

Implementacija višeagentnog sustava umjetne inteligencije za donošenje financijskih trgovačkih odluka

IVE BOTUNAC
Fakultet informatike i digitalnih tehnologija
Sveučilište u Rijeci
Radmile Matejčić 2, 51000 Rijeka
Hrvatska
ive.botunac@gmail.com
ORCID iD: <https://orcid.org/0000-0003-3561-7089>

Izvorni znanstveni rad / *Original scientific paper*

UDK / UDC: 004.8:658.14

Primljeno / Received: 01. rujna 2025. / September 01st, 2025.

Prihvaćeno za objavu / Accepted for publishing: 11. studenog 2025. / November 11th, 2025.

DOI: 10.15291/oc.4863

Sažetak: Primjena umjetne inteligencije u financijskim analizama dovodi do razvoja naprednih višeagentnih sustava koji omogućuju učinkovitiju analizu i donošenje odluka od dosadašnjih metoda. Ovaj rad predstavlja razvoj i implementaciju višeagentnog sustava umjetne inteligencije za generiranje financijskih trgovačkih preporuka koji integrira specijalizirane agente za prikupljanje podataka, tehničku analizu, obradu vijesti i upravljanje portfeljem. Sustav kombinira kvantitativnu analizu zasnovanu na tehničkim indikatorima s kvalitativnim uvidima iz financijskih vijesti tehnikama obrade prirodnog jezika, poput inženjeringa upita i generiranja s pomoću pretraživanja. Arhitektura ovoga sustava omogućuje samostalno djelovanje četiri specijalizirana agenta koji pridonose generiranju trgovačkih preporuka. Evaluacija provedena na sedam reprezentativnih dionica tijekom šestomjesečnog razdoblja 2025. godine pokazuje značajno poboljšanje u upravljanju rizikom u odnosu na referentnu strategiju „kupi i drži“. Rezultati prikazuju značajno smanjenje volatilnosti i maksimalnog pada većine analiziranih dionica, posebno kod visoko volatilnih dionica poput Tesle gdje sustav održava maksimalni pad na 7,72 % u odnosu na 47,84 % referentne strategije. Sustav prilagođava trgovačke preporuke različitim tržišnim uvjetima i specifičnostima svake dionice, čime održava stabilnost portfelja u razdobljima kada su tržišta nestabilna. Analiza financijskih vijesti s pomoću NLP-a omogućuje sustavu da prepozna je li vijest pozitivna ili negativna, koliko je važna za dionicu i kako bi mogla utjecati na njezinu cijenu. Unatoč identificiranim ograničenjima u vidu opreznijeg pristupa tijekom snažnih uzlaznih trendova, modularnost ove arhitekture omogućuje kontinuirani razvoj i optimizaciju pojedinih komponenti. Istraživanje potvrđuje vrijednost višeagentnih pristupa u integraciji različitih izvora podataka za poboljšanje procesa donošenja trgovačkih odluka.

Ključne riječi: višeagentni sustavi, umjetna inteligencija, obrada prirodnog jezika, strategije trgovanja, upravljanje rizikom

JEL klasifikacija: G11, G17, C45

1. Uvod

Financijska tržišta su temeljne komponente globalnih ekonomskih sustava koji omogućuju alokaciju kapitala i upravljanje rizikom među različitim sudionicima. Prema Orsagu (2015), financijska tržišta dijele se na tržište novca i tržište kapitala, pri čemu svaki segment obuhvaća specifične financijske instrumente s različitim karakteristikama dospelja i rizika. Saunders et al. (2022) dodatno specificiraju da se financijska tržišta mogu svrstati u dvije glavne kategorije: primarna naspram sekundarnih tržišta te novčana tržišta naspram tržišta kapitala. Ta podjela omogućuje dublje razumijevanje funkcija i procesa unutar financijskih tržišta u kojima se naglašavaju razlike između tržišta na temelju dospelja vrijednosnih papira koji se na njima trguju (Mishkin i Eakins, 2018).

Tržište kapitala, kao glavni segment financijskog sustava, obuhvaća trgovinu dionicama i dugoročnim dužničkim instrumentima s rokom dospelja duljim od jedne godine. Glavne karakteristike ovoga tržišta obuhvaćaju veće fluktuacije cijena u odnosu na instrumente novčanog tržišta te imaju značajnu ulogu u dugoročnom financiranju korporacija i vlada. Fabozzi et al. (2019) ističu da financijska tržišta pružaju razne ekonomske funkcije poput cjenovnog otkrivanja i likvidnosti, omogućujući efikasnu alokaciju sredstava unutar ekonomije. Analiza financijskih tržišta tradicionalno se provodi dvama glavnim pristupima koji pružaju različite perspektive na procjenu vrijednosti i predviđanje tržišnih kretanja. Tehnička analiza usmjerava se na proučavanje povijesnih podataka o cijenama i volumenima trgovanja radi identifikacije obrazaca i trendova (Murphy, 1999). Fundamentalna analiza fokusira se na procjenu intrinzične vrijednosti vrijednosnica analizom financijskih izvještaja, makroekonomskih pokazatelja i industrijskih čimbenika (Bartram i Grinblatt, 2014).

Hipoteza efikasnog tržišta (engl. *Efficient Market Hypothesis* – EMH) središnji je koncept u financijskoj teoriji koji objašnjava kako se informacije reflektiraju u cijenama dionica. Razvoj EMH-a neodvojivo je povezan s radovima (Fama, 1965; 1991; 1970) čija su istraživanja postavila temelje za suvremeno razumijevanje tržišnih mehanizama. Ta hipoteza pretpostavlja da u zakonski uređenom, dobro funkcionirajućem, transparentnom i konkurentnom tržištu investitori mogu brzo i racionalno reagirati na sve tržišne informacije. Međutim, kasnija istraživanja proširila su razumijevanje složenosti tržišnih dinamika. Malkiel (2003) ističe da iako tržišta nisu savršena i postoje anomalije, rijetko pružaju sustavne prilike za ostvarivanje izvanrednih povrata. Timmermann i Granger (2004) dodatno naglašavaju da postoji prostor za privremenu predvidljivost zbog neprestanog učenja i prilagođavanja sudionika na tržištu kapitala, spominjući adaptivnu prirodu tržišta koja odražava složenost ljudskog ponašanja i evolucijskih procesa. Ta ograničenja EMH-a otvaraju prostor za razvoj naprednih sustava koji mogu identificirati i iskoristiti tržišne neučinkovitosti integracijom različitih izvora podataka i analitičkih pristupa. Napredak u području strojnog učenja (engl. *Machine Learning* – ML) doveo je do značajnih promjena u načinu razvoja i implementaciji automatiziranih sustava za trgovanje gdje algoritmi mogu prepoznati složene obrasce u financijskim podacima. Tradicionalne tehnike analize zamjenjuju se naprednijim pristupima koji se mogu svrstati u četiri glavne kategorije: statističke metode, prepoznavanje uzoraka, strojno učenje i analiza sentimenta. Ta evolucija prema integriranim sustavima strojnog učenja obilježena je prelaskom s tradicionalnih metoda na napredne pristupe poput povratnih neuronskih mreža (engl. *Recurrent Neural Network* – RNN), mreža dugotrajne kratkoročne memorije (engl. *Long Short-Term Memory* – LSTM) i Transformer (Zou et al., 2022).

Primjena umjetne inteligencije (engl. *Artificial Intelligence* – AI) u financijskim analizama omogućuje procesuiranje velikih količina strukturiranih i nestrukturiranih podataka te izvlačenje kompleksnih uzoraka koji tradicionalnim metodama nisu dostupni. Razvoj velikih jezičnih modela (engl. *Large*

Language Model – LLM) i tehnika obrade prirodnog jezika (engl. *Natural Language Processing* – NLP) omogućuje interpretaciju financijskih vijesti, izvještaja i drugih tekstualnih izvora informacija (Yang, Liu i Wang, 2023). Unatoč napretku pojedinačnih AI tehnologija, složenost financijskih tržišta zahtijeva integrirani pristup koji nadilazi ograničenja monolitnih sustava koji se često suočavaju s izazovima poput nedovoljne fleksibilnosti i poteškoća u prilagodbi na različite izvore podataka.

Razvoj višeagentnih sustava (engl. *Multi-Agent Systems*) sljedeća je evolucijska faza u automatizaciji financijskih analiza, omogućujući specijalizaciju različitih komponenti sustava za specifične analitičke zadatke. AI agenti predstavljaju autonomne entitete sposobne za razumijevanje okruženja, donošenje odluka i poduzimanje akcija za postizanje specifičnih ciljeva (Acharya, Kuppan i Divya, 2025). Takav pristup simulira kolaborativni proces odlučivanja kakav provode timovi iskusnih analitičara, pri čemu svaki agent pridonosi svojom ekspertizom u određenoj domeni. Kolaboracija između agenata karakterizira se različitim tipovima suradnje, strukturama komunikacije i strategijama koordinacije koje omogućuju optimalno iskorištavanje specijaliziranih sposobnosti pojedinih agenata (Tran et al., 2025). Unatoč obećavajućim rezultatima postojećih višeagentnih sustava, većina istraživanja fokusira se na specijalizirane domene ili koristi ograničene izvore podataka. Potreba za integriranim sustavom koji kombinira kvantitativne tehničke indikatore s kvalitativnom analizom vijesti naprednim NLP modelima ostaje nedovoljno istražena. Dodatno, pitanje kako optimalno koordinirati različite agentske specijalizacije za donošenje koherentnih trgovačkih odluka predstavlja aktivan istraživački izazov koji zahtijeva daljnju sistematsku evaluaciju.

Cilj ovoga rada je razvoj i implementacija višeagentnog AI sustava za generiranje financijskih trgovačkih preporuka koji integrira specijalizirane agente za prikupljanje podataka, tehničku analizu, obradu vijesti i upravljanje portfeljem. Specifični ciljevi istraživanja obuhvaćaju:

- dizajn modularne arhitekture koja omogućuje neovisni razvoj i optimizaciju specijaliziranih agenata za različite analitičke zadatke
- implementaciju NLP modela, uključujući inženjering upita i RAG pristup, za transformaciju nestrukturiranih financijskih vijesti u kvantitativne značajke
- integraciju tehničkih indikatora i NLP značajki koordiniranim procesom donošenja odluka koji simulira kolaboraciju financijskih stručnjaka
- empirijsku evaluaciju sustava povratnim testom na reprezentativnom uzorku dionica tijekom šestomjesečnog razdoblja s usporedbom prema tradicionalnoj „kupi i drži“ strategiji.

Sustav se temelji na koordinaciji različitih AI agenata što omogućuje kombiniranje različitih analitičkih pristupa za generiranje trgovačkih preporuka. Takav pristup nadilazi ograničenja pojedinačnih metoda sinergijom kvantitativne analize tržišnih podataka i kvalitativnog razumijevanja kontekstualnih informacija iz financijskih izvora, istovremeno održavajući modularnost koja omogućuje kontinuirani razvoj i optimizaciju pojedinih komponenti sustava.

Struktura rada organizirana je u pet glavnih cjelina koje sustavno pristupaju problematici razvoja višeagentnog AI sustava. Sljedeće poglavlje pruža sveobuhvatan pregled postojećih istraživanja u domeni automatiziranih trgovačkih sustava s posebnim naglaskom na razvoj metoda predviđanja na tržištu kapitala i pregled višeagentnog AI sustava u financijama. Treće poglavlje detaljno obrađuje metodološki pristup, uključujući arhitekturu sustava, specifikacije agenata i mehanizme koordinacije. Četvrto poglavlje predstavlja rezultate implementacije i evaluacije sustava empirijskim testiranjem. Peto poglavlje zaključno diskutira implikacije rezultata i postavlja smjernice za buduća istraživanja.

2. Pregled literature

Novija znanstvena literatura u domeni financijskih tehnologija (engl. *FinTech*) obilježena je ubrzanim razvojem koje integrira umjetnu inteligenciju s tradicionalnim pristupima financijskim analizama. Ovaj pregled literature sustavno analizira dva smjera istraživanja koja su formirala temelj za razvoj višeagentnih sustava u financijama: razvoj metoda predviđanja na tržištu kapitala te razvoj višeagentnih AI sustava u financijskim aplikacijama. Detaljnom analizom postojećih rješenja i njihovih ograničenja identificiraju se mogućnosti za napredak koje pružaju koordinirani sustavi specijaliziranih agenata.

2.1 Metode predviđanja na tržištu kapitala

Razvoj prediktivnih metoda na financijskim tržištima obilježava progresivni prijelaz s konvencionalnih statističkih pristupa na sofisticirane sustave temeljene na strojnom učenju i obradi prirodnog jezika. Fischer i Krauss (2018) demonstrirali su kako LSTM mreže mogu postići impresivne dnevne prinose od 0,46 %, pokazujući sposobnost tih arhitektura da uhvate dugotrajne ovisnosti u financijskim podacima koje tradicionalni modeli često propuštaju.

Značajni napredak postignut je razvojem inovativnih pristupa augmentaciji podataka i integraciju multimodalnih informacija. Baek i Kim (2018) predstavili su ModAugNet arhitekturu koja postiže redukciju srednje kvadratne pogreške za više od 50 % na S&P500 i KOSPI200 indeksima. Paralelno, FinBERT model uspješno nadilazi ograničenja standardnih NLP modela treniranjem na šest specifičnih zadataka koji omogućuju učinkovitije hvatanje semantičkih informacija iz financijskih tekstova, posebno se ističući u analizi sentimenta financijskih vijesti (Huang, Wang i Yang, 2023).

Integracija višeslojnih arhitektura dubokih neuronskih mreža (engl. *Deep Neural Network* – DNL) s naprednim NLP modelima evolucijski je korak u razvoju prediktivnih sustava. Aldhyani i Alzahrani (2022) razvili su okvir koji kombinira različite tipove dubokih slojeva, demonstrirajući poboljšanja eksploatacijom komplementarnih karakteristika. BloombergGPT model s 50 milijardi parametara pokazuje značajnu prednost kroz sposobnost integracije i analiza golemih količina financijskih podataka iz različitih izvora (Wu et al., 2023). Napredak u domeni velikih jezičnih modela specifičnih za financije donosi nove mogućnosti u analizi nestrukturiranih podataka. Wang, Yang i Wang (2023) predstavljaju FinGPT model koji izvlači profitabilne značajke iz objavljenih vijesti povezanih s kretanjima cijena, primjenjujući ih na buduće tržišne prognoze. Takvi pristupi nadilaze jednostavne sentiment analize time što sumiraju i analiziraju multimodalne financijske tekstove, omogućujući dublje razumijevanje kontekstualnih informacija. Trenutačni trendovi usmjereni su na hibridne pristupe koji integriraju različite tehnike strojnog učenja s tradicionalnim financijskim analizama i naprednim NLP pristupima. Ku et al. (2023) razvili su sustav predviđanja koji integrira LSTM metode s dinamičkim indikatorima, demonstrirajući kako regionalno specifične prilagodba može poboljšati prediktivnu moć modela. Ta integracija omogućuje stvaranje robusnih sustava koji kombiniraju kvantitativne analize s dubinskim razumijevanjem kontekstualnih informacija.

2.2 Višeagentni AI sustavi u financijama

Daljnji razvoj unutar financijskih tehnologija temeljenih na umjetnoj inteligenciji dospio je do faze razvoja višeagentnih sustava koji predstavljaju novu paradigmu u automatiziranom trgovanju i financijskim analizama. Takvi sustavi karakterizirani su koordiniranim radom specijaliziranih AI

agenata koji kolaborativnim procesima simuliraju kompleksno odlučivanje timova iskusnih financijskih stručnjaka. Tran et al. (2025) identificiraju da se kolaboracija između agenata karakterizira različitim tipovima suradnje: kooperaciju, natjecanje i kompetitivnost te različitim strukturama komunikacije poput centraliziranih, decentraliziranih i hijerarhijskih pristupa koji omogućuju optimalno iskorištavanje specijaliziranih sposobnosti pojedinih agenata.

Specijalizirani AI agenti u financijskim aplikacijama demonstriraju značajne napretke u analizi tržišnih podataka i generiranju trgovačkih preporuka. StockAgent sustav omogućuje simulaciju realnih trgovačkih okruženja višeagentnim pristupom dizajniranim za istraživanje utjecaja vanjskih čimbenika na trgovačke aktivnosti (Zhang et al., 2024a). Sustav uključuje jedinstveni sustav oglasne ploče (engl. *Bulletin Board System* – BBS) koji omogućuje agentima dijeljenje trgovačkih savjeta, čime se simulira realistično okruženje u kojem mišljenja drugih investitora mogu utjecati na investicijske odluke. Slične pristupe simuliranja strukture profesionalnih trgovačkih tvrtki razvijaju (Xiao et al., 2025) kroz TradingAgents okvir koji kombinira fundamentalne, sentiment i tehničke analitičare s upravljanjem rizika. Han et al. (2024) dodatno pokazuju da koordinacija između specijaliziranih agenata može nadmašiti performanse pojedinačnih sustava različitim kolaborativnim strukturama.

Novije istraživanje proširuje razumijevanje višeagentnih sustava implementacijom naprednih memorijskih mehanizama i definiranja karaktera agenata. Yu et al. (2023) predstavljaju FinMem sustav koji se koristi slojevitom memorijskom arhitekturom (engl. *Layered Memory*) i specifičnim dizajnom karaktera agenata kako bi poboljšali performanse trgovanja. Sustav implementira tri tipa memorije: osnovnu tržišnu informacijsku memoriju, memoriju refleksije ulaganja i memoriju opće stručnosti, omogućujući agentima da integriraju povijesno tržišno znanje s trenutnim uvjetima za dugoročne investicijske strategije. Multimodalni pristupi u višeagentnim sustavima značajan su korak naprijed u integraciji heterogenih izvora podataka. FinAgent, kao napredni multimodalni agent na području financija, kombinira analizu cijena, vizualnih prikaza, vijesti i stručnih analiza specijaliziranim modulima za tržišnu inteligenciju (Zhang et al., 2024b). Sustav uključuje jedinstveni dvostruki modul za refleksiju koji kombinira nisko-razinsku refleksiju za analizu kretanja cijena s visoko-razinskom refleksijom za procjenu prošlih trgovačkih odluka, simulirajući proces učenja u donošenju odluka. FinAgent postiže više od 36 % prosječno poboljšanje profita u odnosu na postojeće metode, s posebno impresivnim 92,27 % povratom na jednom od testiranih skupova podataka. Razvoj platformi s otvorenim kodom dodatno pridonosi demokratizaciji pristupa naprednim AI alatima u financijama. Yang et al. (2024) predstavljaju FinRobot kao otvorenu AI agent platformu koja integrira različite LLM modele modularnom četveroslojnom arhitekturom, omogućujući specijalizaciju agenata za različite financijske zadatke od tržišnog predviđanja do analize dokumenata i procjene rizika.

3. Metodologija i podaci

Razvoj učinkovitog sustava za generiranje financijskih trgovačkih preporuka zahtijeva sveobuhvatan metodološki pristup koji integrira napredne NLP modele s višeagentnim arhitekturama. Ta metodologija predstavlja implementaciju višeagentnog sustava koji koordinacijom specijaliziranih agenata omogućuje detaljniju analizu financijskih tržišta, nadilazeći ograničenja tradicionalnih monolitnih pristupa koji se često suočavaju s nedovoljnom fleksibilnošću i poteškoćama u prilagodbi na različite izvore podataka.

Metodološki okvir temelji se na paradigmi distribuiranog donošenja odluka kolaboracijom autonomnih agenata, pri čemu je svaki agent specijaliziran za specifične analitičke zadatke poput prikupljanja

podataka, tehničke analize, obrade vijesti i upravljanja portfeljem. Sustav procesuirao različite izvore podataka uključujući strukturirane financijske podatke i nestrukturirane tekstualne informacije, omogućujući dublje razumijevanje tržišnih dinamika kombinacijom kvantitativnih i kvalitativnih analiza.

3.1 Prikupljanje i obrada podataka

Metodologija obrade podataka organizirana je hijerarhijskim pristupom koji prati logičan slijed od prikupljanja sirovih podataka do generiranja složenih značajki za analizu (Liu et al., 2023). Proces počinje dohvaćanjem strukturiranih tržišnih podataka i polustrukturiranih vijesti, nastavlja se računanjem tehničkih indikatora iz obrađenih podataka te završava s generiranjem NLP značajki tehnikama inženjeringa upita (engl. *Prompt Engineering*) i generiranja s pomoću pretraživanja (engl. *Retrieval-Augmented Generation – RAG*) (Gao et al., 2024).

Proces prikupljanja podataka implementiran je dvama primarnim izvorima koji omogućuju pristup različitim aspektima financijskih tržišta (Guida, 2018). Za potrebe istraživanja odabrani su Finnhub i Yahoo Finance kao primarni izvori podataka zbog pružanja besplatnog aplikacijsko-programskog sučelja (engl. *Application Programming interface – API*) za istraživače.

Yahoo Finance primjenjuje se za dohvaćanje tržišnih podataka o cijenama dionica i drugih tržišnih parametara poput volumena trgovanja, temeljnih za generiranje tehničkih indikatora. Tržišni podaci o dionicama obuhvaćaju informacije kao što su otvorena, najviša, najniža i zatvorena cijena dionice (engl. *Open, High, Low, Close, Volume – OHLCV*) na dnevnoj bazi, kao i prilagođene zatvorene cijene koje uzimaju u obzir korporativne akcije poput podjele dionica i dividendi. Finnhub se primjenjuje za prikupljanje osnovnih podataka o tvrtkama i za prikupljanje raznih financijske novosti. Kombinacija tih dvaju izvora omogućuje sveobuhvatan pristup prikupljanju podataka koji pokriva kvantitativne tržišne pokazatelje i kvalitativne informacije potrebne za izvršavanje ovoga višeagentnog AI sustava. Prikaz svih prikupljenih podataka s Yahoo Finance i Finnhub servisa nalazi se u Tablici 1.

Tablica 1. Prikaz prikupljenih sirovih podataka

Tip podataka	Značajka	Izvor	Opis	Frekvencija ažuriranja
Strukturirani tržišni podaci	OHLCV podaci	Yahoo Finance	Dnevni podaci o cijenama i volumenu	Dnevno
	Osnovni financijski pokazatelji	Finnhub	P/E omjer, EPS, dividende	Kvartalno
Polustrukturirani tržišni podaci	Financijske vijesti	Finnhub	Naslovi i sažeci vijesti	Dnevno
Nestrukturirani tržišni podaci	Sadržaj članaka	Portali	Puni tekst financijskih članaka	Dnevno

Izvor: izrada autora (2025)

Nakon prikupljanja i organizacije sirovih tržišnih podataka, sljedeći korak je transformacija osnovnih podataka o cijeni u tehničke indikatore. Taj proces je važan za kvantifikaciju tržišnih trendova, signala i volatilnosti koji omogućuju dublju analizu tržišnih dinamika. Tehnički indikatori generiraju se izravno iz obrađenih OHLCV podataka dohvaćenih putem Yahoo Finance API-ja implementacijom standardnih

formula za najšire korištene indikatore u tehničkoj analizi. Takav pristup osigurava potpunu kontrolu nad procesima izračuna i eliminira ovisnost o vanjskim izvorima, omogućujući dosljednost i pouzdanost generiranja značajki potrebnih za procese analize koji slijede (Botunac, Panjkota i Matetić, 2020).

Proces generiranja značajki tehničkih indikatora implementiran je radi iskorištavanja ovih značajki za razvoj višeagentnog sustava (Liu et al., 2022). Odabir specifičnog skupa tehničkih indikatora temeljen je na tri ključna kriterija.

Prvo, potrebno je pokrivanje komplementarnih dimenzija tržišne analize: indikatori praćenja trendova identificiraju smjer i snagu kretanja različitim vremenskim horizontima, dok indikatori momenta detektiraju brzinu promjena i ekstremne tržišne uvjete koji signaliziraju potencijalne preokrete. Drugo, odabrani indikatori pripadaju najšire korištenim i empirijski validiranim tehnikama koje su demonstrirale učinkovitost u automatiziranom trgovanju (Fischer i Krauss, 2018; Liu et al., 2022; Sun et al., 2022), što osigurava usporedivost rezultata s postojećim istraživanjima. Treće, ovi indikatori zahtijevaju različite tipove ulaznih podataka čime se omogućuje višeagentnom sustavu da ekstrahira različite perspektive iz istog skupa OHLCV podataka, minimizirajući redundanciju signala. Implementirani tehnički indikatori prikazani su u Tablici 2.

Tablica 2. Implementirani tehnički indikatori

Naziv tehničkog indikatora	Formula
SMA	$SMA_t(n) = \frac{1}{n} \sum_{i=0}^{n-1} P_{t-i}$
MACD	$MACD_t = EMA_m(t) - EMA_n(t)$ $Signal_t = EMA_p(t) \cdot MACD_t$
RSI	$RSI = 100 - \left(\frac{100}{1 + RS} \right)$
CCI	$RSI = 100 - \left(\frac{100}{1 + RS} \right)$

Izvor: izrada autora (2025)

Jednostavan pomičan prosjek (engl. *Simple Moving Average* – SMA) implementiran je kao temeljni indikator koji se upotrebljava za izračunavanje prosječne vrijednosti skupa cijena u određenom razdoblju. Prosječna vrijednost izračunava se kao aritmetička sredina n posljednjih zatvarajućih cijena, čime se omogućuje glađenje kratkotrajnih fluktuacija cijena i isticanje dugotrajnijih trendova na tržištu. Korišteni su SMA periodi od 20 i 50 dana za pokrivanje kratkoročnih i srednjoročnih trendova (Murphy, 1999).

Indikator konvergencija divergencija pomičnih prosjeka (engl. *Moving Average Convergence Divergence* – MACD) implementiran je razlikom između dviju eksponencijalnih pomičnih prosječnih vrijednosti (engl. *Exponential Moving Average* – EMA) različitih perioda, tipično koristeći kombinaciju 12-dnevne i 26-dnevne EMA. Signalna linija MACD-a računa se kao 9-dnevna EMA od MACD vrijednosti i koristi se za generiranje trgovačkih signala kada MACD linija prelazi signalnu liniju, što može ukazivati na uzlazni ili silazni moment (Colby, 2003).

Indeks relativne jakosti (engl. *Relative Strength Indeks* – RSI) koncipiran je kao alat za kvantifikaciju

brzine i promjena u cjenovnim pokretima financijskih instrumenata. Indikator varira od 0 do 100, pri čemu vrijednosti iznad 70 upućuju na potencijalno preкупljeno stanje, a vrijednosti ispod 30 na potencijalno rasprodane uvjete tržišta. Implementiran je s preporučenim periodom od 14 dana za optimalan omjer između osjetljivosti i stabilnosti (Murphy, 1999).

Indeks robnih kanala (engl. *Commodity Channel Indeks* – CCI) implementiran je za identifikaciju cikličnih trendova mjerenjem razlike između tipične cijene i njezina jednostavnog pomičnog prosjeka, standardizirane prema srednjoj apsolutnoj devijaciji. Tipična cijena računa se kao prosjek najviše, najniže i zatvarajuće cijene unutar perioda. Konstanta 0.015 u nazivniku koristi se kako bi većina vrijednosti CCI oscilirala u opsegu od -100 do +100, što olakšava interpretaciju indikatora (Colby, 2003).

3.2 Generiranje NLP značajki

Metodologija generiranja NLP značajki najkompleksniji je dio sustava obrade podataka koji omogućuje transformaciju kvalitativnih financijskih informacija u kvantitativne numeričke vrijednosti. Taj proces zahtijeva integraciju tehnika inženjeringa upita s pristupima generiranja s pomoću pretraživanja kako bi se iz nestrukturiranih financijskih vijesti i priopćenja generirali numerički pokazatelji sentimenta, relevantnosti i potencijalnog tržišnog utjecaja. Za razliku od tehničkih indikatora koji se generiraju iz strukturiranih OHLCV podataka, NLP značajke omogućuju sustavu da razumije i kvantificira kvalitativne čimbenike koji mogu značajno utjecati na tržišna kretanja (Huang, Wang i Yang, 2023).

3.2.1 Inženjering upita kao temelj generiranja značajki

Osnovu korištenja velikih jezičnih modela čine detaljno osmišljeni tekstualni unosi, poznatiji kao upiti (engl. *Prompts*) koji usmjeravaju izlaz modela (Chen et al., 2023). 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 (engl. *Chain-of-thought* – CoT), gdje se model vodi logičkim procesom razmišljanja kako bi se došlo do odgovora (Brown et al., 2020).

Uspješnost upita ovisi o jasnoći instrukcija i preciznosti definiranja očekivanih izlaza, pri čemu je važno pronaći ravnotežu između detaljnosti uputa i fleksibilnosti modela. U financijskom kontekstu, upiti moraju sadržavati dovoljno informacija o tvrtki i tržišnim uvjetima da model može donijeti informirane procjene, ali ne smiju biti preopterećeni nepotrebnim detaljima koji mogu otežati fokusiranje na ključne dijelove upita.

Proces konstrukcije upita implementiran je pristupom koji se sastoji od instrukcije i niza ulaza, kako je prikazano u Tablici 3. U tom kontekstu, upit je strukturiran kako bi model izvršio analizu za specifičnu tvrtku, procijenio utjecaj novosti i objava na cijenu dionice te kvantificirao taj utjecaj serijom značajki poput sentimenta, relevantnosti i potencijalnog utjecaja na trend (Callanan et al., 2023). Struktura upita mora biti dovoljno fleksibilna da se prilagodi različitim tipovima financijskih vijesti, od rutinskih priopćenja tvrtke do značajnih korporativnih događaja.

Tablica 3. Primjer strukture upita za generiranje NLP značajki

Komponenta	Opis	Primjer sadržaja
Sistemska instrukcija	Definiranje uloge modela	You are a quantitative analyst extracting trading signals from news for algorithmic trading.
Analitički zadatak	Specifična instrukcija za analizu	Analyze news for {symbol} and generate 7 precise features predicting next trading day price movement.
Ciljanje značajke	Popis značajki za generiranje	news_relevance, sentiment, price_impact_potential, trend_direction, earnings_impact, investor_confidence, risk_profile_change.
Ulazni podaci	Vijesti i priopćenja za analizu	Recent news articles with significance scores: [NEWS DATA] and [SIGNIFICANT NEWS] sections.
Format izlaza	Specifikacija formata odgovora	Return ONLY valid JSON structure with integer values (-2 to 2).

Izvor: izrada autora (2025)

3.2.2 Implementacija tehnike generiranja s pomoću pretraživanja

RAG predstavlja značajnu inovaciju koja omogućuje integraciju dinamičkih vanjskih izvora znanja s prethodno treniranim jezičnim modelima, što je posebno važno u financijskoj domeni u kojoj se tržišni uvjeti i kontekst brzo mijenjaju (Lewis et al., 2021). U kontekstu analize financijskih vijesti, RAG metoda omogućuje modelima da pristupe relevantnim povijesnim informacijama o tvrtkama, sektorskim trendovima i sličnim tržišnim događajima koji mogu obogatiti razumijevanje trenutnih vijesti.

Implementacija RAG-a u našem sustavu omogućuje da se analiza pojedinačne vijesti obogati s kontekstualnim informacijama o prethodnim performansama tvrtke, industrijskim trendovima i sličnim događajima iz prošlosti koji mogu pomoći u procjeni potencijalnog utjecaja na cijenu dionice. Sustav dohvaćanja koristi se semantičkim pretraživanjem za identificiranje relevantnih kontekstualnih informacija koje mogu poboljšati točnost generiranih NLP značajki, omogućujući modelu da razumije vijesti u širem financijskom kontekstu umjesto oslanjanja samo na sadržaj pojedinačnog članka.

Taj pristup posebno je koristan za analizu financijskih vijesti jer omogućuje modelu da razlikuje rutinske objave i značajne događaje na temelju povijesnih obrazaca i kontekstualnih informacija.

3.2.3 Strukturiranje izlaznih podataka


Generirane NLP značajke strukturiraju se u standardizirani format koji omogućuje dosljednu integraciju s tehničkim indikatorima i tržišnim podacima u procesima analize koji slijede. Kako je prikazano u Tablici 4., svaka značajka definirana je jasnim opisom i numeričkom skalom koja omogućuje kvantitativnu analizu. Odabir numeričke skale od -2 do +2 omogućuje precizno kvantificiranje različitih intenziteta sentimenata i utjecaja bez pretjerane složenosti.

Tablica 4. Specifikacija generiranih NLP značajki

Naziv značajke	Raspon	Opis značajke
Sentiment	-2 do +2	Ocjena emocionalnog tona financijskih vijesti prema dionici. Negativne vrijednosti označavaju pesimistične vijesti, pozitivne optimistične, dok nula predstavlja neutralan ton.
Relevantnost	-2 do +2	Procjena direktne povezanosti vijesti s performansama dionice. Vrijednost 0 označava potpunu nerelevantnost, dok 3 predstavlja vijesti izravno povezane s poslovanjem tvrtke.
Potencijalni utjecaj na cijenu	-2 do +2	Predviđeni utjecaj vijesti na cijenu dionice u sljedećoj trgovinskoj sesiji. Ekstremne negativne vrijednosti upućuju na očekivani pad cijene, pozitivne na rast.
Smjer trenda	-2 do +2	Vjerojatni smjer dugoročnijeg trenda cijene dionice na temelju analiziranih informacija. Pozitivne vrijednosti sugeriraju uzlazni trend, negativne silazni.
Utjecaj na zarade	-2 do +2	Procjena potencijalnog utjecaja vijesti na buduće financijske rezultate tvrtke. Pozitivne vrijednosti označavaju očekivano poboljšanje zarada, negativne pogoršanje.
Povjerenje investitora	-2 do +2	Procjena utjecaja vijesti na povjerenje investitora u tvrtku. Pozitivne vrijednosti označavaju povećanje povjerenja, negativne smanjenje.
Promjena rizičnog profila	-2 do +2	Procjena promjene percepcije rizičnosti ulaganja u dionicu na temelju analiziranih informacija. Pozitivne vrijednosti označavaju smanjenje rizika, negativne povećanje.

Izvor: izrada autora (2025)

Sve generirane NLP značajke strukturiraju se programskim okvirom koji omogućuje učinkovito spajanje statičnih instrukcija s dinamičkim ulaznim podacima, stvarajući prilagođene upite za svaki analitički scenarij. Sustav osigurava da se instrukcije za analizu ostaju konzistentne, dok se ulazni podaci (informacije o tvrtki, vijesti, tržišni kontekst) dinamički prilagođavaju specifičnostima svakog slučaja. Takav pristup osigurava dosljednost u formatu generiranih značajki, visoku kvalitetu kvantificiranih informacija te fleksibilnost u prilagodbi različitim tipovima financijskih vijesti i tržišnim situacijama. Metodologija kombinira prednosti strukturiranog inženjeringa upita s mogućnostima RAG tehnika, omogućujući sustavu da generira precizne kvantitativne značajke iz kvalitativnih financijskih informacija sistematičnim i ponovljivim procesom. Slika 1. prikazuje cjelovit proces generiranja NLP značajki koji obuhvaća sve opisane komponente, od prikupljanja podataka i konstrukcije upita do konačnih kvantificiranih značajki koje služe kao ulaz agentu za upravljanje portfeljem.



Slika 1. Proces generiranja NLP značajki
Izvor: izrada autora (2025)

3.3 Generiranje trgovačkih preporuka

Generiranje trgovačkih preporuka završni je korak analitičkog procesa u kojem se svi prikupljeni tehnički indikatori i NLP značajke kombiniraju u strukturirani upit koji se šalje LLM-u za generiranje konkretnih trgovačkih preporuka. Proces primjenjuje napredne tehnike inženjeringa upita kako bi model mogao interpretirati različite tipove signala i donijeti informiranu trgovačku odluku.

3.3.1 Okvir spajanja odluka i sinteza podataka

Svi generirani tehnički indikatori i NLP kombiniraju se s osnovnim informacijama o dionici u jedinstvenu strukturu podataka. Taj pristup omogućuje da se kvantitativni signali iz tehničke analize kombiniraju s kvalitativnim uvidima iz analize vijesti u koherentnu analitičku osnovu. Upit se strukturira tako da sadrži jasno definirane uloge za svaki tip podatka, tehnički indikatori pružaju kvantitativne signale o tržišnim trendovima, NLP značajke daju kontekst o sentimentu i potencijalnom utjecaju vijesti, dok osnovni podaci o dionici osiguravaju tržišni kontekst za analizu.

3.3.2 Inženjering upita za trgovačke preporuke

Glavni element generiranja preporuka je pristup inženjeringa upita koji imitira proces razmišljanja iskusnih financijskih analitičara (Callanan et al., 2023). Struktura upita dizajnirana je da vodi LLM sustavnom analizom koja uključuje višestruke perspektive i razmatranja rizika. Taj pristup omogućuje prilagodbu strukture upita ovisno o specifičnom cilju analize, primjerice za kratkoročno trgovanje naglasak može biti na tehničkim indikatorima i sentimentnim vijestima, dok za dugoročne investicije može biti na fundamentalnim pokazateljima i dugoročnim trendovima.

Tablica 5. Struktura upita za generiranje trgovačkih preporuka

Komponenta	Opis	Primjer sadržaja
Sistemska instrukcija	Definiranje uloge modela	You are a quantitative portfolio manager responsible for making trading decisions based on comprehensive market analysis.
Analitički zadatak	Specifična instrukcija za analizu	Your primary goal is to maximize portfolio returns while minimizing losses by predicting whether the stock price will move up or down in the next trading period.
Fundamentalni pokazatelji	Financijski pokazatelji i kontekst tvrtke	P/E TTM, ROE, revenue growth, current ratio, debt/equity, market capitalization, beta.
Tehnički indikatori	Kvantitativni signali iz tržišnih podataka	SMA, MACD, RSI, CCI
NLP značajke	Kvantificirane značajke iz vijesti	news_relevance, sentiment, price_impact_potential, trend_direction, earnings_impact, investor_confidence, risk_profile_change (scale -2 to +2).
Ciljanje značajke	Popis značajki za generiranje	trading_signal (BUY/SELL/HOLD), confidence_level (0.1-1.0), position_size (10-100 %)
Povijesni obrasci	Kontekst prethodnih odluka i ishoda	Previous trading decisions and market outcomes with pattern analysis for learning.
Format izlaza	Specifikacija formata odgovora	Return ONLY valid JSON structure with trading_signal, confidence_level, and position_size keys.

Izvor: izrada autora (2025)

3.3.3 Učenje iz povijesnih obrazaca

Sustav za generiranje trgovačkih preporuka primjenjuje pristup učenja s malim brojem primjera (engl. *Few-Shot Learning*) koji uključuje povijesne trgovačke scenarije izravno u strukturu upita. Svaki povijesni primjer sadrži kompletan skup ulaznih podataka: tehnički indikatori, NLP značajke, osnovne informacije o tvrtki te dokumentirani ishod u obliku stvarne promjene cijene dionice sljedećeg trgovačkog dana s jasnom oznakom rasta ili pada u odnosu na prethodni dan (Mosbach et al., 2023). Takav pristup omogućuje LLM-u da prepozna obrasce koji su se u prošlosti vodili određenim tržišnim kretanjima i primijeni tu logiku na trenutačni analitički scenarij. Model može identificirati situacije u kojima su slične kombinacije tehničkih indikator i NLP značajki rezultirale pozitivnim ili negativnim

pomacima cijena, što mu pomaže u donošenju informiranijih preporuka. Povijesni primjeri funkcioniraju kao referentni okvir koji pomaže modelu da bolje ponderiraju različite čimbenike ovisno o kontekstu. Integracija povijesnih obrazaca u upit osigurava da se svaka preporuka temelji ne samo na trenutačnim podacima već i na naučenim vezama između specifičnih kombinacija pokazatelja i njihovih povijesnih ishoda. Taj pristup kontinuirano poboljšava preciznost modela jer omogućuje identifikaciju suptilnih uzoraka koji mogu ukazivati na buduća tržišna kretanja na temelju proučenih poveznica iz prošlih uspješnih i neuspješnih trgovačkih scenarija (Brown et al., 2020).

3.3.4 Format izlaza i struktura preporuka

Konačne trgovačke preporuke generirane su u standardiziranom CSV formatu prikazanom u Tablici 6. koji omogućuje integraciju sa sustavom za provođenje testiranja i alatima za upravljanje portfeljem. Svaka preporuka sadrži sveobuhvatan skup informacija potrebnih za implementaciju i praćenje performansi.

Tablica 6. Struktura izlaznog CSV formata za trgovačke preporuke

Naziv polja	Opis	Primjer vrijednosti
Datum	Datum analize i generiranja preporuke	2025-01-15
Simbol dionice	Simbol dionice za koju radimo analizu	AAPL
Trenutačna cijena	Cijena zatvaranja dionice na dan analize	225.45
Trgovačka akcija	Preporučena trgovačka akcija	BUY, SELL, HOLD
Veličina pozicije	Preporučena veličina pozicije u postocima	30

Izvor: izrada autora (2025)

Generirane preporuke automatski se pohranjuju u CSV datoteke organizirane prema datumu, omogućujući jednostavno praćenje i analizu performansi kroz vrijeme. Taj format omogućuje direktnu integraciju s backtesting alatima za evaluaciju učinkovitosti generiranih preporuka u sljedećoj fazi istraživanja.

3.4 Arhitektura višeagentnog sustava

Višeagentni sustavi predstavljaju naprednu paradigmu u automatiziranom trgovanju na tržištu kapitala koja omogućuje specijalizaciju različitih komponenti sustava za specifične analitičke zadatke. Za razliku od monolitnih pristupa koji pokušavaju riješiti sve probleme jednim modelom, višeagentni sustavi omogućuju da svaki agent razvije duboku ekspertizu u određenoj domeni, od prikupljanja podataka do tehničke analize i obrade prirodnog jezika (Han et al., 2024).

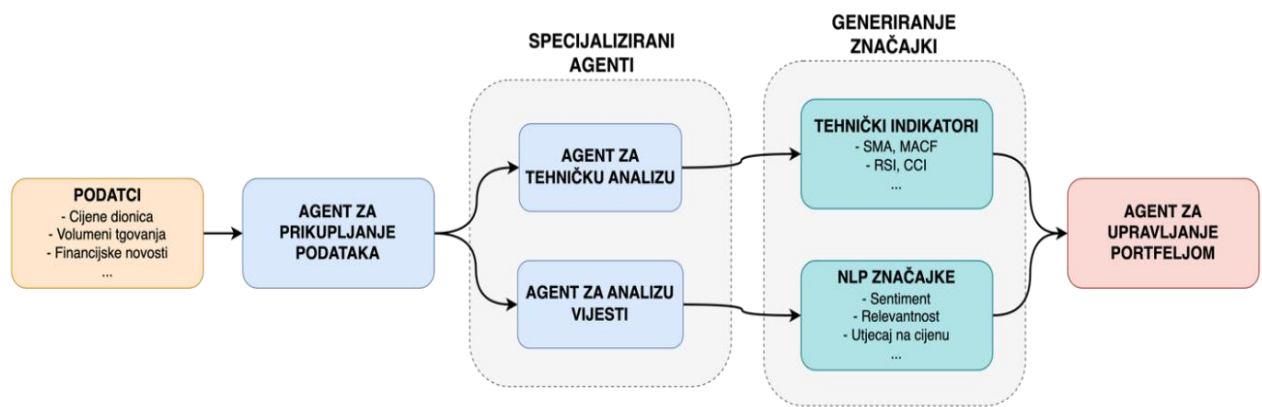
Takav pristup posebno je koristan u financijskoj domeni gdje se složenost analitičkih zadataka kreće od kvantitativne obrade tržišnih podataka do interpretacije nestrukturiranih financijskih vijesti. Istraživanja pokazuju da kolaboracija između specijaliziranih agenata može značajno nadmašiti performanse pojedinačnih sustava sinergijom različitih analitičkih perspektiva (Zhang et al., 2024a). Modularna arhitektura osigurava skalabilnost, pouzdanost i prilagodljivost važne za učinkovito funkcioniranje u dinamičkim tržišnim uvjetima.

3.4.1 Pregled arhitekture

Temelj arhitekture čini koordinirana interakcija između četiri specijalizirana agenta kroz model distribuirane suradnje koji omogućuje da svaki agent pridonosi svojom ekspertizom određenoj fazi ovoga procesa.

Sustav implementira hijerarhijski pristup s jasno definiranim ulogama: agent za prikupljanje podataka osigurava ulazne podatke, agenti za tehničku analizu i za analizu vijesti generiraju specijalizirane značajke iz svojih domena, dok agent za upravljanje portfeljem sintetizira sve informacije u konačne preporuke.

Arhitektura prikazana na Slici 2. slijedi načela modularnog pristupa koji omogućuje neovisni razvoj i optimizaciju svakog agenta za njegov specifični zadatak. Takav pristup omogućuje da se tehnike strojnog učenja, obrade prirodnog jezika i kvantitativne analize mogu prilagoditi i optimizirati za specifične zahtjeve svake domene što rezultira boljim ukupnim performansama (Tran et al., 2025).



Slika 2. Cjelokupna arhitektura višeagentnog sustava

Izvor: izrada autora (2025)

Komunikacija između agenata temelji se na standardiziranim protokolima koji osiguravaju da se različiti tipovi analitičkih značajki mogu učinkovito integrirati u konačni proces donošenja odluka.

Takav pristup omogućuje da svaki agent radi autonomno dok istovremeno pridonosi zajedničkom cilju generiranja kvalitetnih trgovačkih preporuka.

3.4.2 Specijalizirani agenti i njihove funkcionalnosti

Specijalizacija agenata omogućuje optimizaciju za specifične domene finansijske analize podjelom odgovornosti između četiri glavna agenta prikazanih u Tablici 7., pri čemu svaki agent razvija duboku ekspertizu u svojoj domeni i pridonosi cjelokupnom procesu generiranja trgovačkih preporuka.

Tablica 7. Specijalizacija agenata i njihove domene

Naziv agenta	Opis funkcionalnosti agenta	Izlaz
Agent za prikupljanje podataka (engl. <i>Data Collection Agent</i>)	Dohvaća i priprema podatke iz vanjskih izvora (Yahoo Finance, Finnhub), osigurava kvalitetu i upravlja pogreškama.	Očišćeni OHLCV podaci, strukturirane vijesti, osnovne informacije o tvrtkama.
Agent tehničke analize (engl. <i>Technical Analysis Agent</i>)	Izračunava tehničke indikatore iz tržišnih podataka i generira kvantitativne signale za trgovanje.	Tehnički indikatori (SMA, MACD, RSI, CCI), kvantitativni signali.
Agent za analizu vijesti (engl. <i>News Intelligence Agent</i>)	Transformira financijske vijesti u kvantitativne značajke primjenom NLP modela i RAG pristupa.	NLP značajke (sentiment, relevantnost, potencijalni utjecaj na cijenu...).
Agent za upravljanje portfeljem (engl. <i>Portfolio Manager Agent</i>)	Kombinira signale svih agenata i generira konačne trgovačke preporuke s procjenom rizika.	Trgovačke preporuke u CSV formatu s razinom pouzdanosti.

Izvor: izrada autora (2025)

Agent za prikupljanje podataka fokusiran je na pouzdano i učinkovito dohvaćanje informacija iz različitih izvora, implementirajući mehanizme za rukovanje API pozivima, validaciju podataka i upravljanje pogreškama. Takav specijalizirani pristup osigurava da ostali agenti imaju pristup obrađenim podacima spremnim za daljnju analizu.

Agent tehničke analize specijaliziran je za kvantitativnu analizu tržišnih podataka implementacijom tehničkih indikatora. Fokusiranost na jednu domenu omogućuje optimizaciju algoritama za brzinu i točnost, što je važno za procesiranje velikih količina tržišnih podataka u realnom vremenu.

Agent za analizu vijesti implementira prethodno spomenuti NLP pristup za generiranje značajki za transformaciju nestrukturiranih tekstualnih informacija u kvantitativne značajke. Specijalizacija omogućuje da se tehnike inženjeringa upita i RAG pristupa mogu fino prilagoditi specifičnostima financijskog jezika i konteksta.

Agent za upravljanje portfeljem funkcionira kao koordinator koji kombinira ekspertizu svih specijaliziranih agenata sofisticiranim tehnikama spajanja informacija. Ovaj agent implementira logiku koja omogućuje da se različiti tipovi signala i značajki kombiniraju u trgovačke preporuke s definiranim formatom izlaza koji uključuje trgovačku akciju (BUY/SELL/HOLD) i veličinu pozicije (10 – 100 %) što je prikazano u Tablici 6.

3.4.3 Simulacija trgovanja i evaluacijski okvir

Testiranje učinkovitosti višeagentnog sustava provedeno je simulacijom trgovanja koja replicira realne tržišne uvjete bez stvarnog rizika kapitala. Simulacija je konfigurirana početnim portfeljem od 100.000 američkih dolara, omogućujući sustavu da provodi trgovačke transakcije na temelju generiranih preporuka višeagentnom strategijom.

Sustav implementira trgovačku logiku koja čita generirane signale iz CSV datoteka i provodi transakcije prema definiranim pravilima. Za BUY signale, algoritam određuje broj dionica za kupnju tako što ukupan dostupan kapital pomnoži s postotkom preporučene veličine pozicije i podijeli s trenutačnom cijenom dionice. Takav pristup osigurava da se kupnja provodi u skladu s preporučenom alokacijom kapitala, pri čemu se koristi samo dio dostupnih sredstava ovisno o razini pouzdanosti u signal. Za SELL signale, sustav prodaje dio postojećih pozicija izračunavanjem broja dionica za prodaju na temelju trenutačnog broja dionica u portfelju pomnoženog s postotkom preporučene veličine pozicije. Taj pristup omogućuje postupnu likvidaciju pozicije umjesto potpune prodaje, što pomaže u upravljanju rizikom i održavanju fleksibilnosti portfelja. HOLD signali rezultiraju zadržavanjem trenutačne pozicije bez provedbe transakcija.

Proces simulacije organiziran je iterativnim izvršavanjem dnevnih analiza za definirani period, pri čemu sustav automatski identificira trgovačke dane i izbjegava vikende i neradne dane. Rezultati svake dnevne analize pohranjuju se u strukturirane CSV datoteke koje sadrže kompletne informacije o stanju tržišta, tehničkim indikatorima, NLP značajkama i generiranim trgovačkim preporukama, omogućujući detaljnu analizu čimbenika koji utječu na uspješnost pojedinih trgovačkih odluka.

4. Rezultati i diskusija

U ovom poglavlju predstavljena je evaluacija predloženog višeagentnog sustava za generiranje financijskih trgovačkih preporuka analizom performansi implementiranih komponenti i kvalitete generiranih rezultata. Evaluacija obuhvaća testiranje funkcionalnosti specijaliziranih agenata i analizu ukupne učinkovitosti sustava u stvaranju koherentnih trgovačkih preporuka koje integriraju fundamentalne pokazatelje, tehničke indikatore s kvalitativnim informacijama iz financijskih vijesti.

4.1 Rezultati implementacije i evaluacije

Implementacija višeagentnog sustava provedena je sveobuhvatnim testiranjem na sedam reprezentativnih dionica vodećih tehnoloških kompanija tijekom šestomjesečnog razdoblja od siječnja do srpnja 2025. godine. Razdoblje testiranja obilježeno je značajnim makroekonomskim neizvjesnostima uzrokovanim najavljenim trgovinskim tarifama koje bi prema procjenama Tax Foundation mogle smanjiti američki BDP za 0,4 % i povećati troškove za kućanstva za više od 830 dolara godišnje (York, 2025).

Odabir dionica obuhvaća različite sektore i tržišne kapitalizacije: tehnološke kompanije s visokom volatilnošću (Apple Inc. – AAPL, Amazon.com Inc. – AMZN, Meta Platforms Inc. – META, Netflix Inc. – NFLX, Tesla Inc. – TSLA), tradicionalnu industrijsku kompaniju (Johnson & Johnson – JNJ) te maloprodajnog lidera (Walmart Inc. – WMT). Ta diversifikacija uzorka omogućuje evaluaciju sustava na različitim tržišnim karakteristikama i industrijskim dinamikama u uvjetima povišene volatilnosti i neizvjesnosti. Veličina uzorka od sedam dionica usklađena je s metodologijom sličnih istraživanja u domeni LLM baziranih trgovačkih sustava. Zhang et al. (2024b) evaluiraju FinAgent sustav na šest dionica, dok (Yu et al., 2023) testiraju FinMem na pet dionica u šestomjesečnom razdoblju. Xiao et al., (2025) koriste tri dionice za tromjesečnu evaluaciju TradingAgents okvira. U kontekstu validacije višeagentnih AI sustava, fokus je na dubinskoj analizi različitih tržišnih scenarija i sposobnosti adaptacije sustava, a ne na statističkoj reprezentativnosti šireg tržišta što je u skladu s ustanovljenom praksom na ovom istraživačkom području.

Evaluacija performansi višeagentnog sustava temelji se na standardnim financijskim metrikama koje omogućuju objektivnu procjenu uspješnosti trgovačkih strategija. Povrat predstavlja ukupnu promjenu vrijednosti portfelja izraženu u postocima, pokazujući koliko je kapital porastao ili pao u testnom razdoblju. Godišnja volatilnost kvantificira razinu fluktuacije povrata kroz vrijeme, pri čemu više vrijednosti označavaju veće oscilacije u vrijednosti portfelja i veći rizik ulaganja (Olorunnimbe i Viktor, 2023).

Sharpe omjer mjeri omjer između ostvarenog povrata i preuzeta rizika, prilagođen za bezrizičnu stopu ulaganja. Viši Sharpe omjeri označavaju bolju prilagodbu riziku, što znači da strategija ostvaruje veće povrate po jedinici preuzeta rizika.

Maksimalni pad predstavlja najveći postotak smanjenja vrijednosti portfelja od vrha do dna tijekom najlošijeg razdoblja, što je ključna metrika za procjenu najlošijeg scenarija i sposobnosti strategije da očuva kapital tijekom tržišnih padova (Ye et al., 2024).

Tablica 8. prikazuje detaljne rezultate performansi višeagentnog sustava u odnosu na tradicionalni referentni „kupi i drži“ strategiju (engl. *Buy & Hold*).

Analiza pokazuje da višeagentni sustav ostvaruje značajno nižu prosječnu volatilnost u odnosu na prosječne volatilnosti referentnog pristupa. Ta redukcija volatilnosti demonstrira prednost višeagentnog pristupa u upravljanju rizikom kontinuiranom adaptacijom tržišnim uvjetima.

Tablica 8. Rezultati performansi testiranih strategija


Dionica	Strategija	Povrat	Godišnja volatilnost	Sharpe omjer	Maksimalni pad
AAPL	Višeagentni sustav	-6,89 %	8,04 %	-2,04	9,83 %
	Buy & Hold	-15,27 %	40,11 %	-0,70	29,80 %
AMZN	Višeagentni sustav	0,15 %	21,47 %	0,02	18,07 %
	Buy & Hold	-1,40 %	38,10 %	0,05	30,79 %
JNJ	Višeagentni sustav	6,90 %	12,77 %	0,98	7,31 %
	Buy & Hold	7,69 %	21,79 %	0,72	12,59 %
META	Višeagentni sustav	31,97 %	19,75 %	2,89	8,89 %
	Buy & Hold	22,16 %	43,10 %	1,12	34,04 %
NFLX	Višeagentni sustav	28,61 %	20,25 %	2,57	12,13 %
	Buy & Hold	49,51 %	36,60 %	2,39	19,01 %
TSLA	Višeagentni sustav	-3,35 %	6,52 %	-1,35	7,72 %
	Buy & Hold	-16,59 %	75,75 %	-0,14	47,84 %
WMT	Višeagentni sustav	10,47 %	10,56 %	1,81	4,74 %
	Buy & Hold	8,93 %	28,43 %	0,69	21,73 %

Izvor: izrada autora (2025)

Analiza upravljanja rizikom metrikom maksimalnog pada pokazuje da višeagentni sustav postiže niže vrijednosti u odnosu na referentnu strategiju kod svih analiziranih dionica. Kod dionice TSLA, sustav ograničava maksimalni pad na 7,72 % u odnosu na 47,84 % kod referentne strategije. Slični obrasci vidljivi su kod META dionice s maksimalnim padom 8,89 % naspram 34,04 % , te kod AAPL dionice gdje sustav održava pad na 9,83 % u usporedbi s 29,80 %. Kod WMT dionice, sustav postiže rezultat s maksimalnim padom od samo 4,74 % naspram 21,73 % , demonstrirajući efikasnost upravljanja rizikom. Rezultati ukazuju na sposobnost sustava da upravlja rizikom tijekom razdoblja tržišne volatilnosti karakteristične za prvu polovicu 2025. godine.

Slika 3. prikazuje performanse višeagentnog sustava na dionici META, gdje je ostvaren povrat od 31,97 % uz Sharpe omjer od 2,89.

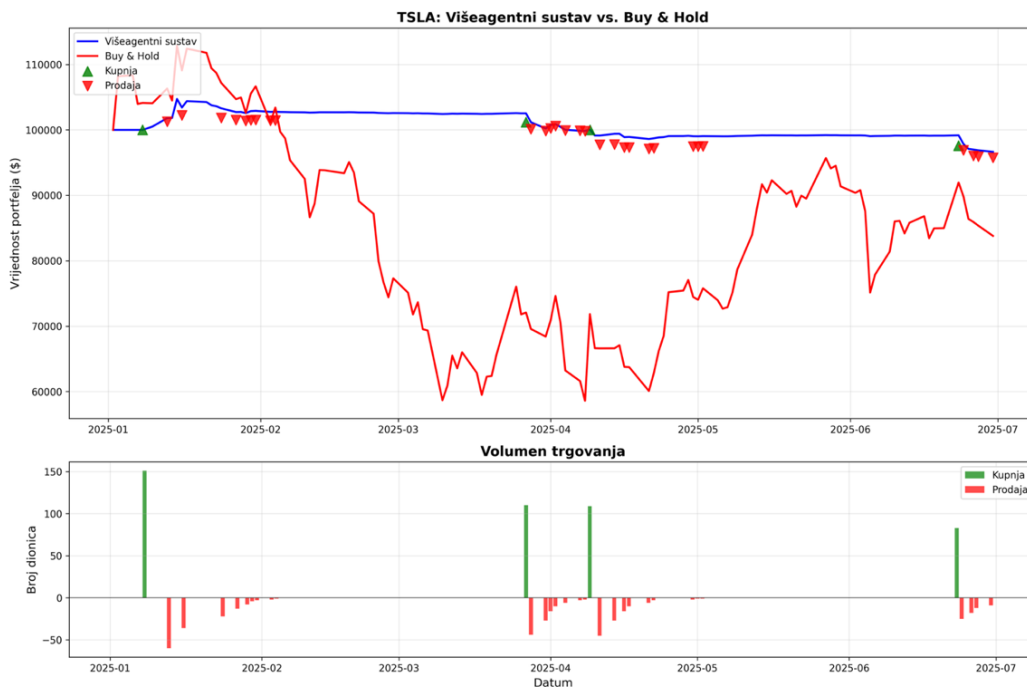
Grafički prikaz pokazuje putanju vrijednosti portfelja kroz vrijeme, s oznakama transakcija koje sustav izvršava.



Slika 3. Rezultati trgovanja za META dionicu

Izvor: izrada autora (2025)

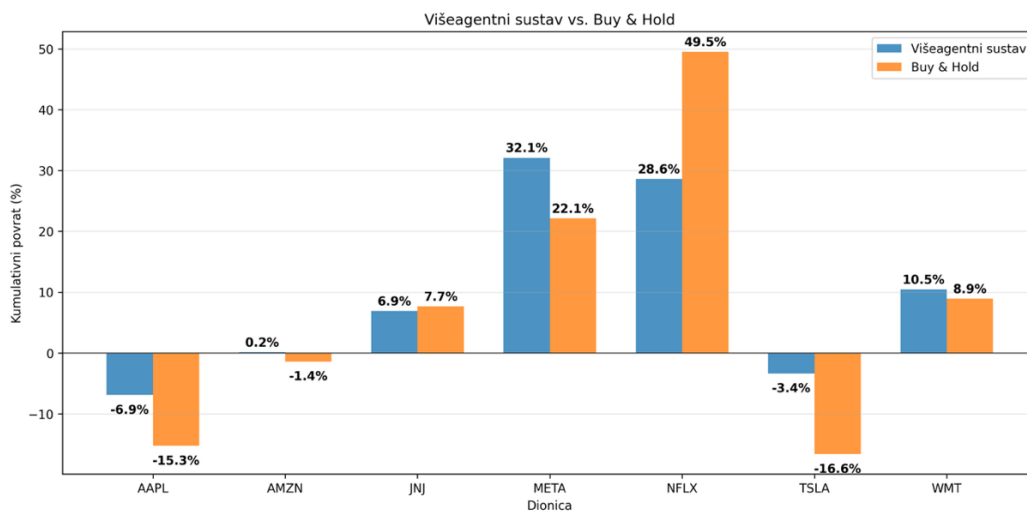
Slika 4. prikazuje performanse na dionici TSLA, gdje višeagentni sustav ostvaruje gubitak od -3,35 % naspram -16,59 % referentne strategije. Grafikon jasno ilustrira dramatičnu razliku u stabilnosti između dvaju pristupa.



Slika 4. Rezultati trgovanja za TSLA dionicu
Izvor: izrada autora (2025)

Dok referentna strategija ima velik pad tijekom ožujka i travnja 2025. godine, višeagentni sustav održava relativno stabilnu horizontalnu putanju cijelo razdoblje. Posebno je uočljivo kako sustav aktivnim upravljanjem pozicijama uspijeva izbjeći velike gubitke tijekom najvolatilnijih razdoblja. Ova sposobnost održavanja stabilnosti portfelja reflektira se u volatilnosti od samo 6,52 % za višeagentni sustav u odnosu na 75,75 % kod usporedne strategije.

Komparativna analiza prikazana na Slici 5. pokazuje performanse u svim analiziranim dionicama.



Slika 5. Performanse strategija po dionicama
Izvor: izrada autora (2025)

Kod dionice AAPL, sustav reducira gubitke s -15,25 % na -6,88 %, dok kod AMZN pretvara gubitak od -1,40 % u povrat od +0,15 %. Kod JNJ dionice, višeagentni sustav ostvaruje povrat od 6,90 % uz značajno nižu volatilnost (12,77 % naspram 21,79 %), demonstrirajući efikasnost na stabilnim dionicama. TSLA pokazuje smanjenje gubitaka s -16,59 % na -3,35 %, pri čemu sustav postiže izvanrednu kontrolu rizika uz maksimalni pad od samo 7,72 %. META ostvaruje povrat od 32,09 % naspram 22,15 % referentne strategije, s istovremenom redukcijom volatilnosti za više od 50 %. WMT dionica ilustrira prednosti sustava kod konzervativnih investicija, gdje višeagentni pristup ostvaruje 10,47 % povrat uz maksimalni pad od samo 4,74 % u usporedbi s 21,73 % kod referentne strategije. Jedino kod NFLX dionice referentna strategija nadmašuje višeagentni pristup u kumulativnom povratu (49,51 % naspram 28,61 %), iako uz značajno veći rizik.

4.2 Diskusija rezultata

Rezultati evaluacije pružaju uvide u karakteristike predloženog višeagentnog sustava za generiranje trgovačkih preporuka. Analiza performansi u različitim tržišnim uvjetima i tipovima dionica prikazuje prednosti implementiranog pristupa te identificira područja za daljnja poboljšanja.

Osnovna prednost višeagentnog sustava proizlazi iz integracije različitih izvora podataka koordiniranom aktivnosti specijaliziranih agenata. Agent za tehničku analizu procesuirao tržišne podatke generirajući time tehničke indikatore, dok paralelno agent za analizu vijesti interpretira nestrukturirane tekstualne informacije u NLP značajke. Ta kombinacija omogućuje sustavu da prepozna situacije u kojima sentiment iz vijesti može pojačati ili oslabiti tehničke signale, rezultirajući trgovačkim odlukama koje nadilaze mogućnosti primjerice tehničke analize. Takav integrirani pristup podržava rezultate Zhang et al. (2024b) koji demonstriraju da multimodalni agenti poput FinAgenta postižu značajna poboljšanja kombiniranjem različitih izvora podataka, iako direktna usporedba performansi nije moguća zbog različitih testnih uvjeta i perioda.

Sustav pokazuje sposobnost održavanja performansi u različitim tržišnim uvjetima. U razdoblju povišene volatilnosti u prvom kvartalu 2025. godine, kada su makroekonomske neizvjesnosti vezane za inflaciju i monetarnu politiku uzrokovale tržišne fluktuacije, višeagentni sustav pokazao je otpornost značajnim smanjenjem volatilnosti u odnosu na referentnu strategiju. Agent za upravljanje portfeljem kontinuirano balansira između potrebe za iskorištavanjem prilika i zaštitom kapitala.

Analiza trgovačke aktivnosti pokazuje adaptivnost sustava na karakteristike pojedinih dionica. Kod visoko volatilne dionice TSLA, sustav izvršava veći broj transakcija omogućujući prilagodbe pozicija u odgovoru na promjene cijene. Nasuprot tome, kod dionice NFLX, sustav pokazuje manju trgovačku aktivnost što sugerira prepoznavanje stabilnijih trendova. Ta prilagodba trgovačke frekvencije je prednost u odnosu na statičke strategije koje primjenjuju uniforman pristup neovisno o tržišnim uvjetima.

NLP značajke ovom sustavu omogućuju kontekstualno razumijevanje tržišnih kretanja. U razdoblju kada tehnički indikatori daju kontradiktorne signale, sposobnost sustava da interpretira sentiment iz financijskih vijesti pomaže u donošenju trgovačkih odluka. Ta karakteristika dolazi do izražaja tijekom objava kvartalnih rezultata i drugih korporativnih događaja koji utječu na cijene dionica. Implementacija slojevite memorijske arhitekture, slično konceptu koji Yu et al. (2023) koriste u FinMem sustavu, omogućuje agentima da integriraju povijesne obrasce s trenutnim tržišnim uvjetima iako se ovaj rad ne koristi eksplicitno dizajniranim karakteristikama agenata kao što to čini FinMem.

Analiza također identificira ograničenja sustava. Primjer predstavlja performansa na dionici NFLX, gdje referentna strategija ostvaruje viši apsolutni povrat 49,51 % naspram 28,61 %. Ovaj rezultat sugerira da sustav može biti konzervativniji tijekom snažnih uzlaznih trendova, prioritizirajući zaštitu kapitala nad ostvarivanjem profita. Ova konzervativnost rezultira nižim rizikom, što može biti prihvatljivo za određene kategorije investitora.

Rezultati potvrđuju vrijednost višeagentnog pristupa u integraciji različitih izvora podataka za poboljšanje procesa donošenja trgovačkih odluka, posebno u domeni upravljanja rizikom. Modularnost arhitekture, slično platformama poput FinRobot (Yang et al., 2024), omogućuje kontinuirani razvoj i optimizaciju pojedinih komponenti bez potrebe za redizajnom cijelog sustava. Buduća istraživanja trebala bi se fokusirati na optimizaciju trgovačke aktivnosti tijekom različitih tržišnih režima i na proširenje evaluacije na dulja razdoblja i širi spektar financijskih instrumenata.

5. Zaključak

Ovaj rad predstavlja razvoj i implementaciju višeagentnog sustava umjetne inteligencije za generiranje financijskih trgovačkih preporuka koji integrira tehnike obrade prirodnog jezika. Sveobuhvatnom analizom i evaluacijom sustava istraživanje prikazuje potencijal višeagentnih arhitektura u prevladavanju ograničenja tradicionalnih pristupa u financijskim analizama.

Provedeno istraživanje potvrdilo je mogućnost uspješne integracije različitih izvora podataka specijaliziranim agentima koji pokrivaju različite aspekte financijske analize. Agent za prikupljanje podataka osigurava pouzdano dohvaćanje informacija o dionicama, agent za tehničku analizu generira standardne tehničke indikatore, agent za analizu vijesti transformira nestrukturirane tekstualne informacije u numeričke NLP značajke, dok agent za upravljanje portfeljem objedinjuje sve informacije u konačne trgovačke preporuke.

Rezultati provedene na sedam dionica tijekom šestomjesečnog razdoblja pokazuju da višeagentni sustav postiže značajno poboljšanje u upravljanju rizikom u odnosu na tradicionalnu „kupi i drži“ referentnu strategiju. Analiza volatilnosti pokazuje smanjenje prosječnih fluktuacija kod svih analiziranih dionica, dok metrika maksimalnog pada prikazuje sposobnost sustava da ograniči gubitke tijekom razdoblja tržišnih turbulencija. Posebno su značajni rezultati kod visoko volatilnih dionica poput TSLA, gdje sustav održava maksimalni pad na 7,72 % u odnosu na 47,84 % pasivne strategije.

Implementacija NLP značajki tehnikama inženjeringa upita i RAG pristupom omogućila je sustavu da kvantificira kvalitativne aspekte financijskih vijesti. Generirane značajke poput sentimenta, relevantnosti i potencijalnog utjecaja na cijenu pružaju dodatnu podršku analize koja nadopunjuje tradicionalne tehničke indikatore. Ta integracija kvantitativnih i kvalitativnih pristupa omogućuje sustavu donošenje informiranih trgovačkih odluka.

Metodološki pristup temeljen na modularnoj arhitekturi pokazao se fleksibilnim i skalabilnim. Standardizirani protokoli komunikacije između agenata omogućuju neovisni razvoj i optimizaciju svake komponente, dok istovremeno osiguravaju rad cijelog sustava. Takav pristup omogućuje buduća proširenja dodavanjem novih specijaliziranih agenata bez potrebe za modificiranjem postojeće arhitekture.

Unatoč pozitivnim rezultatima, istraživanje identificira određena ograničenja sustava. Prvo, evaluacija je ograničena na šestomjesečno razdoblje i sedam dionica, što je relativno kratak vremenski okvir za procjenu robusnosti kroz različite tržišne cikluse. Drugo, konzervativni pristup tijekom snažnih uzlaznih trendova rezultira propuštanjem dijela potencijalnih profita što je vidljivo kod dionice NFLX. Treće,

analiza ne uključuje detaljnu razradu transakcijskih troškova koji bi u praktičnoj primjeni značajno utjecali na neto performanse s obzirom na to da sustav provodi između 20 i 53 transakcije po dionici. Četvrto, nedostaje sustavna usporedba s drugim naprednim AI strategijama poput dubokog podržanog učenja pristupa.

Smjernice za buduća istraživanja uključuju nekoliko smjerova razvoja. Proširenje empirijske analize na dulje razdoblje (dvije-tri godine) i širi skup instrumenata pružilo bi dublji uvid u robusnost pristupa kroz različite tržišne režime. Implementacija dinamičkih trgovačkih pragova uz inkluziju modela transakcijskih troškova omogućila bi realističniju procjenu praktične primjenjivosti. Sistematska usporedba s drugim naprednim AI strategijama, posebno dubokim podržanim učenjem i alternativnim LLM okvirima, pružila bi objektivniju procjenu prednosti višeagentnog pristupa. Uključivanje dodatnih specijaliziranih agenata, poput agenta za analizu makroekonomskih pokazatelja, moglo bi dodatno unaprijediti sustav u prepoznavanju i iskorištavanju tržišnih prilika.

Zaključno, ovaj rad pridonosi razvoju područja automatiziranog trgovanja demonstrirajući vrijednost višeagentnih pristupa u integraciji različitih analitičkih perspektiva. Rezultati potvrđuju da koordinacija specijaliziranih agenata može značajno unaprijediti proces donošenja trgovačkih odluka, posebno u domeni upravljanja rizikom. Iako sustav pokazuje određena ograničenja, njegova modularnost i fleksibilnost pružaju solidnu osnovu za daljnji razvoj sofisticiranijih sustava koji mogu učinkovitije upravljati kompleksnosti suvremenih financijskih tržišta.

Literatura:

Acharya, D. B., Kuppan, K. and Divya, B. (2025) Agentic AI: Autonomous Intelligence for Complex Goals – A Comprehensive Survey, *IEEE Access*, 13, pp. 18912 – 18936.

Aldhyani, T. H. H. and Alzahrani, A. (2022) Framework for Predicting and Modeling Stock Market Prices Based on Deep Learning Algorithms, *Electronics*, 11 (19), Article 3149.

Baek, Y. and Kim, H. Y. (2018) ModAugNet: A New Forecasting Framework for Stock Market Index Value with an Overfitting Prevention LSTM Module and a Prediction LSTM Module, *Expert Systems with Applications*, 113, pp. 457 – 480.

Bartram, S. M. and Grinblatt, M. (2018) Agnostic Fundamental Analysis Works, *Journal of Financial Economics*, 128 (1), pp. 125 – 147.

Botunac, I., Panjkota, A. and Matetic, M. (2020) The Effect of Feature Selection on the Performance of Long Short-Term Memory Neural Network in Stock Market Predictions, *Annals of DAAAM and Proceedings of the International DAAAM Symposium*, Vol. 31, pp. 592 – 598. Vienna: DAAAM International.

Brown, T. B. et al. (2020) Language Models are Few-Shot Learners, *Advances in Neural Information Processing Systems (NeurIPS 2020)*, Vol. 33, pp. 1877 – 1901.

Callanan, E. et al. (2023) Can GPT Models be Financial Analysts? An Evaluation of ChatGPT and GPT-4 on Mock CFA Exams, *arXiv preprint*, arXiv:2310.08678.

- Chen, B. et al. (2023) Unleashing the Potential of Prompt Engineering in Large Language Models: A Comprehensive Review, *arXiv preprint*, arXiv:2310.14735.
- Colby, R. W. (2003) *The Encyclopedia of Technical Market Indicators*, 2nd ed., New York: McGraw-Hill.
- Fabozzi, F. J. et al. (2019) *Foundations of Global Financial Markets and Institutions*, 5th ed., Cambridge, MA: MIT Press.
- Fama, E. F. (1965) The Behavior of Stock-Market Prices, *The Journal of Business*, 38 (1), pp. 34 – 105.
- Fama, E. F. (1970) Efficient Capital Markets: A Review of Theory and Empirical Work, *The Journal of Finance*, 25 (2), pp. 383 – 417.
- Fama, E. F. (1991) Efficient Capital Markets: II, *The Journal of Finance*, 46 (5), pp. 1575 – 1617.
- Fischer, T. and Krauss, C. (2018) Deep Learning with Long Short-Term Memory Networks for Financial Market Predictions, *European Journal of Operational Research*, 270 (2), pp. 654 – 669.
- Gao, Y. et al. (2024) Retrieval-Augmented Generation for Large Language Models: A Survey, *arXiv preprint*, arXiv:2312.10997.
- Guida, T. (ed.) (2018) *Big Data and Machine Learning in Quantitative Investment*, Hoboken, NJ: John Wiley & Sons.
- Han, X. et al. (2024) Enhancing Investment Analysis: Optimizing AI-Agent Collaboration in Financial Research, *Proceedings of the 5th ACM International Conference on AI in Finance (ICAIF 2024)*. arXiv:2411.04788.
- Huang, A. H., Wang, H. and Yang, Y. (2023) FinBERT: A Large Language Model for Extracting Information from Financial Text, *Contemporary Accounting Research*, 40 (2), pp. 806 – 841.
- Ku, C. S. et al. (2023) Improving Stock Market Predictions: An Equity Forecasting Scanner Using Long Short-Term Memory Method with Dynamic Indicators for Malaysia Stock Market, *Mathematics*, 11 (11), Article 2470.
- Lewis, P. et al. (2020) Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks, *Advances in Neural Information Processing Systems (NeurIPS 2020)*, Vol. 33, pp. 9459 – 9474.
- Liu, X.-Y. et al. (2021) FinRL: Deep Reinforcement Learning Framework to Automate Trading in Quantitative Finance, *Proceedings of the 2nd ACM International Conference on AI in Finance (ICAIF 2021)*, pp. 1 – 9.
- Liu, X.-Y. et al. (2023) Dynamic Datasets and Market Environments for Financial Reinforcement Learning, *arXiv preprint*, arXiv:2304.13174.

- Malkiel, B. G. (2003) The Efficient Market Hypothesis and Its Critics, *Journal of Economic Perspectives*, 17 (1), pp. 59 – 82.
- Mishkin, F. S. and Eakins, S. (2018) *Financial Markets and Institutions*, 9th ed., New York: Pearson.
- Mosbach, M. et al. (2023) Few-Shot Fine-Tuning vs. In-Context Learning: A Fair Comparison and Evaluation, *arXiv preprint*, arXiv:2305.16938.
- Murphy, J. J. (1999) *Technical Analysis of the Financial Markets*, New York: New York Institute of Finance.
- Olorunnimbe, K. and Viktor, H. (2023) Deep Learning in the Stock Market – A Systematic Survey of Practice, Backtesting, and Applications, *Artificial Intelligence Review*, 56 (3), pp. 2057 – 2109.
- Orsag, S. (2015) *Investicijska analiza*, Zagreb: Avantis.
- Saunders, A., Cornett, M. M. and Erhemjamts, O. (2022) *Financial Markets and Institutions*, 8th ed., New York: McGraw-Hill.
- Sun, S. et al. (2023) TradeMaster: A Holistic Quantitative Trading Platform Empowered by Reinforcement Learning, *Advances in Neural Information Processing Systems (NeurIPS 2023)*, Vol. 36, pp. 59047 – 59061.
- Timmermann, A. and Granger, C. W. J. (2004) Efficient Market Hypothesis and Forecasting, *International Journal of Forecasting*, 20 (1), pp. 15 – 27.
- Tran, K.-T. et al. (2025) Multi-Agent Collaboration Mechanisms: A Survey of LLMs, *arXiv preprint*, arXiv:2501.06322.
- Wang, N., Yang, H. and Wang, C. D. (2023) FinGPT: Instruction Tuning Benchmark for Open-Source Large Language Models in Financial Datasets, *arXiv preprint*, arXiv:2310.04793.
- Wu, S. et al. (2023) BloombergGPT: A Large Language Model for Finance, *arXiv preprint*, arXiv:2303.17564.
- Xiao, Y. et al. (2025) TradingAgents: Multi-Agents LLM Financial Trading Framework, *arXiv preprint*, arXiv:2412.20138.
- Yang, H. et al. (2024) FinRobot: An Open-Source AI Agent Platform for Financial Applications using Large Language Models, *arXiv preprint*, arXiv:2405.14767.
- Yang, H., Liu, X.-Y. and Wang, C. D. (2023) FinGPT: Open-Source Financial Large Language Models, *arXiv preprint*, arXiv:2306.06031.
- Ye, A. et al. (2024) Learning the Market: Sentiment-Based Ensemble Trading Agents, *arXiv preprint*, arXiv:2402.01441.

York, E. (2025) Trump Tariffs: The Economic Impact of the Trump Trade War. [Online], Available at: <https://taxfoundation.org/research/all/federal/trump-tariffs-trade-war/> [Pristupljeno 30.8.2025].

Yu, Y. et al. (2023) FinMem: A Performance-Enhanced LLM Trading Agent with Layered Memory and Character Design, *arXiv preprint*, arXiv:2311.13743.

Zhang, C. et al. (2024) When AI Meets Finance (StockAgent): Large Language Model-based Stock Trading in Simulated Real-world Environments, *arXiv preprint*, arXiv:2407.18957.

Zhang, W. et al. (2024) A Multimodal Foundation Agent for Financial Trading: Tool-Augmented, Diversified, and Generalist, *Proceedings of the 30th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 4314 – 4325.

Zou, J. et al. (2022) Stock Market Prediction via Deep Learning Techniques: A Survey, *arXiv preprint*, arXiv:2212.12717.

Implementation of a multi-agent artificial intelligence system for financial trading decision-making

IVE BOTUNAC
Faculty of Informatics and Digital Technologies
University of Rijeka
Radmile Matejčić 2, 51000 Rijeka
Croatia
ive.botunac@gmail.com
ORCID iD: <https://orcid.org/0000-0003-3561-7089>

Abstract: The application of artificial intelligence in financial analysis leads to the development of advanced multi-agent systems that enable more effective analysis and decision-making than existing methods. This paper presents the development and implementation of a multi-agent artificial intelligence system for generating financial trading recommendations, integrating specialized agents for data collection, technical analysis, news processing, and portfolio management. The system combines quantitative analysis based on technical indicators with qualitative insights from financial news, utilizing natural language processing techniques such as prompt engineering and retrieval-augmented generation. The system's architecture enables autonomous operation of four specialized agents that contribute to generating trading recommendations. An evaluation conducted over six months in 2025 on seven representative stocks reveals a significant improvement in risk management compared to the "buy and hold" reference strategy. Results demonstrate a significant reduction in volatility and maximum drawdown for most analysed stocks, particularly for highly volatile stocks such as Tesla, where the system maintains a maximum drawdown of 7.72 % compared to 47.84 % for the reference strategy. The system adapts trading recommendations to various market conditions and the specifics of each stock, thereby maintaining portfolio stability during periods of market instability. Financial news analysis using NLP enables the system to recognize whether news is positive or negative, its importance to the stock, and how it may affect its price. Despite identified limitations in adopting a more cautious approach during strong upward trends, the modularity of this architecture enables the continuous development and optimization of individual components. The research confirms the value of multi-agent approaches in integrating different data sources to improve the trading decision-making process.

Keywords: multi-agent systems, artificial intelligence, natural language processing, trading strategies, risk management

JEL classification: G11, G17, C45