online]. Available: <https://gymnasium.farama.org/>
- [159] FinRL, “Three-layer Architecture.” Accessed: Sep. 21, 2024. [Online]. Available: https://finrl.readthedocs.io/en/latest/start/three_layer.html
- [160] S. Jansen, *Machine Learning for Algorithmic Trading*. 2020.
- [161] Finnhub, “Free Stock API and Financial Data.” Accessed: Jul. 10, 2024. [Online]. Available: <https://finnhub.io/>
- [162] Yahoo, “Yahoo Finance - Stock Market Live, Quotes, Business & Finance News”, Accessed: Jul. 10, 2024. [Online]. Available: <https://finance.yahoo.com/>
- [163] Python Software Foundation, “Python Programming Language.” Accessed: Jul. 10, 2024. [Online]. Available: <https://www.python.org/>
- [164] K. Olorunnimbe and H. Viktor, “Deep learning in the stock market—a systematic survey of practice, backtesting, and applications,” *Artif Intell Rev*, vol. 56, no. 3, pp. 2057–2109, Mar. 2023, doi: 10.1007/s10462-022-10226-0.
- [165] New York Stock Exchange, “The New York Stock Exchange (NYSE).” Accessed: Jul. 10, 2024. [Online]. Available: <https://www.nyse.com/>
- [166] E. Callanan *et al.*, “Can GPT models be Financial Analysts? An Evaluation of ChatGPT and GPT-4 on mock CFA Exams,” Oct. 2023, [Online]. Available: <http://arxiv.org/abs/2310.08678>
- [167] CFA Institute, “Chartered Financial Analyst (CFA) Program.” Accessed: Jul. 10, 2024. [Online]. Available: <https://www.cfainstitute.org/>
- [168] LangChain, “LangChain.” Accessed: Jul. 12, 2024. [Online]. Available: <https://www.langchain.com/>
- [169] I. Botunac, A. Panjkota, and M. Matetic, “The effect of feature selection on the performance of long short-term memory neural network in stock market predictions,” in *Annals of DAAAM and Proceedings of the International DAAAM Symposium*, DAAAM International Vienna, 2020, pp. 592–598. doi: 10.2507/31st.daaam.proceedings.081.

- [170] V. Zakamulin, *Market Timing with Moving Averages*. 2017. [Online]. Available: <http://www.springer.com/series/14750>
- [171] A. S. Saud and S. Shakya, “Directional movement index based machine learning strategy for predicting stock trading signals,” *International Journal of Electrical and Computer Engineering*, vol. 12, no. 4, pp. 4185–4194, Aug. 2022, doi: 10.11591/ijece.v12i4.pp4185-4194.
- [172] Stable-Baselines3, “Reliable Reinforcement Learning Implementations.” Accessed: Jul. 10, 2024. [Online]. Available: <https://stable-baselines3.readthedocs.io/>
- [173] X.-Y. Liu, Z. Xiong, S. Zhong, H. Yang, and A. Walid, “Practical Deep Reinforcement Learning Approach for Stock Trading,” Nov. 2018, [Online]. Available: <http://arxiv.org/abs/1811.07522>
- [174] Google, “Google Colaboratory.” Accessed: Jul. 10, 2024. [Online]. Available: <https://colab.research.google.com/>
- [175] W. Zhang *et al.*, “A Multimodal Foundation Agent for Financial Trading: Tool-Augmented, Diversified, and Generalist,” Feb. 2024, [Online]. Available: <http://arxiv.org/abs/2402.18485>
- [176] A. Ye *et al.*, “Learning the Market: Sentiment-Based Ensemble Trading Agents,” Feb. 2024, [Online]. Available: <http://arxiv.org/abs/2402.01441>
- [177] Y. Yu *et al.*, “FinMem: A Performance-Enhanced LLM Trading Agent with Layered Memory and Character Design,” Nov. 2023, [Online]. Available: <http://arxiv.org/abs/2311.13743>
- [178] B. Zhang, H. Yang, T. Zhou, A. Babar, and X.-Y. Liu, “Enhancing Financial Sentiment Analysis via Retrieval Augmented Large Language Models,” Oct. 2023, [Online]. Available: <http://arxiv.org/abs/2310.04027>
- [179] S&P Global, “S&P Dow Jones Indices.” [Online]. Available: <https://www.spglobal.com/en>
- [180] I. Botunac, A. Panjota, and M. Matetic, “The importance of time series data filtering for predicting the direction of stock market movement using neural networks,” in *Annals of DAAAM and Proceedings of the International DAAAM Symposium*, Danube Adria Association for Automation and Manufacturing, DAAAM, 2019, pp. 886–891. doi: 10.2507/30th.daaam.proceedings.123.
- [181] Unsloth, “Unsloth AI.” Accessed: Aug. 22, 2024. [Online]. Available: <https://unsloth.ai/>
- [182] W. McKinney, “Python Data Analysis Library.” Accessed: Feb. 05, 2025. [Online]. Available: <https://pandas.pydata.org/>
- [183] F. Pérez and B. Granger, “Project Jupyter.” Accessed: Feb. 05, 2025. [Online]. Available: <https://jupyter.org/>

- [184] J. D. Hunter, “Matplotlib — Visualization with Python.” Accessed: Feb. 05, 2025. [Online]. Available: <https://matplotlib.org/>
- [185] T. Dettmers, A. Pagnoni, A. Holtzman, and L. Zettlemoyer, “QLoRA: Efficient Finetuning of Quantized LLMs,” May 2023, [Online]. Available: <http://arxiv.org/abs/2305.14314>
- [186] H. Ni *et al.*, “Harnessing Earnings Reports for Stock Predictions: A QLoRA-Enhanced LLM Approach,” Aug. 2024, [Online]. Available: <http://arxiv.org/abs/2408.06634>
- [187] N. Rajaraman, J. Jiao, and K. Ramchandran, “Toward a Theory of Tokenization in LLMs,” Apr. 2024, [Online]. Available: <http://arxiv.org/abs/2404.08335>
- [188] M. Labonne, “Fine-Tune Llama 3.1 Ultra-Efficiently with Unsloth.” Accessed: Aug. 22, 2024. [Online]. Available: <https://towardsdatascience.com/fine-tune-llama-3-1-ultra-efficiently-with-unsloth-7196c7165bab>
- [189] T. Eimer, M. Lindauer, and R. Raileanu, “Hyperparameters in Reinforcement Learning and How To Tune Them,” Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2306.01324>
- [190] Alpaca Markets, “Alpaca Markets.” Accessed: Aug. 22, 2024. [Online]. Available: <https://alpaca.markets/>

Popis slika

Slika 2.1: Arhitektura i primjena FinGPT modela u finansijskom sektoru	11
Slika 2.2: Pregled arhitekture i primjene FinRL modela u finansijskom sektoru	14
Slika 3.1: Prikaz podjele finansijskih tržišta	16
Slika 3.2: Razina tržišne efikasnosti prema hipotezi efikasnog tržišta	19
Slika 3.3: Elementi tehničke analize na finansijskim tržištima	21
Slika 3.4: Komponente fundamentalne analize	22
Slika 3.5: Moderna teorija portfelja, efikasna granica	24
Slika 4.1: Ključne komponente u razvoju NLP-a	25
Slika 4.2: Detaljni prikaz Transformers arhitekture	28
Slika 4.3: Struktura mehanizma pažnje unutar Transformers arhitekture	30
Slika 4.4: Pregled modela temeljenih na Transformers arhitekturi	31
Slika 4.5: Proces treniranja LLM-a s instrukcijama	36
Slika 4.6: Treniranja LLM-a koristeći metodu samostalno generiranih instrukcija	37
Slika 4.7: Prikaz usporedbe RLHF i DPO tehnike	38
Slika 4.8: Prikaz komponenata inženjeringu upita	39
Slika 4.9: Naivni proces generiranja pomoću pretraživanja	41
Slika 4.10: Napredni proces generiranja pomoću pretraživanja	41
Slika 5.1: Dizajn sustava podržanog učenja	44
Slika 5.2: Prikaz algoritama podržanog učenja	49
Slika 5.3: Prikaz <i>Actor-Critic</i> arhitekture	52
Slika 6.1: Prikaz arhitekture sustava	57
Slika 6.2: Procesa obrade i analize teksta u NLP modulu	58
Slika 6.3: Prikaz arhitekture modula za donošenje odluke i trgovanje	60
Slika 6.4: Interakcija stanja, nagrada i akcija unutar PrimoRL modela	61
Slika 6.5: Proces generiranja NLP značajki koristeći upite	69
Slika 6.6: Procedura pripreme podataka za treniranje modela	73
Slika 6.7: Procedura treniranja PrimoGPT modela	74
Slika 7.1: Prikaz podjele podataka	88
Slika 7.2: Kumulativni povrati različitih trgovačkih strategija za dionicu AAPL	105
Slika 7.3: Performanse PrimoRL modela za dionicu AAPL	105
Slika 7.4: Kumulativni povrati različitih trgovačkih strategija za dionicu NFLX	107
Slika 7.5: Performanse PrimoRL modela za dionicu NFLX	108

Slika 7.6: Kumulativni povrati različitih trgovačkih strategija za dionicu MSFT	110
Slika 7.7: Performanse PrimoRL modela za dionicu MSFT	110
Slika 7.8: Kumulativni povrati različitih trgovačkih strategija za dionicu CRM	112
Slika 7.9: Performanse PrimoRL modela za dionicu CRM.....	113
Slika 7.10: Kumulativni povrati različitih trgovačkih strategija za dionicu AMZN ...	115
Slika 7.11: Performanse PrimoRL modela za dionicu AMZN	115
Slika 7.12: Kumulativni povrati za FinRL modele.....	117
Slika 7.13: Kumulativni povrati za PrimoRL modele	118

Popis tablica

Tablica 6.1: Prikaz podataka prikupljenih s Finnhub	64
Tablica 6.2: Prikaz podataka prikupljenih s Yahoo Finance	64
Tablica 6.3: Filtrirani izvori finansijskih novosti.....	66
Tablica 6.4: Primjer osnovnih informacija o tvrtki	67
Tablica 6.5: Primjer priopćenja za javnost.....	67
Tablica 6.6: Primjer tržišnih podataka o dionici	68
Tablica 6.7: Primjer finansijskih novosti	68
Tablica 6.8: Opis NLP značajki.....	70
Tablica 6.9: Primjer instrukcije	71
Tablica 6.10: Primjer ulaznih podataka.....	72
Tablica 6.11: Primjer skupa podatka za trening PrimoGPT modela	74
Tablica 6.12: Ključne komponente okružena	82
Tablica 7.1: Prikaz odabranih dionica za provođenje eksperimenta	88
Tablica 7.2: Prikaz odabranih dionica treniranje PrimoGPT modela.....	89
Tablica 7.3: Primjer generiranih tehničkih indikatora.....	95
Tablica 7.4: Prikaz odabranih hiperparametara.....	98
Tablica 7.5: Primjer generiranih NLP značajki	99
Tablica 7.6: Rezultati PrimoGPT modela	100
Tablica 7.7: Testirani i odabrali hiperparametri za PPO algoritam.....	102
Tablica 7.8: Usporedba performansi trgovачkih strategija za dionicu AAPL.....	104
Tablica 7.9: Prikaz rezultata za dionicu NFLX	107
Tablica 7.10: Prikaz rezultata za dionicu MSFT	109
Tablica 7.11: Prikaz rezultata za dionicu CRM.....	111
Tablica 7.12: Prikaz rezultata za dionicu AMZN.....	114
Tablica 7.13: Prikaz rezultata na razini portfolija	117

Privitak

U svrhu transparentnosti i reproducibilnosti istraživanja, izvorni kod sustava za automatsko trgovanje dostupan je na javnom repozitoriju <https://github.com/ivebotunac/PrimoGPT>. Implementacija je organizirana kroz niz Jupyter bilježnica (engl. Notebooks) i izvornih Python datoteka koje prate strukturu i metodologiju predstavljenu u disertaciji.

Prva bilježnica, *Get and process data*, sadrži implementaciju procesa prikupljanja i obrade podataka opisanog u poglavlju 6.2.. Ovdje su razvijene skripte za dohvati podataka s Finnhub i Yahoo Finance servisa, sustav za filtriranje finansijskih vijesti i pripremu podataka za treniranje modela.

Druga bilježnica, *Train PrimoGPT model*, implementira proces treniranja PrimoGPT modela predstavljen u poglavlju 6.3.2., uključujući sustav za fino podešavanje Llama 3 modela, generiranje upita i instrukcija te evaluaciju točnosti modela.

Treća bilježnica, *Trading benchmark strategy*, sadrži implementaciju referentnih strategija trgovanja opisanih u poglavlju 7.1.3., s tradicionalnim trgovačkim strategijama i tehničkim indikatorima korištenim za usporedbu performansi.

Četvrta bilježnica, *FinRL benchmark strategy*, donosi replikaciju FinRL strategije opisane u poglavlju 7.1.3., koja služi kao referentna implementacija za usporedbu performansi modela.

Peta bilježnica, *Generate NLP features with PrimoGPT*, implementira proces generiranja NLP značajki opisan u poglavlju 6.3., sa sustavom za automatsku ekstrakciju značajki korištenjem PrimoGPT modela.

Šesta bilježnica, *PrimoRL trading with NLP features*, sadrži implementaciju PrimoRL modela i trgovačkog okruženja predstavljenog u poglavlju 6.4., koje integrira NLP značajke u proces donošenja odluka. U ovoj bilježnici provodi se eksperimentalno testiranje sustava na odabranim dionicama tehnoloških kompanija, a rezultati tih eksperimenata detaljno su analizirani i prikazani u poglavlju 7.4., gdje je demonstrirana uspešnost modela u usporedbi s referentnim strategijama trgovanja.

Programska implementacija sustava organizirana je kroz dva glavna modula. Modul PrimoGPT (src/primogpt) sadrži sustav za konstrukciju upita, dohvaćanje i obradu podataka te generiranje NLP značajki, s posebno razvijenim sustavom za kreiranje instrukcija i upravljanje interakcijom s jezičnim modelom. Modul PrimoRL (src/primorl), izrađen je na temelju originalne FinRL implementacije, proširuje osnovnu funkcionalnost s prilagođenim trgovačkim okruženjima koja integriraju NLP značajke.

Detaljna dokumentacija i upute za korištenje dostupne su unutar repozitorija. Kod je razvijen u sklopu doktorskog istraživanja i namijenjen je prvenstveno za edukativne i istraživačke svrhe.