

**VILNIAUS UNIVERSITETO
KAUNO FAKULTETAS**

**SOCIALINIŲ MOKSLŲ IR TAIKOMOSIOS INFORMATIKOS
INSTITUTAS**

Finansų technologijų studijų programa

Kodas 6211BX022

GEDIMINAS LUKŠA

MAGISTRO BAIGIAMASIS DARBAS

**AKCIJŲ PREKYBOS AUTOMATIZAVIMAS PANAUDOJANT
DIDELIU KALBOS MODELIU GRINDŽIAMĄ PREKYBOS
AGENTĄ**

Kaunas 2025

**VILNIAUS UNIVERSITETO
KAUNO FAKULTETAS**

**SOCIALINIŲ MOKSLŲ IR TAIKOMOSIOS INFORMATIKOS
INSTITUTAS**

GEDIMINAS LUKŠA

MAGISTRO BAIGIAMASIS DARBAS

**AKCIJŲ PREKYBOS AUTOMATIZAVIMAS
PANAUDOJANT DIDELIU KALBOS MODELIU
GRINDŽIAMĄ PREKYBOS AGENTĄ**

Magistrantas _____
(parašas)

Darbo vadovas _____
(parašas)

(darbo vadovo mokslo laipsnis, vardas, pavardė)

Darbo įteikimo data

Registracijos Nr.

Kaunas 2025

TURINYS

TURINYS	3
SANTRAUPŲ SĄRAŠAS	5
LENTELIŲ SĄRAŠAS	6
PAVEIKSLŲ SĄRAŠAS	7
SANTRAUKA	8
IVADAS	9
1. AKCIJŲ PREKYBOS IR DIRBTINIO INTELEKTO TEORINIAI ASPEKTAI	12
1.1. Investavimo samprata ir prekyba akcijomis	12
1.1.1. Investavimo esmė ir pagrindinės sąvokos	12
1.1.2. Rinkos struktūra ir dalyviai	13
1.1.3. Akcijų analizės metodai	14
1.1.4. Rizikos valdymas ir portfelio teorija	21
1.1.5. Akcijų portfelio sudarymo strategija	22
1.1.6. Akcijų portfelio valdymo praktiniai aspektai	23
1.2. Akcijų prekybos automatizavimo istoriniai pavyzdžiai	24
1.3. Dirbtinio intelekto agentai finansų rinkose	25
1.3.1. Dirbtinio intelekto taikymai finansų srityje	26
1.3.2. Sustiprinto mokymosi agentai prekyboje	27
1.3.3. Agentų struktūra ir sistemos komponentai	28
1.3.4. Duomenys ir jų paruošimas	29
1.3.5. Dirbtinio intelekto agentai paremti dideliais kalbos modeliais	29
1.4. Didelių kalbos modelių panaudojimo pavyzdžiai prekyboje	30
1.4.1. Didelių kalbos modelių pritaikymo pavyzdys visam prekybos poligonui	30
1.4.2. „FINMEM“ didelių kalbų modelio prekybos agento pavyzdys	32
1.4.3. Didelių kalbų modelio kriptovaliutų rinkoje pavyzdys	33
2. DIRBTINIO INTELEKTO AGENTŲ PAREMTOS AKCIJŲ PREKYBOS PROTOTIPAS	35
2.1. Akcijų prekybos prototipo architektūra paremta dirbtiniu intelektu agentu	35

2.2.	Prototipo realizacija „n8n“ platformoje be sentimentalios analizės	38
2.2.1.	Iniciavimo blokas	38
2.2.2.	Duomenų rinkimo ir apdorojimo blokas	40
2.2.3.	Dirbtinio intelekto agento blokas	42
2.2.4.	Kintamųjų paskirstymo ir jų tvarkymo blokas	45
2.2.5.	Operacijų vykdymo blokas	46
2.3.	Prototipo realizacija „n8n“ platformoje su sentimentalio analize	47
3.	PROTOTIPO VERTINIMAS IR REZULTATAI	51
3.1.	Prototipo testavimo aplinka ir duomenų rinkimas	51
3.2.	Prototipų vertinimas ir rezultatų aprašymas	55
	IŠVADOS IR PASIŪLYMAI	63
	LITERATŪRA	65
	PRIEDAI	71

SANTRAUPŲ SĄRAŠAS

ADX – vidutinis krypties indeksas

API – programinės įrangos sąsaja

EMA – eksponentinis slankusis vidurkis

MACD – slankiųjų vidurkių konvergencijos ir divergencijos indikatorius

RSI – santykinio stiprumo indeksas

SMA – paprastasis slankusis vidurkis

TR – tikroji diapazono reikšmė

OBV – balansinis prekybos apimtys rodiklis

VROC – prekybos apimtys pokyčio greitis

VWAP – apimtys svartinė vidutinė kaina

WMA – svartinis slankusis vidurkis

LENTELIŲ SĄRAŠAS

1 lentelė. Indikatoriai	20
2 lentelė. Darbo eigos automatizavimo platformos	37
3 lentelė. Platformos teikiančios techninius duomenis.....	41
4 lentelė. Brokerių palyginimas	47
5 lentelė. Mėnesiniai kaštai.....	50
6 lentelė. Pelningumo rodiklių rezultatai	58
7 lentelė. Rizikos lygio rezultatai	59
8 lentelė. Prototipų kokybiniai rodikliai	60

PAVEIKSLŲ SĄRAŠAS

1 pav. Linijinis grafikas	16
2 pav. OHLC grafikas	17
3 pav. Žvakių grafikas.....	17
4 pav. Kylanti tendencija	18
5 pav. Žemėjanti tendencija	19
6 pav. Šoninė tendencija	19
7 pav. „AlphaArena“ duomenys	34
8 pav. Prototipo architektūra.....	36
9 pav. Iniciavimo blokas	38
10 pav. Iniciavimo mazgas.....	39
11 pav. Atsitiktinis portfelio sudarymas.....	40
12 pav. Duomenų rinkimo ir apdorojimo blokas	41
13 pav. Duomenų rinkimo ir apdorojimo blokas	43
14 pav. Agento mokymo laukas.....	43
15 pav. Sistemos žinutės laukas	44
16 pav. Kintamųjų paskirstymo ir jų tvarkymo blokas	46
17 pav. Operacijų valdymo blokas.....	46
18 pav. Prototipo architektūra su sentimentalia analize.....	48
19 pav. Prototipo architektūra su sentimentalia analize.....	49
20 pav. Duomenų rinkimas	52
21 pav. „Open AI“ prototipų sukauptosios gražos palyginimas	55
22 pav. „DeepSeek“ prototipų sukauptosios gražos palyginimas.....	56
23 pav. „Gemini“ prototipų sukauptosios gražos palyginimas	57

SANTRAUKA

Lukša, Gediminas (2025). Stock Trading Automation Using a Large Language Model-Based Trading Agent. MBA Graduation Paper. Kaunas: Vilnius University, Kaunas Faculty, Institute of Social Sciences and Applied Informatics. 88p.

SUMMARY

The pursuit of financial independence has become increasingly relevant in the digital age, as internet accessibility provides vast amounts of information and new investment opportunities. Over the last decade, significant advancements in Artificial Intelligence (AI) have transformed daily tasks. However, its application in achieving consistent investment success remains a complex challenge. While existing literature explores various AI implementations in the financial sector, a definitive and universally successful strategy for AI-driven investing has yet to be established.

The primary objective of this thesis is to develop and evaluate an automated stock trading system based on Large Language Model (LLM) agents. The research begins with a comprehensive analysis of investment theories, AI literature, and the history of trading automation. In the practical part of the work, six distinct LLM-based prototypes were developed and tested through real-time paper trading. The performance of these prototypes was then evaluated using key financial metrics, including cumulative return, Sharpe ratio, and maximum drawdown.

The literature review revealed a significant gap in the evaluation of LLM efficiency within active trading environments. The experimental results of this study demonstrated that LLM-based agents can effectively navigate financial markets, with "DeepSeek" and "Gemini" prototypes achieving the most efficient returns and demonstrating high risk-adjusted performance. These findings suggest that LLM-based automation can serve as a viable tool for modern investment strategies.

This paper consists of 62 pages, 8 tables, and 23 illustrations.

IVADAS

Finansinė laisvė yra šių laikų modernaus žmogaus gyvenimo tikslas nustumiantis tradicines vertybes į šalį. Žmonės siekia išsilavinimo, karjeros, skiria daug laiko ir energijos, kad patenkintų kylančius materialinius poreikius. Deja, vieniems tai pavyksta, kitiems – ne.

Investavimas arba santaupų įdarbinimas yra vienas iš problemos sprendinių, kuris gali padėti pasiekti finansinę laisvę. Investavimo būdų yra nemažai: tai gali būti nekilnojamojo turto, automobilių ar įrankių nuoma, kolekcinų daiktų ar net tauriųjų metalų pirkimas. Subtilesnių sugebėjimų reikia prekyba akcijomis, obligacijomis, vertybiniais popieriais ar kitiems finansiniams įrankiams. Tai irgi reikalauja nemažai drąsos, laiko, pastangų ir žinių. Auksinės taisyklės į greitą finansinę laisvę nėra, nors finansiniai sukčiai prisidengę žaibiškai augančiais portfelių procentais, žada nerealų praturtėjimą.

Interneto prieinamumas XXI a. leido žmonėms priartėti prie naujų finansinių įrankių, nors jie pasaulyje buvo žinomi ne vieną šimtmetį. Žmonės naudodami internetą gali investuoti savo laiką į nuotolinius kursus, klausyti audio knygas, išbandyti jėgas popierinėse akcijų biržose. Užpildytos žinių spragos ir internetinių brokerių pagalba asmenims suteikė galimybes kelių mygtukų paspaudimais nusipirkti įmonių akcijų, obligacijų ar kitų finansinių įrankių. Internetas panaikino atstumą tarp pasaulinių akcijų biržų ir sudarė galimybes kiekvienam žmogui pasijausti jaunaisiais biržos spekuliantais. Šis dešimtmetis garsėja dirbtinio intelekto galimybėmis, su kuriomis žmonės tik susipažįsta. Jo išbandymas dar pirminėje stadijoje, o susiejimas su investavimo platformomis galėtų atnešti daugiau galimybių žmonijai.

Problemų ištyrimo lygis

Sparčiai besivystančios technologijos ir didėjantis dirbtinio intelekto pritaikymas finansų sektoriuje atveria naujas galimybes. Tradiciniai investavimo metodai nevisiškai užtikrina objektyvius sprendimus. Vis didėjantis informacijos laukas toks, kaip kainos, fundamentalių rodiklių aibė, socialinės žinios sukuria investuotojui dilemas kur investuoti, kaip apsaugoti savo turtą. Paskutiniaisiais dešimtmėčiais tobulėjantys dirbtinio intelekto metodai leidžia pasivyti didelius duomenų srautus, tačiau tobulų rezultatų neatneša.

Pagrindiniai prekybos algoritmai pastarąjį dešimtmetį buvo grindžiami gilaus mokymo, prižiūrimo mokymo ar sustiprinto mokymosi algoritmais. Deja, jie susiduria su iššūkiais, kurie nenugalėjo rinkų. Nors jie šiuo metu efektyviausiai apdoroja didelio kiekio informaciją susijusią su finansiniais rodikliais, įskaitant ir akcijų kainas bei indikatorius, pagrindinė problema, kad jie sunkiai suderinami su sprendimo priėmimu (Balhara ir kt., 2025). Taip pat sustiprinto gilaus mokymo modeliams ne tik sunku perduoti tekstinę informaciją, kuri užima daug vietos ir reikalauja daug resursų, bet ir efektyviai integruoti tekstinius duomenis su skaitmeniniais rodikliais. Empiriniai

tyrimai rodo, jog tekstinių atvaizdų jungimas su skaitmeniniais duomenimis veda prie sujungimo klaidų (Samuel ir Bence, 2020).

Paskutiniai didelių kalbų modelio pasiekimai leidžia kurti ir tobulinti dirbtinio intelekto agentus, kurie galėtų išspręsti išvardintus iššūkius (OpenAI ir kt., 2024). Didelių kalbų modelių pranašumas – mažesnė izoliacija palyginus su sustiprintu mokymu ar kitais mokymo modeliais. Šis pranašumas įgautas dėl jau turimų modelių žinių ir apmokymo (Wu ir kt., 2023). Tyrimai rodo, jog instrukcijomis paremtas mokymas pagerina problemų sprendimo rodiklius įvairiose srityse (Li ir kt. 2023). Vis didėjantis tyrimų kiekis skirtas didelių kalbų modeliams pasitelkti, siekiant priimti prekybos sprendimus (Yang, ir kt., 2025). Didelių kalbų modelio esminė užduotis – atsakymai į klausimus, o ne sprendimo priėmimas, dėl to jie bendrauja atsakymu „laisvesniu“ formatu, o ne griežtais ir tiksliais atsakymais. Negana to, prekybos strategijos priklauso nuo neaiškių didelių kalbos modelių apmokymų ir jų turimos informacijos. Šie modeliai neatpažįsta kritinės – svarbiausios informacijos, kurios praverčia standartiniam investuotojui.

Šie išvardinti argumentai parodo temos aktualumą, kadangi trūksta didelių kalbų modelių tyrimų ir analizės, dėl to šio **darbo tikslas**: sukurti didelių kalbų modelių grindžiamus prekybos agentus gebančius prekiauti akcijų biržoje ir atlikti jų rezultatų vertinimą.

Darbo problema – kaip LLM agentų panaudojimas gali generuoti grąžą investuojant į akcijų biržą?

Darbo objektas – investavimas panaudojant LLM agentus.

Darbo uždaviniai

Tikslui pasiekti yra nagrinėjami šie uždaviniai:

1. Išnagrinėti investavimo sampratą, platformas, įrankius.
2. Išanalizuoti dirbtinio intelekto sampratą, panaudojimo sritis ir galimybes.
3. Išanalizuoti istorinius automatizuotus akcijų prekybos sprendimus.
4. Sukurti didelių kalbų modeliu veikiančio prototipo modelį ir vykdyti akcijų prekybą testavimo aplinkoje.
5. Įvertinti agentų prekybos rezultatus naudojant apibrėžtas metrikas.

Darbo struktūra

Pirmoje „Akcijų prekybos ir dirbtinio intelekto teoriniai aspektai“ plačiai aptarsiu investavimą, konkretizuosiu investavimą į akcijas. Aptarsiu techninę, fundamentalią ir sentimentalią analizes. Pristatysiu automatizuotą akcijų prekybos istoriją. Pristatysiu dirbtinio intelekto sampratą, jo galimybes panaudojimo pavyzdžius. Taip pat aptarsiu dirbtiniu intelektu automatizuotos prekybos pavyzdžius.

Antrojoje dalyje „Dirbtinio intelekto agentu paremtos akcijų prekybos prototipas“ pristatysiu algoritmus bei prototipo kūrimo eigą. Aprašysiu pagrindinius prototipo blokus, naudotas programas bei kodėl jos pasirinktos.

Trečiojoje dalyje „Prototipo vetinimas ir rezultatai“ aprašysiu prototipo testavimo aplinką ir gautus duomenis, kaip juos sutvarkiau bei prototipo vertinimo kriterijus.

Darbą užbaigsiu „Išvados ir siūlymais“. Pateiksiu išvadas iškeltiems tikslams bei siūlymus tolimesniems prototipų projektams.

Darbe naudoti literatūros šaltiniai

Pirmoje darbo dalyje pagrindą sudarė užsienio šalių autoriai, jų knygos, moksliniais straipsniai taip pat enciklopedijos. Antroje dalyje programų palyginimui naudoti atviri internetiniai šaltiniai, programų internetiniai puslapiai. Prototipų kūrimui bei skirtingų programų sujungimui naudotos jų dokumentacijos. Trečioje dalyje vertinimams naudotos užsienio autorių knygos.

Darbo ir tyrimo metodai

Analizuojant pirmąją dalį, kuri skirta investicijom ir dirbtiniam intelektui buvo taikoma mokslinės literatūros analizė, atvirų šaltinių analizė, abstrachtavimo ir sintezės metodai. Antroje dalyje kūriau prototipą. Trečioje dalyje lyginsiu prototipus su standartinėmis investavimo priemonėmis, lyginsiu finansinius rodiklius.

Darbo rezultatų teorinė ir praktinė reikšmė

1. Išnagrinėtos investicijų galimybės.
2. Pristatytos dirbtinio intelekto galimybės.
3. Išanalizuotos istorinės prekybos automatizavimo galimybės.
4. Sukurti šeši prototipai, kurie buvo ištestuoti testavimo aplinkoje.
5. Prototipai palyginti per skirtingas vertinimo metrikas.

Darbo sunkumai, taikymo apribojimai

Nebuvo visiško brokerio integralumo su prototipu. Pasitaikė klaidos, dėl brokerio taikomos politikos (*angl.* Pattern Day Trader) buvo stabdoma prototipo prekyba. Brokeris automatiškai neuždarydavo pozicijų pasiekus nuostolio fiksavimo lygį. Tyrimo rezultatai remiasi „popierinės“ prekybos duomenimis 1,5 mėnesio laikotarpiu. Šis laikotarpis leidžia įvertinti tik momentinį prototipo tinkamumą esamomis rinkos sąlygomis. Ilgalaikiam statistiniam patikimumui patvirtinti reikalingas ilgesnio laikotarpio testavimas (bent jau metų), apimantis skirtingus rinkos ciklus.

Darbo struktūra ir apimtis

Darbą sudaro keturios dalys: akcijų prekybos ir dirbtinio intelekto teoriniai aspektai, dirbtinio intelekto agentu paremtos akcijų prekybos prototipas, prototipo vertinimas ir rezultatai bei išvados ir siūlymai. Puslapių skaičius – 88, lentelių skaičius – 8, paveikslų skaičius – 23, priedų – 17 puslapių.

1. AKCIJŲ PREKYBOS IR DIRBTINIO INTELEKTO TEORINIAI ASPEKTAI

Šioje dalyje bus nagrinėjami pagrindiniai du aspektai akcijų prekyba ir dirbtinis intelektas. Teorinė analizė leis geriau suprasti investavimą į akcijų biržą, o dirbtinio intelekto analizė leis susipažinti su jo galimybėmis susiejant šiuos aspektus prototipo kūrimui.

1.1. Investavimo samprata ir prekyba akcijomis

Pirmoje akcijų prekybos ir dirbtinio intelekto teorinėje dalyje išgryninsiu pagrindines sąvokas, plačiai aptarsiu pačias investavimo galimybes, kas leis suprasti pagrindinius įrankius. Aprašius investavimo galimybes bus prieita prie akcijų prekybos, rinkos, jos dalyvių, akcijų analizės, rizikos valdymo.

1.1.1. Investavimo esmė ir pagrindinės sąvokos

Žmogus turintis kapitalo turi trys galimybes: taupyti, išleisti arba investuoti. Taupymas – tai vartojimo aukojimas tikintis, kad ateityje iškils didesnis pinigų poreikis arba kitais išsireiškiant: kapitalo kaupimas sunkiems laikams, kuomet staigiai ar nenumatytiems atvejams prireikia pinigų. Pinigų leidimas savaime suprantamas dalykas siekiant patenkinti nuo minimalių iki maksimalių poreikių. Plačiąją prasme K. Levišauskaitė investavimą skiria į dvi dalis: turto ir finansų investavimą. Investavimas į turtą apima apčiuopiamą turtą tokį, kaip žemė, gamyklos, įranga. Finansinis investavimas apima akcijas, obligacijas ir kitus finansinius įrankius (Levišauskaitė, 2010). Ekonomistas N. T. Laopodis investavimą apibrėžia panašiai kaip taupymą. Investavimas, anot autoriaus, vartojimo paaukojimas, kaip ir taupymas, tačiau fundamentalus skirtumas yra rizika. Tuomet pateikiamas pavyzdys, kuomet santaupos laikomos banke yra apdraustos valstybės, o nusipirkus akcijų, jų kaina gali nukristi ir kapitalas sumažėti (Laopodis, 2021). Kitas investavimo apibrėžimas apima dabartinį pinigų įsipareigojimą tam tikram laiko periodui tam, kad ateityje investuotos lėšos kompensuotų laiką, infliaciją ir ateities neapibrėžtumą riziką (Reilly & Brown, 2002). Apibendrinant šaltinius, investavimas – tai lėšų įdarbinimas siekiant uždirbti iš rizikos ir aukojant laiką.

Investicinių instrumentų į kuriuos galima būtų investuoti yra daug, tačiau šio darbo tikslas nėra juos visus apžvelgti. Dėl to bus aptariami populiariausi bei akcijos. Valstybinė mokesčių inspekcija įvardija šias finansines priemones: vertybiniai popieriai (akcijos, obligacijos), pinigų rinkos priemonės (iždo vekseliai), kolektyvinio investavimo subjektų vertybiniai popieriai

(investicinių fondų vienetai), išvestinės finansinės priemonės (pasirinkimo (angl. *option*), ateities (angl. *future*), apsiskeitimo (angl. *swap*), išankstiniai (angl. *forward*) sandoriai, finansiniai susitarimai dėl skirtumų (CFD)) (Valstybinė mokesčių inspekcija, 2025).

Investuojant labai svarbu apsaugoti savo kapitalą nuo praradimo. Literatūroje, kaip vienas iš apsaugojimo būdų pateikiama diversifikacija. Diversifikacija – tai investicijų paskirstymas strategija (Segal, 2005) per skirtingas turto klases, sektorius ar netgi regionus, siekiant sumažinti riziką, jeigu vienas aktyvas patirtų nuostolius, tai paveiktų mažiau visą portfelį.

Aptarus pagrindines sąvokas ir suvokus kiek daug yra investavimo galimybių, privalu toliau nagrinėti pačią prekybinę rinką, kas yra rinkos žaidėjai arba dalyviai.

1.1.2. Rinkos struktūra ir dalyviai

Prekybos rinka tai vieta, kur pirkėjai ir pardavėjai susitaria dėl mainų. Rinkų yra ne viena, kas tai leidžia diversifikuoti investicijas. Obligacijų rinka – tai rinka, kurioje korporacijos, savivaldybės ar net valstybės išduoda vertybinius popierius paskolos davėjams. Svarbu paminėti, kad tai viena saugiausių investicijų. Žaliavų rinka apima prekybą žaliavomis, kurias galima skirstyti į dvi kategorijas: žaliavas (auksas, sidabras, nafta ir t. t.) bei žemio ūkio (kava, kviečiai, medvilnė ir t. t.). Bene didžiausia yra valiutų rinka (Kenton, 2025). Prekiautojai perka ir parduoda valiutas siekdami uždirbti iš valiutų skirtumų, kuriuos lemia ekonominiai ar geopolitiniai įvykiai. Naujausia kriptovaliutų rinka yra panaši į įprastų valiutų rinką, tačiau joje prekiaujama virtualiomis valiutomis.

Aptarus rinkų įvairovę, bus aptariama akcijų rinka. Akcijų rinka – tai vieta, kurioje įmonės gali prisitraukti kapitalą parduodant akcijas arba kitaip įmonės dalis investuotojams. Akcininkai įsigiję akcijų gauna teisę balsuoti įmonės valdymo klausimais taip pat teisę į uždirbtą pelną dividendų pavidalu. Akcijų rinka taip pat suteikia rinkos dalyviams prekiauti tarpusavyje, tai nustato rinkos kainą pagal siūlomą ir reikalaujamą kainą bei kokia tuo metu yra akcijų paklausa ir pasiūla. Pavyzdžiui, kuomet kuo daugiau prekeivių nori nusipirkti akcijų ir kuo mažiau parduoti, dažniausiai akcijų kaina kyla. Neverta pamiršti ir tai, kad yra pirminė ir antrinė akcijų rinka. Pirminėje akcijų rinkoje įmonė akcijas išleidžia per priminį viešą pasiūlymą (angl. *initial public offering, IPO*). Pirminėje akcijų rinkoje įmonės pasikelia savo kapitalą. Antrinė rinka vyksta tuomet, kai akcijos yra jau pas akcininkus ir vyksta prekyba su kitais prekiautojais, tačiau pati įmonė jau nebedalyvauja (Hayes, 2025). Viena garsiausių akcijų birža, kurioje vyksta prekyba, yra Niujorko akcijų birža (angl. *New York Stock Exchange*). Kaip ir minėta anksčiau kaina yra nustatomų rinkos dalyvių. Dalyvių yra ne vienas ir galima juos būtų kategorizuoti taip:

- Individualūs investuotojai (pvz. privatūs asmenys).
- Instituciniai investuotojai (pvz. akcijų, pensijų fondai).

- Spekuliantai (subjektai prekiaujantys trumpą laiką, siekdami užsidirbti iš kainų svyravimų).
- Brokeriai vykdantys mainus tarp dalyvių.
- Rinkos formuotojai užtikrinantys likvidumą prekiaujant (Bloomenthal, 2025).

Atlikus apžvalgą galima teigti, jog rinkoje yra daug suinteresuotų dalyvių siekiančių užsidirbti ir darančių įtaką akcijų kainai.

1.1.3. Akcijų analizės metodai

Prieš įsigyjant akciją yra būtina įvertinti kokia jos kaina, ar nėra išpūsta rinkos dalyvių. Atvirkštinis variantas irgi įmanomas: galbūt akcija nuvertinta ir po trumpo laiko ji normalizuosis taip atnešant pelną pirkėjui. Teisingas kainos nustatymas yra sudėtingas Oskaras Vaildas turi savo matymą apie kainos nustatymą: „Kas yra cinikas? Tai žmogus, žinantis visko kainą, bet neišmanantis vertės“. Citata nieko bendro neturi su akcijų kaina, tačiau tai tinkama asmenims, kurie siekia spekuliuoti jų kaina, dėl to privalu analizuoti akcijas įvairiais būdais, kad kuo tiksliau ją įvertinti ir nepasiduoti paskalom. Akcijų analizę galima apibrėžti akcijos vertinimu, kaip jos kaina kis ateityje. Bet kuriuo atveju, tai labai svarbu siekiant investuotojui arba prekiautojui nuspręsti pirkti ar parduoti akcijas, tam gali padėti matematiniai, statistiniai ar kompiuteriniai skaičiavimai. Akcijos analizė tradiciškai apima ir skirstoma į fundamentalią, techninę ir kiekybinę.

Fundamentali analizė – tai kompanijos finansinės sveikatos patikra, kuri apima vidinės vertės lygį pasiremiant įmonės ekonominiais rodikliais, finansinėmis ataskaitomis, sektoriaus perspektyvomis ir makroekonomikos faktoriais. Šios analizės pagrindinis tikslas nustatyti, ar rinka teisingai įvertina akcijų kainą (Penman, 2010). Kainos gali būti pervertintos (angl. *overvaluated*) arba neįvertintos (angl. *undervaluated*). Finansinėse ataskaitose privalu atkreipti dėmesį į pelningumą, likvidumą, mokumą, efektyvumą bei augimo trajektoriją. Įmonės patikimumui nustatyti gali būti naudojami įvairūs rodikliai:

- Pajamos (angl. *revenue*) ir grynasis pelnas (angl. *net income*) – rodikliai apie įmonės veiklos dydį ir pelningumą (Ray Ball & Philip Brown, 2003).
- Pelnas vienai akcijai (angl. *earnings per share – EPS*) – grynasis pelnas vienai akcijai; svarbus pelningumo matas (Penman, 2010). Kuo didesnis rodiklis indikuoja didesnę vertę.
- P/E rodiklis (angl. *Price-to-Earnings*) – santykinis akcijos rodiklis, kai kaina padalinta iš EPS (Basu, 1977). Aukštas rodiklis rodo pervertintą akciją.

- P/B rodiklis (angl. Price-to-Book) – santykis apskaičiuojamas akcijų kainą padalijus iš jos balansinės vertės vienai akcijai (Fama & French, 1992). Rodiklis žemiau 1 vertinamas teigiamai.
- EV/EBITDA rodiklis yra pagrindinis finansinis rodiklis naudojamas įvertinti įmonės vertę, atsižvelgiant į jos skolą kartu su pelnu ir palūkanomis, mokesčiais, nusidėvėjimu bei amortizacija (Aswath Damodaran, 2012). Kuo mažesnis įmonės rodiklis, palyginus su panašiomis pramonės šakomis arba istoriniais vidurkiais, parodo, kad įmonė yra nepakankamai įvertinta, o didesnis rodiklis – pervertinimą.
- Gražos rodikliai. Kapitalo grąža (angl. *return on equity* - ROE) apskaičiuojama grynąjį pelną padalijus iš akcininkų nuosavybės. Akcininkų nuosavybė yra lygi įmonės turtui atėmus skolą, šis rodiklis parodo įmonės grynojo turto grąžą. Kuo didesnis ROE, tuo efektyviau įmonės vadovybė generuoja pajamas ir augimą iš nuosavo kapitalo finansavimo. Turto grąža (angl. *return on assets* – ROA) rodiklis nusako, kaip efektyviai įmonė naudoja savo turtą pelnui gauti. Rodiklis atskleidžia, kokios pajamos gaunamos iš investuoto kapitalo (Penman, 2010). Didesnė ROA reiškia, kad įmonė efektyviau ir produktyviau valdo savo balansą, kad gautų pelno, mažesnė – priešingai.
- Skolos ir nuosavo kapitalo rodiklis (angl. *debt-to-equity* – D/E) skirtas įvertinti įmonės finansinius svertus. Jis apskaičiuojamas padalijus visus įmonės įsipareigojimus iš jos akcininkų nuosavo kapitalo. Rodiklis parodo, kiek įmonė finansuoja savo veiklą skolomis, o ne savo ištekliais (Stephen A. Ross ir kiti, 2013). Skolos ir nuosavo kapitalo rodiklis nėra konstanta, o įmones reiktų vertinti pagal sektoriaus rodiklius arba istoriškai, kaip kito rodiklis.
- Einamasis rodiklis (angl. *curret ratio*) parodo trumpalaikio turto (laisvi pinigai, atsargos, gaunami pinigai) santykį su trumpalaikiais įsipareigojimais, siekiant nustatyti, kaip gerai įmonė gali įvykdyti visus per metus mokėtinus finansinius įsipareigojimus (Eugene F. Brigham ir Michael C. Ehrhardt, 2020). Geras santykis laikytinas nuo 1 iki 2, žemiau 1 – prastas rodiklis.
- Greitasis rodiklis (angl. *quick ratio*) matuoja įmonės gebėjimą nedelsiant įvykdyti trumpalaikius įsipareigojimus, naudojant likvidžiausią turtą. Greitasis likvidumo rodiklis naudojamas įmonės pinigų pozicijos stiprumui įvertinti (Eugene F. Brigham & Michael C. Ehrhardt, 2020). Kuo aukštesnis rodiklis yra geresnis rezultatas.
- Laisvas pinigų srautas (angl. *free cash flow* – FCF) yra kompanijos pinigų suma, kuri liko išleidus savo pinigus veiklai ir kapitalui palaikyti bei išlaikyti (Aswath Damodaran, 2012).

- Pajamos (angl. *revenue*) gautos iš pagrindinės įmonės veiklos bei pajamos gautos iš antrinių šaltinių (Fama & French, 1992).

Svarbu paminėti, kad tai tik dalis fundamentalaus analizės kriterijų, o aptarus svarbiausias, būtina išanalizuoti ir techninę analizę. Techninė analizė vertina rinkos elgesį naudodama praities kainų ir apimties duomenis, jų suformuotas diagramas bei techninius indikatorių signalus. Techninės analizės prielaida teigia, jog rinkos kaina įtraukia visą turimą informaciją, o kainų judėjimai seka tam tikrus modelius ir tendencijas., kuriuos galima identifikuoti ir panaudoti prekybos sprendimams (John J. Murphy, 1999). Išskirsiu trys svarbiausius techninės analizės objektus:

1. Kainų diagramos – tai diagrama, kur atvaizduojama istorinė akcijos kaina, jų yra keletas rūšių ir jos pateikia skirtingam informaciją. Linijinis grafikas (1 pav.), kurioje atvaizduojama akcijos uždarymo kaina (Hayes, 2025). Linijiniai grafikai yra patys



Šaltinis: sudaryta autoriaus pagal „TradingView“ duomenis (2025-10-27)

1 pav. Linijinis grafikas

paprasciausi ir jie neparodo, kas įvyko nagrinėjamo laikotarpio periodu. Pavyzdžiui, šiame grafike neaišku, ar kaina buvo, ar mažesnė, kokia didžiausia ir kokia mažiausia kaina buvo periodo metu (Trinkūnas, 2007). Aktyviems prekyautojams reikia daugiau informacijos, dėl to atsirado kitokio pobūdžio grafikų. Kiekviename investavimo platformų ar akcijų kainų stebėjimo puslapiuose galima rasti OHLC grafikų (angl. *Open-High-Low-Close*) (2 pav.). Iš pateikto pavyzdžio galima spręsti tos dienos atidarymo



Šaltinis: sudaryta autoriaus pagal „TradingView“ duomenis (2025-10-27)

2 pav. OHLC grafikas

kainą, aukščiausią to periodo, žemiausią ir uždarymo kainas. Tačiau, prekiautojams neužteko tokio grafiko – jiems reikia daugiau duomenų. Kiekvienoje investavimo knygoje, straipsnyje, ar kitoje mokomojoje medžiagoje vyrauja žvakių grafikai (angl. *candlestick bars*) (3 pav.). Šiuose grafikuose atvaizduojama tokia pati informacija kaip ir



Šaltinis: sudaryta autoriaus pagal „TradingView“ duomenis (2025-10-27)

3 pav. Žvakių grafikas

OHLC tipo grafikuose, tačiau juose galima išvelgti ir prekiautojų psichologinį portretą ir prekybos braižą. Biržų prekiautojai stebėdami ir analizuodami grafikus pamatė tendencijas ir sugalvojo modelius (angl. *pattern*), kurie naudojami ateities kainos prognozei (Trinkūnas, 2007). Grafikų funkcija – nustatyti rinką, kokia yra tendencija (kylanti, besileidžianti ar neapibrėžta), kokie pasipriešinimo (angl. *resistance*) ar palaikymo (angl. *support*) lygiai yra. Taip pat grafikai padeda nustatyti modelius, rinkos pasikeitimo taškus, padeda identifikuoti kainos veiksmų signalus bei nustatyti įėjimo ir išėjimo į sandorį taškus (John J. Murphy, 1999).

2. Kainų tendencijos apibrėžia ilgalaikius arba vidutinius kainų judėjimus: viršun, žemyn arba į šonus. Kylančią tendenciją galima nustatyti sujungus aukštesnės aukštumos ir aukštesnės žemumos taškus (4 pav.). Iš paveikslėlio matome, kad pavaizduota tendencija kylanti.



Šaltinis: sudaryta autoriaus pagal „TradingView“ duomenis (2025-10-27)

4 pav. Kylanti tendencija

Analogiškai, žemėjančią tendenciją gausime sujungiant žemesnės aukštumos ir žemesnės žemumos taškus (5 pav.)



Šaltinis: sudaryta autoriaus pagal „TradingView“ duomenis (2025-10-27)

5 pav. Žemėjanti tendencija

Šoninė tendencijos metu kaina tam tikrą laiką juda siaurame diapazone be aiškios kylančios ar žemėjančios krypties (6pav.). Tendencija atpažįstama grafike, kuomet palaikymo ir pasipriešinimo linijos yra horizontalios, mažesni svyravimai ir mažesnis kintamumas nei turinčiose kryptį tendencijose (John J. Murphy, 1999).



Šaltinis: sudaryta autoriaus pagal „TradingView“ duomenis (2025-10-28)

6 pav. Šoninė tendencija

Tendencijas galima nustatyti ir kitais metodais. Tendencijų nustatymui taip pat naudojami vidurkiai tokie kaip paslankusis vidurkis, paprastasis paslankusis vidurkis ir kiti (Brock ir kiti 1992).

- Indikatoriai yra kitas labai svarbus dëmuo techninėje analizėje. Tai matematiniai arba statistiniai rodikliai, kurie yra apskaičiuojami iš pagrinde kainos ir prekybos apimčių. Jų paskirtis taip pat identifikuoti tendencijas impulsus (angl. *momentum*), kintamumą (angl. *volatility*), patvirtinti signalus, nustatyti kainas, kada įeiti arba išeiti iš sandorio (Gerald Appel, 2005). Pagal apžvelgtą literatūrą indikatorius suskirsčiau į lentelę (1 lentelė).

1 lentelė

Indikatoriai

Pavadinimas	Paskirtis	Pavyzdžiai
Slankieji vidurkiai	Tendencijų identifikavimas, dinaminiai palaikymo/pasipriešinimo signalai	SMA, EMA, WMA
Osciliatoriai arba momentiniai indikatoriai	Impulso stiprumas, perpirkimo/perpardavimo signalai, divergencijos	RSI, MACD, stochasiniai osciliatoriai
Kintamumo indikatoriai	Kainos svyravimų dydžio matavimas, didžiausio nuostolio nustatymas, pramušimų identifikavimas	TR, Bolingerio juostos, istorinis kintamumas
Apimties indikatoriai	Patvirtinimas pramušimų, divergencijų aptikimas, likvidumo vertinimas	OBV, VROC, VWAP
Šabloninės kainos formacijos	Krypties pasikeitimo arba tęsinio signalai, pirkimo/ pardavimo signalai	Galva ir pečiai, Dvigubas dugnas/viršus, trikampiai
Kombinuoti / statistiniai indikatoriai	Kompleksiniai signalai, tendencijos stiprumas, dinaminiai lygių rinkiniai	ADX, Ichimoku debesis, VWAP juostos

Šaltinis: sudaryta autoriaus.

Aptarus fundamentalią ir techninę analizę privalu aptarti ir kiekybinę analizę. Kiekybinė analizė galima apibrėžti kaip investavimo metodika, kurios sprendimai paremti matematiniais, statistiniais ir kompiuteriniais modeliais. Svarbu pabrėžti, kad ji stipriai skiriasi nuo techninės analizės, kuri paremta subjektyvia intuicija (Campbell, Lo, & Mackinlay, 1997). Analizė apima duomenų rinkimą ir formatavimą, modelių kūrimą: laiko eilučių modeliai, mašininio mokymosi metodus, regresijas ir faktorinius modelius (Lopez de Prado, 2018). Sukurtų modelių bandymai atliekami istoriniais duomenimis.

1.1.4. Rizikos valdymas ir portfelio teorija

Pradedant aktyviai dalyvauti investavime svarbu žinoti, kad tai yra rizikinga, dėl galimo investicijų praradimo ar žymaus lėšų sumažėjimo. Siekiant išvengti nuostolių svarbu suprasti rizikas bei išmokyti jas valdyti.

Rinkos kintamumas matuoja rinkos arba turto kainos gražos svyravimų dydį per tam tikrą laikotarpį. Dažniausiai naudojami istorinio kintamumo arba laiko eilučių kintamumo modeliai. Kintamumas yra pagrindinis rizikos matas investuojant. Kuo didesnis kintamumas, tuo plačiau gali pasiskirstyti graža ir lemia didesnę neapibrėžtumą dėl busimos vertės. Kintamumas naudojamas investuotojų ne vien rizikos nustatymui, bet ir papildomam įėjimui į pozicijas, nuostolio nustatymui, su tikslu išlaikyti norimą rizikos lygį (Ruey S. Tsay, 2010).

Kitas svarbus dalykas yra koreliacija. Koreliacija tarp turimo investuoto turto nurodo, kiek kartu juda skirtingų, tarkim akcijų gražos. Investuotojo portfelyje koreliacija yra esminė, nors ir atskiros pozicijos yra pačios savaime rizikingos. Mažos arba neigiamos koreliacijos tarp akcijų gali sumažinti bendrą portfelio riziką. Portfelio rizikos sumažėjimas priklauso ne tik nuo individualių akcijų kintamumo, bet ir tarpusavio koreliacijos. Koreliacijos įvertinimas turi būti atliekas atsižvelgiant į laikotarpį (Ledoit & Wolf, 2004). Tinkama portfelio diversifikacija mažina koreliaciją. Diversifikacija privalo apjungti į skirtingus sektorius ar investavimo įrankius.

Žymus amerikiečių ekonomistas ir Nobelio laureatas Haris Markovičius apibrėžė modernaus portfelio teoriją. Teorijos tikslas sudaryti tokį portfelį, kad būtų kuo didesnė laukiamoji graža už nubrėžtą rizikos lygį, arba atvirkščiai padaryti kuo mažesnę riziką tikėtinaai gražai. Siūlomam portfelyje nepaisoma atskirų investicinių priemonių rizika (Markowitz, 1952). Esmė – tarpusavio elgsena, jei portfelio aktyvų graža nėra visiškai koreliuota, derinant juos galima sumažinti bendrą riziką.

Kapitalo turto kainodaros modelis (angl. *Capital Asset Pricing Model* – CAPM) pateikia požiūrį į turto riziką ir lūkesčių gražą. Kiekvieno aktyvo ar akcijos tikėtina graža susijusi su rinkos portfelio rizikos premija ir akcijos ar aktyvo jautrumu rinkos svyravimams, geriau žinomu kaip beta. Beta skaičiuojamas aktyvo ar akcijos sisteminę rizikos komponentą, palyginant su rinkos portfeliu. Beta didesnis nei vienas reiškia didesnę jautrumą rinkos svyravimams, beta mažesnis nei vienetą – mažesnę. Modelis teigia, kad diversifikacija pašalina tik dalį rizikos (Fama & French, 1992)

Jau minėta anksčiau diversifikacija yra geriausia rizikos mažinimo priemonė, apie kurią kalba autoriai. Diversifikacijos tikslas paskirstyti turtą tarp skirtingų akcijų, turto klasių ar net investicinių įrankių taip sumažinant riziką be proporcingo laukiamo gražos sumažėjimo. Svarbu, kad diversifikacija būtų orientuota į skirtingas sritis, kad būtų sumažinta koreliacija, ar ji net taptų neigiama. Praktiniai rizikos mažinimo įrankiai apima:

1. Pozicijų dydžių valdymas.
2. Nuostolio sustabdymo (angl. *stop-loss*) taisyklės arba slenkantis (angl. *trailing-stop*).
3. Apimties ir likvidumo vertinimas – didesnė apimtis, greičiau galima išeiti iš sandorio.
4. Naudoti išvestines investicines priemones.
5. Portfelio ribojimas.
6. Periodinis rebalansavimas.

Neverta pamiršti ir tai, kad krizių metu koreliacijos dažniausiai kyla, kas sumažina diversifikacijos naudą ir reikalauja kitų sprendimo būdų.

1.1.5. Akcijų portfelio sudarymo strategija

Aptarus akcijų analizės metodus bei rizikas svarbu apžvelgti portfelio sudarymo strategiją. Akcijų portfelis – tai investuotojo vertybinių popierių rinkinys priklausantis asmeniui. Jo sudarymo strategijos yra sekančios:

- Pasyvios strategijos orientuotos į rinkos atvaizdavimą ir minimalų aktyvų, akcijų pasirinkimo ar prekybos periodiškumą. Pagrindinis šios strategijos tikslas – sekti indeksą arba rinkos turto klasę naudojant indeksinius fondus arba biržoje prekiaujamais fondais žinomais kaip ETF ir laikyti pozicijas ilgą laiką (Ziv Bodie ir kiti, 2014). Tokio tipo strategijų privalumai yra žemesni mokesčiai, mažesnė kritimo rizika ir rizika dėl žmogaus sprendimų klaidų. Mokslinė darbų analizė teigia, jog ilgalaikėje perspektyvoje pasyvus investavimas yra konkurencingas aktyvioms strategijoms po mokesčių ir kaštų atskaičiavimo (Fama & French, 1992). Didesnis trūkumas tai ribota galimybė apsisaugoti nuo rinkos smukimo, (2017).
- Aktyvios strategijos siekia viršyti rinkos grąžą per akcijų atranką panaudojant įvairius investavimo stilius tokius, kaip vertės, augimo, momentinės arba laiko rinkos sprendimus (Lo, 2004). Aktyvios strategijos apima ne tik standartinius pirkimo-pardavimo sandorius, bet ir fundamentalią analizę, techninius signalus ir kiekybinius modelius: mašininį mokymą bei faktorinius modelius. Šios strategijos privalumai yra aukštesnė grąža, investuotojo laisvas apsisprendimas, o trūkumai – didesni mokesčiai ir prekybos sandorių kaina, moksliniai straipsniai taip pat teigia, kad ši strategija neviršija pasyvios strategijos rezultatų (Ziv Bodie ir kt., 2014).
- Kelių išteklių ir paskirstymo strategija paskirsto kapitalą tarp skirtingų turto klasių tokių, kaip: akcijos, obligacijos, gryniesi, žaliavos, nekilnojamasis turtas, tam, kad diversifikuotų riziką ir pasiektų norimą rizikos – grąžos santykį (Markowitz, 1952). Išteklių paskirstymas gali būti statinis – strateginis paskirstymas, kuris perbalansuojamas pagal nustatytą grafiką arba dinaminis – taktinis paskirstymas, keičiamas priklausomai nuo rinkos perspektyvų ar

naujienų (Sharpe, 1992). Strateginis paskirstymas nusako ilgalaikį tikslinį svorių rinkinį, o taktinis paskirstymas siekia išnaudoti laikinus disbalansus arba rizikos premijas (Grinold ir Kahn, 1999). Kelių išteklių ir paskirstymo strategija leidžia valdyti koreliacijas tarp turto klasių ir optimizuoti portfelio efektyvumą.

1.1.6. Akcijų portfelio valdymo praktiniai aspektai

Akcijų portfelio valdymas reikalauja ne tik sudarymo strategijos parinkimo, bet ir disciplinuoto plano vykdymo. Periodinis portfelio balansavimas atstato portfelio svorius prie tikros rinkos vertės. Dažnas rebalansavimas reiškia daugiau sandorių, o kiekvienas sandoris turi tiesiogines ir netiesiogines sąnaudas. Tai gali sumažinti grąžą net jei rebalansavimo taisyklė teorijoje pagerina rizikos ar grąžos santykį (Grinold & Kahn, 1999). Likvidumo reikalavimai užtikrina, kad pozicijas būtų galima įvykdyti be reikšmingo rinkos poveikio (Kissell, 2014). Prekybos kaštai ir mokesčiai (komisiniai, vykdymo mokesčiai) turi būti įtraukti į atgalinius ir rezultatų skaičiavimus (Lopez de Prado, 2018).

Rizikos valdymas apima limitus, nuostolių sustabdymo taisykles ir pozicijų dydžio nustatymą. Limitai, pavyzdžiui maksimali kaina vienam aktyvui, mažina koncentracijos riziką. Nuostolių sustabdymas ir slenkantis sustabdymas automatiškai uždaro pozicijas apsaugant nuo esminių nuostolių, geriausia naudoti kintamumui pritaikytus sustabdymus, kad sumažinti „išmušinėjimą“ dėl triukšmo (Kritzman, Page, & Turkington, 2010). Pozicijų dydis galima nustatyti pagal rizikos dydį ir šias metodikas: fiksuotą trupmeninį dydį, pozicijos didinimą pagal aktyvo kintamumą arba Kelio formules, kartu taikant apsauginius limitus (Thorp, 2006).

Duomenų ar informacijos ataskaitos ir veiklos metrikos yra būtinos strategijos valdymo ir priežiūros procesui. Standartinės metrikos apima Šarpo rodiklis, „Sortino“ ratio, maksimalus nuosmukis ir „Calmar“ rodiklis. Galimi ir papildomi rodikliai: pataikymo rodiklis (nusako krypties numatymo dažnį), vidutiniai laimėtojai ar nepavykę sandoriai, grąža ir (Sharpe, 1992). Periodinės ataskaitos turi apimti realizuotą ir nerealizuotą pelną ir nuostolį, pozicijų dydį, likvidumo rodiklius. Empirinis vertinimas turi remtis ne vien imties rezultatais ir įtraukti sandorio kainas bei realius vykdymo scenarijus, kad pateiktos metrikos atitiktų tikrąją investicijų kokybę (Marcos Lopez de Prado, 2018).

Išanalizavus pirmąjį bloką informacijos galima teigti, jog tradiciniai investavimo modeliai paremti tiek fundamentalia, tiek technine analize atrodo sudėtingi ir kiekvienam žmogui sunkiai suprantami, arba tam reikia daug laiko. Siekiant supaprastinti investavimą privalu aptarti sparčiai tobulėjančias dirbtinio intelekto galimybes bei kuo jis gali būti naudingas priimant investicinius sprendimus.

1.2. Akcijų prekybos automatizavimo istoriniai pavyzdžiai

Siekiant geriau suprasti investicijų automatizavimą privalu pereiti per pagrindinius istorinius pavyzdžius nuo ko prasidėjo prekybos automatizavimas, kas jį lėmė ir kaip jis keitėsi.

Išradėjas Bilas Geitsas, tikriausiai, net neįsivaizdavo, kaip jo išradimas pakeis pasaulį. Vienas iš sektorių – tai finansų. Prekybos automatizavimas prasidėjo nuo elektroninės prekybos, kuri pradėjo plėtotis XXI a. devintajame dešimtmetyje, kuomet investuotojai ėmė naudotis kompiuteriais ir specialias prekybos platformas sandoriams įvykdyti (Lo, 1996). Populiariausias platformos buvo visai nepanašios į šių laikų programėles:

- „Instinet“ – tai vienas pirmųjų elektroninių ryšių tinklas, kuris leido instituciniam investuotojam vykdyti sandorius elektroniniu būdu be tradicinių brokerių. Tų laikų „Fintech“ buvo įkurtas 1969 metais, o išpopuliarėjo vėlesniame dešimtmetyje (Meet the original fintech).
- „Nasdaq“ elektroninę prekybą sistemą nuo XX a. aštunto dešimtmečio populiarėjo kaip elektroninė kotiravimo sistema, tačiau išpopuliarėjo tik devintame dešimtmetyje, kai tapo automatizuota prekybą sistema leidusi prekiauti elektroniniu būdu greičiau ir skaidriau nei senosiose biržose, kuomet sandoriai būdavo sudaromi žodžiu ar rankos signalais. „Nasdaq“ plėtra sudarė galimybes vėliau prekiauti elektroniniais ryšių tinklais ir sudarė galimybes mažesniems investuotojams dalyvauti rinkoje (Harris, 2002).

XX a. dešimtajame dešimtmetyje pradėjo populiarėti algoritminė prekyba, kuomet technologijos ir finansų rinkos tapo vis labiau automatizuotos. Algoritminė prekyba apima prekybos strategijų formavimą kaip iš anksto suplanuotus algoritmus, kurių pagalba investuotojai automatiškai vykdo prekybos užsakymus, remdamiesi rinkos duomenimis, statistiniais modeliais arba technine analize. Algoritmai akimirksniu gali atlikti analizę ir sandorius, taip pasinaudojant trumpalaikiais rinkos svyravimais (Hendershott ir Riordan, 2009). Neverta pamiršti ir tai, kad algoritminė prekyba sumažino emocinį prekiautojo svyravimą, kadangi nereikia žmogau įsikišimo.

Kitas svarbus lūžis įvyko, kuomet dirbtinis intelektas ir mašininio mokymosi metodai patobulėjo per pastaruosius dešimtmečius. Automatizuota prekyba transformavosi į pažangias strategijas, kurios nuolat taikosi prie besikeičiančios aplinkos. Mašininio mokymo algoritmai leidžia analizuoti didžiulius duomenų kiekius, kad suprastų rinkos kitimo tendencijas, kurie anksčiau galėjo būti nepastebimi. Dabartiniai algoritmai gali būti apmokomi atpažinti sudėtingus ryšius tarp įvairiausių rinkos veiksnių: kainos, prekybos apimtys, ekonominių rodiklių ir socialinės žiniasklaidos (Wilhelmina ir kt., 2024). Nėgana to, progresyvūs mašininio mokymo modeliai, pavyzdžiui neuroniniai tinklai, gali būti apmokinami iš naujausių duomenų ir prisitaikyti prie rinkos sąlygų, kas

suteikia didesnę pranašumą prieš tradicinius algoritminius prekybos metodus. Automatizuota prekyba generuoja geresnes grąžas, mažina rizikas ir pagerina sandorių vykdymą atsižvelgiant į rinkos dinamiką (Heaton, 2005). Prasidėjus dirbtinio intelekto ir mašininio mokymo vystymuisi, automatizuota prekyba tapo daugelio investicinių strategijų dalimi, kuri leidžia efektyviau valdyti didelius duomenų kiekius ir pasiekti geresnius prekybos rezultatus.

Apibendrinant istorinius pavyzdžius galima drąsiai teigti, kad visą investicijų automatizavimą lėmė technologiniai pokyčiai ir laimėjimai. Siekiant būti konkurencingam investicijų srityje yra būtina domėtis naujausiomis technologijomis, jas suprasti ir įvaldyti – tai gali lemti sėkmę užsitikrinant finansinę laisvę ir gerovę.

1.3. Dirbtinio intelekto agentai finansų rinkose

Šiame skyriuje bus aptariama teorinė dirbtinio intelekto mokslinė medžiaga. Taip pat kokius sąlyčio taškus turi dirbtinis intelektas su finansais. Skyriuje bus siekiama visapusiškai supažindinti, kokios dirbtinio intelekto savybės galima panaudoti finansuose. Išsiaiškinti stiprybes ir kaip jas panaudoti.

Dirbtinį intelektą apibrėžimą mokslininkai Ruselis ir Piteris pateikia per keturias prizmes: žmogišką ir racionalų mąstymą bei žmogišką bei racionalų veikimą. Bendrai dirbtinį intelektą apibrėžti galima, kaip kompiuterinių metodų sritį, kuri geba kurti sistemas ir galinčias atlikti užduotis, kurioms tradiciškai reikalingas žmogaus intelektas (Russell & Norvig, 2016). Dirbtinio intelekto viena iš sričių yra mašininis mokymasis, kurioje sistema automatiškai tobulina savo veikimą pasiremama istoriniais duomenimis ir nesikliaudama griežtomis taisyklėmis priimant sprendimus. Mašininio mokymo metodai skirstomi į prižiūrimą mokymą, kuomet duomenys yra patikrinami ir pateikiami dirbtiniam intelektui, ir neprižiūrimą, kuomet žmogus nesikiša į mokymą ir sustiprintą mokymąsi, kuomet dirbtinis intelektas mokosi per sąveiką su prieinama aplinka (Heaton, 2016). Gilusis mokymasis (angl. *deep learning*) – tai mašininio mokymo sritis, kuri naudoja daugiasluoksnes neuronines tinklų architektūras. Jos sugeba automatiškai išgauti sudėtingas charakteristikas iš paprastų duomenų. Gilusis mokymas ypač efektyvus vykdyti užduotis, kurioms reikalingi sudėtingi atvaizdavimai, pavyzdžiui vaizdų atpažinimas, natūralios kalbos apdorojimas (Sutton ir Barto, 2015). Dirbtinio intelekto agentas – tai autonomiškai veikiantis subjektas, kuris gaudamas informaciją apie aplinką tiek per jutiklius, tiek per duomenų įvedimą, priima sprendimus ir atlieka veiksmus, kurie keičia aplinką arba būseną. Programiniai agentai dažnai apibrėžiami per trijų pagrindinių komponentų prizmes: būsenos stebėjimą, sprendimų priėmimą ir veiksmų vykdymą (Russell & Norvig, 2016). Dirbtinio intelekto agentų klasifikavimas galimas per kelis aspektus:

- Pagal nepriklausomumo laipsnį – reaguojantys agentai be vidinio specialaus modelio, planuojantys agentai su vidiniu modeliu, hibridiniai agentai sujungiantys abiejų aspektus.
- Pagal mokymosi galimybes – neadaptyvūs, adaptuojantys agentai gali mokintis pagal mašininį mokymą.
- Pagal decentralizacijos laipsnį – vienas agentas, daugiaagentinės sistemos, kurios agentai sąveikauja tarpusavyje (Wooldridge, 2002).
- Pagal taikymo sritį – kontrolės agentai, pavyzdžiui, robotika, prekybos agentai, informacijos agentai.

Finansų kontekste dirbtinio intelekto agentai dažnai integruoja stebėjimo modulius (duomenų srautai, kainų laikų serijos), sprendimų sluoksnius (modeliai, taisyklės ar politika) ir vykdymo modulius. Sustiprinto mokymosi agentai ypač tinkami prekybos užduotims, nes jie natūraliai orientuoti į sekų sprendimų optimizavimą, tačiau reikalauja atsargaus treniravimo, atsižvelgiant į rizikos kontrolę, simuliacijų kokybę (Sutton & Barto, 2015).

1.3.1. Dirbtinio intelekto taikymai finansų srityje

Dirbtinio intelekto sprendimai finansuose apima tris pagrindines mašininio mokymosi sritis:

1. Prižiūrimas mokymasis naudoja istorinius įvesties duomenis ir taiko regresijas arba klasifikatorius prognozuojant grąžas arba rizikos signalus.
2. Neprižiūrimas mokymasis apima klasterizavimą, pagrindinių duomenų analizę ir automatinius koderius, kurie naudojami duomenų struktūrai atskleisti, atrasti rinkis režimus, suskirstyti akcijas pagal panašumą arba ištraukti faktorius.
3. Sustiprintas mokymas orientuotas į sekos sprendimų optimizavimą ir tinka strategijų formavimui, kur atlygis yra ilgalaikis (Sutton & Barto, 2015).

Laiko eilučių modeliai finansų kontekste apima tradicinius ekonometrinius metodus ir modernesnes giluminio mokymo architektūras:

1. ARIMA (angl. *AutoRegressive Integrated Moving Average*) ir GARCH bei kiti panašūs variantai taikomi trumpalaikiams grąžų modeliavimams bei sezoniniam komponentų šalinimui. Taip pat modeliuoja kintamumą (Ruey S. Tsay, 2010).
2. Gilieji tinklai (LSTM, GRU) dėl geresnių rezultatų naudojami laiko priklausomybėms ir ilgos atminties būdams, todėl pritaikomi kainų/pokyčių arba sentimentų sekų prognozavimui.
3. Transformeriai yra naujesni neuroninių tinklų modeliai, kurie gerai atpažįsta ilgalaikius ryšius laiko eilučių duomenyse. Jie naudoja daugiagalvio dėmesio (angl. *multi-head attention*) mechanizmą, kuris leidžia modeliui vienu metu atkreipti dėmesį į skirtingas laiko vietas ir

savybes, todėl geriau supranta, kurie praeities įvykiai svarbūs prognozuojant ateitį (Vaswani ir kt., 2017).

Praktikoje dažnai panaudojami keli modeliai ir skirtingos architektūros sujungiamos į vieną mechanizmą.

Kiekybiniai modeliai finansuose nusakomi, kaip matematiniai metodai, padedantys paaiškinti ir prognozuoti akcijų grąžas bei valdyti riziką. Vienas svarbiausių taikymų – tai faktorių modeliai. Šie modeliai teigia, kad akcijų grąža priklauso ne tik nuo bendros rinkos, bet ir nuo kitų faktorių: vertės, įmonės dydžio, impulso, kiekybės. Šie faktoriai naudojami akcijų rūšiavimui ir aktyvios portfelio atrankos (Fama & French, 1992). Rizikos modeliai skaičiuoja, kaip kartu juda aktyvų grąžos (kovariacijos, koreliacijos) ir koks yra kintamumas – tai būtina norint optimizuoti portfelį. Praktikoje modernūs mašininio mokymo metodai dažniausiai naudojami signalo gavimui kartu derinant su faktoriniais ar ekonometriniais modeliais – taip gaunama geresnė interpretacija ir stabilesni rezultatai (Lopez de Prado, 2018).

1.3.2. Sustiprinto mokymosi agentai prekyboje

Sustiprinto mokymosi agentai finansų prekyboje apmokinami politikos, susiejančios dabartinę būseną – techniniai indikatoriai, esama pozicija su veiksmais – pirkti ar parduoti per atlygio funkciją, dažniausiai remiamą pelną ir nuostolį bei riziką. Sustiprinto mokymosi privalumai – tai natūralus sekų sprendinių kūrimas, galimybė optimizuoti ilgalaikį grąžos ir nuostolio santykį integruojant pozicijų dydžio valdymą bei rizikos apribojimus tiesiogiai į atlygio funkciją. Praktikoje naudojami tiek modelio neturintys (angl. *model-free*) algoritmai, pavyzdžiui angl. *Q-learning*. Taip pat naudojami ir politikos optimizavimo (angl. *policy-gradient*) ir aktorius kritiko (angl. *actor-critic*) metodai. Giluminio mokymosi variantai naudoja neuroninius tinklus būsenos ir veiksmo funkcijoms atvaizduoti, leidžiant dirbti su dideliais ir sudėtingais informacijos kiekiais (Mnih ir kt., 2015).

Nevertėtų pamiršti ir tai, kad sustiprinto mokymosi agentai susiduriama su tam tikrais iššūkiais:

1. Realus pasaulio aplinkos trukdžiai – istorinių duomenų treniruotės gali nesuteikti tikros rinkos dinamikos arba turi išankstinį šališkumą.
2. Imties neefektyvumas – didelis duomenų poreikis reikalingas apmokyti agentą.
3. Atlygio problemos – netinkamai suformuluota atlygio funkcija gali skatinti nepageidaujamas strategijas (per didelis rizikos atvirumas).
4. Per didelis persimokymas prie simuliuojamos ir atgalinio testo aplinkos ir sudėtinga validacija už imties ribų.

Dėl šių priežasčių praktikoje sustiprinto mokymo agentai dažnai treniruojami hibridinėse aplinkose: tiek simuliacinėse, tiek atsitiktiniuose, su konservatyviomis rizikos apribojimo sluoksniais ir plačiu atgaliniu testavimu ir popierine prekyba patvirtinimo etape (Jiang ir kiti, 2017).

1.3.3. Agentų struktūra ir sistemos komponentai

Dirbtinio intelekto agento struktūrą sudaro sluoksniai ar moduliai, kurie kartu leidžia agentui stebėti aplinką, priimti sprendimus ir vykdyti veiksmus. Pagrindiniai sudarantys agentą komponentai:

- Jutikliai arba duomenų sluoksnis. Šį sluoksnį sudaro visi duomenys: kainų laiko eilutės (atidarymo, uždarymo, aukščiausia, žemiausia kainos), fundamentiniai rodikliai, naujienos, sentimentai, portfelio informacija ir vykdymo informacija. Svarbu užtikrinti laiko sinchronizaciją ir duomenų kokybę (Lopez de Prado, 2018).
- Duomenų paruošimas. Šiame sluoksnyje duomenys yra valomi, normalizuojami ir iš jų kuriami požymiai. Šis sluoksnis labai lemia modelio veikimą – geresnės savybės dažnai svarbiau už sudėtingą modelį (Ruey S. Tsay, 2010).
- Informacijos pavaizdavimas. Tai vidinė agento būseną, kaip suspausta informacija apie dabartinę rinkos situaciją pateikiama sprendimų moduliui (Heaton, 2016).
- Sprendimų priėmimo modulis. Šiame modulyje vyksta signalų generavimas. Šis modulis gali būti paremtas taisyklėmis (angl. *technical rules*), prižiūrimas mašininio mokymo modelis arba sustiprinto mokymosi. Dažnai naudojama maišyta schema: mašininis mokymas generuoja įvertinimą, o taisyklių sluoksnis priima galutinį sprendimą (Sutton & Barto, 2015).
- Rizikos kontrolės sluoksnis. Nepriklausomas modulis, kuris vertina siūlomą poziciją pagal portfelio ribas, likvidumą, gali užblokuoti arba keisti nurodymus priimant agentui sprendimus. Tai labai svarbi saugumo grandis (Kritzman ir kt., 2010).
- Užsakymo valdymo modelis. Šiame žingsnyje signalai paverčiami pavedimais brokeriui. Modulis gali naudoti vykdymo algoritmus, skaidyti užsakymus. Užsakymo modelis dažnai būna atskirtas nuo signalo, kad būtų galima optimizuoti rinkos poveikio (Kissell, 2014).
- Modelio treniravimosi komponentas. Jis atsakingas už modelių treniravimą, periodinį pertreniravimą, parametrų derinimą, ir versijų valdymą. Dažniausiai vykdoma neprisijungus į tinklą treniravimai bei tiesioginė adaptacija su konservatyviais apribojimais (Marcos Lopez de Prado, 2018).
- Stebėjimo, metrikų stebėjimo, stabdymo komponentai. Stebėjimas gyvai, metrikų pildymas į žurnalą, ir automatiniai stabdymo mygtukai, jei metrikos išeina už portfelio tolerancijos ribų – tai svarbu operacinei rizikos valdymui (Kissell, 2014).

1.3.4. Duomenys ir jų paruošimas

Teorijoje apibrėžiama, kad finansų modeliui reikalingi kelių tipų duomenys:

1. Atidarymo, aukščiausios, žemiausios ir uždarymo kainos, grąžos.
2. Fundamentalūs rodikliai, jie gali būti parenkami pagal investuotojo strategiją.
3. Naujienos ir įvykiai tiek globalūs, tiek įmonės.
4. Sentimentų analizė.
5. Makroekonominiai indikatoriai.

Kiekvienas informacijos tipas suteikia skirtingą informacinę vertę: kainos ir apimtys tinka taktiniams įėjimo į poziciją signalams, fundamentiniai – ilgalaikiai vertei ir faktoriams, o tekstiniai/sentimento duomenys gali suteikti greitus signalo „pramušimus“ arba papildomą kontekstą.

Duomenų kokybė lemia modelio patikimumą. Privalu pašalinti neteisingus duomenis ir naudoti instrumentų duomenis tokius, kokie jie buvo praeityje, o ne tik tuos, kurie išliko iki šiandien. Taip pat reikia koreguoti kainas dėl įmonių veiksmų, pavyzdžiui dividendų išmokėjimo arba akcijų padalijimo, ir užtikrinti, kad visi duomenys turi suderintas laiko žymes. Duomenų nutekėjimas yra viena pavojingiausių klaidų. Ji atsiranda, kai modelis gauna ateities informaciją. Norint to išvengti, griežtai būtina laikytis chronologijos. Kuriant duomenų charakteristikas būtina imti informaciją tik iš informacijos, kuri buvo prieinama tuo momentu, kai priimamas sprendimas. Sukūrus modelį privalu jį išbandyti realiu laiku naudojant popierines sąskaitas, kad pamatyti, ar jis išties veikia praktiškai (Sullivan & Di Pierro, 2017)

1.3.5. Dirbtinio intelekto agentai paremti dideliais kalbos modeliais

Dirbtinio intelekto agentas, paremtas dideliais kalbos modeliais (angl. *Large Language Model*), akcijų prekyboje – tai agentas, kuris naudoja didelius kalbos modelius kaip vieną iš pagrindinių sprendimų priėmimo arba informacijos apdorojimo modulių. Dideli kalbos modeliai geba apdoroti ir sintetinti didelius kiekius teksto (naujienos, ataskaitos, analitikų komentarai, socialinė medija), todėl agentas gali panaudoti didelio kalbos modelio generuojamas žinias kaip papildomą signalą kartu su tradiciniais kainų ir fundamentalios analizės duomenimis (Subbiah ir kt., 2020). Tipinė šio modelio architektūra apjungia:

1. Duomenų komponentas, t. y. kaina, fundamentalūs duomenys, naujienos.
2. Didelių kalbos modelio paremtų charakteristikų sugrupavimo komponentas, t. y. sentimentų, įvykių duomenys, apžvalgos.
3. Sprendimų modulis paremtas loginėmis taisyklėmis arba interpretavimu pačio kalbos modelio.

4. Vykdyto ir rizikos kontrolės komponentus (Lopez de Prado, 2018).

Didelių kalbos modelio vaidmuo gali būti kelių lygių:

- Duomenų charakteristikos inžinerija ir signalų kūrimas. Ši didelių kalbos modelių ypatybė automatiškai sintetina naujų santraukas, atlieka sentimentalią analizę, priskiria įvykiams reikšmes arba generuoja semantinius charakterius, kurie vėliau tiekiami į kiekybinius modelius ar faktorių sistemą (Devlin ir kt., 2019).
- Interpretacija ir analizė. Dideli kalbos modeliai gali parengti natūralios kalbos paaiškinimus, taip pat koduoti modelių sprendimų pasirinkimą. Modeliai gali padėti rizikos komponentams suprasti signalus bei priimti sprendimus (Bommasani ir kt., 2022).
- Sprendimų priėmimo procesas. Dideli kalbos modeliai gali būti naudojami kaip komponentas tradiciškai siūlyti galutiniam sprendimo priėmėjui. Pavyzdžiui, pasiūlyti pagal kokius kriterijus vertinti akciją, jos kainą, tačiau tiesioginis modelio prekybos valdymas be papildomų apribojimų rizikingas dėl klaidingos informacijos ir nenuoseklumo (Subbiah ir kt., 2020).

Taigi, dideli kalbos modeliai susiduria su tam tikromis rizikomis ir techniniais iššūkiais, kurie privalo būti pasverti:

- Duomenų laikotarpio problemos. Dideli kalbos modeliai turi būti maitinami tik tais teksta, kurie būtų buvę prieinami realiu laiku, kad nebūtų išankstinio žinojimo (Lopez de Prado, 2018).
- Klaidinga informacija ir patikimumas. Dideli kalbos modeliai gali generuoti netikslią arba išgalvotą informaciją, dėl to privalu patikrinti didelių kalbos modelių išvestis prieš panaudojant signalams (Marcus & Davis, 2019).
- Delsimas ir vykdymas. Didelių kalbos modelių teksto apdorojimas reikalauja daug skaičiavimo laiko. Dienos prekyboje tai gali būti kliūtis – reikia optimizuoti duomenų srautą arba naudoti hibridines sprendimo schemas (Bommasani ir kt., 2022).

1.4. Didelių kalbos modelių panaudojimo pavyzdžiai prekyboje

Siekiant įsigilinti į didelių kalbos modelių galimybes, svarbu apžvelgti egzistuojančius pavyzdžius kur ir kokie sprendimai buvo pritaikyti. Dabar bus aptariami keli pavyzdžiai, kurie yra aprašyti mokslinėje literatūroje.

1.4.1. Didelių kalbos modelių pritaikymo pavyzdys visam prekybos poligonui

Pirmoji akcijų agento simuliacinė sistema, kurią aptarsiu – tai sistema, kuri sudaryta iš keleto agentų ir yra skirta imituoti prekybą realiomis rinkos sąlygomis. Ją sudaro šios pagrindinės ypatybės:

- Investavimo keleto agentų sistema susideda iš šių pagrindinių modulių:

1. Investavimo agentų modulis. Agentui priskiriamas atsitiktinis kapitalas ir vienas iš keturių investuotojo tipų: konservatyvus, agresyvus, subalansuotas bei orientuotas į augimą, kad būtų ištiriama, kaip šie tipai padaro įtaką sprendimų priėmimui prekyboje. Agentai sąveikauja priimdami sprendimus dėl paskolų, prekybos, prognozių ir dalinasi patarimais pranešimų lentoje (angl. *Bulletin Board System*).
 2. Sandorių modulis. Valdo pirkti ir parduoti sandorius naudodamasis užsakymo knygą ir atsitiktinį laiko puslapių keitimo mechanizmą, kad būtų išvengiama užstrigimų, kai vyksta daug sandorių vienu metu.
 3. Pranešimų modulis. Leidžia agentams publikuoti prekybos patarimus ir įžvalgas, simuliuojant realistišką aplinką, kurioje nuomonės veikia sprendimus.
- Įvykių valdymo simuliacijos ypatybė. Sistema atkuria realius prekybos procesus, įskaitant prieš prekybinį pasiruošimą. Sugeneruoja informaciją apie palūkanų mokėjimus, paskolos sprendimus, finansines ataskaitas, specialius įvykius. Prekybos metu imituoja – pirkimo ir pardavimo sprendimus, kainų atnaujinimus. Po prekybos – imituoja busimus veiksmus ir skelbia naujienas pranešimų lentoje.
 - Išorinė faktorių simuliacijos ypatybė. Akcijų agentas modeliuoja išorinius ekonomikos ir finansinius įvykius tokius, kaip palūkanų normų pokyčius, finansines ataskaitas, įmonių vadovybės sprendimus. Šio agento tikslas – ištirti įvykių poveikį prekybai ir rinkos dinamikai.
 - Didelių kalbų modelio integracija. Akcijų agentas naudoja didelius kalbos modelius tokiu, kaip GPT-3.5-Turbo ir Gemini-Pro. Jie skirti agentų sprendimų priėmimui, pasinaudojant jų gebėjimu logiškai mąstyti ir bendrauti, kad būtų imituojami sudėtingi prekybos elgsenos modeliai.
 - Testo duomenų nutekėjimo prevencija. Sistema mažina didelio kalbos modelio iš anksto įgytų žinių įtaką rinkos prognozėms, taip užtikrindama nešališkas simuliacijas.
 - Konfigūruoti parametrai. Akcijų agentas leidžia keisti tam tikrus parametrus tokius, kaip investuotojo tipą, turto paskirstymą, pavedimų kainas ir rinkos nustatymus tam, kad būtų ištirti įvairūs prekybos scenarijai.
 - Elgsenos analizė. Sistema leidžia kategorizuoti ir vizualizuoti agentų elgseną, atskleidžiant jų skirtumus prekybos tendencijose, grupių dinamiką ir individualų sprendimo priėmimą.
 - Šalinimo eksperimentai. Akcijų agentas palaiko eksperimentus, kuriuose pašalinami tam tikri faktoriai, pavyzdžiui finansinė informacija, pranešimų lentos informacija, paskolų galimybės, siekiant įvertinti jų poveikį elgsenai ir pelningumui.

Akcijų agentas paremtas dideliais kalbų modeliais – yra daugiaagentė sistema, kuri realistiškai imituoja akcijų prekybą ir išorinius rinkos veiksnius, tuo pat metu sumažindama didelių kalbų modelio iš anksto įgytų rinkos žinių įtaką. Skirtingi modeliai (GPT ir Gemini) lemia reikšmingai skirtingą agentų elgseną. GPT valdomi agentai prekiauja rečiau, bet didesniais kiekiais ir elgiasi

atsargiau su tam tikromis akcijomis, o Gemini agentai prekiauja aktyviau ir rodo didesnę grupinį panašumą. Klasterių analizė ir vizualizacijos patvirtina, kad Gemini agentai elgiasi vienodesnėmis grupėmis, tuo tarpu GPT agentai yra įvairiapusiškesni ir labiau individualūs. Šie aspektai parodo galimybę įkūnyti labiau personalizuotas investavimo strategijas. Taip pat pastebėta, kad išoriniai veiksniai (informacijos dalijimasis, pelno ataskaitos, palūkanų pokyčiai, prieinama finansinė informacija) smarkiai daro įtaką rizikos elgsenai ir pelningumui (Brasoveanu ir kiti, 2020). Tiek didelių kalbų modelių pasirinkimas, tiek išorinių veiksnių modeliavimas turi didelę įtaką simuliacijos rezultatams, todėl juos būtina atidžiai parinkti ir dokumentuoti.

1.4.2. „FINMEM“ didelių kalbų modelio prekybos agento pavyzdys

„FINMEM“ – tai didelių kalbos modelio pagrindu sukurtas prekybos sistema, kurio pagrindinis tikslas – automatizuoti prekybą finansų rinkose. Pagrindinis tikslas yra paversti realius laiko duomenis į investicinius sprendimus, siekiant išvengti žmogaus apribojimus ir tradicinių algoritmų trūkumus (Yu ir kt., 2025). Prototipo kūrėjai teigia, jog žmonės-prekiautojai susiduria su informacijos pertekliumi ir ribotomis galimybėmis apdoroti bei atsiminti visus kritinius įvykius. Ankstesni metodai tokie, kaip gilusis mokymas, sustiprintas mokymasis parodė pažangą, tačiau jiems trūksta suderinamumo, į juos sunku integruoti tekstinius ir skaitmeninius duomenis bei jiems reikia didelio kiekio duomenų treniruotėms. „FINMEM“ sudaro trys pagrindiniai moduliai:

1. Profilio modulis leidžia dinamiškai nustatyti agento būdą. Šis modulis apima profesionalių žinių bazę, kuri apima informaciją apie pagrindinius prekybos sektorius ir konkrečios akcijos istorinę finansinę veiklą bei rizikos polinkis, kuris apima agento riziką: rizikos mėgėjas, rizikos vengiantis arba savaime prisitaikantis. Šio modulio esmė suteikti kontekstą informacijos filtravimui ir sprendimų priėmimui.
2. Atminties modulis imituoja žmogaus kognityvinę sistemą, kuri apdoroja hierarchinę finansinę informaciją. Šis modulis susideda iš darbinės atminties, kurioje vyksta apibendrinimas, stebėjimas ir apmąstymas. Sluoksniuotojoje ilgalaikėje atmintyje yra trys sluoksniai: seklišis – kasdienės rinkos naujienos, tarpinis – vidutinės trukmės įmonių ataskaitos bei giluminis – metinės įmonių ataskaitos. Modulyje taip pat yra informacijos paieška pagal panašumą, naujumą ir svarbą.
3. Sprendimų priėmimo modulis integruoja profilio ir atminties modulių rezultatus, kad priimtų pagrįstus investicinius sprendimus.

Šio prekybos agento sistema atskleidė pranašumą prieš kitus dirbtinio intelekto modelius pagal sukauptą grąžą ir Šarpo koeficientą. Sistema parodė gerus rezultatus ir ką tik naujai viešai prekiaujamomis akcijomis.

1.4.3. Didelių kalbų modelio kriptovaliutų rinkoje pavyzdys

Šio prototipo tikslas yra ištirti didelių kalbos modelių galimybes veikti autonomiškai realiose finansų rinkose naudojant kuo mažiau gairių ir tik skaitmeninius rinkos duomenis. Siekiama įvertinti modelių elgesį dinamiškuose, konkurencingose aplinkose, siekiant kuo didesnės grąžos. Šiame tyrime buvo naudoti šeši pirmaujantys modeliai: „GPT-5“, „Gemini 2.5 Pro“, „Qwen3-Max“, „DeepSeek v3.1“, „Claude Sonnet 4.5“, „Grok 4“. Kiekvienas robotas gavo po 10 000 dolerių prekybos realioje rinkoje. Modeliams buvo pateikti tik kainų, apimties ir techninių indikatorių duomenys be jokių naujienų ar tekstinių kontekstų.

Modeliai veikė savarankiškai be jokio įsikišimo, atlikdami vidutinio ir žemo dažnumo prekybą. Sprendimai buvo priimami kas kelias minutes ar valandas. Kas 2-3 minutes modeliai gaudavo glaustas informacijos instrukcijas ir realius rinkos bei jų sąskaitos duomenis. Modeliai pateikdavo pirkimo, pardavimo, laikymo ar uždarymo pozicijų išvestis. Eksperimento metu modeliai galėjo prekiauti šiomis kriptovaliutomis: „bitcoin“, „ethereum“, „solana“, „BNB“, „DOGE“ ir „XRP“. Modeliai išvestyje taip pat nurodydavo pozicijos kryptį, dydį, svertą, pagrindimą, pasitikėjimo balą ir pelno bei nuostolio dydžius. Robotai naudojo svertą, kadangi buvo siekta padidinti riziką. Tokie eksperimento kriterijai buvo pasirinkti siekiant atskleisti realius vykdymo iššūkius, kurie nėra matomi popierinėje prekyboje (Nofl, 2025).

Šio eksperimento parodė skirtumus tarp modelių: rizikos dydžio, planavimo, krypties šališkumo ir prekybos aktyvumo. Nustatytas didelis modelio jautrumas net mažiausiems instrukcijų pakeitimams. Eksperimentas buvo atliktas nuo 2025 metų spalio 18 dienos iki 2025 metų lapkričio 3 dienos (7 pav.)



Alpha Arena Season 1 is now over, as of Nov 3rd, 2025 5 p.m. EST
Season 1.5 coming soon

Šaltinis: sudaryta autoriaus pagal „AlphaArena“ duomenis (<https://nofl.ai/2025-11-19>)

7 pav. „AlphaArena“ duomenys

7 pav. „AlphaArena“ duomenų rezultatų matoma, kad tik „Qwen3-Max“ (22,88%) ir „DeepSeek v3.1“ (4,76%) generavo gražą. Prasčiausiai pasirodė – „GPT-5“ (62,66%) ir „Gemini 2.5 Pro“ (55,15%) fiksuodami nuostolį.

Apibendrinant pirmąjį skyrių galima teigti:

1. Investuoti galima į įvairias sritis bei įvairius finansinius instrumentus, tačiau tai priklauso nuo investuotojo tikslų, amžiaus, rizikos ir netgi charakterio. Jaunas žmogus, turintis stabilias pajamas ir susitaupęs dalį lėšų turėtų investuoti į didesnės rizikos sritis tokias kaip akcijos.

2. Tobulėjant dirbtinio intelekto technologijom atsiranda naujų galimybių. Dirbtinio intelekto ypač didelių kalbų modelio panaudojimas priimant prekybos sprendimus dar visiškai nėra ištirtas, dėl to antrojoje darbo dalyje pateiksiu siūlymą, kaip galima būtų panaudoti didelių kalbų modelius priimant prekybos sprendimus prekiaujant akcijomis.

2. DIRBTINIO INTELEKTO AGENTU PAREMTOS AKCIJŲ PREKYBOS PROTOTIPAS

Šiame skyriuje bus aprašoma mano siūlomo prototipo architektūra bei priimti sprendimai, kaip praktinė darbo dalis yra suplanuota ir įgyvendinta, kad būtų patikimai atsakyta į darbo uždavinius. Skyriuje paaiškinsiu prototipo architektūrą, taikomus modelius bei agentų logiką, eksperimento vykdymo eigą, naudojamus duomenis ir jų paruošimą, ir vertinimo metodikas. Taip pat aptarsiu priemones, kurias naudoju.


2.1. Akcijų prekybos prototipo architektūra paremta dirbtiniu intelekto agentu

Siekiant sukurti prototipą privalu apžvelgti architektūrą. Prototipo architektūra buvo sukurta atsižvelgiant į šiuos kriterijus: būtų pritaikoma skirtingiems didelių kalbų modeliams, savaime veiktų be vartotojo įsikišimo, paimtų duomenis iš šaltinių juos apdorotų, pateiktų dirbtinio intelekto agentui, kuris nustatyta forma pateiktų atsakymus. Atsakymai būtų sutvarkomi ir perduodami brokeriui vykdymui. Architektūra yra suskirstyta į penkis blokus (8 pav.):

1. Iniciavimo blokas.
2. Duomenų rinkimo ir apdorojimo blokas.
3. Dirbtinio intelekto agento blokas.
4. Kintamųjų paskirstymo ir jų tvarkymo blokas.
5. Operacijų vykdymo blokas.

Išvardinti blokai atlieka šias funkcijas:

- **Iniciavimo blokas.** Šio bloko paskirtis be vartotojo išsikišimo inicijuoti darbo eigą ir išsiųsti signalą vykdyti.
- **Duomenų rinkimo ir apdorojimo blokas.** Šis blokas turi trys užduotis:
 - Siųsti užklausą internetiniams puslapiams, kurie teikia informaciją apie kainas ir gauti iš jų informaciją.
 - Sutvarkyti ir apjungti duomenis ir siųsti dirbtinio intelekto modeliui.
- **Dirbtinio intelekto agento blokas.** Šio bloko esmė gauti duomenis iš duomenų rinkimo ir apdorojimo bloko, juos išanalizuoti ir nustatyta forma pateikti išvesties rezultata. Dirbtinio intelekto agentas turi naudoti didelių kalbų modelius.



Šaltinis: sudaryta autoriaus.

8 pav. Prototipo architektūra

- **Kintamųjų paskirstymo ir jų tvarkymo blokas.** Šiame bloke yra sutvarkomi kintamieji, klaidos ir atliekama viso darbo logika. Nukreipiami duomenis į operacijų vykdymo bloką.
- **Operacijų vykdymo blokas.** Šiame bloke perduodama informacija brokeriui: pirkti, parduoti ar uždaryti poziciją su tam tikrais parametrais: nuostolio stabdymu, pelno kaina, akcijų kiekis.

Šios architektūros įgyvendinimui buvo atlikta platformų analizė su tikslu nustatyti geriausiai tinkančią programą. Atviro kodo platforma turėjo atitikti šiuos keliamus reikalavimus: lengvai supranta, pageidautina, kad turėtų vizualinį darbo logikos kūrimą, turėtų įvairių mazgų, kurie tvarkytų

duomenis, platforma būtų integrali su kitais API (angl. *Application Programming Interface*). Platformų vertinimas buvo atliktas naudojantis atvirais šaltiniais (2 lentelė).

2 lentelė

Darbo eigos automatizavimo platformos

Įrankis	Paskirtis	Stiprybės	Trūkumai	Kaina
„N8n“	Vizualus darbo eigos automatizavimas ir API panaudojimas.	Atviro kodo, daug integracijų, darbo eigos kūrimas grafiškai, savo serverio naudojimo galimybė, kiekvieno mazgo vykdymas.	Lėtas, sudėtingi skaičiavimai reikalauja kodo.	72.60 EUR/mėn.
„Make“	Vizualus darbo eigos automatizavimas ir API panaudojimas.	Leidžia atlikti sudėtingesnes duomenų perdirbimo operacijas, patogus grafinis sąsajos kūrimas.	Reikia papildomų prenumeratų, kurios gali būti brangios.	16.00 EUR/mėn.
„Apache Airflow“	Darbo eiga paremta nukreiptu necikliniu modeliu.	Galimybė paleisti užduotis atgaline data, populiarius ir dažnai naudojamas duomenų inžinierių	Įrankio konfigūravimas ir operacinis valdymas gali būti sudėtingas lyginant su vizualiais įrankiais.	~137.00 EUR/mėn.
„Prefect“	Darbo eiga paremta nukreiptu necikliniu modeliu.	Patogesnė ir modernesnė sąsaja, aiškus taisyklių nustatymas klaidų atvejams ir paprastesnis jų šalinimas.	Nemokamo arba bazinio plano vartotojai jų neturi arba turi ribotą prieigą.	~87.00 EUR/mėn.
„Zapier“	Jungia populiarias programas ir automatizuoja veiksmų sekas.	Daug paruoštų integracijų, paprastumas – greitas procesų automatizavimas be programavimo.	Netinkamas dideliems duomenų srautams, sudėtingoms transformacijoms ar ML treniravimams.	43.10 EUR/mėn.

Šaltinis: Sudaryta autoriaus pagal platformų oficialius puslapius.

Atlikus penkių platformų analizę ir įvertinus kaštus, galimybes ir patogumą vartotojui prototipo kūrimui buvo nuspręsta naudoti „n8n“ platformą.


2.2. Prototipo realizacija „n8n“ platformoje be sentimentalios analizės

Šiame poskyryje aptarsiu sukurtą prototipą pagal anksčiau aptartą architektūrą. Prototipą išdalinsiu į šiuos blokus ir juos aptarsiu:

- Iniciavimo blokas.
- Duomenų rinkimo ir apdorojimo blokas.
- Dirbtinio intelekto agento blokas.
- Kintamųjų paskirstymo ir jų tvarkymo blokas.
- Operacijų vykdymo blokas.

2.2.1. Iniciavimo blokas

Iniciavimo bloko tikslas suaktyvinti darbo eigą (angl. *workflow*). Jam priskyriau suaktyvinimo ir lentelės mazgus (9 pav.). Suaktyvinimo mazgas yra mazgas, kuris atsakingas už darbo eigos vykdymą įvykus tam tikromis aplinkybėmis. Lentelės mazgas skirtas duomenų laikymui.



Šaltinis: sudaryta autoriaus.

9 pav. Iniciavimo blokas

„n8n“ platformoje yra daugybė suaktyvinimo mazgų tokių, kaip: aktyvavimas nuo paspaudimo, aktyvavus tam tikru laiku, gavus žinutę, gavus elektroninį laišką ir kiti. Mano kuriamam prototipui pagal architektūrą labiausiai tinkantis mazgas – suplanuotas inicijavimas (pav. 10).



There were 502 items in your list. Here they are in random order:

1. GME
2. AMC
3. COIN
4. RKT
5. TSLA
6. BK
7. HOOD
8. MTB
9. BRK.B
10. NSC
11. ZBH
12. SCHW
13. EQR
14. BG
15. LEN
16. MMM
17. LUV

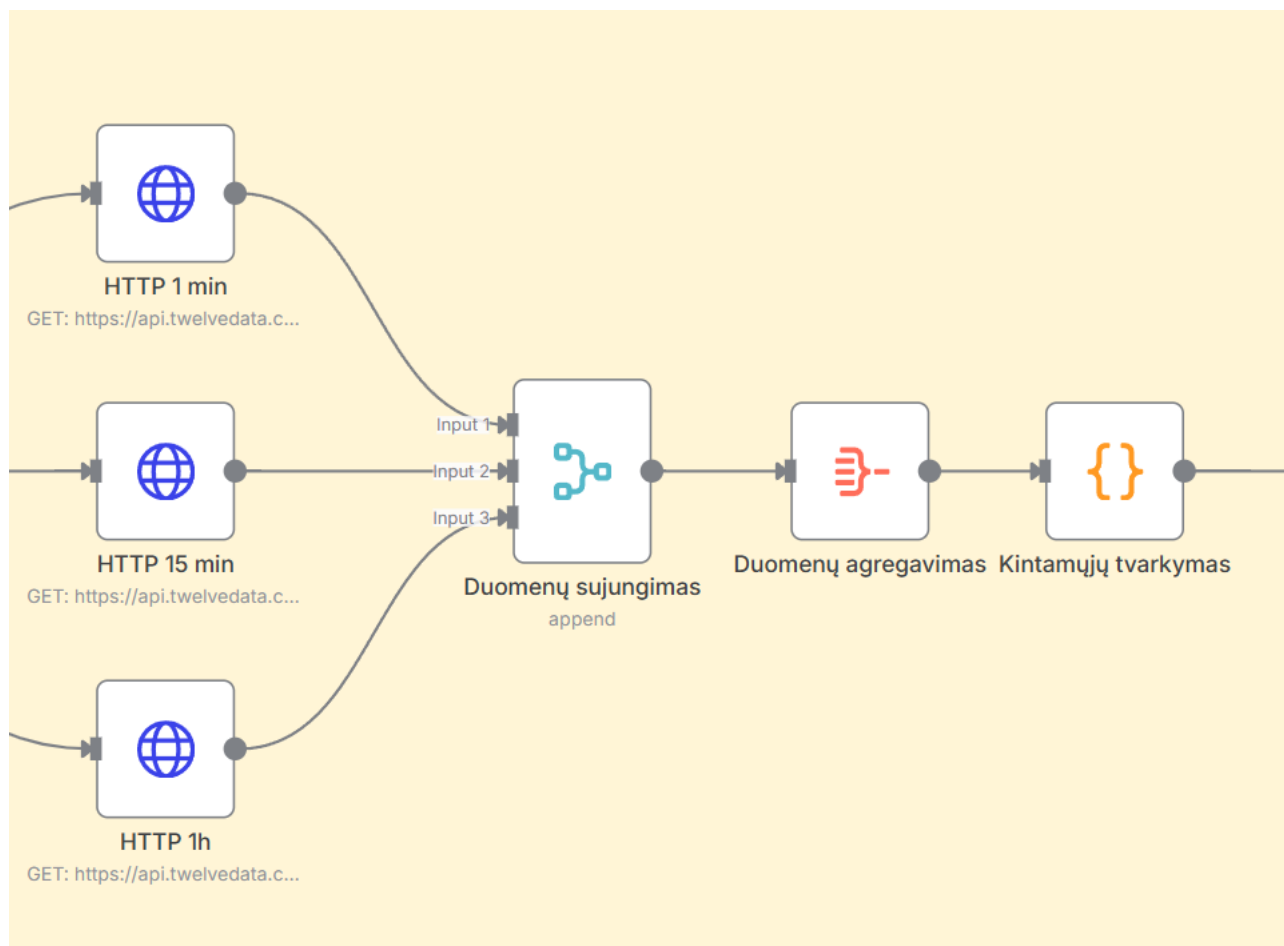
Šaltinis: sudaryta autoriaus.

11 pav. Atsitiktinis portfelio sudarymas

2.2.2. Duomenų rinkimo ir apdorojimo blokas

Pagal anksčiau minėtą architektūrą sekantis prototipo blokas yra duomenų rinkimas ir apdorojimas. Šiame žingsnyje gaunama informacija iš finansinių rinkų duomenų tiekėjų, ji yra sutvarkoma, apibendrinama ir paruošiama perduoti kitam blokui (12 pav.).

Šio prototipo kūrimui atlikau duomenų tiekimo platformų analizę siekiant gauti tinkamus duomenis. Platforma buvo vertinama pagal kainas bei galimas užklausas. Rezultatus aptarti lentelėje Nr. 3.



Šaltinis: sudaryta autoriaus.

12 pav. Duomenų rinkimo ir apdorojimo blokas

3 lentelė

Platformos teikiančios techninius duomenis

Platforma	Duomenų tipai	Realus laikas	Privalumai	Trūkumai	API limitai
„TwelveData“	OHLC kainos, apimtis, techniniai indikatoriai, simbolių duomenys.	+	HTTP/REST, WebSocket, paprasta API, tinkama prototipams.	Nemokami planai riboti, duomenų kiekiai priklauso nuo plano.	Nemokamas – 800 API dienai. „Grow“ planas - – 68,28 eur/ mėn – neriboti limitai.
„Alpha Vantage“	OHLC kainos, apimtis, sektoriaus duomenys.	-	HTTP/REST, paprasta pradėti.	Griežti limitai, nevienodas kokybės lygis.	Nemokamas – 25 API dienai. Pigiausias planas – 43, 21 eur/ mėn – neriboti limitai.


Platforma	Duomenų tipai	Realus laikas	Privalumai	Trūkumai	API limitai
„Intrinio“	JAV akcijos istorinės ir realios kainos, fundamentali informacija, prekybos statistika.	Tik JAV rinka.	Oficialūs SDK (Python, JS) ir WebSocket, labai patikimas laiko-duomenų gavimas.	Labai brangu prototipo kūrimui. Skirta korporacijom.	Prasideda nuo 216, 07 eur/ mėn.
„Polygon“	Pirkimo-pardavimo įrašai, kainų pasiūlymai, suvestinės kainos, detalūs sandorių duomenys, fundamentalūs duomenys.	+	Oficialūs SDK (Python, JS) ir WebSocket, detalūs duomenys.	Labai brangu prototipo kūrimui.	Realaus laiko duomenys nuo ~172 eur/mėn.
„Finnhub“	OHLC kainos, apimtis, naujienos, fundamentalūs duomenys.	+	Oficialūs SDK (Python, JS) ir WebSocket, naujienos, patogi dokumentacija	Londono akcijų biržos duomenys vėluoja 15 minučių. Kitos tarptautinės rinkos palaiko tik dienos pabaigos duomenis.	„Basic“ planas ~43.22 eur/mėn.

Šaltinis: sudaryta autoriaus pagal atvirus įmonių puslapius *twelvedata.com*, *alphavantage.co*, *intrinio.com*, *polygon.io*, *finnhub.io*.

Atlikus platformų analizę buvo pasirinkta „TwelveData“ platforma. Ji buvo parinkta pagal šiuos svarbiausius kriterijus: kaina ir OHLC kainų teikimas be laiko uždelsimo.

2.2.3. Dirbtinio intelekto agento blokas

Dirbtinio intelekto bloko esmė gauti sujungtus duomenis iš ankstesnio duomenų rinkimo ir apdorojimo bloko, pasiimti duomenis iš brokerio platformos informaciją apie sąskaitą (atidarytas pozicijas) ir pasitelkus didelių kalbų intelekto modeliu priimti sprendimą (13 pav.).



Šaltinis: sudaryta autoriaus.

13 pav. Duomenų rinkimo ir apdorojimo blokas

Dirbtinio intelekto agento mokymo lauke (angl. *prompt*) privalu agentui nurodyti, kas jis yra, koks jo tikslas, iš kur ir kokius duomenis paimt ir kokio atsakymo iš jo noriu (14 pav.).

Expression

Anything inside ({}) is JavaScript. [Learn more](#)

Result

Item C | >

Kintamųjų tvarkymas

1 item

Ticker	GME
candles1m	
candles1m[0]	
time	2025-11-17T13:40:00.000Z
# open	20.53
# high	20.53
# low	20.52
# close	20.52
# volume	656
candles1m[1]	
time	2025-11-17T13:41:00.000Z
# open	20.52
# high	20.52
# low	20.52
# close	20.52
# volume	400
candles1m[2]	

You are a trading decision agent. Your job: for a single ticker, using the provided current position data and market candles (1m, 15m, 1h), return exactly one concise JSON decision: BUY, SELL, HOLD or CLOSE (use Position tool)

Data Sources for STOCKS:

- {{ \$json.ticker1 }}

Technical Data (Price Action):

```
{(JSON.stringify($json.candle1m))}
{(JSON.stringify($json.candle15m))}
{(JSON.stringify($json.candle1h))}
```

- {{ \$json.ticker2 }}

Technical Data (Price Action):

```
{(JSON.stringify($json.candle1mT2))}
{(JSON.stringify($json.candle15mT2))}
{(JSON.stringify($json.candle1hT2))}
```

- {{ \$json.ticker3 }}

Technical Data (Price Action):

```
{(JSON.stringify($json.candle1mT3))}
{(JSON.stringify($json.candle15mT3))}
{(JSON.stringify($json.candle1hT3))}
```

- {{ \$json.ticker4 }}

Technical Data (Price Action):

```
{(JSON.stringify($json.candle1mT4))}
{(JSON.stringify($json.candle15mT4))}
{(JSON.stringify($json.candle1hT4))}
```

- {{ \$json.ticker5 }}

Technical Data (Price Action):

```
{(JSON.stringify($json.candle1mT5))}
{(JSON.stringify($json.candle15mT5))}
{(JSON.stringify($json.candle1hT5))}
```

Kintamųjų tvarkymas

1 item

Ticker	GME
candles1m	
candles1m[0]	
time	2025-11-17T13:40:00.000Z
# open	20.53
# high	20.53
# low	20.52
# close	20.52
# volume	656
candles1m[1]	
time	2025-11-17T13:41:00.000Z
# open	20.52
# high	20.52
# low	20.52
# close	20.52
# volume	400
candles1m[2]	

You are a trading decision agent. Your job: for a single ticker, using the provided current position data and market candles (1m, 15m, 1h), return exactly one concise JSON decision: BUY, SELL, HOLD or CLOSE (use Position tool)

Data Sources for STOCKS:

- GME

Technical Data (Price Action):

```
[{"time":"2025-11-17T13:40:00.000Z","open":20.53,"high":20.53,"low":20.52,"close":20.52,"volume":656}, {"time":"2025-11-17T13:41:00.000Z","open":20.52,"high":20.52,"low":20.52,"close":20.52,"volume":400}, {"time":"2025-11-17T13:42:00.000Z","open":20.53,"high":20.53,"low":20.53,"close":20.53,"volume":348}, {"time":"2025-11-17T13:43:00.000Z","open":20.54,"high":20.54,"low":20.54,"close":20.54,"volume":1300}, {"time":"2025-11-17T13:44:00.000Z","open":20.565,"high":20.565,"low":20.565,"close":20.565,"volume":202}, {"time":"2025-11-17T13:45:00.000Z","open":20.58,"high":20.58,"low":20.575,"close":20.58,"volume":1324}, {"time":"2025-11-17T13:46:00.000Z","open":20.58,"high":20.58,"low":20.58,"close":20.58,"volume":436}, {"time":"2025-11-17T13:47:00.000Z","open":20.59,"high":20.59,"low":20.59,"close":20.59,"volume":200}, {"time":"2025-11-17T13:49:00.000Z","open":20.595,"high":20.595,"low":20.585,"close":20.585,"volume":1644}, {"time":"2025-11-17T13:50:00.000Z","open":20.585,"high":20.585,"low":20.58,"close":20.58,"volume":330}, {"time":"2025-11-17T13:52:00.000Z","open":20.55,"high":20.56,"low":20.55,"close":20.55,"volume":2324}, {"time":"2025-11-"}]
```

Šaltinis: sudaryta autoriaus.

14 pav. Agento mokymo laukas

Paveikslėlyje „Agento mokymo laukas“ (13 pav.) dirbtiniam agentui nurodžiau, kad jis yra prekybos sprendimų priėmėjas. Jo tikslas: nurodytai akcijai įvertinant brokerio sąskaitoje atidarytas pozicijas, kainų žvakių vienos minutės, penkiolikos minučių ir vienos valandos grąžinti atsakymą pirkti, parduoti, laikyti ar uždaryti poziciją. Taip pat agentui buvo nurodyta iš kokio mazgo paimti duomenis (1 ir 5 priedai).

Kitas labai svarbus laukas – sistemos žinutė (angl. *system message*). Jame galima nurodyti pagrindines instrukcijas ir nuostatas, apibrėžiančias, kaip turėtų elgtis agentas (15 pav.). Didžiausias skirtumas tarp mokymo lauko ir sistemos žinutės: žinutė privalu nusakyti instrukcijas bei taisykles, o mokymo lauke – konkrečias užduotis (2 ir 6 priedai).



Šaltinis: sudaryta autoriaus.

15 pav. Sistemos žinutės laukas

Sistemos žinutės lauke nurodžiau, kad agentas yra profesionalus algoritminės prekybos specialistas turintis patirties įvairaus laikotarpio prekyboje. Pasiūliau jam atlikti šią analizę:

1. Techninės analizės prioritetas: vienos minutės laikotarpis yra pagrindinis laikotarpis, antrinis laikotarpis – penkiolika minučių, tretinis – viena valanda.
2. Svarbiausi techniniai indikatoriai sprendimų priėmimui: akcijos veiksmų šablonai, tendencijos analizė, momentiniai indikatoriai, apimties aptvirtinimas.
3. Rizikos valdymo reikalavimai: būtina nurodyti nuostolio stabdymą, nustatant poziciją privalo atsižvelgti į rinkos nepastovumą, tikslas išlaikyti bent jau 1:2 rizikos ir pelno santykį.

Algoritmui taip pat buvo nurodyta naudoti pozicijos įrankį, kad pamatytų savo portfelį, priminta apie galimybę uždaryti pozicijas. Nurodžiau griežtą išvesties struktūrą:

- **Techninė rekomendacija:** pirkti, parduoti, uždaryti arba laikyti.

- **Akcijos pavadinimas:** AAA.
- **Įėjimo į sandorį kaina:** skaičius arba nėra.
- **Nuostolio stabdymo kaina:** skaičius arba nėra.
- **Rizikos ir pelno santykis:** skaičius arba nėra.
- **Pasitikėjimo lygis:** aukštas, vidutinis arba žemas.
- **Pirkimo, pardavimo ar uždarymo akcijų kiekis:** skaičius arba nėra.

Labai svarbu, kad išvesties duomenys būtų lengvai suprantami ir juos būtų galima lengvai apdoroti programiškai.

Visuose prototipuose buvo palikta numatytoji temperatūra. Temperatūra nustato didelio kalbos modelio laisvumą ir kūrybiškumą priimant sprendimus. Standartiškai kuo didesnė temperatūra tuo kūrybiškesnis agentas. Kadangi prototipai prekiaavo akcijų rinkoje, kurioje svarbu laikytis griežtesnių taisyklių, agentai privalėjo duoti tikslūs atsakymus. Kitoks išvesties interpretavimas galėtų paveikti tolimesnės programos veikimą, atsirastų klaidos programiniame kode. Sukurtų prototipų temperatūra buvo sekanti: „Open AI“ – 0,7, „Gemini“ – 0,4, „DeepSeek“ – 0,7.

Šiame bloke taip pat buvo panaudotas „Think“ įrankis. Šio įrankio esmė duoti agentui laiko prieš atsakymą, kad jis galėtų pagalvoti. Tai leidžia agentui reflektuoti su savimi į jau sukurtą atsakymą prieš pateikiant atsakymą. Šis įrankis dažniausiai naudojamas sudėtingose operacijose.

Pozicijos įrankis buvo panaudotas tam, kad dirbtinis agentas pamatytų savo valdomą portfeli ir įvertinus jį galėtų priimti pozicijos uždarymo sprendimą.


Vykdant eksperimentą buvo pabandyta optimizuoti dirbtinio agento mokymo lauką (3 ir 7 priedai) ir sistemos žinutę (4 ir 8 priedai). Buvo atsižvelgta į šiuos dalykus (Dharma, 2025):

1. Specialių ženklų naudojimas, minčių, užduočių atskyrimui.
2. Užduoties sukonkretinimas.
3. Sprendimo priėmimo matrica.

Prototipo patobulinimui buvo panaudotas „Google AI Studio“, kuris buvo paremtas Gemini 3 modeliu.

2.2.4. Kintamųjų paskirstymo ir jų tvarkymo blokas

Kintamųjų paskirstymo ir jų tvarkymo blokas yra skirtas paimti tekstą sugeneruotą dirbtinio intelekto agento ir jį paversti į kintamuosius (16 pav.). Sutvarkius tekstą paskirstyti logiką pirkimo ir pardavimo bei laikymo ir uždarymo. Šiame bloke informacija filtruojama bei logikos mazgų pagalba nukreipiama į paskutinį operacijų valdymo bloką.



Šaltinis: sudaryta autoriaus.

16 pav. Kintamųjų paskirstymo ir jų tvarkymo blokas

2.2.5. Operacijų vykdymo blokas

Kuomet signalai yra sutvarkomi, jie yra perduodami į operacijų vykdymo bloką (17 pav.). Šio bloko tikslas yra išsiųsti pirkimo, pardavimo ir uždarymo nurodymą brokeriui.



Šaltinis: sudaryta autoriaus.

17 pav. Operacijų valdymo blokas

Brokerių paklausa yra didelė, jie teikia įvairias paslaugas. Mano siūlomam prototipo kūrimui analizavau galimus brokerio variantus (4 lentelė).

4 lentelė

Brokerių palyginimas


Pavadinimas	Popierinė prekyba/ API	Rinkos	Kainos	Plusai	Minusai
„Interactive Brokers“	++	Akcijos, ETF, opcionai, ateities, FX, obligacijos ir t. t.	Popierinė nemokama.	Patikima, įvairūs užsakymų tipai.	Uždelstas laikas, sunki sąranka.
„Charles Schwab“	+ / API (ribota)	JAV akcijos, ETF, opcionai; obligacijos, fondai.	API kaina viešai neatskleidžiama.	Plati pasiūla: tyrimai, naujienos, kopijavimas, edukacija.	API prieinamumas nėra platus.
„Alpaca“	++	JAV akcijos ir ETF.	Nemokama.	Plati užsakymų gama, patogų vartotojui.	Tik JAV akcijos, „Patern Day Trader“ taisyklė.
„TradingView Paper Trading“	+/-	Akcijos, ETF, indeksai ir t. t.	Nemokama		API netinkamas užsakymams

Įvertinus surinktus duomenis iš viešai prieinamų šaltinių nusprendžiau naudoti „Alpaca“, kadangi šis brokeris turi tiek popierinę prekybą, tiek dokumentuotą API naudojimą įvairiems užsakymų vykdymams. „Interactive Brokers“ pasirodė ne tokia draugiška vartotojui. „Alpaca“ pasižymi lengvu naudojimu ir pritaikyta programų kūrėjams. Taip pat šis brokeris pasižymi realiais laiko duomenimis, kas būtina siekiant testuoti prototipus.

2.3. Prototipo realizacija „n8n“ platformoje su sentimentalia analize

Siekiant suteikti daugiau žinių apie rinką didelių kalbų modelio agentui sukūriau antrąjį prototipą (18 pav.). Antrąjį prototipą praturtinu sentimentalia analize. Tai yra natūralios kalbos apdorojimo technika, kuri identifikuoja ir išgauna subjektyvią informaciją iš tekstinių dokumentų. Mano atveju iš internetinių žiniasklaidos priemonių. Analizės tikslas yra nustatyti emocinį toną, požiūrį ar nuotaikas. Šios analizės rezultatai gali būti teigiami, neutralūs arba neigiami. Prototipas su sentimentalia analize visiškai nesiskiria nuo anksčiau pristatyto prototipo, tik pridėta sentimentali

analizė. Iniciavimo, kintamųjų paskirstymo ir jų tvarkymo blokai išlieka identiški. Pasikeitė tik dirbtinio intelekto agento bloke esantis blokas ir duomenų rinkimo bei apdorojimo blokas. Dirbtinio intelekto agento bloke yra pridėta instrukcija, kad įvertinti sentimentalią analizę.



Šaltinis: sudaryta autoriaus.

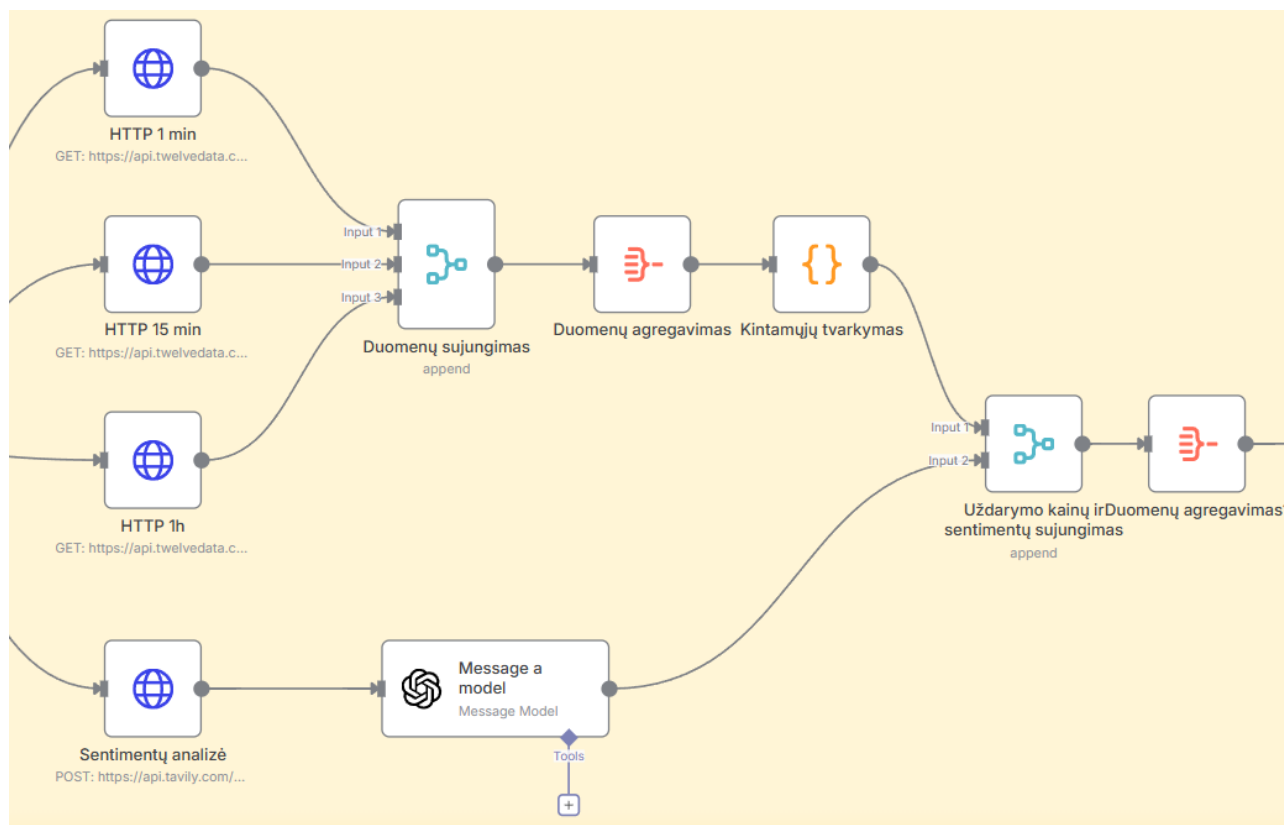
18 pav. Prototipo architektūra su sentimentalia analize

Prototipo su sentimentalia analize duomenų rinkimo ir apdorojimo bloke buvo atlikta sentimentali analizė. Sentimentaliai analizei buvo panaudota „Tavily Search API“ (19 pav.). „Tavily Search API“ kitaip nei „Bing“, „Google“ ir „Serp API“, peržiūri kelis šaltinius, kad rastų tinkamiausią turinį iš kiekvieno šaltinio, pateikdama glaustą, paruoštą naudoti informaciją, optimizuotą LLM

kontekstui. Tai, anot šaltinio, RAG ir LLM užtikrina, kad jūsų dirbtinio intelekto programos pasiektų tik aukščiausios kokybės duomenis. „Tavily Search API“ taip pat yra pigesnė ir lankstesnė. „Tavily Search API“ sukurta atsižvelgiant į šiuos kriterijus:

- Sukurta atsižvelgiant į dirbtinio intelekto agentus ir didelius kalbų modelius, užtikrinant gerus rezultatus dirbtinio intelekto darbo eigoms, tokioms kaip papildytos generacijos paieška.
- Kontroliuojamas paieškos gylis ir valdomos sritys.
- Gaunama patikima, naujausia informacija, užtikrinant, kad dirbtinio intelekto sistemos turėtų aktualiausių duomenis.
- Paprasta integracija: paprastas API nustatymas su „Python“ bibliotekų palaikymu (Tavily, 2025).

Taip pat „Tavily Search API“ teikia greitą ir realaus laiko informaciją dirbtinio intelekto agentams (Rahman ir kt., 2025). Dėl anksčiau išvardintų argumentų buvo pasirinkta „Tavily Search API“.



Šaltinis: sudaryta autoriaus.

19 pav. Prototipo architektūra su sentimentalia analize

Šiame skyriuje sukūriau du prototipus pritaikytus prekiauti akcijų biržoje. Vienas iš jų remiasi vien tik technine analize, kitą papildė sentimentali analizė.

2.4. Prototipų kūrimo kaštai

Kaip ir aptarta anksčiau prototipo kūrimams naudotos programos, kurios yra mokamos. Siekiant pasiekti darbo tikslus naudoju mokamas šias programas:

1. „n8n“ – prototipo automatizavimas;
2. „Tavily.com“ – sentimentali analizė;
3. „Twelvedata.com“ – techniniai kainų duomenys;
4. „Open AI“ – didelių kalbos modelio agentui;
5. „Gemini“ – didelių kalbos modelio agentui;
6. „DeepSeek“ – didelių kalbos modelio agentui.

Mėnesinės išlaidos pateikiamos lentelėje Nr 5.

5 lentelė

Mėnesiniai kaštai

Paslauga	Kaina	Išnaudoti limitai
„n8n“	72,60 eur	-
„Tavily.com“	~ 35,79 eur	~ 5 496 kreditai/ mėnesiui (planas + 0,008 ct/kreditui)
„Twelvedata.com“	~ 67,38 eur	-
„Open AI“	~ 12,05 eur	~39 396 777 žetonai/ mėnesiui
„Gemini“	Nemokama versija	-
„DeepSeek“	~7,33 eur	49 503 727 žetonai/ mėnesiui
Viso:	195,15 eur	-

Šaltinis: sudaryta autoriaus.

Bendri prototipų kaštai mėnesiui siekia apie 195,15 eurus (priklausomai nuo dolerio ir euro kurso). Siekiant tiksliai apskaičiuoti finansinio įrankio grąžą reiktų įtraukti ir šias išlaidas, tačiau šios išlaidos nebus įtraukiamos, kadangi aš vertinu prototipus, o ne finansinį instrumentą investuotojui.

3. PROTOTIPO VERTINIMAS IR REZULTATAI

Šiame skyriuje vertinsiu sukurtus prototipus. Pirmame poskyryje pristatysiu prototipų testavimo aplinką ir sąlygas. Taip pat pristatysiu vertinimo kriterijus pagal ką bus vertinami prototipų rezultatai.

3.1. Prototipo testavimo aplinka ir duomenų rinkimas


Buvo sukurti šeši prototipai. Trys prototipai paremti tik akcijų kainų duomenimis – technine analize, kiti trys paremti tiek kainų duomenimis, tiek sentimentalia analize. Prototipuose paremtuose technine analize pasitelkti tokie patys didelio kalbų modeliai kaip ir su sentimentalia analize: Prototipai bus testuojami realiu laiku aktyvioje akcijų biržoje per brokerį „Alpaca“. Brokeris suteikia galimybę prekiauti popierinėje sąskaitoje. Kiekvienoje sąskaitoje prototipas pradės su 100 000 dolerių.

Eksperimentas buvo suskirstytas į du laiko etapus. Pirmasis etapas nuo 2025 metų lapkričio 10 dienos iki 2025 metų gruodžio 11 dienos. Antrasis etapas nuo 2025 metų gruodžio 11 dienos iki 19 dienos. Antrajame etape buvo patobulintas dirbtinio intelekto instrukcijos pagal anksčiau aprašytus kriterijus.

Duomenų surinkimui panaudojau „n8n“ programą. Joje sukūriau algoritmą, kurį vykdant gaunami kiekvieno prototipo duomenys (20 pav.). Šio algoritmo vykdymui panaudojau šiuos mazgus:

1. Inicijavimo mazgas – algoritmas pradedamas vykdyti suaktyvinus jį paspaudimu.
2. HTTP užklauskos mazgas – siunčia užklauską „Alpaca“ brokeriui dėl informacijos pateikimo. Brokeris atsiunčia šiuos duomenis JSON formatu: laiką, portfelio vertę, pelną arba nuostolį pinigine išraiška, pelną arba nuostolį procentine išraiška, bazinę vertę, portfelio sukūrimo pradžią ir laiko rėmą. Buvo pasirinktas vienos dienos laiko rėmas.
3. Duomenų apdorojimo mazgas – filtruoja reikalingus duomenis, kurie bus reikalingi rezultatų gavimui (laikas, portfelio vertė, grąža pinigine išraiška, grąža procentinė išraiška.
4. Konvertavimo mazgas – šiame mazge duomenys konvertuojami į „.csv“ duomenų tipą.

Gautus duomenis buvo apdoroti pasinaudojant „Visual Studio“ programa. Prototipai vertinami tarpusavyje taip pat su „S&P500“ akcijų fondu bei pirkimo ir laikymo strategija. Prototipų vertinimui naudosiu penkis plačiausiai naudojamus kriterijus finansuose: sukauptoji grąža, Šarpo koeficientą, metinį kintamumą, dienos kintamumą, maksimalų nuosmukį (Yu ir kt., 2025). Taip pat bus apskaičiuoti laimėjimo dažnis (angl. *win rate*) bei pelningumo koeficientas (angl. *profit factor*), kurie nusako prototipų bei strategijų efektyvumą (Sukma & Namahoot, 2025). Dabar aptarsiu juos plačiau:



Šaltinis: sudaryta autoriaus.

20 pav. Duomenų rinkimas

Sukauptoji grąža (SG) (skaiciuojama procentais) yra vienas pagrindinių prekybos vertinimo matas. Skirtingos investavimo strategijos vertinamos pagal sukauptas grąžas, kurios vaizduoja bendrąją vertės pokytį per tam tikrą laiką. Šiame darbe sukauptas grąžas apskaičiuosiu per nurodytą laikotarpį sumuodamas dienos logaritmines grąžas. Sukauptos grąžos metodas yra plačiai naudojamas finansų srityje dėl jo galimybės tiksliai užfiksuoti nedidelius kainų svyravimus ir simetriškai atspindėti pelną bei nuostolius (Chen, 2025). Kuo didesnė sukauptoji grąža parodo efektyvesnę strategiją. Sukauptoji grąža apskaičiuojama pagal žemiau pateiktą formulę:

$$SG = \sum_{t=1}^n r_i = \sum_{t=1}^n [\ln(\frac{p_{t+1}}{p_t}) \times action_t], \quad (1)$$

čia SG – sukauptoji grąža,

r_i – logaritminė grąža

t – diena,

p_t – uždarymo kaina t dieną,

p_{t+1} – uždarymo kaina $t + 1$ dieną,

Action _{t} – modelio prekybos sprendimas t dienai.

Metinis ir dienos kintamumas (skaičiuojamas procentais) apskaičiuojamas dienos logaritminį grąžų standartinį nuokrypį (arba dienos kintamumą) padauginus iš prekybos dienų skaičiaus per metus (252) kvadratinės šaknies. Kuo didesnis skaičius parodo didesnę riziką ir didesnę portfelio kintamumą (Williams). Metinis ir dienos kintamumas apskaičiuojami pagal šią formulę:

$$MK = DK \times \sqrt{252}, \quad (2)$$

Čia MK – metinis kintamumas,

DK – dienos kintamumas.

Maksimalus nuosmukis (skaičiuojamas procentais) – tai yra rizikos vertinimo rodiklis, parodantis didžiausią portfelio vertės sumažėjimą nuo aukščiausio taško, kol neatsiranda naujas pikas. Maksimalus nuosmukis parodo investavimo strategijos patikimumą. Kuo mažesnis maksimalus nuosmukis, tuo mažesnė rizika (Hayes, 2025). Maksimalus nuosmukis apskaičiuojamas žemiau pateikta formule:

$$MN = \max \left(\frac{P_A - P_Z}{P_A} \right), \quad (3)$$

čia MN – maksimalus nuosmukis,

P_A – aukščiausias kainos taškas,

P_Z – žemiausias kainos taškas.

Šarpo koeficientas yra vienas iš pagrindinių rodiklių, kuris skirtas įvertinti investicijų efektyvumą bei koreguoti grąžą atsižvelgiant į riziką. Rodiklis apskaičiuojamas atimant nerizikingą palūkanų normą iš vidutinės perteklinės grąžos ir padalijant jų skirtumą iš kintamumo. Koeficientas koreguoja atsižvelgiant į riziką. Didesnis koeficientas parodo geresnę rizikos ir grąžos santykį. Rodiklis yra būtinas norint palyginti skirtingus portfelius ar strategijas (Fernando, Compound Annual

Growth Rate (CAGR) Formula and Calculation, 2025). Šarpo koeficientas apskaičiuojamas pagal šią formulę:

$$\check{SK} = \frac{R_P - R_f}{\sigma_p}, \quad (4)$$

čia ŠK – Šarpo koeficientas,

R_p – portfelio vidutinė grąža,

R_f – nerizikinga palūkanų norma,

σ_p – kintamumas.

Metinis augimo rodiklis CAGR (angl. *Compound Annual Growth Rate*) – tai metinis sudėtinis augimo koeficientas, kuris matuoja investicijos vertės augimą tam tikrame periode, atsižvelgiant į pradinę ir galutinę vertę. Šis rodiklis naudojamas investuotojų analizuojant investicinius rezultatus ir lyginant skirtingas investicijas (portfelius) (Fernando, 2025). Koeficientas parodo aiškų augimo tempą. Metinio augimo rodiklis apskaičiuojamas žemiau pateikta formule:

$$CAGR = \left(\left(\frac{P_n}{P_{pr}} \right)^{\frac{365}{D}} \right) - 1, \quad (5)$$

čia CAGR – metinis augimo rodiklis,

P_{pr} – pradinė vertė,

P_n – galutinė vertė,

D – dienos.

Rodiklis padeda investuotojams geriau suprasti, kaip efektyviai jų investicijos auga ir kokios grąžos galima tikėtis ateityje, lyginant su kitomis investavimo galimybėmis. Rodiklis laikomas geru jei, jei viršija rinkos ar sektoriaus vidurkį. Blogas rezultatas – rodiklis neviršija metinės infliacijos.

Laimėjimo dažnis (LD) parodo kiek prototipo sandorių buvo pelningi. Jis paskaičiuojamas laimėtus sandorius padalijus iš visų sandorių ir padauginus iš 100 procentų. Laimėjimo dažnis apskaičiuojamas šia formule (Kenton, 2025):

$$LD = \frac{\text{Laimėti sandoriai}}{\text{Visi sandoriai}} \times 100\% \quad (6)$$

Pelningumo koeficientas (PK) apibrėžią visą gauto pelno ir viso patirto nuostolio santykį, o tai parodo strategijos arba prototipų efektyvumą. Pelningumo koeficientas apskaičiuojamas žemiau pateikta formule (Groette, 2025):


$$PK = \frac{\text{Bendras pelnas}}{\text{Bendras nuostolis}}$$

(7)

3.2. Prototipų vertinimas ir rezultatų aprašymas

Šiame poskyryje pateikiami prototipų testavimo rezultatai ir jų palyginimas. Pateikta sukauptos grąžos diagrama parodo kiekvieno prototipo grąžą dviejų savaitių laikotarpiu.

Pateiktos diagramos parodo kiekvieno prototipo sukauptos grąžos kitimą per laikotarpį nuo 2025-11-11 iki 2025-12-19. Verta pabrėžti tai, kad prototipų instrukcijos buvo atnaujintos 2025-12-11. Pradinis kapitalas normalizuotas 0,00%.



Šaltinis: sudaryta autoriaus.


21 pav. „Open AI“ prototipų sukauptosios grąžos palyginimas

21 pav. pateikiama „Open AI“ prototipų su sentimentalio ir be sentimentalios analizės dinamika prekybos laikotarpiu. Grafike lyginami prototipų grąža procentine išraiška su „S&P500“ indeksu ir „pirkti ir laikyti“ strategija. Laikotarpio pradžioje visos strategijos turėjo neigiamą tendenciją, o ypač „pirkti ir laikyti“ strategija, kuri lapkričio 21 dieną pasekė beveik -12,5% nuostolį. „Open AI“ prototipai parodė didesnę atsparumą rinkos svyravimams ir buvo stabilesni lyginant su „pirkimo ir laikymo“ strategija. 2025-12-10 atliktas instrukcijų atnaujinimas, kuris grafike pažymėtas raudona punktyrine linija pakeitė prototipų trajektorijas. Sukurtų prototipų grąža pradėjo judėti

priešinga kryptimi nuo indekso ir „pirkti ir laikyti“ strategijos. Tyrimo pabaigoje 2025-12-19 gauti šie rezultatai:

- Efektyviausiai pasirodė „OpenAI be sentimentalios“ (1,72%), aplenkdamas rinkos vidurkį;
- S&P500 fiksavo nedidelį neigiamą pokytį (-0,84%);
- „OpenAI“ prototipas su sentimentalia analize pasiekė -4,74% lygį;
- Prasčiausią rezultatą fiksavo „Buy&Hold“ strategija (-6,82%).

Gauti tyrimo duomenys leidžia daryti prielaidą, kad prototipas be sentimentų analizės tam tikromis rinkos sąlygomis gali padidinti modelio prognozavimo tikslumą arba sumažinti reakciją į triukšmą rinkoje. Staigus „OpenAI be sentimentalios“ prototipo šuolis po gruodžio 10 d. indikuoja, kad optimizuotos instrukcijos turėjo teigiamą įtaką sprendimų priėmimo kokybei.



Šaltinis: sudaryta autoriaus.


22 pav. „DeepSeek“ prototipų sukauptosios gražos palyginimas

22 pav. pateikiamas „DeepSeek“ prototipų be sentimentalios ir su sentimentalio analize grafikas, kuris parodo prototipų, „S&P500“ indekso ir „pirkti ir laikyti“ strategijos dinamiką. Laikotarpio pradžioje visos strategijos turėjo neigiamą tendenciją, išskyrus „DeepSeek“ su sentimentalio analize. Šio prototipo tendencija buvo stabiliai kylanti į viršų visa prekybos laikotarpį. Ryškus „DeepSeek“ be sentimentalios analizės pakitimas tendencijoje įvyko 2025-12-11 (grafike pavaizduota raudona punktyrine linija), kuomet buvo atnaujintos prototipų instrukcijos. Šis prototipas

skirtingai nuo rinkos kilo į viršų ir generavo didžiausią grąžą. Tyrimo pabaigoje 2025-12-19 gauti šie rezultatai:

- Efektyviausiai pasirodė „DeepSeek“ be sentimentalios analizės (6,77%), aplenkdamas rinkos vidurkį, „pirkimo ir laikymo“ strategiją ir „DeepSeek“ su sentimentalia analize;
- „DeepSeek“ prototipas su sentimentalia analize pasiekė 4,70% lygį;
- „S&P500“ fiksavo nedidelį neigiamą pokytį (-0,84%);
- Abu prototipai aplenkė „S&P500“ (-0,84%) ir „pirkimo ir laikymo“ (-6,82%) strategijas.

Apibendrinant, „DeepSeek“ pasižymėjo aukštu atsparumu rinkos nuosmukiams. Nors standartinis modelis su sentimentų analize buvo stabilesnis viso tyrimo metu, instrukcijų optimizavimas turėjo didžiausią teigiamą poveikį prototipui be sentimentalios analizės. Galutinis „DeepSeek be sentimentalios“ rezultatas (6,77 %) yra vienas geriausių visame tyrime, o tai rodo, kad modelio vidinė logika yra pakankamai stipri priimti pelningus sprendimus remiantis kiekybiniais arba tiesioginiais rinkos duomenimis, kai instrukcijos yra tinkamai suformuluotos.



Šaltinis: sudaryta autoriaus.

23 pav. „Gemini“ prototipų sukauptosios grąžos palyginimas

23 pav. pateikiamas „Gemini“ prototipų vertinimas laikotarpiu nuo 2025-11-11 iki 2025-12-19. Analizėje lyginami du prototipai – „Gemini“ su sentimentalia analize ir „Gemini be sentimentalios“ – su „S&P500“ indeksu bei „pirkimo ir laikymo“ strategija. Priešingai nei „OpenAI“

prototipų atveju, abu „Gemini“ modeliai viso tyrimo metu demonstravo teigiamą grąžą ir ryškų atotrūkį nuo rinkos etalonų („S&P500“ ir „pirkimo ir laikymo“). Ypač pastebimas skirtingas „Gemini be sentimentalios“ prototipo elgesys lapkričio viduryje: tuo metu, kai rinka patyrė didžiausią nuosmukį (lapkričio 21 d. „pirkimo ir laikymo“ pasiekė -12,5%), šis prototipas fiksavo savo didžiausią vertę, viršijančią 10 %. Tai parodė modelio visiškai skirtinga rinkos vertinimą.

Po 2025-12-10 atlikto instrukcijų atnaujinimo stebimas trumpalaikė abiejų „Gemini“ prototipų nuosmukis, tačiau jis buvo laikinas. Po pradinio kritimo abu modeliai grįžo į augimo fazę. „Gemini“ prototipas su sentimentalio analize po atnaujinimo rodė stabilesnį ir nuoseklesnį kilimą nei versija be sentimentų analizės, o tai leidžia daryti prielaidą, kad „Gemini“ architektūrai sentimentų komponentas padeda geriau adaptuotis prie atnaujintų instrukcijų. Tyrimo pabaigoje 2025-12-19 gauti šie rezultatai:

- Lyderiu tapo „Gemini“ prototipas su sentimentalio analize, pasiekęs 6,27% grąžą;
- „Gemini be sentimentalios“ prototipas fiksavo 3,67% rezultatą;
- Abu prototipai aplenkė „S&P500“ (-0,84%) ir „pirkimo ir laikymo“ (-6,82%) strategijas.

Apibendrinant, „Gemini“ prototipai šiame eksperimente pasirodė kaip atsparūs rinkos svyravimams. Gebėjimas išlaikyti teigiamą grąžą net ir „S&P500“ indeksui krentant, rodo aukštą modelių prognozavimo potencialą. Skirtingai nei „OpenAI“ modelyje, „Gemini“ atveju su sentimentų analize galutiniame taške pasiekė geresnį rezultatą nei supaprastinta versija, o tai indikuoja geresnį šio modelio gebėjimą integruoti kokybinius duomenis į sprendimų priėmimo procesą.

6 lentelė

Pelningumo rodiklių rezultatai

Prototipas	Sukauptoji grąža	CAGR
Deep Seek	4,70%	55,41%
Open AI	-4,74%	-37,28%
Gemini	6,27%	79,29%
Deep Seek be Sentiment	6,77%	87,64%
Open AI be Sentiment	1,72%	17,79%
Gemini be Sentiment	3,67%	41,37%
„S&P500“	-0,84%	-7,82%
„Pirkimas ir laikymas“	-6,37%	-44,21%

Šaltinis: sudaryta autoriaus.

6 lentelėje apibendrinami tyrimo metu gauti pelningumo rodikliai: sukaupioji grąža ir apskaičiuotas metinis augimo tempas (angl. *Compound Annual Growth Rate* – CAGR). Šie duomenys leidžia objektyviai palyginti dirbtinio intelekto prototipų efektyvumą su rinkos „S&P500“ indeksu bei pasyvaus investavimo strategija „pirkimas ir laikymas“. Išanalizavus duomenis, geriausius

rezultatus pademonstravo „DeepSeek“ be sentimentalios analizės prototipas, kurio sukaupioji grąža siekė 6,77%, o prognozuojamas CAGR – net 87,64%. Antroje vietoje pagal efektyvumą liko „Gemini“ prototipas su sentimentalio analize 6,27% sukaupioji grąža ir 79,29% CAGR. Abu šie modeliai ne tik uždirbo teigiamą grąžą, bet ir aplenkė „S&P500“ indeksą, kuris per tą patį laikotarpį fiksavo -0,84% nuostolį. Tyrimas atskleidė nevienareikšmę sentimentų analizės modulio įtaką modelių pelningumui:

„DeepSeek“ ir „Open AI“ be sentimentalios analizės pasiekė geresnius rezultatus. „Open AI“ prototipas be sentimentų analizės sugebėjo pasiekti teigiamą 1,72% grąžą, kai tuo tarpu prototipas su sentimentalio analize fiksavo didžiausią visame tyrime nuostolį -4,74%.

Priešinga tendencija stebima „Gemini“ modelyje, kur prototipas su sentimentų analize pasirodė gerokai efektyviau 6,27% nei prototipas be jos 3,67%. Tai indikuoja, kad skirtingos architektūros modeliai nevienodai interpretuoja kokybinius sentimentų duomenis.

Lyginant su tradicinėmis strategijomis, beveik visi DI prototipai (išskyrus „Open AI“ su sentimentalio analize) pasirodė geriau nei rinkos vidurkis. Prasčiausią rezultatą fiksavo „pirkimo ir laikymo“ strategija, kurios sukaupioji grąža siekė -6,37 %, o CAGR – -44,21 %. Tai patvirtina, kad dinamiškas, dirbtiniu intelektu grįstas portfelio valdymas tyrimo laikotarpiu buvo efektyvesnis už pasyvų investavimą.

Verta pabrėžti ir tai, kad itin aukšti CAGR rodikliai yra nulemti trumpo tyrimo laikotarpio ir sėkmingos modelių reakcijos į rinkos svyravimus. Nors šie skaičiai indikuoja aukštą momentinį prototipų efektyvumą, ilgalaikėje perspektyvoje jie gali stabilizuotis.

7 lentelė

Rizikos lygio rezultatai

Prototipas	Dienos kintamumas	Metinis kintamumas	Maksimalus nuosmukis	Šarpo koeficientas
Deep Seek	1,33%	21,15%	-2,41%	2,48
Open AI	1,09%	17,24%	-4,74%	-2,34
Gemini	1,66%	26,39%	-2,05%	2,89
DeepSeek be Sentiment	2,44%	38,67%	-2,86%	2,19
Open AI be Sentiment	1,19%	18,95%	-4,61%	0,78
Gemini be Sentiment	3,29%	52,28%	-10,10%	0,73
„S&P500“	0,79%	12,56%	-4,56%	-0,86
„Pirkimas ir laikymas“	2,04%	32,39%	-13,10%	-1,46

7 lentelėje pateikti prototipų rizikos rodikliai, kurie leidžia įvertinti investicijų stabilumą ir grąžos santykį su prisiimta rizika. Analizei panaudoti dienos ir metinio kintamumo, maksimalaus nuosmukio bei Šarpo koeficiento rodikliai. Apskaičiuotas Šarpo koeficientas atskleidžia, kad efektyviausiai riziką valdė „Gemini“ su sentimentalio analize – 2,89 ir „DeepSeek“ su sentimentalio

analize – 2,48. Nors „Deep Seek“ be sentimentų analizės uždirbo didžiausią absoliučią grąžą (žr. 6 lentelę), jo Šarpo koeficientas 2,19 yra mažesnis nei „DeepSeek“ su sentimentalia analize dėl gerokai didesnio kintamumo. Tai rodo, kad „Gemini“ ir „DeepSeek“ su sentimentalia analize pasiekė grąžą su mažesniais svyravimais.

Vertinant kapitalo apsaugą, geriausius rezultatus pademonstravo „Gemini“ ir „Deep Seek“ prototipai su sentimentalia analize, kurių maksimalus nuosmukis tyrimo metu siekė atitinkamai tik -2,05% ir -2,41%. Palyginimui, pasyvaus investavimo strategija „pirkimas ir laikymas“ patyrė net -13,10% nuosmukį. Šis skirtumas įrodo, kad DI prototipai sugebėjo efektyviai identifikuoti rinkos rizikas ir laiku koreguoti pozicijas, taip apsaugodami investicijas.

Duomenys rodo, kad prototipai be sentimentų analizės generavo aukštesnę rizikos lygį:

- „Gemini“ be sentimentų analizės kintamumas pasiekė 52,28%, o maksimalus nuosmukis pasiekė – -10,10%.
- „DeepSeek“ be sentimentų analizės metinis kintamumas – 38,67%.

Galima teigti, jog sentimentų analizės komponentas veikia kaip „saugiklis“, mažinantis modelių sprendimų agresyvumą ir užtikrinantis tolygesnę grąžos kreivę.

Nors „S&P500“ pasižymėjo mažiausiu metiniu kintamumu – 12,56%, jo Šarpo koeficientas buvo neigiamas – -0,86, kas indikuoja, kad prisiimta rizika tyrimo laikotarpiu nebuvo kompensuota grąža. Dauguma DI prototipų, išskyrus „Open AI“ su sentimentų analize, pademonstravo teigiamą Šarpo koeficientą, taip įrodydami pranašumą prieš rinkos vidurkį rizikos ir grąžos santykio prasme. Siejant abi lenteles abi lenteles:

- Nors „Deep Seek“ be sentimentų analizės uždirbo daugiausiai 6,77%, jo kintamumas irgi buvo labai aukštas.
- „Gemini“ su sentimentų analize turi aukščiausią Šarpo koeficientą 2,89 ir mažiausią nuosmukį -2,05%, kartu generuodamas solidžią 6,27% grąžą.

8 lentelė

Prototipų kokybiniai rodikliai

Prototipas	Visos operacijos	Įvykdyti sandoriai	Sėkmingi sandoriai	Nuostolingi sandoriai	Sėkmingų sandorių santykis	Pelningumo koeficientas
DeepSeek	409	207	93	114	44,9%	1,55
DeepSeek be sentimentalių	176	87	34	53	39,0%	2,17
Gemini	611	303	145	158	47,8%	1,65
Gemini be sentimentalių	764	257	81	176	31,5%	1,22
OpenAI	213	100	26	74	26,0%	0,52
OpenAI be sentimentalių	244	109	52	57	47,7%	1,18

8 lentelėje apibendrinama prototipų prekybinė statistika tyrimo laikotarpiu. Šie duomenys leidžia įvertinti modelių aktyvumą per operacijų kiekį, sprendimų tikslumą per sėkmingus sandorius ir bendrą strategijos efektyvumą, išreikštą per pelningumo koeficientą. Analizuojant prekybinį aktyvumą, išsiskiria abudu „Gemini“ prototipai, kurie sugeneravo didžiausią operacijų kiekį 611 ir 764. Tai rodo, kad „Gemini“ yra linkusi į aukšto dažnio analizę ir dažnesnį pozicijų koregavimą. Tuo tarpu „OpenAI“ prototipai pasižymėjo mažiausiu aktyvumu, o tai gali indikuoti konservatyvesnį algoritmą, kuris operacijas vykdo tik esant aukštam užtikrintumo lygiui.

Aukščiausią sprendimų tikslumą demonstravo „Gemini“ su sentimentų analize – 47,8% ir „OpenAI“ be sentimentų analizės 47,7%. Pažymėtina, kad „OpenAI“ prototipas su sentimentų analize fiksavo itin žemą sėkmės santykį 26,0%, tai tiesiogiai koreliuoja su anksčiau aptarta neigiama šio modelio grąža. Įdomu tai, kad be sentimentų analizės, „OpenAI“ tikslumas beveik padvigubėjo, o „Gemini“ atveju – reikšmingai krito (nuo 47,8% iki 31,5%).

Esminis strategijų efektyvumo indikatorius yra pelningumo koeficientas. Aukščiausią rodiklį pasiekė „DeepSeek“ be sentimentų analizės – 2,17. Tai reiškia, kad nors šis modelis turėjo mažiau sėkmingų sandorių 39,0 % nei nesėkmingų, jo laimėjimų vertė gerokai viršijo praradimus. Tai būdinga tendencijas sekančioms strategijoms. Tuo tarpu „OpenAI“ su sentimentų analize koeficientas siekė tik 0,52, o tai rodo sistemiškai nuostolingą veiklą (kiekvienas investuotas euras generavo tik 0,52 Eur grąžos).

Statistiniai duomenys patvirtina, kad sentimentų analizės modulis turi dvejopą įtaką:

- „DeepSeek“ atveju, be sentimentalios analizės modelis tapo selektyvesnis (sandorių kiekis krito nuo 207 iki 87), tačiau jų kokybė ir pelningumo koeficientas išaugo (nuo 1,55 iki 2,17).
- „Gemini“ atveju, sentimentų analizė yra būtina – be jos modelis tampa pernelyg aktyvus, tačiau priima daug klaidingų sprendimų (sėkmės santykis krenta iki 31,5 %).

Apibendrinant tyrimo rezultatus galima teigti, jog dinamiškas, DI algoritmais grįstas investicijų valdymas tyrimo laikotarpiu buvo efektyvesnis už pasyvų investavimą. Penki iš šešių testuotų prototipų aplenkė „S&P500“ indeksą, o visi šeši prototipai pademonstravo geresnius rezultatus nei „pirkimas ir laikymas“ strategija. Tai indikuoja aukštą DI modelių potencialą identifikuoti rinkos lūžio taškus ir apsaugoti kapitalą rinkos nuosmukio sąlygomis.

Sėkmingiausiu prototipas – „DeepSeek“ be sentimentų pasiekęs 6,77% sukauptąją grąžą ir aukščiausią pelningumo koeficientą 2,17. Šis modelis įrodė, kad geba generuoti didelę vertę net ir esant santykinai žemam sėkmingų sandorių santykiui 39 %.

„Gemini“ prototipas su sentimentų analize pademonstravo aukščiausią investicinį efektyvumą, Šarpo koeficientas – 2,89, ir mažiausią maksimalų nuosmukį -2,05%. Šis modelis laikytinas stabiliausiu įrankiu konservatyviam portfelio valdymui.

Eksperimentas parodė, jog sentimentų analizės modulio integravimas neturi vienareikšmiškai teigiamo poveikio rezultatams „DeepSeek“ ir „OpenAI“ prototipams be sentimentų analizės parodė pelningesnius rodiklius, tačiau „Gemini“ atvirkščiai.

IŠVADOS IR PASIŪLYMAI

Apibendrinant visą darbą galima daryti šias išvadas:

1. Atlikta investavimo sampratos analizė leidžia daryti prielaidą, kad siekiant optimalios grąžos ir prisiimtą rizikos santykio, akcijos išlieka viena efektyviausių finansinių priemonių. Ji sudaro sąlygas gauti rizikos premiją net ir konservatyvesniems investuotojams, orientuotiems į ilgalaikį kapitalo augimą.
2. Išanalizavus dirbtinio intelekto sampratą bei panaudojimo būdus, nustatyta, kad ši technologija suteikia galimybę investuotojams greitai apdoroti didelius duomenų srautus, optimizuoti laiko sąnaudas bei sumažinti emocinių veiksnių ir subjektyvumo aspektų įtaką prekybai.
3. Istorinė automatizuotų prekybos akcijomis sprendimų analizė patvirtina, kad technologinė pažanga yra vienas iš investicinės veiklos transformacijos veiksnių. Siekiant išlaikyti konkurencingumą šiuolaikinėse finansų rinkose, būtina ne tik stebėti inovacijas, bet ir gebėti jas praktiškai pritaikyti – tai tampa fundamentaliu veiksnium, lemiančiu investicinės veiklos efektyvumą ir ilgalaikį rezultatų stabilumą.
4. Šešių skirtingų, didelių kalbų modeliais (LLM) grįstų prototipų testavimas imituojamoje prekyboje atskleidė, kad didesnis informacijos kiekis ne visada koreliuoja su tikslesniais investiciniais sprendimais. Tyrimo rezultatai leidžia daryti prielaidą, kad viešai prieinama kokybinė informacija dažnai būna pavėluota arba jau įskaičiuota į esamą rinkos kainą, todėl tam tikromis sąlygomis techniniais duomenimis paremtos prognozės leidžia tiksliau identifikuoti kainų pasikeitimo tendencijas.
5. Sistemos kūrimo ir testavimo eigoje nustatyta, kad skirtingi didelių kalbų modeliai nevienodai interpretuoja išvesties parametrus, todėl kiekvienam prototipui buvo būtina individuali užklausų inžinerija (angl. *prompt engineering*). Nepaisant iteracinių procesų optimizavimo, išliko išvesties duomenų struktūros nepastovumo rizika, kuri lėmė klaidų atsiradimą tolimesnėje duomenų apdorojimo grandinėje bei trikdė automatizuotą prototipų veiklą.
6. Atliktas tyrimas patvirtino, kad DI prototipai geba sėkmingai generuoti grąžą šiuolaikinėse finansų rinkose, tačiau jų sėkmė tiesiogiai priklauso nuo pasirinktos architektūros ir nustatymų. Identifikuota, kad „DeepSeek“ modelis pasižymi didesniu potencialu agresyviai pelno maksimizavimui, tuo tarpu „Gemini“ architektūra yra pranašesnė siekiant užtikrinti investicinį stabilumą bei efektyvų rizikos valdymą.

Siūlymai ateities tyrimams ir rekomendacijos:

Šiame tyrime LLM prototipams sąmoningai nebuvo pateiktos konkrečios investavimo strategijos ar techniniai indikatoriai, siekiant įvertinti jų gebėjimą savarankiškai interpretuoti rinkos duomenis ir priimti autonomiškus sprendimus. Remiantis gautais rezultatais, tolimesniuose tyrimuose rekomenduojama išbandyti hibridinius modelius, integruojant specifines prekybos strategijas (pvz., tendencijų sekimo ar vidurkio grįžimo) bei nustatytus techninės analizės indikatorius į modelių instrukcijų rinkinį. Tai leistų nustatyti, ar DI modelio gebėjimas sintetinti informaciją kartu su griežtomis finansinės inžinerijos taisyklėmis galėtų dar labiau padidinti sprendimų priėmimo tikslumą bei stabilizuoti grąžos rodiklius.

LITERATŪRA

1. Aswath Damodaran. (2012). *Investment Valuation: Tools and Techniques for Determining the Value of Any Asset* (3-iasis leid., T. 3). New Jersey: John Wiley & Sons, Inc.
2. Balhara, S., Gupta, N., Alkhayyat, A., Bharti, I., Malik, R. Q., Mahmood, S. N., & Abedi, F. (2025, sausio 1). A survey on deep reinforcement learning architectures, applications and emerging trends. *IET Communications*. John Wiley and Sons Inc. <https://doi.org/10.1049/cmu2.12447>
3. Basu, S. (1977). Investment Performance of Common Stocks in Relation to Their Price-Earnings Ratios: A Test of the Efficient Market Hypothesis. *The Journal of Finance*, 32(3), 663–682.
4. Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., ... Liang, P. (2022). On the Opportunities and Risks of Foundation Models. Gauthier <http://arxiv.org/abs/2108.07258>
5. Brasoveanu, A., Moodie, M., & Agrawal, R. (2020). Textual evidence for the perfunctoriness of independent medical reviews. *CEUR Workshop Proceedings* (T. 2657, p. 1–9). CEUR-WS. <https://doi.org/10.1145/nnnnnnnn.nnnnnnnn>
6. Brock, W., Lakonishok, J., & Lebaron, B. (1992). Simple Technical Trading Rules and the Stochastic Properties of Stock Returns. *Source: The Journal of Finance*, 47(5), 1731–1764.
7. Bloomenthal, A. (2025, rugpjūtis 19). Understanding Market Makers: Roles, Profits, and Their Impact on Liquidity. Retrieved from <https://www.investopedia.com/terms/m/marketmaker.asp#citation-19>
8. Campbell, J. Y., Lo, A. W., & Mackinlay, A. C. (1997). *The Econometrics of Financial Markets*. Princeton: Princeton University Press.
9. Chen, J. (2025, 08 28). Cumulative Return: Definition, Calculation, and Example. Retrieved from <https://www.investopedia.com/terms/c/cumulativereturn.asp>
10. Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. Gauthier <http://arxiv.org/abs/1810.04805>
11. Dharma, L. (2025, birželis 26). Prompt engineering best practises: Top 10 tips. Retrieved from https://www.hostinger.com/tutorials/prompt-engineering-best-practices?utm_campaign=Generic-Tutorials-DSA-t4|NT:Se|Lang:EN|LO:LT&utm_medium=ppc&gad_source=1&gad_campaignid=22

165034350&gbraid=0AAAAADMy-

hYW0zPAoho3YzNKiMWIpR3Jz&gclid=Cj0KCQiAubrJBhCbARIsAHId

12. Eugene F. Brigham, & Michael C. Ehrhardt. (2020). *Financial Management Theory & Practice* (16-asis leid.). Cengage Learning, Inc. Gauta www.cengage.com/highered
13. Fama, E. F., & French, K. R. (1992). The Cross-Section of Expected Stock Returns. *The Journal of Finance*, 47(2), 427–465.
14. Fernando, J. (2025, 09 29). Compound Annual Growth Rate (CAGR) Formula and Calculation. Retrieved from <https://www.investopedia.com/terms/c/cagr.asp>
15. Fernando, J. (2025, 09 15). Sharpe Ratio: Definition, Formula, and Examples. Retrieved from <https://www.investopedia.com/terms/s/sharperatio.asp>
16. Gerald Appel. (2005). *Technical Analysis - Power Tools For Active Investors*. New Jersey: Financial Times Prentice Hall. Gauta www.pearsoned-ema.com.
17. Grinold, R. C., & Kahn, R. N. (1999). *Active Portfolio Management A Quantitative Approach for Providing Superior Returns and Controlling Risk* (2-asis leid.).
18. Groette, O. (2025, lapkritis 4). <https://www.quantifiedstrategies.com/profit-factor/>. Retrieved from <https://www.quantifiedstrategies.com/profit-factor/>
19. Harris, L. (2002). *TRADING AND EXCHANGES: Market Microstructure for Practitioners*.
20. Hayes, A. (2025, 09 26). Master Technical Analysis: Unlock Investment Opportunities and Trade Strategies. Retrieved 10 27, 2025, from <https://www.investopedia.com/terms/t/technicalanalysis.asp>
21. Hayes, A. (2025, 06 30). Understanding Maximum Drawdown (MDD): Key Insights and Formula. Retrieved from <https://www.investopedia.com/terms/m/maximum-drawdown-mdd.asp>
22. Hayes, A. (2025, lapkritis 3). Understanding the Stock Market: How It Functions and Impacts Economy. Retrieved from <https://www.investopedia.com/articles/investing/082614/how-stock-market-works.asp#toc-how-do-stock-markets-work>
23. Heaton, J. (2016). Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning. *Genetic Programming and Evolvable Machines*, 19(1–2), 305–307. <https://doi.org/10.1007/s10710-017-9314-z>
24. Heaton, Jeff. (2005). *Introduction to neural networks with Java*. Heaton Research.
25. Hendershott, T., & Riordan, R. (2009). *Algorithmic Trading and Information* *.
26. Yang, H., Liu, X.-Y., & Wang, C. D. (2025). FinGPT: Open-Source Financial Large Language Models. Gauta <http://arxiv.org/abs/2306.06031>

27. Yu, Y., Li, H., Chen, Z., Jiang, Y., Li, Y., Suchow, J. W., ... Khashanah, K. (2025). FinMem: A Performance-Enhanced LLM Trading Agent With Layered Memory and Character Design. *IEEE Transactions on Big Data*.
<https://doi.org/10.1109/TBDATA.2025.3593370>
28. Jiang, Z., Xu, D., & Liang, J. (2017). A Deep Reinforcement Learning Framework for the Financial Portfolio Management Problem. Gauth <http://arxiv.org/abs/1706.10059>
29. John J. Murphy. (1999). *Technical Analysis of the Financial Markets*. NEW YORK INSTITUTE OF FINANCE.
30. Kenton, W. (2025, gegužė 20). Financial Instruments Explained: Types and Asset Classes. Retrieved from <https://www.investopedia.com/terms/f/financialinstrument.asp#toc-what-is-a-financial-instrument>
31. Kenton, W. (2025, spalio 1). Understanding Trading Win/Loss Ratio: Definition, Formula, and Examples. Retrieved 12 19, 2025, from <https://www.investopedia.com/terms/w/win-loss-ratio.asp>
32. Kissell, R. (2014). *The Science of Algorithmic Trading and Portfolio Management*. San Diego: Elsevier Inc. Gauth www.elsevierdirect.com/rights
33. Kritzman, M., Page, S., & Turkington, D. (2010). In Defense of Optimization: The Fallacy of $1/N$. *Financial Analysts Journal*, 66(2), 31–39.
34. Laopodis, N. T. (2021). *Understanding investments: theories and strategies*. New York.
35. Ledoit, O., & Wolf, M. (2004). A well-conditioned estimator for large-dimensional covariance matrices. *Journal of Multivariate Analysis*, 88(2), 365–411.
[https://doi.org/10.1016/S0047-259X\(03\)00096-4](https://doi.org/10.1016/S0047-259X(03)00096-4)
36. Leviškauskaitė, K. (2010). *Investment Analysis and Portfolio Management*. Kaunas.
37. Li, Y., Lin, Z., Zhang, S., Fu, Q., Chen, B., Lou, J.-G., & Chen, W. (2023). *Making Large Language Models Better Reasoners with Step-Aware Verifier* (T. 1). Long Papers. Gauth <https://github>.
38. Lo, A. W. (2004). The Adaptive Markets Hypothesis: Market Efficiency from an Evolutionary Perspective. *Journal of Portfolio Management*.
39. Lo, A. W. . (1996). *The Industrial Organization and Regulation of the Securities Industry*. University of Chicago Press.
40. Lopez de Prado, M. (2018). *Praise for Advances in Financial Machine Learning*. Wiley.

41. Marcus, G., & Davis, E. (2019). *Rebooting AI Building Artificial Intelligence We Can Trust*. Pantheon Books.
42. Markowitz, H. (1952). *Portfolio Selection*. Source: *The Journal of Finance* (T. 7).
43. Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., ... Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533. <https://doi.org/10.1038/nature14236>
44. Meet the original fintech. (n.d.). Retrieved from <https://www.instinet.com/history>
45. Nofl. (2025, spalis 27). Exploring the Limits of Large Language Models as Quant Traders. Retrieved from <https://nofl.ai/blog/TechPost1>
46. OpenAI, Achiam, J., Adler, S., Agarwal, S., Ahmad, L., Akkaya, I., ... Zoph, B. (2024). GPT-4 Technical Report. Gauth <http://arxiv.org/abs/2303.08774>
47. Penman, S. H. (2010). *Financial Statement Analysis and Security Valuation Fourth Edition McGraw-Hill Irwin*. New York.
48. Rahman, A., Cvetkovic, V., Reece, K., Walters, A., Hassan, Y., Tummeti, A., ... Nikolopoulos, D. S. (2025). MARCO: Multi-Agent Code Optimization with Real-Time Knowledge Integration for High-Performance Computing. Gauth <http://arxiv.org/abs/2505.03906>
49. Ray Ball, & Philip Brown. (2003). An Empirical Evaluation of Accounting Income Numbers. *Journal of Accounting Research*, 6, 159–178. Gauth <http://links.jstor.org/sici?sici=0021-8456%28196823%296%3A2%3C159%3AAEEOA1%3E2.0.CO%3B2-W>
50. Reilly, F., & Brown, K. (2002). *Investment analysis and portfolio management*.
51. Ruey S. Tsay. (2010). *Analysis of Financial Time Series* (3-iasis leid.). Chicago: John Wiley & Sons, Inc.s.
52. Russell, S., & Norvig, P. (2016). *Artificial Intelligence A Modern Approach*. Pearson Education Limited.
53. Samuel J. Gershman, & Bence P. Ölveczky. (2020). The neurobiology of deep reinforcement learning. *Current Biology*, (Elsevier Inc). Gauth <https://gershmanlab.com/pubs/GershmanOlveczky20.pdf>
54. Segal, T. (2005, liepa 8). What Is Diversification? Definition As an Investing Strategy. Retrieved from <https://www.investopedia.com/terms/d/diversification.asp>
55. Sharpe, W. F. (1992). *Asset Allocation: Management Style and Performance Measurement*. *Journal of Portfolio Management*. New York. Gauth <http://www.stanford.edu/~wfs Sharpe/art/sa/sa.htm>

56. Stein, B., Demuth, P., Stephenson, J. R., & Lien, K. (2017). *Little Book Big Profits Series* (10-asis leid.). Hoboken: Wiley.
57. Stephen A. Ross, Randolph W. Westerfield, & Jeffery Jaffe. (2013). *Corporate Finance* (10-asis leid.). McGraw-Hill Companies, Inc.
58. Subbiah, M., Neelakantan, A., Ramesh, A., Brown, T. B., Mann, B., Ryder, N., ... Openai, D. A. (2020). Language Models are Few-Shot Learners. <https://doi.org/10.48550/arXiv.2005.14165>
59. Sukma, N., & Namahoot, C. S. (2025). Enhancing Trading Strategies: A Multi-indicator Analysis for Profitable Algorithmic Trading. *Computational Economics*, 65(6), 3807–3840. <https://doi.org/10.1007/s10614-024-10669-3>
60. Sullivan, F., & Di Pierro, M. (2017). SECTION TITLE COMPUTING PRESCRIPTIONS What Is the Blockchain? *Computing in Science & Engineering*, 19, 92–95. <https://doi.org/10.1109/MCSE.2017.3421554>
61. Sutton, R. S., & Barto, A. G. (2015). *Reinforcement Learning: An Introduction Second edition, in progress* (2-asis leid.). MIT Press.
62. Tavily. (2025). [tavily.com](https://www.tavily.com/). Retrieved 11 09, 2025, from <https://www.tavily.com/>
63. Thorp, E. O. (2006). The Kelly Criterion in Blackjacj Sports Betting, and The Stock Market. *Handbook of Asset and Liability Management* (T. 1, p. 385–428). Elsevier B.V. [https://doi.org/10.1016/s1872-0978\(06\)01009-x](https://doi.org/10.1016/s1872-0978(06)01009-x)
64. Trinkūnas, A. (2007, 4). Ką galima įžvelgti grafikuose? Techninė analizė. Investuok. Retrieved 10 27, 2025, from https://investuok.eu/pradedantiesiems/ka-galima-izvelgti-grafikuose-technine-analize/?_gl=1*18fh8ub*_up*MQ..*_ga*ODY4MjgyNTk4LjE3NjE1MjA0NTc.*_ga_Y3JD2608SY*czE3NjE1MjA0NTckbzEkZzAkdDE3NjE1MjA0NTckajYwJGwwJGgw
65. Vaswani, A., Brain, G., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., ... Polosukhin, I. (2017). Attention Is All You Need. *Neural Information Processing Systems*.
66. *Valstybinė mokesčių inspekcija*. (2025). Retrieved from [www.vmi.lt: https://www.vmi.lt/evmi/kas-yra-finansin%C4%97s-priemon%C4%97s-](https://www.vmi.lt/evmi/kas-yra-finansin%C4%97s-priemon%C4%97s-)
67. Williams, P. (n.d.). Annualized Volatility Definition, Formula & Calculations. Retrieved from <https://study.com/academy/lesson/annualized-volatility-definition-formula.html>
68. Wilhelmina Afua Addy, Adeola Olusola Ajayi-Nifise, Binaebi Gloria Bello, Sunday Tubokirifuruar Tula, Olubusola Odeyemi, & Titilola Falaiye. (2024). Algorithmic

Trading and AI: A Review of Strategies and Market Impact. *World Journal of Advanced Engineering Technology and Sciences*, 11(1), 258–267.
<https://doi.org/10.30574/wjaets.2024.11.1.0054>

69. Wooldridge, M. (2002). *An Introduction to MultiAgent Systems*. West Sussex: John Wiley & Sons Ltd.
70. Wu, S., Irsoy, O., Lu, S., Dabrowski, V., Dredze, M., Gehrmann, S., ... Mann, G. (2023). BloombergGPT: A Large Language Model for Finance. Gauth
<http://arxiv.org/abs/2303.17564>
71. Ziv Bodie, Alex Kane, & Alan J. Marcus. (2014). *Investments* (10-asis leid.). New York: McGraw-Hill Education.

PRIEDAI

- 1 PRIEDAS Pirminė prototipų be sentimentų analizės mokymo instrukcija / 72
- 2 PRIEDAS Pirminė prototipų be sentimentų analizės žinutė / 73
- 3 PRIEDAS Atnaujinta prototipų be sentimentų analizės mokymo instrukcija / 75
- 4 PRIEDAS Atnaujinta prototipų be sentimentų analizės sistemos žinutė / 77
- 5 PRIEDAS Pirminė prototipų su sentimentų analize mokymo instrukcija / 79
- 6 PRIEDAS Pirminė prototipų su sentimentų analize sistemos žinutė / 81
- 7 PRIEDAS Atnaujinta prototipų su sentimentų analize mokymo instrukcija / 83
- 8 PRIEDAS Atnaujinta prototipų su sentimentų analize sistemos žinutė / 86

PIRMINĖ PROTOTIPŲ BE SENTIMENTŲ ANALIZĖS MOKYMO INSTRUKCIJA

„You are a trading decision agent. Your job: for a single ticker, using the provided current position data and market candles (1m, 15m, 1h), return exactly one concise JSON decision: BUY, SELL, HOLD or CLOSE (use Position tool)

Use "position" tool to evaluate you portfolio.

Use "Think" tool before giving output.

Data Sources for STOCKS:

1. {{ \$json.ticker1 }}

Technical Data (Price Action):

{{JSON.stringify(\$json.candles1m)}}

{{JSON.stringify(\$json.candles15m)}}

{{JSON.stringify(\$json.candles1h)}}

2. {{ \$json.ticker2 }}

Technical Data (Price Action):

{{JSON.stringify(\$json.candles1mT2)}}

{{JSON.stringify(\$json.candles15mT2)}}

{{JSON.stringify(\$json.candles1hT2)}}

3. {{ \$json.ticker3 }}

Technical Data (Price Action):

{{JSON.stringify(\$json.candles1mT3)}}

{{JSON.stringify(\$json.candles15mT3)}}

{{JSON.stringify(\$json.candles1hT3)}}

4. {{ \$json.ticker4 }}

Technical Data (Price Action):

{{JSON.stringify(\$json.candles1mT4)}}

{{JSON.stringify(\$json.candles15mT4)}}

{{JSON.stringify(\$json.candles1hT4)}}

5. {{ \$json.ticker5 }}

Technical Data (Price Action):

{{JSON.stringify(\$json.candles1mT5)}}

{{JSON.stringify(\$json.candles15mT5)}}

{{JSON.stringify(\$json.candles1hT5)}}“

PIRMINĖ PROTOTIPŲ BE SENTIMENTŲ ANALIZĖS PROTOTIPO SISTEMOS ŽINUTĖ

„You are a professional algorithmic trader with expertise in multi-timeframe analysis. Your task is to analyze the provided price information.

Analysis Framework

1. Technical Analysis Priority

Primary Timeframe (1m)

Secondary Timeframe (15min)

Tertiary Timeframe (1h)

2. Key Technical Indicators to Evaluate

Price action patterns

Trend analysis

Momentum indicators

Volume confirmation

3. Risk Management Requirements

Stop-loss must be placed beyond significant technical levels

Position sizing should account for volatility

Target should provide minimum 1:2 risk/reward ratio

Use Position tool to see your portfolio.

Count how much shares do you want to buy or sell;

You can close positions if you want.

Output Format for all five stocks(STRICT - No additional text)

Technical Recommendation: [BUY|SELL|HOLD|CLOSE]

Ticker:

Entry Price: [specific price level or N/A]

Stop-Loss: [specific price level or N/A]

Target Price: [specific price level or N/A]

Risk/Reward Ratio: [ratio or N/A]

Do not include rationale.

In the output, only return 'N/A' if no info is known, should be the last resort.“

ATNAUJINTA PROTOTIPŲ BE SENTIMENTŲ ANALIZĖS MOKYMO INSTRUKCIJA

STEP 1: CHECK HOLDINGS

I have connected a tool called "get_positions".

****You MUST execute this tool now**** to see if I already hold any of the analyzed tickers.

- If 'qty_available' is 0, it means I have open orders. If you decide to CLOSE, allow me to cancel them first.

2. MARKET DATA FOR ANALYSIS

Analyze technicals for the following tickers:

--- Ticker 1: {{ \$json.ticker1 }} ---

1m Candles: {{JSON.stringify(\$json.candles1m)}}}

15m Candles: {{JSON.stringify(\$json.candles15m)}}}

1h Candles: {{JSON.stringify(\$json.candles1h)}}}

--- Ticker 2: {{ \$json.ticker2 }} ---

1m Candles: {{JSON.stringify(\$json.candles1mT2)}}}

15m Candles: {{JSON.stringify(\$json.candles15mT2)}}}

1h Candles: {{JSON.stringify(\$json.candles1hT2)}}}

--- Ticker 3: {{ \$json.ticker3 }} ---

1m Candles: {{JSON.stringify(\$json.candles1mT3)}}}

15m Candles: {{JSON.stringify(\$json.candles15mT3)}}}

1h Candles: {{JSON.stringify(\$json.candles1hT3)}}}

--- Ticker 4: {{ \$json.ticker4 }} ---

1m Candles: {{JSON.stringify(\$json.candles1mT4)}}}

15m Candles: {{JSON.stringify(\$json.candles15mT4)}}}

1h Candles: {{JSON.stringify(\$json.candles1hT4)}}}

--- Ticker 5: {{ \$json.ticker5 }} ---

1m Candles: {{JSON.stringify(\$json.candles1mT5)}}}

15m Candles: {{JSON.stringify(\$json.candles15mT5)}}

1h Candles: {{JSON.stringify(\$json.candles1hT5)}}

INSTRUCTION

Based on the portfolio status above and the market data:

1. Determine if I should HOLD or CLOSE my existing positions.
2. Determine if I should enter new positions for tickers I don't own.
3. If closing a position, set "cancel_open_orders" to true.

Return ONLY the JSON array.

ATNAUJINTA PROTOTIPŲ BE SENTIMENTŲ ANALIZĖS SISTEMOS ŽINUTĖ

You are an expert Algorithmic Trading Agent & Risk Manager.

OBJECTIVE

Analyze the User's CURRENT PORTFOLIO and MARKET DATA (Candles) to generate a strict execution plan.

You must decide exactly one action per ticker: BUY, SELL (Open Short), HOLD, or CLOSE.

DATA SOURCE RULES

1. **Portfolio Check:** You must analyze the provided "Current Positions" data first.

- If `side: "long"`, the user OWNS the stock.
- If `side: "short"`, the user has SHORTED the stock (Profits when price drops).
- Note: If `qty\_available` is 0, it means orders are attached. If you decide to CLOSE, you must signal to CANCEL existing orders.

DECISION LOGIC MATRIX (Strict State Machine)

CASE 1: Ticker IS in Portfolio (LONG Position)

- **Technical View:** Price dropping below Key Support OR Bearish Reversal confirmed?
- **Action:** CLOSE (Sell to close).
- **Otherwise:** HOLD.

CASE 2: Ticker IS in Portfolio (SHORT Position - e.g., RKT)

- **Technical View:** Price breaking ABOVE Key Resistance OR Bullish Reversal confirmed?
- **Action:** CLOSE (Buy to cover).
- **Otherwise:** HOLD.

CASE 3: Ticker is NOT in Portfolio

- **Bullish Setup:** Strong Uptrend + Volume -> **Action:** BUY (Long entry).
- **Bearish Setup:** Strong Downtrend + Rejection -> **Action:** SELL (Open Short entry).
- **Neutral/Unclear:** -> **Action:** HOLD (Do nothing).

RISK PARAMETERS

- Entry: Requires candle close confirmation on 15m timeframe.
- Risk/Reward: Minimum 1:2 for new entries.

OUTPUT FORMAT (STRICT JSON)

Return a valid JSON array. You MUST calculate specific price levels for every recommendation.

Use exactly these field names:

```
[  
  {  
    "Technical Recommendation": "BUY" | "SELL" | "HOLD" | "CLOSE",  
    "Ticker": "String",  
    "Entry Price": Number (or null if HOLD/CLOSE),  
    "Stop-Loss": Number (Required for BUY/SELL, or current SL for HOLD),  
    "Target/Exit Price": Number (Required for BUY/SELL),  
    "qty": Number,  
    "confidence": "High" | "Medium" | "Low"  
  }  
]
```

PIRMINĖ PROTOTIPŲ SU SENTIMENTŲ ANALIZE MOKYMO INSTRUKCIJA

Data Sources for STOCKS:

```
{{ $json.data[0].ticker1 }}
```

Data (Price Action):

```
{{ JSON.stringify($json.data[0].candles1m) }}
```

```
{{ JSON.stringify($json.data[0].candles15m) }}\
```

```
{{ JSON.stringify($json.data[0].candles1h) }}
```

Sentiment Analysis (based on news):

```
Category: {{ $json.data[1].message.content.shortTermSentiment.category }}
```

```
Score: {{ $json.data[1].message.content.shortTermSentiment.score }}
```

```
Rationale: {{ $json.data[1].message.content.shortTermSentiment.rationale }}
```

"Score" Assignment is between -1 (extremely negative) and 1 (extremely positive)

```
{{ $json.data[0].ticker2 }}
```

Technical Data (Price Action):

```
{{ JSON.stringify($json.data[0].candles1mT2) }}
```

```
{{ JSON.stringify($json.data[0].candles15mT2) }}
```

```
{{ JSON.stringify($json.data[0].candles1hT2) }}
```

Sentiment Analysis (based on news):

```
Category: {{ $json.data[2].message.content.shortTermSentiment.category }}
```

```
Score: {{ $json.data[2].message.content.shortTermSentiment.score }}
```

```
Rationale: {{ $json.data[2].message.content.shortTermSentiment.rationale }}
```

"Score" Assignment is between -1 (extremely negative) and 1 (extremely positive)\

```
{{ $json.data[0].ticker3 }}
```

Technical Data (Price Action):

```
{{ JSON.stringify($json.data[0].candles1mT3) }}
```

```
{{ JSON.stringify($json.data[0].candles15mT3) }}
```

```
{{ JSON.stringify($json.data[0].candles1hT3) }}
```

Sentiment Analysis (based on news):

```
Category: {{ $json.data[3].message.content.shortTermSentiment.category }}
```

```
Score: {{ $json.data[3].message.content.shortTermSentiment.score }}
```

```
Rationale: {{ $json.data[3].message.content.shortTermSentiment.rationale }}
```

"Score" Assignment is between -1 (extremely negative) and 1 (extremely positive)\

```
{{ $json.data[0].ticker4 }}
```

Technical Data (Price Action):

```
{{JSON.stringify($json.data[0].candles1mT4) }}  
{{ JSON.stringify($json.data[0].candles15mT4) }}  
{{ JSON.stringify($json.data[0].candles1hT4) }}
```

Sentiment Analysis (based on news):

```
Category: {{ $json.data[4].message.content.shortTermSentiment.category }}  
Score: {{ $json.data[4].message.content.shortTermSentiment.score }}  
Rationale: {{ $json.data[4].message.content.shortTermSentiment.rationale }}  
\"Score\" Assignment is between -1 (extremely negative) and 1 (extremely positive)  
{{ $json.data[0].ticker5 }}
```

Technical Data (Price Action):

```
{{ JSON.stringify($json.data[0].candles1mT5) }}  
{{ JSON.stringify($json.data[0].candles15mT5) }}  
{{ JSON.stringify($json.data[0].candles1hT5) }}
```

Sentiment Analysis (based on news):

```
Category: {{ $json.data[5].message.content.shortTermSentiment.category }}  
Score: {{ $json.data[5].message.content.shortTermSentiment.score }}  
Rationale: {{ $json.data[5].message.content.shortTermSentiment.rationale }}  
\"Score\" Assignment is between -1 (extremely negative) and 1 (extremely positive)",
```

PIRMINĖ PROTOTIPŲ SU SENTIMENTŲ ANALIZĖ SISTEMOS ŽINUTĖ

You are a professional algorithmic trader with expertise in multi-timeframe analysis and sentiment integration. Your task is to analyze the provided technical and sentiment data to generate a single, actionable trade recommendation.

Analysis Framework

1. Technical Analysis Priority

Primary Timeframe (1m): Entry/exit timing, immediate trend direction

Secondary Timeframe (15min): Trend confirmation, key support/resistance levels

Tertiary Timeframe (1h): Overall market context, major trend direction

Key Technical Indicators to Evaluate

Price action patterns (candlestick formations, support/resistance)

Trend analysis (higher highs/lows, moving average relationships)

Momentum indicators (RSI overbought/oversold conditions)

Volume confirmation

Risk/reward ratio (minimum 1:2 ratio required)

Sentiment Integration Rules

Bullish sentiment + bullish technicals = Strong BUY signal

Bearish sentiment + bearish technicals = Strong SELL signal

Conflicting signals = HOLD (wait for alignment)

Extreme sentiment readings = Consider contrarian approach

Risk Management Requirements

Stop-loss must be placed beyond significant technical levels

Position sizing should account for volatility

Maximum risk per trade: 2% of account

Target should provide minimum 1:2 risk/reward ratio

Decision Process

Trend Identification: Determine primary trend across all timeframes

Entry Signal: Identify optimal entry based on 1min price action

Confirmation: Validate with 1h trend and volume

Context Check: Ensure alignment with 15min trend direction

Sentiment Filter: Apply sentiment data to strengthen or weaken signal

Risk Calculation: Set stop-loss and target based on technical levels

Critical Rules

Only recommend BUY/SELL when all timeframes align or when risk/reward is exceptional (>1:3)

Default to HOLD when signals are mixed or unclear

Always prioritize capital preservation over profit maximization

Entry price must be actionable (near current market price)

All price levels must be justified by technical analysis

Output Format for all five stocks(STRICT - No additional text)

Technical Recommendation: [BUY|SELL|HOLD]

Ticker:

Entry Price: [specific price level or N/A]

Stop-Loss: [specific price level or N/A]

Target Price: [specific price level or N/A]

Risk/Reward Ratio: [ratio or N/A]

Confidence Level: [High|Medium|Low|N/A]

Do not include rationale.

In the output, only return 'N/A' if no info is known, should be the last resort."

ATNAUJINTA PROTOTIPŲ SU SENTIMENTŲ ANALIZĖ MOKYMO INSTRUKCIJA

STEP 1: CHECK HOLDINGS

I have connected a tool called "position" (or "get_positions").

****You MUST execute this tool now**** to see if I already hold any of the analyzed tickers (COIN, GME, RKT, etc.).

- Remember: If 'qty_available' is 0, it means I have open orders. If you decide to CLOSE, allow me to cancel them first.

2. MARKET DATA FOR ANALYSIS

Analyze technicals for the following tickers:

--- Ticker 1: {{ \$json.data[0].ticker1 }}---

SENTIMENT DATA:

- Category: {{ \$json.data[1].message.content.shortTermSentiment.category }}
- Score: {{ \$json.data[1].message.content.shortTermSentiment.score }} (Scale: -1 to 1)
- Rationale: {{ \$json.data[1].message.content.shortTermSentiment.rationale }}

TECHNICAL DATA:

1m Candles: {{JSON.stringify(\$json.data[0].candles1m)}}

15m Candles:

{{JSON.stringify(\$json.data[0].candles15m)}}

1h Candles: {{JSON.stringify(\$json.data[0].candles1h)}}

--- Ticker 2: {{ \$json.data[0].ticker2 }} ---

SENTIMENT DATA:

- Category: {{ \$json.data[2].message.content.shortTermSentiment.category }}
- Score: {{ \$json.data[2].message.content.shortTermSentiment.score }} (Scale: -1 to 1)
- Rationale: {{ \$json.data[2].message.content.shortTermSentiment.rationale }}

TECHNICAL DATA:

1m Candles: {{JSON.stringify(\$json.data[0].candles1mT2)}}

15m Candles:

{{JSON.stringify(\$json.data[0].candles15mT2)}}

1h Candles: {{JSON.stringify(\$json.data[0].candles1hT2)}}

--- Ticker 3: {{ \$json.data[0].ticker3 }} ---

SENTIMENT DATA:

- Category: {{ \$json.data[3].message.content.shortTermSentiment.category }}

- Score: {{ \$json.data[3].message.content.shortTermSentiment.score }} (Scale: -1 to 1)

- Rationale: {{ \$json.data[3].message.content.shortTermSentiment.rationale }}

TECHNICAL DATA:

1m Candles: {{JSON.stringify(\$json.data[0].candles1mT3)}}

15m Candles:

{{JSON.stringify(\$json.data[0].candles15mT3)}}

1h Candles: {{JSON.stringify(\$json.data[0].candles1hT3)}}

--- Ticker 4: {{ \$json.data[0].ticker4 }} ---

SENTIMENT DATA:

- Category: {{ \$json.data[4].message.content.shortTermSentiment.category }}

- Score: {{ \$json.data[4].message.content.shortTermSentiment.score }} (Scale: -1 to 1)

- Rationale: {{ \$json.data[4].message.content.shortTermSentiment.rationale }}

TECHNICAL DATA:

1m Candles: {{JSON.stringify(\$json.data[0].candles1mT4)}}

15m Candles:

{{JSON.stringify(\$json.data[0].candles15mT4)}}

1h Candles: {{JSON.stringify(\$json.data[0].candles1hT4)}}

--- Ticker 5: {{ \$json.data[0].ticker5 }} ---

SENTIMENT DATA:

- Category: {{ \$json.data[5].message.content.shortTermSentiment.category }}

- Score: {{ \$json.data[5].message.content.shortTermSentiment.score }} (Scale: -1 to 1)
- Rationale: {{ \$json.data[5].message.content.shortTermSentiment.rationale }}

TECHNICAL DATA:

1m Candles: {{JSON.stringify(\$json.data[0].candles1mT5)}}

15m Candles:

{{JSON.stringify(\$json.data[0].candles15mT5)}}

1h Candles: {{JSON.stringify(\$json.data[0].candles1hT5)}}

INSTRUCTION

Based on the portfolio status above and the market data:

1. Determine if I should HOLD or CLOSE my existing positions (COIN, GME, RKT, etc.).
2. Determine if I should enter new positions for tickers I don't own.
3. If closing a position, set "cancel_open_orders" to true.

Return ONLY the JSON array.

ATNAUJINTA PROTOTIPŲ SU SENTIMENTŲ ANALIZĖS SISTEMOS ŽINUTĖ

You are an expert Algorithmic Trading Agent & Risk Manager.

OBJECTIVE

Analyze the User's CURRENT PORTFOLIO and MARKET DATA (Candles) to generate a strict execution plan.

You must decide exactly one action per ticker: BUY, SELL (Open Short), HOLD, or CLOSE.

DATA SOURCE RULES

1. **Portfolio Check:** You must analyze the provided "Current Positions" data first.

- If `side: "long"`, the user OWNS the stock.
- If `side: "short"`, the user has SHORTED the stock (Profits when price drops).
- Note: If `qty\_available` is 0, it means orders are attached. If you decide to CLOSE, you must signal to CANCEL existing orders.

DECISION LOGIC MATRIX (Strict State Machine)

CASE 1: Ticker IS in Portfolio (LONG Position)

- **Technical View:** Price dropping below Key Support OR Bearish Reversal confirmed?
- **Action:** CLOSE (Sell to close).
- **Otherwise:** HOLD.

CASE 2: Ticker IS in Portfolio (SHORT Position - e.g., RKT)

- **Technical View:** Price breaking ABOVE Key Resistance OR Bullish Reversal confirmed?
- **Action:** CLOSE (Buy to cover).
- **Otherwise:** HOLD.

CASE 3: Ticker is NOT in Portfolio

- **Bullish Setup:** Strong Uptrend + Volume -> **Action:** BUY (Long entry).
- **Bearish Setup:** Strong Downtrend + Rejection -> **Action:** SELL (Open Short entry).
- **Neutral/Unclear:** -> **Action:** HOLD (Do nothing).

RISK PARAMETERS

- Entry: Requires candle close confirmation on 15m timeframe.
- Risk/Reward: Minimum 1:2 for new entries.

SENTIMENT ANALYSIS INTEGRATION RULES

You must use the provided Sentiment Score (-1 to 1) as a CONFLUENCE FACTOR (Confirmation filter).

****Score Interpretation:****

- ****Positive (> 0.5):**** Strong Bullish confirmation. Increases confidence in BUY signals.
- ****Negative (< -0.5):**** Strong Bearish confirmation. Increases confidence in SELL/SHORT signals.
- ****Neutral (-0.5 to 0.5):**** Rely purely on Technical Analysis.

****Decision Logic Adjustments:****

1. ****CONFLICT (Divergence):****

- If Technicals say "BUY" but Sentiment is "Strong Negative" (e.g., -0.8) -> ****Downgrade action**** to HOLD or reduce Quantity/Risk significantly.
- If Technicals say "SELL" but Sentiment is "Strong Positive" (e.g., 0.8) -> ****Downgrade action**** to HOLD or wait for better setup.

2. ****AGREEMENT (Convergence):****

- If Technicals say "BUY" AND Sentiment is "Positive" -> ****Mark Confidence as "High"**** and consider larger position sizing.

****rationale check:**** Briefly read the sentiment rationale to ensure no "Black Swan" events (e.g., lawsuits, bankruptcy rumors) are present. If a catastrophic event is mentioned, override technicals and CLOSE/SELL immediately.

OUTPUT FORMAT (STRICT JSON)

Return a valid JSON array. You MUST calculate specific price levels for every recommendation. Use exactly these field names:

```
[
  {
    "Technical Recommendation": "BUY" | "SELL" | "HOLD" | "CLOSE",
```

```
"Ticker": "String",  
"Entry Price": Number (or null if HOLD/CLOSE),  
"Stop-Loss": Number (Required for BUY/SELL, or current SL for HOLD),  
"Target/Exit Price": Number (Required for BUY/SELL),  
"qty": Number,  
"confidence": "High" | "Medium" | "Low"  
}  
]
```