

UNIVERZITA PARDUBICE

FAKULTA EKONOMICKO-SPRÁVNÍ

DIPLOMOVÁ PRÁCE

2025

Bc. Mikuláš Antonik

Univerzita Pardubice

Fakulta ekonomicko-správní

Změny na finančních trzích vlivem umělé inteligence

Diplomová práce

Univerzita Pardubice
Fakulta ekonomicko-správní
Akademický rok: 2024/2025

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Mikuláš Antonik**
Osobní číslo: **E23060**
Studijní program: **N0413A050009 Ekonomika a management**
Specializace: **Ekonomika a management podniku**
Téma práce: **Změny na finančních trzích vlivem umělé inteligence**
Zadávající katedra: **Ústav podnikové ekonomiky a managementu**

Zásady pro vypracování

Cílem práce je využít vybrané nástroje umělé inteligence, které usnadňují investiční rozhodování managementu podniku a neprofesionálním investorům včetně doporučení pro investory vyplývající z výsledků formulované umělou inteligencí, zda investici koupit, prodat či držet.

Osnova:

- Teoretická východiska související s umělou inteligencí v investicích.
- Změny v investování vlivem umělé inteligence.
- Analýza a komparace vybraných nástrojů umělé inteligence a jejich vliv na investory.
- Uvedení doporučení pro investory a management podniku.

Rozsah pracovní zprávy: **cca 50 stran**
Rozsah grafických prací:
Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam doporučené literatury:

DUNIS, Ch., et al. Artificial intelligence in financial markets. London: Palgrave Macmillan, 2016, 344 s. ISBN 978-1-137-48880-0.
GRAHAM, B. Intelligentní investor. Praha: Grada, 2007, 504 s. ISBN 978-80-247-1792-0.
KOHOUT, P. Investice nová strategie. Praha: Grada, 2018, 216 s. ISBN 978-80-271-2101-4.
NOVOTNÝ, J. Investování na finančních trzích s podporou psychologické analýzy. Ostrava: Key publishing, 2018, 181 s. ISBN 978-80-7418-291-4.
VESELÁ, J. Investování na kapitálových trzích. Praha: Wolters Kulwer, 2019, 952 s. ISBN 978-80-7598-212-4.

Vedoucí diplomové práce: **Ing. Josef Novotný, Ph.D.**
Ústav podnikové ekonomiky a managementu

Datum zadání diplomové práce: **1. září 2024**
Termín odevzdání diplomové práce: **30. dubna 2025**

prof. Ing. Jan Stejskal, Ph.D. v.r.
děkan

L.S.

doc. Ing. et Ing. Renáta Myšková, Ph.D. v.r.
garant studijního programu

V Pardubicích dne 1. září 2024

Prohlašuji:

Práci s názvem Změny na finančních trzích vlivem umělé inteligence jsem vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámen s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 2.4. 2025

Mikuláš Antonik v.r.

Poděkování

Tímto bych rád poděkoval vedoucímu své diplomové práce Ing. Josefu Novotnému, Ph.D. za ochotu, trpělivost a vstřícný přístup při konzultacích. Velmi si vážím jeho odborných rad, připomínek a podnětů, které přispěly ke kvalitnímu zpracování této práce.

ANOTACE

Tato práce se zaměřuje na využití nástrojů umělé inteligence v oblasti investičního rozhodování. Pomocí metod sentimentální analýzy a komparace obchodních strategií hodnotí efektivitu AI při obchodování akcií vybraných společností. Dále práce analyzuje možnosti automatizace obchodování prostřednictvím vybraných platforem z hlediska výnosnosti, rizika a technických omezení.

KLÍČOVÁ SLOVA

umělá inteligence, sentimentální analýza, akcie, automatizované obchodování, obchodní strategie, investiční rozhodování

TITLE

The Impact of Artificial Intelligence on Financial Markets

ANNOTATION

This thesis focuses on the application of artificial intelligence tools in investment decision-making. Using methods of sentiment analysis and comparison of trading strategies, it evaluates the effectiveness of AI in trading stocks of selected companies. Furthermore, the thesis analyzes the possibilities of trading automation through selected platforms in terms of profitability, risk, and technical limitations.

KEYWORDS

artificial intelligence, sentiment analysis, stocks, automated trading, trading strategies, investment decision-making

OBSAH

| | |
|--|-----------|
| Úvod..... | 12 |
| 1 Teoretická východiska související s umělou inteligencí v investicích | 13 |
| 2 Změny v investování vlivem umělé inteligence | 34 |
| 2.1 Algoritmické obchodování | 34 |
| 2.2 Detekce podvodů | 36 |
| 2.3 Chatboti a AI asistenti..... | 39 |
| 2.4 Hodnocení úvěrového rizika | 40 |
| 2.5 Etika a regulace AI v oblasti investičního managementu..... | 42 |
| 3 METODOLOGIE..... | 43 |
| 4 Analýza a komparace vybraných nástrojů umělé inteligence a jejich vliv na investory | 46 |
| 4.1 Představení jazykových modelů určených k podpoře programování | 47 |
| 4.2 Analýza sentimentu pomocí AI | 49 |
| 4.3 Vývoj a komparace investičních strategií s využitím AI v prostředí TradingView | 61 |
| 4.5 Využití ChatGPT a Alpaca k automatizovanému obchodování | 79 |
| 5 Doporučení pro investory a management podniku | 84 |
| Závěr..... | 86 |
| Použité zdroje | 88 |

Seznam ilustrací

| | |
|---|----|
| Obrázek 1: Predikce globálního trhu s generativní AI | 24 |
| Obrázek 2: Nejlepší AI vývojářské společnosti financované vlastním kapitálem | 25 |
| Obrázek 3: Ukázka z prostředí Google Sheets | 50 |
| Obrázek 4: Schéma systému analýzy sentimentu | 51 |
| Obrázek 5: Graf korelace mezi skórem sentimentu a cenou akcií | 55 |
| Obrázek 6: Graf korelací mezi sentimentem a cenou akcií AltIndex | 60 |
| Obrázek 7: Ukázka z platformy TradingView po úspěšném vytvoření strategie..... | 62 |
| Obrázek 9: Schéma infrastruktury Google Cloud | 74 |
| Obrázek 10: Cloudové funkce obchodního bota | 75 |
| Obrázek 11: Cloud Scheduler spouštěč funkcí | 76 |
| Obrázek 12: Ukázka notifikací z Telegramu..... | 77 |
| Obrázek 13: Ukázka obchodních signálů v Telegram kanálu..... | 80 |
| Obrázek 14: Schéma automatizovaného obchodního bota na platformě Zapier..... | 81 |

Seznam tabulek

| | |
|---|----|
| Tabulka 1: NVDA sentimentální analýza | 52 |
| Tabulka 2: OKLO sentimentální analýza..... | 53 |
| Tabulka 3: TSLA sentimentální analýza..... | 54 |
| Tabulka 4: AltIndex analýza sentimentu NVDA | 57 |
| Tabulka 5: AltIndex analýza sentimentu OKLO..... | 58 |
| Tabulka 6: AltIndex analýza sentimentu TSLA..... | 59 |
| Tabulka 7: Zhodnocení výkonu Supertrend strategie navržené modelem GPT (měsíční horizont)..... | 63 |
| Tabulka 8: Zhodnocení výkonu Supertrend strategie navržené modelem GPT (3 měsíce).... | 64 |
| Tabulka 9: Zhodnocení výkonu Supertrend strategie navržené modelem GPT (6 měsíců).... | 65 |
| Tabulka 10: Zhodnocení vylepšené Supertrend strategie s ADX filtrem model GPT (měsíc) | 66 |
| Tabulka 11: Zhodnocení vylepšené Supertrend strategie s ADX filtrem model GPT (3 měsíce) | 67 |
| Tabulka 12: Zhodnocení vylepšené Supertrend strategie s ADX filtrem model GPT (6 měsíců) | 68 |
| Tabulka 13: Zhodnocení Supertrend strategie navrženou Deep Seek (měsíc)..... | 69 |

| | |
|--|----|
| Tabulka 14: Zhodnocení Supertrend strategie navrženou Deep Seek (3 měsíce)..... | 70 |
| Tabulka 15: Zhodnocení Supertrend strategie navrženou Deep Seek (6 měsíců)..... | 71 |
| Tabulka 16: Výkonnostní metriky bota z platformy Zapier..... | 83 |

Seznam zkratek

| | |
|---------|---|
| AAPL | Apple Inc. |
| AI | Artificial Intelligence (Umělá inteligence) |
| ADX | Average Directional Index |
| API | Application Programming Interface |
| ATR | Average True Range |
| AWS | Amazon Web Services |
| BBANDS | Bollinger Bands |
| CME | Chicago Mercantile Exchange |
| CTO | Chief Technology Officer |
| ETF | Exchange Traded Fund |
| GCP | Google Cloud Platform |
| GPT | Generative Pre-trained Transformer |
| HFT | High-Frequency Trading |
| HDP | Hrubý domácí produkt |
| ICE | Intercontinental Exchange |
| LSTM | Long Short-Term Memory |
| MACD | Moving Average Convergence Divergence |
| ML | Machine Learning |
| NLP | Natural Language Processing |
| NVDA | Nvidia Corporation |
| OKLO | Oklo Inc. |
| Pub/Sub | Publish/Subscribe |
| RNN | Recurrent Neural Network |

| | |
|---------|--|
| RSI | Relative Strength Index |
| RSS | Really Simple Syndication |
| SMA/EMA | Simple Moving Average / Exponential Moving Average |
| SVM | Support Vector Machine |
| TSLA | Tesla Inc. |
| VPS | Virtual Private Server |

Úvod

Umělá inteligence (AI) se v současné době řadí mezi nejvýznamnější technologické inovace s rozsáhlým uplatněním napříč různými odvětvími, včetně finančnictví a investic. Její schopnost efektivně zpracovávat velké objemy dat, odhalovat tržní vzorce a optimalizovat investiční strategie zásadně proměňuje přístup investorů k rozhodovacím procesům. Díky pokroku v oblasti strojového učení a neuronových sítí AI nejenže analyzuje historická data, ale také provádí prediktivní analýzy a generuje obchodní signály v reálném čase. S rostoucí dostupností těchto technologií se jejich využití v investiční oblasti stává čím dál populárnější, a to jak mezi drobnými investory, tak v institucionálním sektoru.

Cílem práce je využít vybrané nástroje umělé inteligence, které usnadňují investiční rozhodování managementu podniku a neprofesionálním investorům včetně doporučení pro investory vyplývající z výsledků formulované umělou inteligencí, zda investici koupit, prodat či držet.

Teoretická část práce se zabývá základními principy umělé inteligence a její aplikací ve finančním sektoru. Jsou zde popsány klíčové oblasti využití AI v investování, včetně algoritmického obchodování, analýzy sentimentu, detekce podvodů a predikce tržních trendů. Dále se věnuje etickým a regulačním aspektům spojeným s implementací AI v oblasti finančních trhů.

Praktická část práce se soustředí na konkrétní aplikace AI v oblasti investování. Nejprve jsou představeny jazykové modely podporující programování a analýzu tržních dat. Následně je zkoumána efektivita investičních strategií v prostředí TradingView, kde byly strategie navrženy jazykovými modely AI. Dále je testována možnost sestavení autonomního obchodního bota na platformě Google Cloud Platform s využitím umělé inteligence a analyzována integrace AI signálů s obchodní platformou Alpaca. Další významnou částí praktické analýzy je srovnání sentimentální analýzy prováděné pomocí Google Cloud Platform a již existující AI aplikací Altindex. V závěru práce jsou na základě provedených analýz uvedena doporučení pro investory a management podniku týkající se efektivního využití umělé inteligence v investičním rozhodování.

1 Teoretická východiska související s umělou inteligencí v investicích

Finanční trhy představují nedílnou součást globálního hospodářství, přičemž hrají klíčovou roli při alokaci kapitálu, snižování rizik a podpoře ekonomického růstu. Úvodní části této kapitoly byla proto věnována pozornost základní definici a charakteristice finančních trhů. V poslední době se však podoba finančních trhů dynamicky mění díky rychlému rozvoji moderních technologií, zejména umělé inteligence. Technologie umělé inteligence přináší zcela nové přístupy k analýze a fungování trhů. Tato kapitola byla dále zaměřena na teoretická východiska spojená s umělou inteligencí a jejím uplatněním v oblasti investic, přičemž zdůraznila její podstatu, historický vývoj, současné využití a zásadní schopnosti, které přispívají k transformaci finančních trhů.

1.1 Definice a význam finančních trhů

Finanční trhy představují komplexní systém, ve kterém dochází k obchodování s různými finančními nástroji, jako jsou akcie, dluhopisy, komodity, měny a deriváty.

V každé ekonomice se ekonomické subjekty ocitají v situacích, kdy mají buď přebytek, nebo nedostatek finančních prostředků, což jim brání v realizaci jejich plánovaných činností. Například někdo může vymyslet vynález, který by mohl být pro společnost velmi přínosný, ale nemá dostatek kapitálu na jeho realizaci. Na druhé straně může být někdo, kdo má v daný moment přebytečné peníze. Pokud se podaří propojit tyto dva subjekty, může být vynález uveden do praxe, což přinese výhody jak vynálezci, tak poskytovateli peněz a celé ekonomice (Bodie, Kane a Marcus, 2013).

Podobně jako jednotlivci mohou finanční prostředky potřebovat také firmy nebo stát. Finanční trhy tvoří klíčový mechanismus, který umožňuje přesun kapitálu od těch, kteří mají přebytek finančních prostředků, k těm, kteří je potřebují k financování svých aktivit. Tímto se podporuje ekonomický růst a efektivní alokace zdrojů (Veselá, 2019).

1.2 Struktura finančních trhů

Finanční trhy lze členit dle několika různých kritérií. Jedním z nejzákladnějších je rozdělení na trhy primární a sekundární.

Primární trh hraje klíčovou roli v získávání nových finančních prostředků, včetně úspor drobných investorů, a jejich přeměně v dlouhodobé investice, takové finanční zdroje jsou obzvláště důležité pro financování projektů, které provádějí korporace, územní samosprávy

nebo stát. V rámci tohoto procesu jsou investorům nabízeny nově emitované cenné papíry jako odměna za jejich investice. V případě prodeje cenných papírů na primárním trhu emitent získává finanční prostředky od prvních kupujících (Novotný, 2018).

Význam primárního trhu cenných papírů je do značné míry ovlivněn tím, jak efektivně fungují trhy sekundární. Zájem investorů o nové cenné papíry je ovlivněn cenovým vývojem obdobných (nebo stejných) cenných papírů obchodovaných na sekundárním trhu, stejně jako jejich likviditou. Pokud mají cenné papíry na sekundárním trhu vysokou likviditu a pozitivní cenový trend, může to zvýšit atraktivitu nově vydávaných cenných papírů a podpořit úspěch primárního trhu (Rejnuš, 2016).

Na sekundárním trhu se obchodují cenné papíry, které už byly dříve vydány do oběhu. Hlavní funkcí tohoto trhu je určování jejich tržních cen a zajištění likvidity. Díky tomu mohou investoři snadno a rychle převádět cenné papíry na hotovost, což zvyšuje jejich chuť investovat dál (Veselá, 2019).

Obchodování na sekundárním trhu, zejména u dlouhodobých cenných papírů, je mnohem častější než na trhu primárním, protože tyto cenné papíry se zde prodávají opakovaně. Na primárním trhu je totiž cenný papír většinou prodán jen jednou. Na druhou stranu, u krátkodobých cenných papírů peněžního trhu, které mají kratší životnost a vyžadují častou obnovu, bývá objem obchodů na primárním trhu mnohem vyšší než u dlouhodobých cenných papírů (Rejnuš, 2016).

1.3 Hlavní účastníci finančních trhů

Na finanční trzích působí různí účastníci, z nichž každý hraje specifickou roli a má své vlastní cíle a strategie. Jednu z těchto skupin tvoří individuální investoři. Tito investoři jsou jednotlivci, kteří vkládají své finanční prostředky do různých aktiv, jako jsou akcie, dluhopisy nebo komodity, s cílem dosažení zisku a zajištění finanční stability. Nejčastějším motivem individuálních investorů je usilování o dlouhodobém růstu svých investic, například ve formě spoření na důchod, nebo akumulace krátkodobých zisků z obchodování. Přestože investují relativně menší částky, jejich celkový vliv na trhy je významný, jelikož tvoří velkou část poptávky po různých investičních produktech a přispívají tak k likviditě trhů (Hayes, 2024).

Další významnou skupinu na finančních trzích tvoří institucionální investoři. Skupina institucionálních investorů zahrnuje velké organizace, jako jsou penzijní fondy, pojišťovny, investiční fondy a banky. Tyto subjekty spravují rozsáhlé objemy kapitálu, který investují do různých aktiv, a jejich investiční rozhodnutí mají často výrazný dopad na tržní pohyby.

Institucionální investoři využívají pokročilé analytické nástroje a strategie, aby maximalizovali výnosy pro své klienty, což jim umožňuje ovlivňovat tržní trendy a ceny aktiv. Díky svým rozsáhlým zdrojům mají také přístup k exkluzivním investičním příležitostem, které jsou pro individuální investory často nedostupné (Chen, 2024).

Emitenti představují další klíčové subjekty na finančních trzích. Jsou to firmy, vlády a další organizace, které vydávají finanční nástroje, jako jsou akcie, dluhopisy, ETF nebo jiné cenné papíry, s cílem získat kapitál na financování svých projektů. Firmy například vydávají akcie, aby získaly prostředky na růst a inovace, zatímco vlády vydávají dluhopisy na financování veřejných projektů a pokrytí rozpočtových deficitů. Emitenti hrají klíčovou roli v přerozdělování kapitálu na trzích, a poskytují investorům možnost podílet se na jejich podnikatelských nebo veřejných projektech (Hayes, 2020).

Důležitou roli na finančních trzích hrají také regulátoři, jako jsou centrální banky a komise pro cenné papíry. Regulátoři dohlížejí na to, aby byly dodržovány zákony a pravidla, které zajišťují stabilitu a spravedlivost trhů. Centrální banky například ovlivňují monetární politiku a úrokové sazby, což má dopad na likviditu na trzích a celkovou ekonomickou stabilitu. Regulace je nezbytná pro udržení důvěry investorů a ochranu před podvody a nekalými praktikami, které by mohly narušit fungování trhů (Schmidt, 2024).

Mezi další důležité subjekty na finančních trzích patří brokeři a dealeri, kteří zprostředkovávají nákupy a prodeje finančních nástrojů mezi investory. Tito zprostředkovatelé hrají klíčovou roli při zajišťování likvidity a umožňují, aby trhy fungovaly efektivně. Poskytují také investiční poradenství a další služby, které jsou nezbytné pro efektivní obchodování na trzích (Veselá, 2019).

V neposlední řadě je nutné zmínit ratingové agentury, které hodnotí finanční zdraví emitentů a jejich finančních nástrojů, poskytují investorům důležité informace, které ovlivňují jejich investiční rozhodnutí a tím i vývoj na trzích (Rejnuš, 2016).

1.4 Typy finančních trhů

Existuje několik různých typů trhů, přičemž každý z nich se zaměřuje na specifické druhy a kategorie finančních nástrojů, které jsou na něm obchodovány. Finanční trhy lze dále rozdělit do různých kategorií podle toho, které instrumenty se na nich obchodují, každý z těchto trhů má své vlastní funkce a hraje specifickou roli v rámci širšího finančního systému.

Akciové trhy

Možná nejznámějším typem finančních trhů jsou akciové trhy. Jedná se o místa, kde společnosti umisťují své akcie, které jsou následně obchodovány investory a obchodníky. Akciové trhy slouží společnostem k získávání kapitálu, zatímco investoři zde hledají možnosti zisku.

Akcie mohou být obchodovány na registrovaných burzách, jako je např. New York Stock Exchange (NYSE), Nasdaq, nebo na mimoburzovním (OTC) trhu. Většina obchodů s akciemi probíhá prostřednictvím regulovaných burz, které hrají důležitou ekonomickou roli (Hayes, 2024).

Mezi typické účastníky akciového trhu patří profesionální i neprofesionální investoři, obchodníci, tvůrci trhu (Market Makers, MMs) a specialisté, kteří udržují likviditu a zajišťují oboustranné trhy. Důležitou roli na akciových trzích mají brokeri, kteří fungují jako prostředníci a zprostředkovávají obchody mezi kupujícími a prodávajícími, aniž by sami zaujímali pozici v akciích (Graham, 2007).

Mimoburzovní trhy (OTC Markets)

Mimoburzovní trh (Over-the-Counter, OTC) je trh decentralizovaný, což znamená, že nemá fyzická místa obchodování a obchodování probíhá elektronicky na přímo, tedy bez zprostředkovatele. OTC trhy jsou charakteristické svou flexibilitou, protože zde často dochází k obchodování s méně standardizovanými finančními instrumenty, jako jsou deriváty, měny nebo dluhopisy, které nejsou kótované na burzách. Tato flexibilita umožňuje přizpůsobení podmínek obchodů konkrétním potřebám účastníků (Veselá, 2019).

Na OTC trhu se uplatňuje méně přísná regulace ve srovnání s burzovními trhy, což může vést k vyšší rizikovosti obchodů, ale zároveň nabízí větší volnost při strukturování transakcí. Nižší úroveň regulace má také za následek nižší likviditu a transparentnost, což znamená, že obchodování na těchto trzích může být méně časté a ceny nejsou tak snadno zjistitelné jako na regulovaných burzách. OTC trhy se často využívají pro obchodování s dluhopisy, měnovými páry nebo určitými deriváty, které nejsou standardizované nebo veřejně obchodované na burze (Schwab, 2024).

Dluhopisové trhy

Dluhopis je cenný papír, ve kterém investor půjčuje peníze na určité období za předem stanovenou úrokovou sazbu. Dluhopis si můžeme představit jako smlouvu mezi věřitelem a dlužníkem, která obsahuje podrobnosti o půjčce a jejích platbách (Stroukal, Berka, 2024).

Dluhopisy vydávají korporace, obce, státy a suverénní vlády k financování projektů a provozu. Například na dluhopisovém trhu se prodávají cenné papíry, jako jsou státní pokladniční poukázky, střednědobé a dlouhodobé státní dluhopisy vydávané Ministerstvem financí ČR. Dluhopisový trh je také nazýván trhem s dluhy, úvěrovým trhem nebo trhem s fixním výnosem (Rejnuš, 2016).

Peněžní trhy

Peněžní trhy obvykle obchodují s produkty s vysoce likvidními krátkodobými splatnostmi (méně než jeden rok) a jsou charakterizovány vysokou mírou bezpečnosti a relativně nižším úrokovým výnosem ve srovnání s jinými trhy (Bodie, Kane a Marcus, 2013).

Na velkoobchodní úrovni peněžní trhy zahrnují velkoobjemové obchody mezi institucemi a obchodníky. Na maloobchodní úrovni zahrnují peněžní trhy fondy peněžního trhu kupované individuálními investory a účty peněžního trhu otevírané zákazníky bank. Jednotlivci mohou také investovat na peněžních trzích nákupem krátkodobých depozitních certifikátů (CDs), komunálních směnek nebo pokladničních poukázek (Hayes, 2024).

Derivátové trhy

Derivát je smlouva mezi dvěma nebo více stranami, jejíž hodnota je založena na dohodnutém podkladovém finančním aktivu (jako je cenný papír) nebo sadě aktiv (jako je index).

Místo přímého obchodování s akciemi se na derivátovém trhu obchoduje s futures a opčními kontrakty a dalšími pokročilými finančními produkty, jejichž hodnota je odvozena od podkladových instrumentů, jako jsou dluhopisy, komodity, měny, úrokové sazby, tržní indexy a akcie (Bodie, Kane a Marcus, 2013).

Futures trhy jsou místa, kde jsou futures kontrakty zařazeny a obchodovány. Na rozdíl od forwardů, které se obchodují OTC, futures trhy využívají standardizované specifikace kontraktů, jsou dobře regulované a používají clearingová centra k vypořádání a potvrzení obchodů (Veselá, 2019).

Opční trhy, podobně kotují a regulují opční kontrakty. Obě futures a opční burzy mohou zařazovat kontrakty na různé třídy aktiv, jako jsou akcie, cenné papíry s pevným výnosem, komodity a podobně (Novotný, 2018).

Devizový trh (Forex Market)

Devizový trh (Forex) je místo, kde účastníci mohou nakupovat, prodávat, zajišťovat a spekulovat na vývoji směnných kurzů mezi měnovými páry. Devizový trh je nejlikvidnějším

trhem na světě, protože hotovost je nejlikvidnějším aktivem. Devizový trh zpracovává více než 7,5 bilionu dolarů v denních transakcích, což je více než futures a akciové trhy dohromady (Ganti, 2024).

Stejně jako mimoburzovní trhy, i devizový trh je decentralizovaný a skládá se z globální sítě počítačů a brokerů po celém světě. Devizový trh tvoří banky, komerční společnosti, centrální banky, investiční manažerské firmy, hedgeové fondy a retailoví forex brokeři a investoři (Novotný, 2018).

Komoditní trhy

Komoditní trhy jsou místa, kde se producenti a spotřebitelé setkávají, aby obchodovali s fyzickými komoditami, jako jsou zemědělské produkty (např. kukuřice, dobytek, sója), energetické produkty (ropa, plyn, uhlíkové kredity), drahé kovy (zlato, stříbro, platina) nebo „měkké“ komodity (např. bavlna, káva, cukr). Tyto trhy se nazývají spotovými komoditními trhy, kde se fyzické zboží směňuje za peníze. Většina obchodů s těmito komoditami se však odehrává na derivátových trzích, které využívají spotové komodity jako podkladová aktiva. Forwardy, futures a opce na komodity se obchodují jak OTC, tak na registrovaných burzách po celém světě, jako je Chicago Mercantile Exchange (CME) a Intercontinental Exchange (ICE) (Fernando, 2024).

Trhy s kryptoměнами

Kryptoměnové trhy nabízí tisíce digitálních měn, které se obchodují globálně napříč nezávislými online kryptoměnovými burzami. Tyto burzy poskytují digitální peněženky, které umožňují obchodníkům směňovat jednu kryptoměnu za jinou nebo za fiat měny, jako jsou dolary či eura. Vzhledem k tomu, že většina kryptoměnových burz jsou centralizované platformy, uživatelé jsou náchylní k hackům nebo podvodným aktivitám. Existují také decentralizované burzy, které fungují bez centrální autority. Tyto burzy umožňují přímé peer-to-peer (P2P) obchodování, aniž by transakce zprostředkovávala nějaká burzovní autorita. Na hlavních kryptoměnách je také dostupné obchodování s futures a opcemi (Hayes, 2024).

1.5 Úvod do umělé inteligence

Umělá inteligence (AI) je jedním z nejpobulárnějších a nejrychleji se rozvíjejících oborů v oblasti moderních technologií, který zásadně ovlivňuje různé aspekty lidského života a průmyslových odvětví. Umělou inteligenci lze definovat jako schopnost strojů vykazovat inteligentní chování, podobné tomu lidskému, včetně schopnosti učit se, rozhodovat se a řešit problémy. Cílem vývoje umělé inteligence je vytvoření systémů, které jsou schopné analyzovat

velké množství dat, rozpoznávat vzorce, přizpůsobovat se novým situacím a vykonávat úkoly autonomně nebo s minimálním zásahem člověka (Kaplan, A., & Haenlein, M., 2019).

V oblasti investování a financí AI zásadně mění způsob, jakým jsou finanční trhy analyzovány a jak jsou investiční rozhodnutí přijímány. Algoritmy umělé inteligence dokážou zpracovávat obrovská množství dat v reálném čase, identifikovat skryté vzorce na trzích a provádět prediktivní analýzy, čímž zefektivňují obchodní strategie a optimalizují investiční portfolia. Tento pokrok napomáhá jak drobným, tak institucionálním investorům lépe reagovat na dynamické změny finančních trhů (IBM, 2023).

1.6 Podstata a význam umělé inteligence

Umělá inteligence (AI) je oblastí, která se zaměřuje na studium inteligentního chování u lidí, zvířat, ale také u strojů, s cílem nalézt způsoby, jak takové chování technicky replikovat v různých typech systémů či artefaktů. Jde o jednu z nejnáročnějších a současně nejvíce fascinujících výzev, které kdy lidstvo přijalo. Ačkoli se může na první pohled zdát, že vytvoření AI není tak složité, praxe ukázala, že jde o velmi komplexní problém. Tato snaha bývá často přirovnávána k průzkumu hlubokého vesmíru, obě oblasti vyžadují mimořádnou technologickou i intelektuální zdatnost (Dunis et al., 2016).

V oblasti financí pak AI začíná hrát klíčovou roli. Od automatizovaných obchodních systémů až po predikce tržních trendů pomocí strojového učení – umělá inteligence má potenciál zásadně změnit způsob, jakým investoři a finanční instituce přistupují k rozhodování. Ačkoliv je stále náročné plně porozumět všem technickým výzvám, které AI přináší, její vliv na finanční trhy a investování je nezpochybnitelný. Právě schopnost AI analyzovat obrovské objemy dat a identifikovat složité vzory může v budoucnu přinést nové možnosti, jak maximalizovat výnosy a snižovat rizika (Whitby, 2009).

Z praktického hlediska se AI již osvědčila v různých odvětvích, včetně financí, a její aplikace neustále rostou. Jak je uvedeno v dalších kapitolách, AI nyní formuje technologii a společnost a bude to dělat stále intenzivněji i v oblasti finančních trhů. AI nám může poskytnout hlubší pochopení některých z nejnáročnějších otázek, které si kdy lidstvo kladlo, například o povaze rozhodování, predikci a analýze rizik. Jsme teprve na počátku cesty, která nám může přinést odpovědi nejen na otázky týkající se inteligence a myšlení, ale také na to, jak optimalizovat investiční procesy a rozvíjet ekonomickou stabilitu (Plummer, 2024).

1.7 Historický vývoj umělé inteligence

Nacházíme se na začátku nové éry, kde část našich každodenních činností postupně přebírá umělá inteligence (AI). Tento nový technologický svět přináší řadu otázek a vyvolává zájem o hlubší porozumění. To je důvodem k ohlédnutí se zpět na počátky tohoto vývoje, které sahají do poloviny 20. století.

Umělá inteligence byla poprvé představena americkým informatikem a kognitivním vědcem Johnem McCarthym na konferenci Dartmouthské univerzity ve Spojených Státech Amerických. McCarthy je považován za otce umělé inteligence, svými myšlenkami položil základy pro další výzkum a rozvoj tohoto odvětví, které dnes výrazně ovlivňuje i oblast financí a investic.

Tato část je zaměřena na klíčové okamžiky spojené s vývojem umělé inteligence, které významně ovlivnily její evoluci od 50. let 20. století až po současnost (Knihová, 2024).

Turingův test

Rok 1950 je spojen s Turingovým testem, který vymezuje způsob, jakým lze u stroje posoudit jeho schopnost inteligentního chování na úrovni člověka. Tento test, definoval Alan Turing a stal se jedním z prvních kroků ve výzkumu AI (Mitchell, 2024).

Konference v Dartmouth

Dalším již zmíněným důležitým momentem je rok 1955, kdy americký informatik John McCarthy na konferenci univerzity Dartmouth poprvé použil termín „umělá inteligence“. Tento rok je považován za oficiální počátek oboru AI a odstartoval širší výzkum v této oblasti (Historyofdatascience.com, 2021).

ELIZA

Rok 1966 přinesl vývoj chatbota ELIZA, který na Massachusettském technologickém institutu (MIT) vytvořil Joseph Weizenbaum. ELIZA simulovala rozhovor s psychoterapeutem, což představovalo významný posun ve schopnosti počítačů zpracovávat lidský jazyk (Ireland, 2012).

Zima umělé inteligence

V 70. a 80. letech nastalo období stagnace, označované jako „zima umělé inteligence“. Po nadějných začátcích přišlo zklamání a investoři ztratili zájem o výzkum, což vedlo ke snížení financí a tím i zpomalení vývoje AI (Knihová, 2024).

Deep blue

Rok 1996 se zapsal do historie vítězstvím šachového počítače Deep Blue nad mistrem světa Garrym Kasparovem. Tento úspěch přilákal globální pozornost k tomu, co AI dokáže (IBM, 2024).

Siri

V roce 2011 přišel přelom pro širokou veřejnost, když společnost Apple poprvé představila inteligentní hlasovou asistentku Siri jako součást iPhone 4 S. Stejný rok byl také rokem, kdy superpočítač Watson porazil dva lidské soupeře v televizní soutěži Jeopardy, což opět zvýšilo zájem o potenciál umělé inteligence (McDonough, 2024).

Alexa

V roce 2014 se na scénu dostala další hlasová asistentka – Alexa od společnosti Amazon, která rozšířila možnosti AI v domácnostech (Grey, 2022).

Chatbot Tay

Rok 2016 se nesl ve znamení selhání, když chatbot Tay, vyvinutý k simulaci konverzačního stylu mladé dívky, musel být po několika hodinách provozu stažen z důvodu nevhodného obsahu, včetně rasistických a sexistických výroků.

Další významný úspěch se odehrál v roce 2017, kdy AI porazila světového velmistra ve strategické hře go. Tento výsledek opět dokázal, že AI může překonat lidské schopnosti v komplexních úlohách (Knihová, 2024).

Etické zásady

V roce 2018 Evropská unie stanovila etické zásady pro vývoj AI, aby zajistila, že budoucí rozvoj této technologie bude probíhat v souladu s morálními a etickými principy. Tyto zásady reflektují potřebu regulace a zodpovědného přístupu k vývoji umělé inteligence (Evropská komise pro efektivitu justice, 2018).

1.8 Současnost

Nyní je to skoro 70 let od chvíle, kdy se poprvé objevil pojem umělá inteligence a celým světem hýbe technologie ChatGPT.

ChatGPT je jazykový model od společnosti OpenAI. Tento jazykový model je založen na architektuře hluboké neuronové sítě nazývané Transformer a je schopný generovat textové odpovědi podobné lidským na širokou škálu vstupních podnětů. Otevírá tak novou kapitolu v interakci mezi člověkem a strojem, jeho schopnost vytvářet texty, které se blíží lidské

komunikaci, přináší revoluční možnosti nejen ve vědě a vzdělávání, ale také v oblasti umění a byznysu. ChatGPT tak představuje důkaz toho, jak daleko jsme se posunuli v chápání a využívání umělé inteligence (Zhang et al., 2023).

Globální růst průmyslu umělé inteligence

Od roku 2000 do roku 2016 byly Spojené státy hlavním hráčem v oblasti technologií umělé inteligence. V tomto období mělo USA registrováno 3033 start-upů, což představovalo 37,41 % všech světových AI start-upů (Buchanan & Cao, 2018). Tento podíl se rovněž promítá do výrazného 71,78 % podílu na celkovém financování v oblasti umělé inteligence na světové úrovni, Spojené státy byly rovněž první zemí, která začala masivně investovat do umělé inteligence. V letech 2012 až 2016 investovalo USA do technologií umělé inteligence 18,2 miliardy dolarů, zatímco Čína pouze 2,6 miliardy dolarů a Velká Británie 850 milionů dolarů. Nicméně od roku 2017 Spojené státy ztratily vedoucí pozici ve prospěch Číny, která začala intenzivně investovat do umělé inteligence a překonala USA v celkovém financování. Na asijském trhu Čína dominuje, jelikož tvoří 68,67 % všech asijských AI start-upů za posledních pět let (CB Insights, 2018).

Čína také předstihla USA v oblasti AI patentů za posledních pět let, a to nejvíce v oblasti "strojového vidění", kde vlastní více než 55 % všech globálních patentů. Strojové vidění zahrnuje technologie jako například rozpoznávání obličeje a objektů, které se využívají v oblastech, jako je autonomní řízení, e-commerce, veřejná bezpečnost a zdravotnictví. Dramatický nárůst oblasti umělé inteligence v posledních letech vysvětlují hned dva hlavní důvody. Prvním důvodem je obrovský nárůst dostupných dat. V současnosti vytváříme každý den okolo 2,5 kvintilionu bajtů dat, přičemž 90 % všech dat, která kdy byla generována, vzniklo za poslední dva roky. Druhým důvodem je zvýšení výpočetní síly a kapacity datového úložiště, které společně otevřely nové možnosti pro vývoj nových řešení v oblasti AI. Na celém světě bylo za posledních pět let založeno 5154 AI start-upů, což představuje nárůst o 175 % v porovnání s předchozími dvanácti lety (Marr, 2018).

Jedním z hlavních důvodů, proč Čína zvýšila svůj podíl na trhu v oblasti umělé inteligence, je přístup k obrovskému množství dat, které jsou klíčové pro strojové učení. Například platforma WeChat, kterou používá zhruba miliarda lidí, každý den generuje obrovské množství dat. Čína je také významným výrobcem čipů pro AI a lídrem v technologii rozpoznávání obličejů (McKinsey Global Institute, 2017).

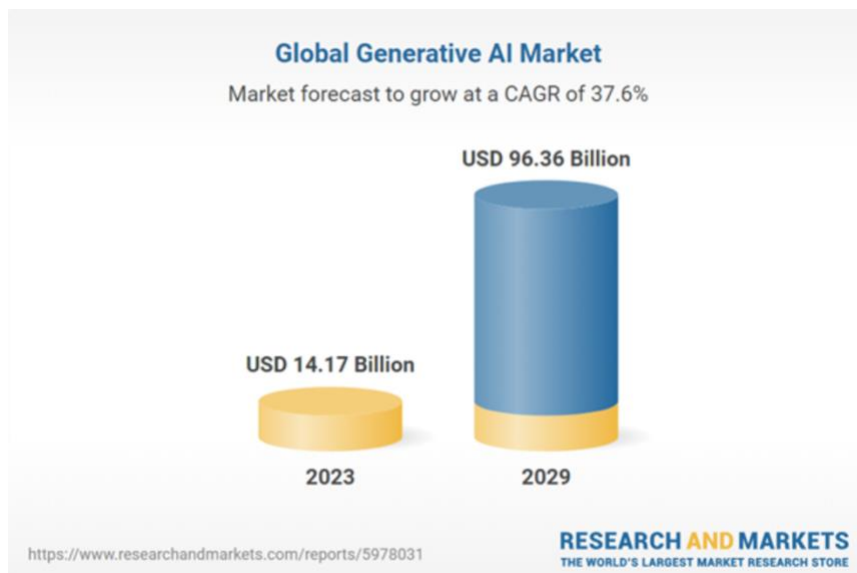
Technologická zařízení potřebují čipy, a právě v této oblasti nyní probíhá ostrá konkurence mezi Čínou a USA. Společnost Alibaba nedávno představila svůj první AI čip, který vyvinula pro cloudové služby. Tento čip, nazvaný Hanguang 800, je prvním inferenčním AI čipem na světě. Alibaba ho používá ke zlepšení vyhledávání produktů, personalizovaných doporučení a automatických překladů na svých stránkách. CTO společnosti Jeff Zhang označil tento čip za zásadní krok vpřed, který výrazně zvyšuje výpočetní kapacity firem a zlepšuje energetickou účinnost. Zajímavé je, že Alibaba neplánuje čip prodávat jako komerční produkt (Alibabacloud.com, 2019).

Zatímco AI technologie se vyvíjejí rychlým tempem, společnosti jako Facebook a Google stále pracují na svých vlastních AI čipech, aby zlepšily výkon ve svých datových centrech. Mezi americkými a čínskými firmami však existují rozdíly v jejich zaměření. Čínské společnosti jako Tencent, Alibaba a Baidu se soustředí hlavně na výzkum AI v rozpoznávání obrazu, zatímco americké firmy jako Google, IBM a Microsoft se více zaměřují na strojové učení a syntézu řeči. V roce 2017 čínská vláda oznámila ambiciózní plán stát se světovým lídrem v oblasti AI do roku 2030, s cílem dohnat Spojené státy už do roku 2020. K tomu bude v čínském městě Tchien-t'in vytvořen „průmyslový park inteligence“ s finanční podporou 16 miliard dolarů (Kun.uz, 2024).

Evropa, na rozdíl od Číny a USA, v závodu o AI trochu zaostává. Podle studie společnosti McKinsey z roku 2017 se mezi Evropou, Čínou a USA stále udržuje podobný odstup. Přestože evropské HDP je srovnatelné s USA, a dokonce mírně vyšší než v Číně, digitální sektor ICT tvoří v Evropě jen 1,7 % HDP, zatímco v Číně je to 2,1 % a v USA 3,3 %. Evropa má ale jednu velkou výhodu – disponuje více než šesti miliony profesionálních vývojářů, což je více než v USA. Evropská komise si také uvědomuje důležitost AI a plánuje vytvořit investiční fond, který bude každoročně investovat 20 miliard eur po dobu následujících deseti let (Evropská komise, 2024).

Globální trh s generativní AI

Na obrázku č.1 lze vidět, že globální trh s generativní AI byl v roce 2023 oceněn na 14,17 miliardy USD a očekává se, že do roku 2029 vzroste na 96,36 miliardy USD, což znamená průměrný roční růst 37,64 %. Jedná se pouze o odvětví s generativní AI, nikoliv o celém odvětví.



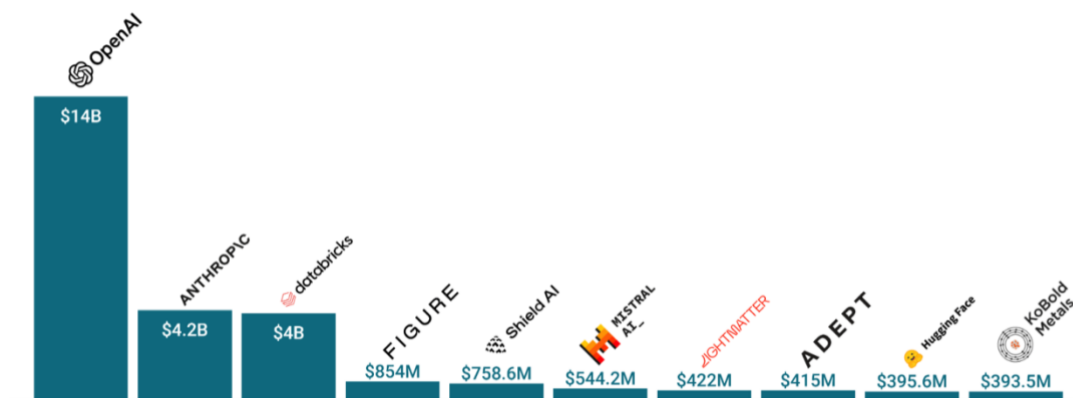
Obrázek 1: Predikce globálního trhu s generativní AI

Zdroj: Yahoo finance, 2024

Trh je vysoce konkurenční, s velkými firmami a start-upy soupeřícími o své místo. Rychlé technologické změny nutí dodavatele přizpůsobovat se, protože zákazníci očekávají neustálé inovace a vylepšování produktů. Tato situace nutí firmy přehodnotit a posílit své unikátní nabídky, aby si udržely silnou pozici na trhu (Yahoo finance, 2024).

Nejrychleji rostoucí startupy v oblasti umělé inteligence roku 2024

Od roku 2020 bylo do AI firem investováno více než 28 miliard dolarů prostřednictvím více než 240 investičních kol (k datu 22. března 2024). Z této částky, jak lze vidět na obrázku č. 2, získala samotná společnost OpenAI (známá svým produktem ChatGPT) více než 12 miliard dolarů, což představuje přes 40 % veškerých investic. Na druhou stranu čtvrtina společností, které zaznamenaly úspěch, získala méně než 10 milionů dolarů, přičemž některé vůbec nečerpaly venture kapitál (CB Insights, 2024).



Obrázek 2: Nejlepší AI vývojářské společnosti financované vlastním kapitálem

Zdroj: Yahoo finance, 2024

Zajímavé je, že přibližně 68 % těchto společností je teprve v raných fázích financování, případně dosud neobdržely žádné externí financování. Tento fakt ukazuje, že většina AI firem je teprve na začátku své cesty a stále hledá prostředky pro svůj další růst (Yahoo finance, 2024).

Skutečnost, že 68 % AI společností je teprve v raných fázích financování, naznačuje, že mnoho z nich má potenciál pro další růst. Vzhledem k tomu, že některé z těchto firem již dosáhly úspěchu, aniž by získaly výrazné finanční prostředky, by investoři mohli využít příležitosti podpořit mladé a inovativní společnosti v tomto rychle rostoucím odvětví. Na letošním seznamu je 19 firem, které dosáhly statusu „jednorozce“ (tedy jejich hodnota přesáhla 1 miliardu dolarů). Zajímavým příkladem je Sakana AI, společnost založená jedním z hlavních autorů slavné výzkumné práce „Transformer“. Transformer je nová architektura hluboké neuronové sítě, která dokáže lépe porozumět lidskému jazyku a také ho generovat. Tato architektura přinesla zásadní zlepšení ve zpracování přirozeného jazyka a umožnila modelům AI přesněji a efektivněji chápat kontext slov ve větě než předchozí modely. Sakana má nejvyšší hodnotu na zaměstnance – neuvěřitelných 67 milionů dolarů na jednoho, když v roce 2024 dosáhla hodnota společnosti 200 milionů dolarů, měla pouhé tři zaměstnance. Firma pracuje na nových AI architekturách inspirovaných přírodou a nedávno uvedla tři modely zaměřené na japonštinu (CB Insights, 2024).

Tento příklad ukazuje, jak i malé týmy s unikátním know-how mohou dosáhnout ohromných ocenění, pokud se zaměří na něco skutečně inovativního.

1.9 Klíčové schopnosti umělé inteligence využívané v investování

Díky AI mohou stroje napodobovat lidské chování tím, že se učí z dat, rozpoznávají vzory a podle nich přizpůsobují své činnosti. AI se uplatňuje v mnoha oblastech, od automatizace a konverzačních platforem po modernizaci domácností, finančního sektoru, zdravotnictví a bezpečnosti. Stroje dokážou provádět opakující se úkoly rychle a efektivně, což firmám umožňuje získat konkurenční výhodu. Hluboké neuronové sítě navíc usnadňují detekci podvodů a vytvářejí přesnější předpovědi, čímž AI stále více napodobuje schopnost lidského rozhodování. Všechny tyto vlastnosti činí AI klíčovým nástrojem pro zlepšení technologických a obchodních procesů. Tato podkapitola blíže představuje, jak stroje vybavené umělou inteligencí řeší různé úkoly s využitím svých jedinečných schopností (Jitesh, 2021).

Strojové učení

Strojové učení je technologií, která pohání chatboty, překládací aplikace, uspořádání obsahu na sociálních sítích či doporučování seriálů na oblíbené platformě Netflix. Strojové učení je mimo jiné také základem autonomních vozidel či systémů, které dokážou diagnostikovat zdravotní stavy z obrázků. Firmy, které dnes implementují umělou inteligenci, často právě využívají strojové učení, jelikož je to klíčová metoda pro řešení většiny úkolů v oblasti umělé inteligence (Brown, 2021).

Strojové učení umožňuje počítačům učit se z dat bez explicitního naprogramování. V praxi to znamená, že modely jsou trénovány na základě reálných dat (například transakce z bank), a poté jsou schopny rozpoznat vzory a vytvářet předpovědi. Tento přístup mění mnoho průmyslových odvětví, od výroby po maloobchod, bankovníctví a zdravotnictví. Firmy díky strojovému učení získávají nové hodnoty nebo zlepšují efektivitu svých procesů (Tucci, 2024).

Typy strojového učení

Existuje několik různých typů strojového učení, které pohánějí digitální produkty a služby, které používáme každý den. I když všechny tyto typy směřují k podobnému cíli (vytvořit stroje a aplikace schopné fungovat bez lidského dohledu), každý z nich k tomu přistupuje trochu jiným způsobem. Pro lepší pochopení těchto rozdílů následuje přehled čtyř hlavních typů strojového učení, které se v současnosti nejčastěji využívají (Brown, 2021).

Strojové učení s učitelem

V tomto přístupu jsou algoritmy trénovány na datových sadách, které obsahují předem označené údaje. Každý datový prvek je opatřen štítkem, který algoritmu ukazuje, jak by měl být interpretován. Například algoritmus může být trénován na obrázcích květin, kde je každá

květina správně označena svým druhem, což algoritmu pomáhá při budoucím rozpoznávání květin na základě nových fotografií. Tento typ učení je široce využíván pro modely predikce a klasifikace, což je také důležité při obchodování na finančních trzích například v případě technické analýzy (Coursera, 2024).

Strojové učení bez učitele

Tento typ učení pracuje s datovými sadami, které nejsou opatřeny žádnými štítky. Algoritmy samy odhalují vzorce a struktury v datech bez toho, aby dostávaly předem definované instrukce. Například může být algoritmus naplněn velkým množstvím neoznačených uživatelských dat z platformy sociálních médií a identifikovat trendy v chování uživatelů. Tento přístup je obvykle využíván vědci a výzkumníky pro rychlé odhalování vzorců ve velkých neoznačených datových souborech (Brown, 2021).

Polo užitečné strojové učení

Přístup polo užitečného strojového učení kombinuje jak označené, tak neoznačené datové sady. Algoritmy začínají s malým množstvím označených dat, aby se nasměroval jejich vývoj, a poté jsou trénovány na velkých množstvích neoznačených dat, což vede k dokončení modelu. Například algoritmus může začít s menší množinou označených hlasových dat a poté se trénovat na větší sadě neoznačených dat, aby vytvořil model pro rozpoznávání řeči (Coursera, 2024).

Posilované učení

Posilované učení využívá metodu pokus-omyl. Algoritmy jsou nasazeny v konkrétním prostředí a po každé akci získávají zpětnou vazbu, která jim pomáhá optimalizovat své budoucí chování. Podobně jako se učí dítě, algoritmus postupně chápe prostředí a zdokonaluje své akce s cílem dosáhnout nejlepších výsledků. Posilované učení je užitečné tam, kde algoritmus musí činit sekvence rozhodnutí k dosažení určitého cíle, jako je například hraní her nebo vývoj sofistikovaných investičních modelů, které dokáží rychleji reagovat na dynamiku trhu a maximalizovat výnosy při minimalizaci potenciálních ztrát (Craig & Tucci, 2024).

Neuronové sítě

Neuronové sítě se inspiřují způsobem, jakým pracuje lidský mozek. Neuronové sítě zpracovávají a analyzují velké množství dat, aby se samy učili rozpoznávat vzory a vztahy prostřednictvím opakovaného tréninku (Kohout, 2018). Tento přístup je založen na strojovém učení bez učitele. Aby neuronová síť dokázala správně nalézt spojení mezi různými daty a pochopit je, prochází procesem tréninku, který zahrnuje opakované analýzy dat. Na začátku

jsou váhy neuronů nastaveny náhodně, a když jsou do sítě zadána data, informace procházejí jednotlivými vrstvami neuronů, které zpracovávají vstupy a aplikují na ně váhy. Výstup se poté porovná se skutečným výsledkem, což umožňuje upravit váhy pomocí procesu zpětné propagace, kde se váhy neuronů posilují nebo oslabují na základě úspěšnosti předpovědi. Tento cyklus propagace vpřed a zpětné propagace se opakuje mnohokrát s různými datovými sadami, což neuronové síti umožňuje neustále se zdokonalovat a lépe porozumět složitým vztahům v datových sadách (Dunis, 2016).

Příklady využití neuronových sítí zahrnují rozpoznávání zdrojů, řízení procesů a klasifikace dat. Za zmínku také stojí využití neuronových sítí v investičním prognózování. Modely založené na bázi těchto sítí se používají pro předpovědi finančních trhů, detekci anomálií či řízení rizik, čímž napomáhají investorům a finančním institucím v rozhodovacích procesech a zlepšování jejich výkonu (Vonko, 2022).

Hluboké učení

Hluboké učení je podmnožinou strojového učení, které využívá vícevrstvé neuronové sítě, tzv. hluboké neuronové sítě, k simulaci komplexního rozhodování lidského mozku. Většina aplikací umělé inteligence je dnes poháněna různými formami hlubokého učení.

Hlavním rozdílem mezi hlubokým učení a strojovým učení je struktura neuronové sítě. Tradiční, „nehluboké“ modely strojového učení používají jednoduché neuronové sítě s jednou nebo dvěma vrstvami výpočetních jednotek. Na druhé straně modely hlubokého učení používají tři a více vrstev, často stovky nebo tisíce, k trénování těchto modelů. Modely hlubokého učení můžeme také zařadit do přístupu učení bez učitele (Kumar, 2024).

Hluboké učení je součástí datové vědy, která pohání mnoho aplikací a služeb, zlepšuje automatizaci a umožňuje analytické i fyzické úkoly bez lidského zásahu. Dobrým příkladem je také slavný jazykový model ChatGPT od OpenAI, který je založen na architektuře hluboké neuronové sítě zvané „Transformer“. Tento model generuje textové odpovědi podobné těm lidským a nachází uplatnění v oblastech, jako jsou konverzační asistenti nebo automatizace textových úloh (Kumar, 2024).

Počítačové vidění

Počítačové vidění představuje schopnost umělé inteligence, která se opírá o metody hlubokého učení. Tato technologie se využívá k rozpoznávání vzorů na základě vizuálních dat. Inteligentní výpočetní systémy s touto schopností zpracovávají, analyzují a interpretují obrázky tím, že zachycují reálné snímky nebo videa ze svého okolí a vytvářejí si představu o prostředí. Při

příštím zapojení do rozšířené reality během nakupování, usednutí do autonomního vozidla, nebo přístupu do zabezpečené oblasti např. brokerské aplikace pomocí systému rozpoznávání obličejů si vzpomeňte, že za těmito technologiemi stojí právě počítačové vidění (Jitesh, 2021).

Zpracování přirozeného jazyka (NLP)

Natural Language Processing (NLP) je technologie strojového učení, která umožňuje počítačům interpretovat, manipulovat a rozumět lidskému jazyku. Organizace, které disponují velkými objemy hlasových a textových dat z různých komunikačních kanálů, jako jsou e-maily, textové zprávy, sociální sítě, videa, audio a další, využívají softwaru s NLP k automatickému zpracování těchto dat, analýze záměru nebo sentimentu zprávy a poskytování okamžitých reakcí na lidskou komunikaci (Aws.amazon.com, 2024).

V oblastech jako pojišťovnictví, právo a zdravotnictví hraje NLP klíčovou roli při ochraně citlivých informací v dokumentech, čímž se zajišťuje bezpečnost osobních údajů. Technologie NLP umožňují chatbotům a hlasovým asistentům komunikovat se zákazníky přirozeněji a nabízet jim personalizovaná doporučení nebo odpovídat na jejich otázky v reálném čase. Marketingové týmy zase využívají nástroje NLP k analýze zákaznického sentimentu, což jim pomáhá pochopit emoce a názory zákazníků a tím lépe přizpůsobit své produkty a služby. Díky těmto možnostem NLP významně zlepšuje zákaznickou zkušenost a zvyšuje efektivitu obchodních operací (Aws.amazon.com, 2024).

Rekurentní neuronové sítě (RNN)

Rekurentní neuronové sítě (RNN) jsou speciálně navrženy pro rozpoznávání vzorů v sekvencích dat, což je odlišuje od tradičních dopředných neuronových sítí, které umí pracovat pouze se statickými vstupy, jako jsou texty, obrázky, videa či numerická data. RNN si díky své „paměti“ udržují vnitřní stav, který jim umožňuje pamatovat si předchozí vstupy, a vykazovat tak dynamické časové chování, proto mají rekurentní neuronové sítě výhodu při práci s proměnlivými délkami vstupních a výstupních dat, což je zásadní při úlohách, jako je analýza časových řad, kde je struktura hodnot uspořádána chronologicky, například historické ceny akcií. RNN dokáží tato data efektivně zpracovat a přinášet předpovědi o budoucím vývoji trhu (Alphanome.ai, 2023).

V oblasti investování se RNN uplatňují především při předpovědích cen akcií, kde model může na základě historických dat předpovídat budoucí hodnoty a průběžně se adaptovat na nové informace. Dalším využitím je analýza sentimentu, která zkoumá například reakce veřejnosti na významné zprávy či tweety, což může pomoci investorům odhadnout vliv těchto událostí na

trh. RNN jsou využívány také pro optimalizaci portfolia, kde analyzují historické výkonnosti různých tříd aktiv a doporučují vhodnou alokaci dle rizikového profilu investora (Alphanome.ai, 2023).

RNN však také čelí několika výzvám. Mezi ně patří problém mizejícího a explodujícího gradientu, což znamená, že při tréninku RNN v některých situacích může signál, který upravuje váhy sítě, buď slábnout, až z něj skoro nic nezůstane, nebo se naopak příliš zesílit. V případě slábnutí se síť nedokáže efektivně učit, protože změny, které by jí pomohly se zlepšit, jsou příliš malé. Naopak, pokud je signál moc silný, trénink se „rozhodí“ a výsledky jsou nepřesné. Oba tyto problémy tak brání síti učit se správně. Trénink RNN navíc vyžaduje značné výpočetní zdroje, zejména při práci s rozsáhlými datsety, a navíc jsou modely také náchylné k přetrénování, což snižuje jejich přesnost na nových datech (Moghar & Hamiche, 2020).

Dlouhá krátkodobá paměť (LSTM)

LSTM (Long Short-Term Memory) je typ rekurentní neuronové sítě (RNN), který se stal velmi populárním v oblasti hlubokého učení, především díky své schopnosti pracovat s dlouhodobými závislostmi. Tato architektura je zvláště efektivní při analýze sekvenčních dat, jako jsou texty, zvukové signály nebo časové řady, kde je důležité mít na paměti předchozí informace, aby se správně interpretovaly ty následující (Siddharth, 2024).

Na rozdíl od běžných neuronových sítí, které zpracovávají jednotlivé datové body izolovaně, LSTM dokáže zpracovávat celé sekvence. Umožňuje to mechanismus zpětné vazby a specifické struktury, které uchovávají důležité informace a rozhodují, která data si zapamatovat a která zapomenout. Tento přístup umožňuje LSTM efektivně zachytit vzory a struktury v datech, což je zásadní pro úlohy jako je strojový překlad, generování textu nebo rozpoznávání řeči (Mathworks, 2024).

Díky svým výjimečným schopnostem se LSTM stala klíčovým nástrojem v umělé inteligenci a hlubokém učení, což umožnilo značné pokroky v různých oblastech od automatizovaného překládání po analýzu sentimentu ve velkých objemech textu (MIT, 2023).

Algoritmus vlčí smečky (GWO)

GWO je algoritmus, který je inspirován sociální hierarchií a loveckými metodami vlků šedých. Vlci žijí ve smečkách po 5-12 jedincích s přísnou sociální hierarchií. Na vrcholu jsou alfa vlci (samec a samice), kteří činí hlavní rozhodnutí o spánku, lovu a denním režimu. Pod nimi jsou beta vlci, kteří pomáhají s rozhodováním a mohou se stát náhradou za alfu. Nejnižší postavení jsou omega vlci, kteří musí poslouchat všechny ostatní. Mezi alfou a omegou jsou takzvaní

podřízení (delta) vlci, kteří poslouchají alfu a betu, ale dominují nad omegou, mají různé role – průzkumníci hlídají území, strážci zajišťují bezpečnost, starší vlci jsou kandidáti na alfu/betu, lovci pomáhají s lovem a pečovatelé se starají o slabé a nemocné členy smečky. Celý systém zajišťuje organizovanost a disciplínu ve smečce (Mirjalili, 2014).

GWO je oblíbený díky své jednoduchosti, efektivitě a schopnosti vyhnout se uvíznutí v lokálních optimech. Napodobuje hierarchickou strukturu vlčí smečky při hledání kořisti, kde nejlepší řešení reprezentuje alfa vlk, druhé nejlepší beta vlk atd. Tento přístup umožňuje efektivní prohledávání prostoru řešení a nalezení optimálního výsledku (Rezaei, Bozorg-Haddad & Chu, 2018).

GWO algoritmus má v oblasti predikce akcií několik praktických využití, včetně optimalizace obchodních strategií (hledání nejlepších vstupních/výstupních bodů a optimalizace parametrů technických indikátorů), portfolio managementu (optimalizace vah aktiv a vyvážení rizika) a samotné predikce cen (předpověď pohybů a identifikace trendů), přičemž jeho hlavními výhodami jsou schopnost vyhnout se lokálním minimům díky hierarchické struktuře (alfa, beta, delta, omega vlci), dobrá rovnováha mezi průzkumem a využitím nalezených řešení a přirozená inspirace sociální hierarchií vlků, což v praxi vede ke snížení rizika špatných investičních rozhodnutí a systematictějšímu přístupu k obchodování (Mirjalili, 2014).

Podporné vektorové stroje

Support Vector Machine (SVM) neboli podporný vektorový stroj je výkonný algoritmus strojového učení, který se široce využívá jak pro lineární a nelineární klasifikaci, tak pro regresní analýzu a detekci odlehlých hodnot. SVM jsou vysoce přizpůsobivé, což je činí vhodnými pro různé aplikace jako je klasifikace textu, klasifikace obrazů, detekce spamu, identifikace rukopisu, analýza genové exprese, detekce obličejů a detekce anomálií.

SVM jsou obzvláště účinné, jelikož se zaměřují na nalezení maximální oddělovací roviny mezi různými třídami v cílovém prostoru, což je činí robustními jak pro binární, tak pro víceúrovňovou klasifikaci (IBM, 2023).

V oblasti investování nachází SVM široké uplatnění především pro predikci vývoje cen finančních instrumentů, optimalizaci investičního portfolia, analýzu tržních trendů a vzorů, řízení investičních rizik, automatické obchodní systémy, detekci podvodných transakcí a analýzu sentimentu trhu. SVM se v investiční praxi osvědčily díky schopnosti zpracovat velké množství tržních dat a indikátorů, identifikovat komplexní vztahy mezi proměnnými,

poskytovat spolehlivé predikce i v nestabilním prostředí, přizpůsobit se měnícím se tržním podmínkám a minimalizovat falešné signály a šum v datech (Geeksforgeeks, 2025).

1.10 Typy AI

Umělá inteligence (AI) se v současnosti vyvíjí s cílem napodobit lidské funkce, přičemž míra, do jaké dokáže stroj replikovat lidské schopnosti, slouží jako klíčové kritérium pro klasifikaci různých typů AI. Tento systém klasifikace se odvíjí od porovnání strojů s lidskými dovednostmi, přičemž AI schopné vykonávat pokročilé, lidskému chování podobné úkoly, jsou považovány za vyspělejší typy. Na druhé straně AI s omezenými funkcemi a nižšími výkony spadá do skupiny jednodušších typů.

Z pohledu této klasifikace existují dva základní přístupy. Jeden z nich se zaměřuje na analýzu AI na základě její podobnosti s lidskou myslí a schopnosti „myslet“ či „cítit“ jako lidé. V rámci tohoto systému rozlišujeme čtyři základní typy AI: reaktivní AI, AI s omezenou pamětí, AI s teorií mysli a vědomé AI. Každý z těchto typů má své specifické charakteristiky a úroveň pokročilosti, které odráží vývoj umělé inteligence v porovnání s lidskými schopnostmi (IBM, 2023).

Reaktivní AI

Jedná se o nejstarší formy systémů AI, které mají extrémně omezené schopnosti, napodobují schopnost lidské mysli reagovat na různé druhy podnětů. Tyto stroje postrádají funkce založené na paměti, to znamená, že takové stroje nemohou využívat dříve získané zkušenosti k ovlivnění svých současných akcí, tedy nemají schopnost „učit se“. Stroje s reaktivní AI lze použít pouze k automatickému reagování na omezenou sadu nebo kombinaci vstupů. Populárním příkladem reaktivního AI stroje je již zmíněný IBM Deep Blue, stroj, který porazil šachového velmistra Garryho Kasparova v roce 1997 (Joshi, 2022).

AI s omezenou pamětí

AI s omezenou pamětí zahrnují schopnosti reaktivní AI, avšak s přidanou schopností dočasně ukládat data z minulých zkušeností, což jí umožňuje využívat historická data pro rozhodování. AI s omezenou pamětí je to, co pohání širokou škálu současných aplikací, jako jsou generativní AI nástroje, autonomní vozidla či virtuální asistenti (IBM, 2023).

Teorie mysli

AI s konceptem „teorie mysli“ označuje schopnost algoritmů přisuzovat mentální stavy subjektům, se kterými interagují. Tento typ AI dosud nebyl plně vyvinut, ale otevírá cestu pro emocionálně inteligentní roboty, kteří se v konverzaci podobají lidem. Systémy tohoto typu

umělé inteligence budou schopny rozhodovat na základě porozumění a zapamatování si emocí, čímž budou moci přizpůsobovat své chování během interakcí.

Cesta k dosažení této úrovně je velmi náročná, a to vzhledem ke složitosti lidské komunikace, kde se chování rychle přizpůsobuje měnícím se emocím. Jedním z největších problémů pro AI je schopnost skutečně porozumět a chápat, i když AI dokáže vytvářet významná umělecká díla, často postrádá skutečné porozumění svým výtvorům. Dosažení úrovně teorie mysli by představovalo zásadní krok ve vývoji umělé inteligence (Huang, 2023).

Vědomá AI

Posledním typem je vědomá AI, jenž představuje nejpokročilejší typ umělé inteligence. Jak již název napovídá, jedná se o AI, která se vyvinula na úroveň lidské inteligence, až natolik, že si je sama vědoma své existence. Ačkoli je vědomá AI konečným cílem vývoje umělé inteligence, jsme od jejího dosažení vzdáleni desítky, ne-li stovky let (Huang, 2023).

2 Změny v investování vlivem umělé inteligence

Umělá inteligence (AI) je v současnosti hybnou silou ve finančních službách, zefektivňuje procesy, snižuje náklady a zároveň čelí novým bezpečnostním rizikům. Tento vývoj má výrazný dopad na budoucnost celého sektoru.

Podle zprávy společnosti Deloitte se až 79 % finančních institucí na celém světě již zapojilo do implementace různých forem AI. Očekává se, že globální trh s AI ve finančních službách dosáhne do roku 2027 hodnoty 45,6 miliardy dolarů, což naznačuje, že AI se rychle stává nedílnou součástí správy finančních dat a procesu rozhodování, kdy dokáže zpracovávat a analyzovat velké objemy informací, což předtím vyžadovalo mnohem více času a úsilí.

AI významně ovlivňuje různé oblasti finančního sektoru, včetně plateb, úvěrového hodnocení a správy aktiv. Například využití AI v podobě chatbotů urychluje a zefektivňuje zákaznický servis, zatímco zlepšená detekce podvodů a dodržování předpisů zvyšuje spolehlivost institucionálních operací. Díky AI lze efektivněji řešit i komplikované procesy, jako je splnění požadavků v oblasti ověření identity a opatření proti praní špinavých peněz, což přináší snížení nákladů a zlepšení nabídky bank (Ruiz,2024).

Zavedení AI do finančního sektoru přináší i nová rizika. Mezi ně patří zvyšující se hrozby kybernetických útoků a potenciální zaujatost v datech, což může vést k neférovým rozhodnutím, zejména v oblasti poskytování úvěrů. Centrální banky proto pečlivě zkoumají dopady AI a aktivně ji integrují do svých operací, aby zlepšily shromažďování dat, statistickou analýzu a řízení platebních systémů. Je zásadní, aby bylo zajištěno, že AI přinese prospěch nejen bankám, ale i jejím klientům, což podtrhuje odpovědnost finančních institucí za správné řízení jejich zaváděcích procesů (Ruiz, 2024).

2.1 Algoritmické obchodování

Algoritmické obchodování (také známé jako automatizované obchodování, black-box obchodování nebo algo-trading) využívá počítačový program, který se řídí definovaným souborem pokynů pro realizaci obchodů. Tyto obchody mají potenciál generovat zisky s rychlostí a frekvencí, kterou lidský obchodník nemůže dosáhnout.

Definované sady pokynů se zakládají na časování, ceně, množství nebo jakémkoli matematickém modelu. Kromě vytváření příležitostí k zisku pro obchodníka, algoritmické obchodování zvyšuje likviditu trhů a činí obchodování systematictější, protože eliminuje vliv lidských emocí na obchodní aktivity (Seth, 2023).

Algoritmické obchodování se dělí do tří hlavních skupin: algoritmy na provádění obchodů, „black-box“, algoritmy zaměřené na zisk, a algoritmy pro vysokofrekvenční obchodování (HFT), i když se v praxi tyto oblasti mohou překrývat, všechno jsou to automatizované procesy, které se starají o obchodování a rozhodování na finančních trzích. Tyto procesy využívají data, jako je cena, čas, objem obchodů, a další parametry pro řešení problémů, které by dříve vyžadovaly zásah finančních odborníků (Chen, 2024).

Algoritmické obchodování se zásadně posunulo od 70. a 80. let, především, díky digitalizaci obchodování. První algoritmy prováděly jednoduché úkoly, jako bylo obchodování podle cen a objemů, s rozvojem technologií se tyto algoritmy staly rychlejšími a složitějšími, zvláště s nástupem vysokofrekvenčního obchodování (HFT), které umožňuje provádět obchody během mikrosekund. Integrace umělé inteligence (AI) přinesla ještě větší vylepšení – algoritmy nyní dokážou analyzovat obrovské množství dat, odhalovat vzorce a pružně reagovat na změny na trhu. Tento přístup se v současné době využívá i mimo tradiční trhy, jako jsou kryptoměny nebo komodity, což obchodníkům otevírá nové možnosti (Addy, 2024).

Moderní technologie a finanční inovace přinesly v posledních letech zásadní průlom v oblasti předpovídání vývoje akciového trhu. Současné predikční systémy kombinují inteligentní učící se algoritmy s pokročilým zpracováním dat, což umožňuje přesnější analýzu tržních pohybů. Klíčovou roli hrají především rekurentní neuronové sítě, které dokážou efektivně rozpoznávat složité vzorce a nelineární vztahy v datech. Systémy pracují jak s historickými, tak s aktuálními daty v reálném čase, přičemž zohledňují širokou škálu faktorů ovlivňujících trh od makroekonomických událostí přes politickou situaci až po přírodní katastrofy. S rostoucí globalizací a propojeností trhů již není možné spoléhat pouze na tradiční metody předpovídání, proto se do popředí dostávají moderní technologie jako strojové učení a zpracování přirozeného jazyka (NLP). Tyto nástroje pomáhají lépe pochopit a předvídat komplexní dynamiku finančních trhů, která je ovlivňována stále větším množstvím proměnných a vnějších vlivů.

Zajímavý příklad moderního přístupu k předpovídání vývoje na akciovém trhu představuje ve své studii (Prabakara et al., 2024). Systém nazvaný SMS-ILS kombinuje několik pokročilých metod umělé inteligence způsobem, který dosud nebyl v této oblasti běžný. Autoři propojili neuronové sítě typu LSTM a RNN pro analýzu časových řad, klasifikační síť DBN pro zpracování získaných vzorců a optimalizační algoritmus GWO pro automatické vylepšování celého systému. Výsledky jejich výzkumu jsou pozoruhodné – systém dosáhl 97% úspěšnosti při předpovídání pohybů tržních cen akcií, tato vysoká přesnost jasně ukazuje,

že kombinování různých metod strojového učení může být velmi účinné i při tak složité úloze, jakou je predikce vývoje akciového trhu.

Ovšem je třeba zdůraznit, že se jedná o výpočetně náročný proces, který je efektivní především při analýze jednotlivých akcií, nikoliv celého trhu. Významnou roli zde hraje také dostupnost a kvalita historických dat, která mohou být pro některé společnosti limitovaná. Z toho plyne, že i přes současné vysoké úspěchy existuje prostor pro další vylepšení, například pomocí hybridních modelů hlubokého učení a pokročilejších optimalizačních technik. Tyto poznatky mohou být cenným základem pro budoucí výzkum v této dynamicky se rozvíjející oblasti.

Analogický přístup k využití umělé inteligence v predikci finančních trhů prezentují (Mohammed, S. et al., 2023), kteří kromě již zmíněných LSTM sítí rozšířili svůj přístup o implementaci Support Vector Machines (SVM). Jejich metodologie se zaměřuje především na analýzu historických dat napříč různými segmenty trhu, zahrnující jak denní, tak intradenní obchodování. Zvláštní důraz přitom kladou na schopnost modelů vypořádat se s vysokou volatilitou trhu. Výsledky jejich studie potvrzují předchozí zjištění o účinnosti strojového učení při identifikaci obecných tržních trendů, ovšem přesná predikce konkrétních cenových úrovní zůstává problematická. Z jejich analýzy vyplývá, že další vývoj v této oblasti by se mohl ubírat směrem k implementaci pokročilejších architektur, jako je například Bi-LSTM, které by mohly dále zvýšit přesnost predikcí.

Zmíněné pokročilé metody strojového učení nacházejí významné uplatnění i v oblasti optimalizace investičních portfolií, kde LSTM sítě společně s dalšími AI algoritmy pomáhají správcům aktiv efektivněji analyzovat tržní data a optimalizovat alokaci prostředků. Kombinace prediktivních schopností umělé inteligence s tradičními principy portfolio managementu umožňuje vytváření dynamičtějších investičních strategií, které se dokáží lépe přizpůsobovat měnícím se tržním podmínkám. Vzhledem k rostoucí komplexitě finančních trhů a množství dostupných dat se dá očekávat, že význam AI technologií v oblasti správy portfolií bude nadále růst, přičemž další vývoj pravděpodobně přinese ještě sofistikovanější řešení pro optimalizaci investičních rozhodnutí (Leewayhertz.com, 2024).

2.2 Detekce podvodů

Umělá inteligence a strojové učení přinášejí také významné využití v oblasti detekce a prevence podvodů. Současný vývoj naznačuje, že technologie pro detekci podvodů se stávají standardní součástí firemních bezpečnostních systémů. Jejich hlavním přínosem je schopnost průběžně monitorovat finanční transakce a včas identifikovat potenciální rizika. Podvody v podnikovém

prostředí mohou mít různé dopady. Vedle přímých finančních ztrát často dochází k poškození důvěryhodnosti firmy a vztahů se zákazníky. V některých případech následují právní komplikace a dodatečné náklady na nápravu vzniklých škod. Proto firmy hledají účinné nástroje pro včasnou detekci podezřelých aktivit (Nweze et al., 2024).

Jak již bylo zmíněno, moderní systémy využívající umělou inteligenci dokážou pracovat s velkými objemy dat v reálném čase, což umožňuje identifikovat nestandardní transakce nebo podezřelé vzorce chování. Systém průběžně monitoruje aktivitu a upozorňuje na potenciální problémy. Tyto systémy využívají několik základních přístupů uvedených v předchozí kapitole. Například ke zpracování dat a detekci podvodů je využíváno strojové učení s učitelem, jenž představuje metodu, která pracuje s historickými příklady již známých podvodů, což systému umožňuje učit se z předchozích případů. Dalším příkladem je učení bez učitele, které funguje na principu samostatného vyhledávání anomálií v datech, kdy systém identifikuje odchylky od běžného chování bez předchozích příkladů. Hluboké učení pak představuje pokročilejší přístup, který využívá komplexní neuronové sítě k analýze složitějších vztahů a vzorců v datech. Každá z těchto metod má své specifické využití a může být nasazena samostatně nebo v kombinaci s ostatními podle konkrétních potřeb organizace. Zpracování přirozeného jazyka představuje další významný nástroj v oblasti detekce podvodů. Analyzuje textovou komunikaci, včetně emailů a chatových konverzací, a pomocí stanovených parametrů vyhledává potenciálně rizikové prvky, na tyto prvky následně upozorňuje příslušné oddělení (Nweze et al., 2024).

Systémy založené na umělé inteligenci se průběžně aktualizují na základě nových dat. Zatímco se metody podvodů vyvíjejí, systémy se adaptují na nové vzorce chování, tato vlastnost umožňuje identifikovat i dříve neznámé formy podvodného jednání, ačkoliv úspěšnost detekce závisí především na kvalitě vstupních dat a nastavení systému (Vinay, Yuan & Wu, 2023).

Implementace těchto řešení vyžaduje důkladnou přípravu a koordinaci napříč jednotlivými odděleními. Organizace musí při zavádění systémů zvážit několik klíčových aspektů. Základem je zajištění kvalitních vstupních dat, bez kterých by systém nemohl efektivně fungovat. Následuje pečlivý výběr vhodných algoritmů, které budou odpovídat konkrétním potřebám a cílům organizace. Nezbytnou součástí procesu je také důkladné zaškolení zaměstnanců, kteří budou se systémem pracovat. V neposlední řadě je nutné zajistit soulad s regulačními požadavky, které se na danou oblast vztahují. Celý tento proces je dlouhodobou záležitostí

a vyžaduje úzkou spolupráci mezi IT oddělením, finančním úsekem a bezpečnostním týmem (Nweze et al., 2024).

Ve finančním sektoru lze v současné praxi pozorovat využití těchto systémů především u bankovních institucí, které implementují automatizované systémy pro monitoring transakcí. Dále jsou systémy využívány investičními společnostmi, při prevenci tzv. insider tradingu.

Trend směřuje k další automatizaci a integraci umělé inteligence do bezpečnostních procesů. Pro organizace to může znamenat efektivnější ochranu aktiv, pro klienty potenciálně vyšší zabezpečení jejich prostředků. Zároveň je třeba brát v úvahu, že technologie sama o sobě nepředstavuje kompletní řešení a měla by být součástí širší bezpečnostní strategie (Xu et al., 2023).

Mnoho známých společností úspěšně implementovalo datově orientované přístupy k odhalování podvodů. Příkladem může být PayPal, globální lídr v oblasti online plateb. PayPal využívá strojové učení k analýze milionů transakcí v reálném čase a je trénován k identifikaci anomálií prostřednictvím analýzy různých faktorů, jako jsou částky transakcí, geografické lokace a chování uživatelů. Porovnáváním aktuálních transakcí s historickými daty dokáže systém detekovat podvody s vysokou přesností a tím předejít finančním ztrátám (Mishra, 2023).

Další příklad pochází z bankovního průmyslu, kde byla umělá inteligence využita k boji proti podvodům s kreditními kartami. Banky jako JP Morgan Chase aplikují pokročilé techniky strojového učení k monitorování milionů transakcí napříč různými kanály, včetně výběrů z bankomatů, online nákupů a transakcí v kamenných obchodech. Korelací transakčních dat s profily zákazníků mohou detekovat anomálie indikující podvod. Například pokud je karta zákazníka použita k nákupu v jedné zemi, zatímco současně probíhá jiná transakce na jiném místě, může systém označit tuto aktivitu k dalšímu prošetření (Medium.com, 2024).

Dalším, kdo implementoval systémy detekce podvodů založené na umělé inteligenci je Amazon. V Amazonu využívají pokročilé techniky analýzy dat k monitorování zákaznických transakcí, zkoumání nákupního chování a detekci podvodných aktivit, jako jsou falešné recenze a neoprávněný přístup k účtům. Systém porovnává transakční data v reálném čase s rozsáhlými historickými informacemi o nákupech, aby odhalil neobvyklé vzorce chování. Díky této schopnosti může Amazon efektivně předcházet podvodům dříve, než se negativně projeví na zákaznících (Li et al., 2024).

2.3 Chatboti a AI asistenti

Finanční chatboti se stali nepostradatelnými nástroji pro investory hledající informace o finančních trzích v reálném čase. Tyto inteligentní konverzační systémy využívají zpracování přirozeného jazyka a algoritmy strojového učení k rychlé analýze velkého množství finančních dat. Investoři mohou kdykoliv s těmito chatboty komunikovat a získávat aktuální informace o tržních trendech a výkonnosti různých finančních instrumentů (Cheung, 2024).

V rychle se měnícím prostředí finančních trhů jsou data, informace a komunikace naprosto klíčové. Chatboti pomáhají činit informovaná investiční rozhodnutí poskytováním komplexních analýz, předpovědí trendů a hodnocení rizik. Jejich schopnost zpracovávat složité finanční informace a poskytovat přizpůsobená doporučení výrazně zvyšuje efektivitu rozhodovacích procesů investorů (Stockgeist.ai, 2024).

Chatboti a umělá inteligence zároveň zásadně proměnili způsob, jakým finanční instituce komunikují se svými klienty a zpracovávají tržní operace. Prostřednictvím různých komunikačních platforem mohou klienti provádět finanční transakce, získávat aktualizace v reálném čase a dostávat rychlé odpovědi na své dotazy. V důsledku toho se finanční chatboti stali cennými pomocníky pro finanční instituce i jejich klienty, umožňují jim lépe analyzovat tržní data a s větší jistotou činit informovaná rozhodnutí na finančních trzích (Stockgeist.ai, 2024).

Dnes existují různé chatovací aplikace umělé inteligence, které významně zlepšují finanční služby. Mezi nejvýznamnější příklady patří virtuální asistent Erica od Bank of America. Erica je sofistikovaný AI asistent, který pomáhá zákazníkům s každodenními bankovními operacemi, jako jsou informace o zůstatku na účtu, detaily transakcí, a dokonce poskytuje i základní finanční poradenství (Cheung, 2024).

Další průkopnickou aplikací je COIN od JP Morgan Chase. Tento pokročilý program, využívající technologie strojového učení, se specializuje na kontrolu složitých právních dokumentů. Dříve jejich přezkoumání a interpretace vyžadovaly ruční práci trvající až 360 000 hodin ročně. Díky COIN tento proces JPMorgan Chase výrazně zefektivnil, čímž podstatně snižuje čas a náklady spojené s kontrolou dokumentace (Medium.com, 2024).

Goldman Sachs přišel s vlastním řešením v podobě AI chatbota, který se zaměřuje především na investiční poradenství. Tento systém poskytuje personalizované služby na základě komplexní analýzy dat zákazníků, jejich osobních preferencí a rizikových profilů. Tím umožňuje poskytovat vysoce individualizované investiční strategie (Cheung, 2024).

Současný vývoj v oblasti AI chatbotů je teprve začátkem. Budoucnost chatbotů ve finančním sektoru přinese významné změny v tom, jakým způsobem budou banky a finanční instituce komunikovat se svými klienty. Chatboti vybavení pokročilou umělou inteligencí budou schopni poskytovat osobní finanční poradenství a díky emoční inteligenci lépe porozumět potřebám klientů. Získají také větší samostatnost při rozhodování o běžných finančních operacích, jako je detekce podvodů nebo poskytování finančních doporučení v reálném čase. Důležitým prvkem bude zapojení blockchain technologie, která zajistí vyšší bezpečnost a průhlednost transakcí. Komunikace s chatboty se rozšíří o hlasové ovládání a video hovory, kdy klienti budou moci mluvit a vizuálně komunikovat přímo s AI asistentem, což přispěje k vytvoření přívětivějšího prostředí pro uživatele. Tyto pokročilé funkce výrazně zlepší kvalitu a dostupnost finančních služeb pro všechny klienty (Howell, 2024).

2.4 Hodnocení úvěrového rizika

Implementace umělé inteligence do procesu kreditního skórování představuje významný pokrok v oblasti hodnocení úvěrového rizika za poslední dekádu. Zatímco tradiční skóringové modely operují s limitovaným množstvím proměnných a využívají převážně statická pravidla hodnocení, systémy založené na umělé inteligenci přinášejí do tohoto procesu modernější přístup k evaluaci bonity klientů. Moderní systémy umělé inteligence významně rozšiřují možnosti analýzy dat při hodnocení úvěrového rizika. Na rozdíl od tradičních metod, které se omezují především na základní finanční ukazatele, AI systémy pracují s podstatně širším spektrem informací, vedle standardních údajů o příjmech a platební historii dokáží tyto systémy zpracovat a vyhodnotit také složitější vzorce chování klientů, jako jsou jejich nákupní zvyklosti, způsob využívání finančních služeb či celková online aktivita. Tento komplexní přístup k analýze dat, který by byl při manuálním zpracování časově i personálně náročný, umožňuje vytvořit detailnější a přesnější obraz o finanční situaci žadatele a lépe tak předpovědět potenciální rizika spojená s poskytnutím úvěru (Thefintechmag.com, 2023).

Klíčovou výhodou využití strojového učení při kreditním skórování je jeho schopnost odhalit v datech souvislosti a vzory, které tradiční analytické metody často přehlédnou. Systémy založené na strojovém učení neustále aktualizují a zdokonalují své hodnotící modely díky kontinuálnímu přísunu nových dat. Výsledkem je dynamický systém hodnocení, který se dokáže pružně přizpůsobovat měnícím se ekonomickým podmínkám a tržním výkyvům. Tato flexibilita je zvláště cenná v období ekonomické nestability, kdy se úvěrová rizika mohou rychle měnit (Patil, 2024).

Inovativní systémy AI v oblasti úvěrového hodnocení významně rozšiřují dostupnost finančních služeb, přičemž jejich moderní způsob posuzování je zvláště přínosný pro žadatele, kteří by při běžném hodnocení měli ztíženou pozici. Místo spoléhání se pouze na klasickou úvěrovou historii mohou AI systémy zohlednit různé další relevantní informace, což otevírá nové možnosti i lidem, kteří zatím neměli příležitost vybudovat si standardní úvěrovou historii. Pokročilé metody hodnocení založené na umělé inteligenci činí finanční služby dostupnější pro širší okruh zájemců, přičemž současně zachovávají odpovědný přístup k řízení rizik a umožňují efektivnější správu úvěrového portfolia (Patil, 2024).

Podívejme se nyní na reálné příklady, kde umělá inteligence pomáhá lépe hodnotit důvěryhodnost klientů a přináší měřitelné výsledky.

Praktické využití a efektivitu algoritmů strojového učení v oblasti bankovníctví potvrzuje společnost American Express. Podle statistik zveřejněných společností vedlo nasazení pokročilých analytických metod ke dvojnásobnému pozitivnímu efektu, konkrétně desetiprocentnímu poklesu míry nesplacení úvěrů a patnáctiprocentnímu nárůstu úspěšně schválených úvěrových žádostí. Reálné výsledky z finančního sektoru tak jednoznačně demonstrují, jak může propojení tradičního bankovníctví s moderními technologiemi přinést měřitelné zlepšení v oblasti řízení rizik a současně podpořit expanzi úvěrového portfolia bez kompromisů v oblasti bezpečnosti. Další sektorem využití umělé inteligence v problematice kreditního scoringu je pojišťovnictví, kde AI umožňuje lépe posuzovat rizikovost klientů a nastavovat adekvátní výši pojistného. Příkladem je společnost Progressive Insurance, která analyzuje úvěrovou historii, řídičské záznamy a další data k vytvoření přesného rizikového profilu a stanovení férové ceny pojištění (Ginimachine.com, 2023).

Umělá inteligence v oblasti kreditního scoringu přináší také revoluci do světa e-commerce, kde pomáhá přesněji vyhodnocovat důvěryhodnost zákazníků žádajících o úvěr. Působivé výsledky demonstruje spolupráce brazilského maloobchodního giganta Via Varejo se společností Zest AI – jejich pokročilý scoringový systém dokázal zvýšit počet schválených úvěrů o 15 % a zároveň snížit míru nesplacení o pětinu (Ginimachine.com, 2023).

Systémy umělé inteligence také proměňují oblast správy nemovitostí, kde pronajímatelé využívají AI kreditní scoring k efektivnějšímu výběru nájemníků. Příkladem je platforma Zumper, jejíž algoritmus analyzuje kreditní historii, pracovní záznamy, příjmy a další údaje uchazečů. Systém dokáže zpracovat žádosti desetkrát rychleji než tradiční metody a s 95 % přesností předpovídá schopnost nájemníků plnit své platební závazky (Amin, 2023).

2.5 Etika a regulace AI v oblasti investičního managementu

Implementace umělé inteligence v investičním managementu přináší zásadní etické výzvy. Článek od CFA Institute reaguje komplexními doporučeními, která mají zajistit rovnováhu mezi technologickou inovací a ochranou investorů. Investiční profesionálové musí při využívání AI systémů dodržovat etický kodex a zajistit odpovídající monitoring a transparentnost. Klíčová je schopnost vysvětlit klientům rozhodovací procesy AI a zajistit ochranu jejich zájmů. Úspěšná implementace etických principů vyžaduje efektivní spolupráci mezi investičními profesionály a technologi. Pouze tento interdisciplinární přístup může zajistit vývoj systémů, které splňují technické i etické požadavky. Rostoucí význam etického přístupu k AI se stává konkurenční výhodou. Investiční společnosti, které dokáží skloubit inovace s etickými principy, budují dlouhodobou důvěru klientů a posilují svou tržní pozici (CFA Institute, 2022).

Evropská unie vytváří průkopnický regulatorní rámec prostřednictvím AI Act, který představuje první komplexní právní rámec pro regulaci umělé inteligence na světě, zavádí hierarchický systém klasifikace AI podle úrovně rizika (od nepřijatelného po minimální) a stanovuje odpovídající regulatorní požadavky. Pro finanční sektor jsou klíčové zejména požadavky na transparentnost algoritmů, vysvětlitelnost AI rozhodnutí, lidský dohled, dokumentaci a ochranu osobních údajů. Součástí AI Act je také povinné testování, monitoring systémů a posuzování dopadů na základní práva. Při porušení těchto pravidel hrozí významné sankce až do výše 6 % z celkového ročního obrátu společnosti. Účinnost této přelomové legislativy se očekává od roku 2025 (Berkow, 2024).

3 METODOLOGIE

Tato kapitola se zabývá metodami a postupy, které byly využity v rámci výzkumu zaměřeného na aplikaci umělé inteligence (AI) při investičním rozhodování. Hlavním cílem bylo otestovat vybrané nástroje umělé inteligence a jejich efektivitu v podpoře rozhodování profesionálních i neprofesionálních investorů na akciovém trhu. Konkrétně bylo zkoumáno, zda jsou tyto AI nástroje schopny spolehlivě predikovat pohyby cen akcií a zda mohou investorům nabídnout užitečná doporučení k nákupu, prodeji či držení akcií.

3.1 Výběr analyzovaných společností

V první fázi byly vybrány společnosti, jejichž akcie byly použity k testování AI nástrojů. Do analýzy byly zařazeny veřejně obchodované společnosti NVIDIA (NVDA), Tesla (TSLA), Apple (AAPL) a OKLO, a to na základě následujících kritérií:

- **Tržní význam společnosti** – byly vybírány firmy s významným postavením na americkém trhu, jejichž akcie jsou pravidelně obchodovány a často se objevují v médiích.
- **Dostupnost mediálních a tržních dat** – pro provedení sentimentální analýzy bylo nezbytné mít dostatek dostupných mediálních zpráv a cenových dat.
- **Diverzifikace segmentů** – cílem bylo zahrnout společnosti z různých segmentů trhu (technologie, automobilový průmysl, energetika), aby bylo možné testovat AI nástroje napříč odvětvími.

3.2 Stanovení investičního horizontu

Analýza a testování predikčních schopností AI byly provedeny ve třech časových horizontech – krátkodobém (1 měsíc), střednědobém (3 měsíce) a dlouhodobém (6 měsíců). Kratší horizonty byly zvoleny s cílem otestovat schopnosti AI nástrojů predikovat krátkodobé výkyvy cen akcií, zatímco delší horizont (6 měsíců) byl použit pro ověření dlouhodobější stability a spolehlivosti těchto predikcí.

Vedle těchto hlavních investičních horizontů byly provedeny také dva doplňkové příklady:

- **Sentimentální analýza mediálních zpráv** probíhala v rámci měsíčního horizontu, přičemž cílem bylo zjistit, zda a jak mediální sentiment ovlivňuje krátkodobý cenový vývoj akcií.
- **Testování automatizovaného obchodování pomocí platformy Zapier** bylo realizováno pouze v krátkodobém horizontu dvou týdnů. Délka experimentu byla limitována testovacím obdobím bezplatné verze platformy Zapier. Účelem tohoto krátkého horizontu bylo ověření

reálné funkčnosti a praktické použitelnosti obchodních signálů generovaných sentimentální analýzou.

3.3 Sběr a zpracování dat

Data pro analýzu byla získávána primárně z veřejně dostupných finančních databází, konkrétně z platformy TradingView (2025) a finančních portálů Yahoo Finance (2025) a Google Finance (2025). Mediální zprávy využitě pro sentimentální analýzu byly čerpány z veřejně dostupných zdrojů prostřednictvím Google Cloud Platform s pomocí API jazykových modelů Claude a OpenAI. Data zahrnovala:

- **Denní ceny akcií** – využíváné k testování obchodních strategií na základě technické analýzy a predikčních modelů.
- **Finanční zprávy a sentimentální data** – získaná automatizovaným sběrem přes Google Cloud Sheets a následně analyzovaná AI modely, přičemž sentimentální analýza byla provedena prostřednictvím API od OpenAI a jazykového modelu Claude.

3.4 Postup analýzy

Analýza byl realizována v následujících krocích:

1. **Automatizovaná sentimentální analýza** – sentiment zpráv byl analyzován pomocí jazykových modelů, výstupy byly následně srovnávány s tržními pohyby cen akcií, aby se ověřilo, zda existuje korelace mezi sentimentem a vývojem cen akcií.
2. **Vývoj a testování obchodních strategií** – strategie založené na technické analýze byly vytvořeny za pomoci AI modelů (ChatGPT, Deep Seek). Strategie byly testovány a vyhodnocovány na platformě TradingView v definovaných časových horizontech.
3. **Implementace automatizovaného obchodního bota** – proběhlo testování možností automatizace pomocí platformy Google Cloud Platform s využitím Pub/Sub infrastruktury, neuronových sítí (LSTM) a platformy Alpaca. Projekt zahrnoval analýzu technické proveditelnosti plně autonomního obchodního systému.
4. **Praktické obchodování s využitím AI a Zapier** – realizováno bylo 40 obchodů, na jejichž základě byla ověřena reálná efektivita sentimentální analýzy při investičním rozhodování. Obchody byly realizovány manuálně kvůli omezením platformy Alpaca.

3.5 Omezení výzkumu

Při interpretaci výsledků výzkumu je nezbytné vzít v úvahu následující omezení:

- **Absence transakčních nákladů a dividend** – výpočty výnosů nezahrnovaly transakční poplatky a dividendy, což mohlo ovlivnit přesnost výsledků.
- **Krátkodobost některých příkladů:** Délka testování automatizované obchodní strategie s platformou Zapier byla pouze dvoutýdenní z důvodu využití zkušební bezplatné verze, což představovalo omezený prostor pro detailnější zhodnocení dlouhodobé stability a výkonnosti této strategie.
- **Limitovaná výpočetní kapacita platformy Google Cloud Platform:** Příklad zaměřený na automatizaci obchodování prostřednictvím neuronových sítí (LSTM) na platformě Google Cloud Platform narazil na technická omezení. Zejména nedostatečná dostupná kapacita operační paměti (RAM) výrazně limitovala možnosti testována složitějších predikčních modelů, což ovlivnilo výslednou spolehlivost a použitelnost této části výzkumu.
- **Integrace a technická omezení platform:** Během výzkumu se objevila technická omezení v oblasti integrace obchodních API (např. platforma Alpaca), což znemožnilo plnou automatizaci obchodních procesů. V důsledku těchto omezení musely být kupní operace provedeny manuálně, což snižovalo úroveň automatizace a zvyšovalo riziko lidské chyby.
- **Historická data** – výsledky vycházejí z historických cenových a mediálních dat, což nemusí plně reflektovat budoucí tržní realitu.

Uvedená metodologie představuje jasný rámec, podle kterého byla práce provedena, a umožňuje pochopení, jak byla data získána, zpracována a jak byly formulovány závěry pro investiční doporučení.

4 Analýza a komparace vybraných nástrojů umělé inteligence a jejich vliv na investory

Celosvětová pozornost se v současnosti soustředí na vývoj a aplikace umělé inteligence, přičemž technologické společnosti i výzkumné instituce soupeří o to, kdo dosáhne největšího pokroku a inovací v této oblasti. Tento intenzivní rozvoj se výrazně promítá i do finančního sektoru, kde se AI stále více stává klíčovým prvkem investičních strategií a automatizovaných obchodních systémů. Právě tento fakt je hlavním důvodem, proč se tato část práce zaměřuje na analýzu a porovnání dostupných AI nástrojů využitelných v investování a na zhodnocení jejich efektivity při tvorbě strategií na finančních trzích.

Cílem této části je nejen identifikovat přístupy, které jsou široce dostupné a využitelné pro investory, ale také poskytnout komplexní přehled o jejich přínosech a omezeních v kontextu dynamicky se vyvíjejícího trhu.

V rámci výzkumu bylo testováno několik AI nástrojů s důrazem na širokou dostupnost a minimální nákladovost, aby byly využitelné nejen profesionálními investory, ale i širší veřejností. Pro komplexní analýzu bylo nezbytné nejprve rozlišit jednotlivé platformy a jejich funkčnost. Praktická část se proto zaměřuje na srovnání různých přístupů a strategií využívajících AI k podpoře investičních rozhodnutí s cílem poskytnout podložené závěry jejich účinnosti.

Prvním krokem této analýzy je představení klíčových technických nástrojů umělé inteligence, které umožňují implementaci investičních strategií. Jelikož se tato práce zaměřuje na specifické investiční postupy a strategie s důrazem na minimalizaci nákladů, je nezbytné využívat prvky programování a automatizace, které umožňují efektivní implementaci obchodních strategií bez nutnosti drahých profesionálních řešení. V této souvislosti hrají klíčovou roli moderní jazykové modely, které mohou usnadnit nejen tvorbu kódu, ale i analýzu tržních dat a sentimentu. Mezi zvolené nástroje, které byly v této práci využity pro účel tvorby kódů a analýzy dat, patří modely vyvinuté společnostmi OpenAI (ChatGPT), Google (Gemini), DeepSeek a Anthropic (Claude). Tyto nástroje hrají klíčovou roli v automatizaci obchodních strategií, analýze sentimentu a programování algoritmických automatizovaných modelů.

Dále jsou popsány konkrétní investiční projekty realizované napříč různými platformami, přičemž bude vysvětlen jejich princip, komponenty a způsob využití AI v rámci dané strategie. Tyto přístupy budou následně zhodnoceny podle stanovených kritérií, která reflektují

efektivitu, přesnost predikcí, uživatelskou přívětivost a možnosti implementace do reálného obchodování.

Závěrečná část praktické analýzy poskytne doporučení, jakým způsobem mohou jednotlivé AI nástroje efektivně podpořit investiční rozhodování, jaké jsou jejich limity a jak je lze kombinovat pro dosažení optimálních výsledků. Výstupy této práce mohou sloužit nejen akademické sféře, ale také investorům hledajícím inovativní přístupy k využití umělé inteligence v obchodování na finančních trzích.

4.1 Představení jazykových modelů určených k podpoře programování

ChatGPT (OpenAI)

ChatGPT je pokročilý jazykový model od OpenAI, který umí generovat text, analyzovat data a pomáhat s programováním, je univerzální a snadno se přizpůsobí různým úkolům, což z něj dělá skvělého pomocníka jak pro jednotlivce, tak pro firmy. Často se využívá k automatizaci úloh, jako je tvorba obsahu, analýza sentimentu nebo generování obchodních strategií. Díky své schopnosti porozumět kontextu dokáže poskytovat relevantní odpovědi, které pomáhají uživatelům efektivně pracovat (Open AI, 2025).

ChatGPT byl v rámci výzkumu využit jako podpora pro automatizaci obchodních signálů a optimalizaci obchodních strategií. Využití zahrnovalo práci s API (rozhraní, které umožňuje komunikaci mezi různými systémy, aplikacemi nebo službami) a integraci do pracovních postupů na platformách jako Zapier a TradingView. Tento model pomáhal s úpravou kódů a zefektivňováním obchodních algoritmů na základě tržních dat.

Gemini (Google)

Gemini jazykový model od společnosti Google se odlišuje tím, že zvládá nejen práci s textem, ale i s obrázky a kódem. To ho předurčuje k úlohám, kde je potřeba kombinovat různé typy dat. Skvěle se hodí pro analýzu tržních trendů, automatizaci procesů nebo vizuální zpracování informací (Google Gemini, 2025). Je ideální pro uživatele, kteří pracují s komplexními datovými soubory a hledají nástroj, který jim pomůže lépe porozumět souvislostem a efektivně je využít. Gemini byl využit jako podpora při programování a řešení technických problémů spojených s vývojem algoritmického obchodního systému. Pomocí API poskytoval asistenci při tvorbě a optimalizaci kódu a pomáhal s implementací automatizovaných obchodních strategií.

DeepSeek

Deep Seek je nově vzniklý open-source jazykový model, který se rychle stal konkurencí zavedeným AI modelům díky své efektivitě, nižším nákladům a otevřenému přístupu k vývoji. Otevřený kód umožňuje vývojářům i firmám přizpůsobit Deep Seek jejich potřebám, což z něj činí flexibilní a dostupné řešení. Jeho využití sahá od webového vyhledávání přes analýzu dat, kybernetickou bezpečnost až po vědecký výzkum, kde pomáhá s tříděním velkých objemů informací a identifikací klíčových vzorců. Díky nižším provozním nákladům, otevřenému přístupu a rychlé adaptaci na tržní podmínky si Deep Seek získává stále větší popularitu mezi firmami a jednotlivci hledajícími inteligentní a přizpůsobitelná řešení pro efektivní zpracování dat (Deepseek.com, 2025).

DeepSeek byl využit k úpravě a optimalizaci kódu při vytváření obchodních strategií na platformě TradingView.

Claude (Anthropic)

Claude od Anthropicu je výkonný a spolehlivý jazykový model, který se zaměřuje na generování textu, analýzu dat a automatizaci složitějších procesů. Oproti jiným AI systémům vyniká přesností, odolností vůči chybám a vysokou úrovní bezpečnosti, což z něj dělá vhodnou volbu pro firmy pracující s citlivými informacemi. Najde využití například ve finanční analýze, právních službách nebo kybernetické bezpečnosti, kde pomáhá s automatizací zpracování dokumentů, tvorbou predikčních modelů nebo kategorizací dat. Díky podpoře NLP, schopnosti generovat kód a multimodálnímu přístupu k datům dokáže pracovat s širokou škálou vstupů, včetně textových a vizuálních dat, jako jsou grafy nebo tabulky. Nabízí různé verze (Opus, Sonnet, Haiku), které se liší výkonem a rychlostí zpracování, a lze je snadno integrovat do podnikových systémů prostřednictvím API. Podporuje cloudová řešení jako AWS a Google Cloud, což umožňuje jeho efektivní nasazení ve firmách s vysokými nároky na škálovatelnost a bezpečnost (Claude.ai, 2025).

Claude byl využit ke zpracování dat z RSS feedů a provedení analýzy sentimentu v prostředí Google Script. Pomáhal s interpretací tržních zpráv a klasifikací sentimentu na základě zpracovaných informací.

Uvedené jazykové modely umělé inteligence byly hodnoceny v kontextu jejich aplikace v jednotlivých investičních strategiích. Testování bude probíhat na základě jejich schopnosti analyzovat sentiment, generovat obchodní signály, asistovat při programování algoritmických

strategií a optimalizovat obchodní rozhodnutí. Výsledky byly porovnávány s cílem určit efektivitu jednotlivých přístupů.

4.2 Analýza sentimentu pomocí AI

Jedním z přístupů, který si již nyní získává rostoucí popularitu, je analýza sentimentu finančních zpráv s cílem zjistit, jak mediální pokrytí ovlivňuje vývoj cen akcií. Z tohoto důvodu byl v rámci výzkumu sestaven projekt zaměřený na návrh a implementaci systému umožňujícího automatizovanou analýzu sentimentu akcií vybraných společností, konkrétně NVIDIA (NVDA), TESLA (TSLA) a OKLO. Pro zpracování sentimentální analýzy byl využit jazykový model Claude. Systém běží v prostředí Google Apps Script, je integrován s Google Sheets a využívá API od OpenAI pro další zpracování dat, což umožňuje plně automatizovanou analýzu a ukládání výsledků.

Hlavním cílem této implementace bylo analyzovat vztah mezi mediálním sentimentem a cenovým vývojem vybraných akcií a zjistit, zda existuje statisticky významná korelace, která by mohla sloužit jako podklad pro investiční rozhodování. Celý systém je navržen tak, aby umožňoval pravidelný sběr, analýzu a vyhodnocování sentimentu bez nutnosti manuálního zásahu za pomoci umělé inteligence.

Popis implementace

Systém je navržen jako plně automatizovaný nástroj pro analýzu sentimentu finančních zpráv a jeho vztahu k cenovému vývoji vybraných akcií a tržních indexů. Celý proces probíhá prostřednictvím kombinace několika klíčových technologií, konkrétně Google Sheets, Google Apps Script, OpenAI API a Google News RSS feed, což umožňuje efektivní a systematické zpracování tržních informací. Hlavním cílem systému je identifikovat vztah mezi mediálním sentimentem a cenou akcií, což může investorům pomoci lépe pochopit, zda pozitivní či negativní zprávy skutečně ovlivňují tržní pohyby.

Každý den ve 14:45 středoevropského času, což odpovídá době těsně před otevřením amerických burz, systém automaticky stahuje nejnovější zprávy o vybraných společnostech, konkrétně Nvidia, Tesla a Oklo. K tomuto účelu je využíván Google News RSS feed, který umožňuje automatické získávání aktuálních zpravodajských titulků a popisů. Získané zprávy jsou následně očištěny od nežádoucích znaků a nadbytečných informací, aby byly ve správném formátu pro další zpracování.

Jakmile jsou data připravena, systém provádí analýzu sentimentu prostřednictvím jazykového modelu Claude. Každý titulek je odeslán k vyhodnocení, přičemž model přiřazuje číselné skóre

sentimentu v rozsahu od 1 do 100, kde nižší hodnoty signalizují negativní sentiment a vyšší hodnoty odpovídají pozitivní náladě na trhu. Výstup sentimentální analýzy je poté automaticky zaznamenán do Google Sheets, jak lze vidět na obrázku 3, kde je každému dni přiřazeno odpovídající sentimentální skóre a zároveň je v tabulce načtena denní uzavírací cena akcie,

| | A | B | C | D | E | F |
|----|------------|-------------------------|---------------|------------------|--------------|---------------------------------|
| 1 | NVDA | Morning Sentiment Score | Closing Price | Sentiment Change | Price Change | Sentiment Correlations to Price |
| 2 | 12/30/2024 | 65 | 137.49 | | 0.35% | |
| 3 | 12/31/2024 | 85 | 134.29 | 20 | -2.33% | -0.7532324479 |
| 4 | 1/2/2025 | 75 | 138.31 | -10 | 2.99% | 0.2151386285 |
| 5 | 1/3/2025 | 85 | 144.47 | 10 | 4.45% | 0.5525262212 |
| 6 | 1/6/2025 | 90 | 149.43 | 5 | 3.43% | 0.4815165279 |
| 7 | 1/7/2025 | 90 | 140.14 | 0 | -6.22% | 0.4511550012 |
| 8 | 1/8/2025 | 70 | 140.11 | -20 | -0.02% | 0.5175467323 |
| 9 | 1/10/2025 | 70 | 135.91 | 0 | -3.00% | 0.6175670889 |
| 10 | 1/13/2025 | 64 | 133.23 | -6 | -1.97% | 0.6817865762 |
| 11 | 1/14/2025 | 64 | 131.76 | 0 | -1.10% | 0.6842257957 |
| 12 | 1/15/2025 | 65 | 136.24 | 1 | 3.40% | 0.7069906246 |
| 13 | 1/16/2025 | 65 | 133.57 | 0 | -1.96% | 0.705513139 |
| 14 | 1/17/2025 | 71 | 137.71 | 6 | 3.10% | 0.6751600749 |
| 15 | 1/21/2025 | 70 | 140.83 | 1 | 2.27% | 0.2628915514 |
| 16 | 1/22/2025 | 50 | 147.07 | -20 | 4.43% | -0.03962585947 |
| 17 | 1/23/2025 | 40 | 147.22 | -10 | 0.10% | -0.06672930177 |
| 18 | 1/24/2025 | 60 | 142.62 | 20 | -3.12% | 0.2393260799 |
| 19 | 1/27/2025 | 45 | 118.42 | -15 | -16.97% | 0.3423460891 |
| 20 | 1/28/2025 | 35 | 128.99 | -35 | 8.93% | 0.348620428 |
| 21 | 1/29/2025 | 60 | 123.70 | 25 | -4.10% | 0.4129391297 |
| 22 | 1/30/2025 | 45 | 124.65 | -15 | 0.77% | 0.490684313 |
| 23 | 1/31/2025 | 40 | 120.07 | -5 | -3.67% | 0.5338108501 |
| 24 | 2/3/2025 | 45 | 116.66 | 5 | -2.84% | 0.1422502464 |
| 25 | 2/4/2025 | 65 | 118.65 | 20 | 1.71% | 0.5060744762 |

Cenové nabídky nejsou získávány ze všech trhů a mohou být až o 20 minut zpožděny. Informace jsou poskytovány „tak, jak jsou“ a jsou určeny pouze pro informativní účely.

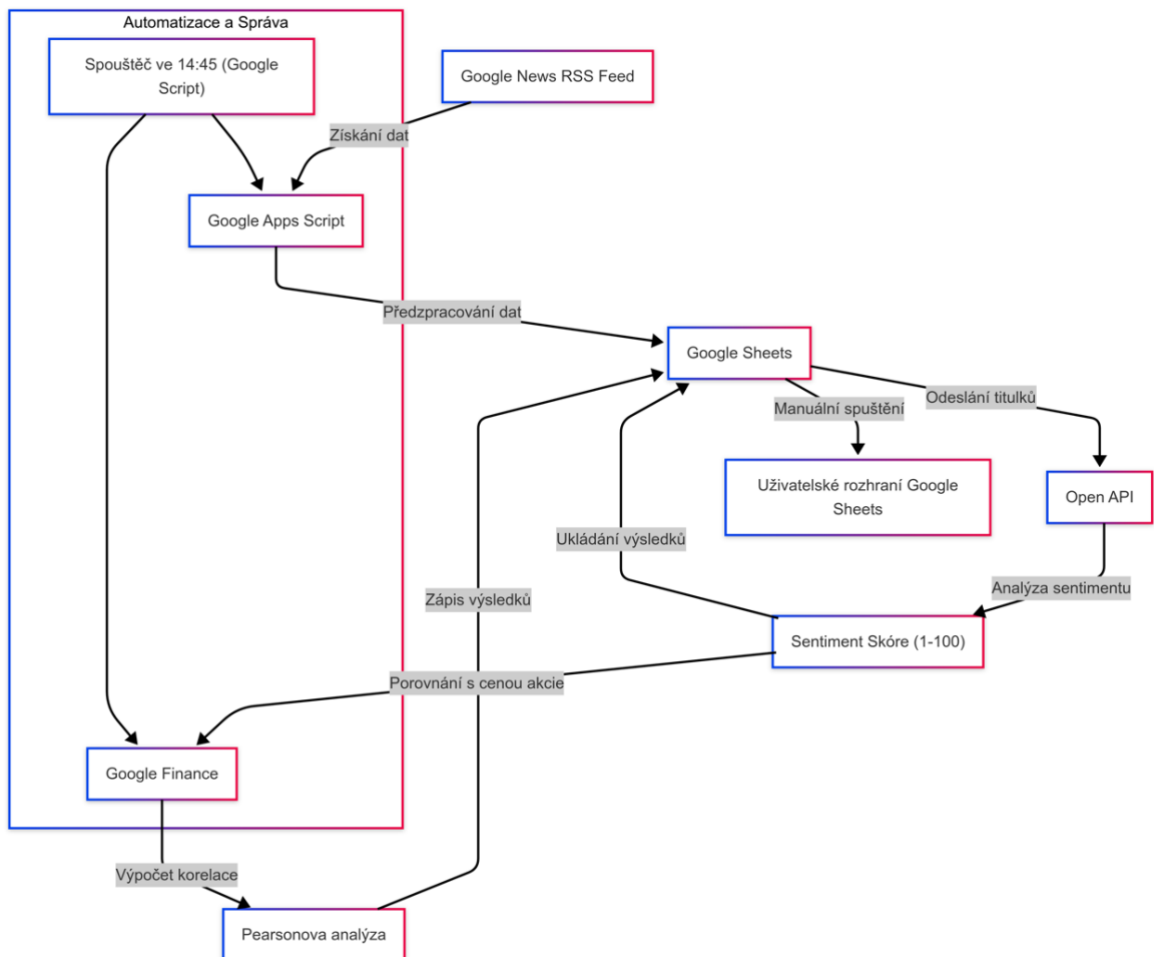
+ NVDA Sentiment TSLA Sentiment OKLO Sentiment Nasdaq Sentiment S&P 500

Obrázek 3: Ukázka z prostředí Google Sheets

Zdroj: Vlastní zpracování

kteřá je získána pomocí funkce Google Finance. Celkový sběr dat z hlediska náročnosti trval měsíc. Pro zhodnocení, zda existuje vztah mezi sentimentem zpráv a cenovým vývojem akcií, je následně prováděna statistická analýza, konkrétně výpočet Pearsonova korelačního koeficientu. Tento koeficient umožňuje kvantifikovat vztah mezi sentimentálním skóre a cenou akcie, přičemž pokud se hodnota korelace blíží +1, znamená to silnou pozitivní souvislost mezi růstem sentimentu a cenou akcií, zatímco hodnota blížící se -1 by indikovala opačnou závislost, tedy že negativní sentiment je spojen s poklesem ceny. Korelace blížící 0 naopak naznačuje, že mezi sentimentem a cenou akcií není žádný významný vztah. Výpočet korelace je automaticky prováděn pro každou sledovanou společnost i tržní index a výsledky jsou zanášeny do tabulky, což umožňuje sledování vývoje sentimentální korelace.

Uživatel má možnost manuálně spustit analýzu pro konkrétní společnost nebo všechny sledované tituly najednou, což je umožněno prostřednictvím uživatelského menu v rozhraní Google Sheets. Skript dále obsahuje chytrou správu času spuštění, což znamená, že analýza probíhá pouze v pracovní dny a přesně v 14:45, což lze vidět na obrázku 4, přičemž systém automaticky zajišťuje, aby se nespouštěl o víkendech nebo během dnů, kdy jsou trhy zavřené. Tento mechanismus minimalizuje zbytečné dotazy na API a snižuje náklady na provoz.



Obrázek 4: Schéma systému analýzy sentimentu

Zdroj: Vlastní zpracování

Celý systém je optimalizován tak, aby byl co nejefektivnější a měl co nejnižší provozní náklady, což je dosaženo využitím Google Apps Script namísto externích serverů či cloudových služeb, jako je AWS, a proto umožňuje snadnou integraci do existujících pracovních postupů a eliminuje nutnost vlastního serverového řešení. Využití Google Sheets zároveň usnadňuje vizualizaci výsledků a jejich sdílení, což činí systém atraktivním i pro uživatele bez hlubších technických znalostí.

Tabulka 1: NVDA sentimentální analýza

| NVDA | Sentiment skóre | Uzavírací cena | Změna sentimentu | Změna ceny | Korelace mezi sentimentem a cenou akcií |
|------------|-----------------|----------------|------------------|------------|---|
| 02.01.2025 | 75 | 138,31 | -10 | 2,99 % | 0,215138629 |
| 03.01.2025 | 85 | 144,47 | 10 | 4,45 % | 0,552526221 |
| 06.01.2025 | 90 | 149,43 | 5 | 3,43 % | 0,481516528 |
| 07.01.2025 | 90 | 140,14 | 0 | -6,22 % | 0,451155001 |
| 08.01.2025 | 70 | 140,11 | -20 | -0,02 % | 0,517546732 |
| 10.01.2025 | 70 | 135,91 | 0 | -3,00 % | 0,617567089 |
| 13.01.2025 | 64 | 133,23 | -6 | -1,97 % | 0,681786576 |
| 14.01.2025 | 64 | 131,76 | 0 | -1,10 % | 0,684225796 |
| 15.01.2025 | 65 | 136,24 | 1 | 3,40 % | 0,706990625 |
| 16.01.2025 | 65 | 133,57 | 0 | -1,96 % | 0,705513139 |
| 17.01.2025 | 71 | 137,71 | 6 | 3,10 % | 0,675160075 |
| 21.01.2025 | 70 | 140,83 | 1 | 2,27 % | 0,262891551 |
| 22.01.2025 | 50 | 147,07 | -20 | 4,43 % | -0,039625859 |
| 23.01.2025 | 40 | 147,22 | -10 | 0,10 % | -0,066729302 |
| 24.01.2025 | 60 | 142,62 | 20 | -3,12 % | 0,23932608 |
| 27.01.2025 | 45 | 118,42 | -15 | -16,97 % | 0,342346089 |
| 28.01.2025 | 35 | 128,99 | -35 | 8,93 % | 0,348620428 |
| 29.01.2025 | 60 | 123,70 | 25 | -4,10 % | 0,41293913 |
| 30.01.2025 | 45 | 124,65 | -15 | 0,77 % | 0,490684313 |
| 31.01.2025 | 40 | 120,07 | -5 | -3,67 % | 0,53381085 |
| 03.02.2025 | 45 | 116,66 | 5 | -2,84 % | 0,142250246 |
| 04.02.2025 | 65 | 118,65 | 20 | 1,71 % | 0,139966203 |

Zdroj: Vlastní zpracování

Analýza ukazuje, že propojení mezi sentimentem a vývojem ceny akcií NVDA není konzistentní a podléhá výrazným změnám, jak dokládají výsledky uvedené v tabulce 1.

V některých obdobích je korelace mezi sentimentem a cenou výraznější. Například mezi 10. a 17. lednem rostly oba ukazatele souběžně, přičemž korelace dosáhla 0,70. Naopak 22. ledna sentiment prudce oslabil o 20 bodů, ale akcie paradoxně posílily o 4,43 %, což vedlo k téměř nulové korelaci (-0,03) stejný případ se opakoval následující den.

Podobně jako v případě NVDA i zde v případě OKLO platí, že sentiment sám o sobě není dostatečně silným faktorem pro předvídání pohybu cen, což vyplývá z výsledků tabulky 2. Přestože se hodnota sentimentu akcií OKLO pohybovala v rozmezí 65–95 bodů, změny nebyly vždy v souladu s cenovým vývojem. Například 3. ledna 2025 se sentiment mírně snížil o 3 body, ale akcie přesto vzrostly o 24,71 %. Naopak 27. ledna došlo k poklesu sentimentu o 5 bodů, avšak cena se propadla o -25,61 %. To naznačuje, že na tržní vývoj působí i další faktory, které mohou mít větší váhu než samotný sentiment.

Tabulka 2: OKLO sentimentální analýza

| OKLO | Sentiment skóre | Uzavírací cena | Změna sentimentu | Změna ceny | Korelace mezi sentimentem a cenou akcií |
|------------|-----------------|----------------|------------------|------------|---|
| 02.01.2025 | 85 | 21,85 | 0 | 2,92 % | -0,925252304 |
| 03.01.2025 | 82 | 27,25 | -3 | 24,71 % | -0,367252302 |
| 06.01.2025 | 85 | 30 | 0 | 10,09 % | 0,39513269 |
| 07.01.2025 | 95 | 29,5 | 10 | -1,67 % | 0,391224829 |
| 08.01.2025 | 90 | 26,12 | -5 | -11,46 % | 0,393193466 |
| 10.01.2025 | 85 | 25,24 | -5 | -3,37 % | 0,467814282 |
| 13.01.2025 | 75 | 22,88 | -10 | -9,35 % | 0,361688325 |
| 14.01.2025 | 90 | 22,81 | 15 | -0,31 % | 0,296332104 |
| 15.01.2025 | 65 | 24,17 | -25 | 5,96 % | 0,304846338 |
| 16.01.2025 | 76 | 24,23 | 11 | 0,25 % | 0,263845009 |
| 17.01.2025 | 76 | 26,05 | 0 | 7,51 % | 0,350748255 |
| 21.01.2025 | 90 | 31,25 | 14 | 19,96 % | 0,337435597 |
| 22.01.2025 | 86 | 34,17 | -4 | 9,34 % | 0,062825637 |
| 23.01.2025 | 75 | 38,78 | -11 | 13,49 % | -0,192856849 |
| 24.01.2025 | 70 | 41,82 | -5 | 7,84 % | -0,233234003 |
| 27.01.2025 | 65 | 31,11 | -5 | -25,61 % | -0,199202517 |
| 28.01.2025 | 85 | 34,12 | 20 | 9,68 % | -0,164357391 |
| 29.01.2025 | 85 | 35,3 | 0 | 3,46 % | -0,188175653 |
| 30.01.2025 | 78 | 41,91 | -7 | 18,73 % | -0,20715608 |
| 31.01.2025 | 78 | 41,61 | 0 | -0,72 % | -0,255744757 |
| 03.02.2025 | 75 | 45,93 | -3 | 10,38 % | -0,144357769 |
| 04.02.2025 | 78 | 46,89 | 3 | 2,09 % | 0,425828405 |

Zdroj: Vlastní zpracování

Cenové pohyby jsou často výraznější než samotné změny sentimentu. Například 21. ledna sentiment vzrostl o 14 bodů a cena akcií posílila o 19,96 %, což ukazuje na určitou souvislost. Oproti tomu 30. ledna sentiment poklesl o 7 bodů, ale akcie přesto vzrostly o 18,73 %, což naznačuje, že v některých případech nemusí být sentiment klíčovým hybatelem cenového vývoje.

Stejně jako v předchozích případech i data v tabulce 3 ukazují, že vazba mezi sentimentem a cenou akcií TSLA není stabilní a v čase se mění. Na začátku sledovaného období byla korelace spíše negativní – například 3. ledna 2025 sentiment oslabil o 3 body, zatímco cena vzrostla o 8,22 %. Podobná situace nastala 15. ledna, kdy sentiment poklesl o 5 bodů, ale akcie posílily o 8,04 %. Tato data naznačují, že sentiment nemusí být vždy klíčovým faktorem ovlivňujícím cenový pohyb.

Tabulka 3: TSLA sentimentální analýza

| TLSA | Sentiment skóre | Uzavírací cena | Změna sentimentu | Změna ceny | Korelace mezi sentimentem a cenou akcií |
|------------|-----------------|----------------|------------------|------------|---|
| 02.01.2025 | 48 | 379,28 | 0 | -6,08 % | -0,309248703 |
| 03.01.2025 | 45 | 410,44 | -3 | 8,22 % | -0,373959621 |
| 06.01.2025 | 46 | 411,05 | 1 | 0,15 % | -0,24939451 |
| 07.01.2025 | 46 | 394,36 | 0 | -4,06 % | -0,31273976 |
| 08.01.2025 | 53 | 394,94 | 7 | 0,15 % | -0,354228572 |
| 10.01.2025 | 55 | 394,74 | 2 | -0,05 % | -0,176955919 |
| 13.01.2025 | 60 | 403,31 | 5 | 2,17 % | -0,220768412 |
| 14.01.2025 | 60 | 396,36 | 0 | -1,72 % | -0,029330924 |
| 15.01.2025 | 55 | 428,22 | -5 | 8,04 % | 0,019078854 |
| 16.01.2025 | 55 | 413,82 | 0 | -3,36 % | 0,096951285 |
| 17.01.2025 | 55 | 426,5 | 0 | 3,06 % | 0,146075464 |
| 21.01.2025 | 55 | 424,07 | 0 | -0,57 % | 0,190642977 |
| 22.01.2025 | 60 | 415,11 | 5 | -2,11 % | 0,191570605 |
| 23.01.2025 | 53 | 412,38 | -7 | -0,66 % | 0,191053789 |
| 24.01.2025 | 53 | 406,58 | 0 | -1,41 % | 0,184108993 |
| 27.01.2025 | 53 | 397,15 | 0 | -2,32 % | 0,162058477 |
| 28.01.2025 | 55 | 398,09 | 2 | 0,24 % | 0,121533357 |
| 29.01.2025 | 55 | 389,1 | 0 | -2,26 % | 0,146833018 |
| 30.01.2025 | 45 | 400,28 | -10 | 2,87 % | 0,133838549 |
| 31.01.2025 | 60 | 404,6 | 15 | 1,08 % | -0,049965718 |
| 03.02.2025 | 65 | 383,68 | 5 | -5,17 % | 0,440983385 |
| 04.02.2025 | 40 | 392,2 | -25 | 2,22 % | 0,259948885 |


Zdroj: Vlastní zpracování

Postupem času se korelace začala měnit a ve druhé polovině ledna bylo možné pozorovat její postupný nárůst. Například 31. ledna sentiment vzrostl o 15 bodů a cena akcií se zvýšila o 1,08 %, což naznačuje slabou, ale pozitivní vazbu. Nejvýraznější korelace byla zaznamenána 4. února 2025 (0,7567), kdy sentiment prudce klesl o 25 bodů. Tento jev může ukazovat na

situaci, kdy se trh silně řídí investorskou náladou, což se však nevyskytuje konzistentně po celé sledované období.

Celkové zhodnocení prvního příkladu

K celkovému zhodnocení prvního projektu byl přidán graf na obrázku 5 ilustrující vztah mezi sentimentem a cenovým vývojem akcií vybraných společností. Analýza ukázala, že společnost NVIDIA (NVDA) vykazovala nejvyšší míru korelace, přičemž v první polovině sledovaného období dosahovala hodnot blízkých se 0,8 až 1, z čehož vyplývá výrazná souvislost mezi mediálním sentimentem a cenovými pohyby této akcie.



Obrázek 5: Graf korelace mezi skórem sentimentu a cenou akcií

Zdroj: Vlastní zpracování

Strategie využívající umělou inteligenci (Claude, OpenAI API), Google Sheets a Google Script pro analýzu sentimentu a cen akcií je technologicky dobře koncipovaná, avšak má určitá omezení. Google Sheets sice umožňuje snadnou manipulaci s daty a jejich automatizaci prostřednictvím Google Scriptu, nicméně pro komplexnější analýzy postrádá dostatečný výpočetní výkon. AI modely efektivně extrahují sentiment z textových dat, avšak jejich přesnost závisí na kvalitě trénovacích dat a kontextu jednotlivých zpráv. Otevřená API pro získávání tržních dat poskytují aktuální informace o cenách, avšak jejich využití je omezeno

počtem povolených volání, což může vést k vyšším nákladům a zkreslení výsledků při vyšší frekvenci dotazů. Náklady na provoz této strategie byly minimalizovány na 0,88 USD za měsíc, avšak rozšíření o další zdroje by vedlo k nárůstu finanční náročnosti.

Z provedené analýzy vztahu mezi sentimentem a cenami akcií (NVDA, OKLO, TLSA) vyplývá, že korelace mezi těmito faktory není konzistentní. Zatímco v některých obdobích lze pozorovat pozitivní vztah mezi sentimentem a cenovým vývojem, v jiných případech dochází k opačnému pohybu, nebo se žádná významná souvislost neprojevuje. To naznačuje, že samotný sentiment nemusí být dostatečně spolehlivým prediktorem cenových pohybů, a jeho využití pro investiční rozhodování má svá omezení. Zároveň je třeba vzít v úvahu, že časový rámec testování byl omezen na jeden měsíc z důvodu náročnosti implementace celého systému, což mohlo ovlivnit výsledky analýzy. Přesto může sentiment sloužit jako užitečný doplňkový indikátor, zejména při identifikaci extrémních tržních nálad, které mohou signalizovat zvýšenou pravděpodobnost výraznějších cenových pohybů.

Aby strategie byla efektivnější, je nutné sentiment doplnit o další analytické nástroje, jako jsou objemy obchodů, technické indikátory (RSI, MACD, Supertrend) nebo fundamentální ukazatele. Pro praktické využití v tradingu je potřeba jej rozšířit a zpřesnit.

Komparace s aplikací AltIndex

V rámci komparace byl tento přístup rovněž porovnán s analýzou sentimentu pomocí platformy AltIndex, která poskytuje prediktivní analýzu akciových trhů na základě alternativních dat a strojového učení. AltIndex je velmi atraktivní, jelikož shromažďuje a analyzuje netradiční datové zdroje, jako jsou pracovní inzeráty, návštěvnost webových stránek, hodnocení na sociálních platformách a trendy v oblasti mobilních aplikací.

V porovnání s manuálně sestavenou analýzou sentimentu, která byla založena pouze na zprávách z Google Finance Feedu, lze předpokládat, že AltIndex poskytuje komplexnější a přesnější predikce. Důvodem je větší objem zpracovávaných dat a pokročilé algoritmy umělé inteligence, které byly optimalizovány odborníky na finanční trhy a datovou analytiku.

Použití AltIndex přináší několik klíčových výhod pro uživatele. Kromě analýzy sentimentu nabízí také možnost generování obchodních signálů na základě AI a upozorňuje investory na důležité tržní trendy. Platforma disponuje širokou škálou funkcí, mezi které patří například AI – generované výběry akcií, predikce cenových pohybů, analýza insider tradingu a pokročilá technická analýza.

V této části bylo provedeno hodnocení sentimentální analýzy poskytnuté AltIndexem a následná komparace s předchozím přístupem realizovaným v prostředí Google Scripts. Důvodem této komparace je zjistit, zda je efektivnější si manuálně sestavit systém s využitím AI modelů, což sice vyžaduje více času, práce a technických znalostí, avšak přináší nižší náklady a hlubší pochopení souvislostí, nebo zda je výhodnější využít hotové řešení v podobě placené aplikace, která je okamžitě dostupná a nabízí historická data, ale za cenu vyšších provozních nákladů. Pro objektivní zhodnocení byla testována prémiová verze aplikace v rámci sedmidenního zkušebního plánu, což umožnilo přímé srovnání funkcionality, přesnosti a efektivity obou přístupů. Klíčovou výhodou AltIndexu byla dostupnost historických dat sentimentu (viz. tabulka 4), která eliminovala nutnost manuálního sběru dat, jako tomu bylo v předchozím příkladu.

Tabulka 4: AltIndex analýza sentimentu NVDA

| NVDA | Sentiment skóre | Uzavírací cena | Změna sentimentu | Změna ceny | Korelace mezi sentimentem a cenou akcií |
|------------|-----------------|----------------|------------------|------------|---|
| 02.01.2025 | 89 | 138,31 | 18 | 2,99 % | 0,2151 |
| 03.01.2025 | 85 | 144,47 | -4 | 4,45 % | 0,5525 |
| 06.01.2025 | 83 | 149,43 | -2 | 3,43 % | 0,4815 |
| 07.01.2025 | 84 | 140,14 | 1 | -6,22 % | 0,4512 |
| 08.01.2025 | 83 | 140,11 | -1 | -0,02 % | 0,5175 |
| 10.01.2025 | 84 | 135,91 | 1 | -3,00 % | 0,6176 |
| 13.01.2025 | 80 | 133,23 | -6 | -1,97 % | 0,6818 |
| 14.01.2025 | 77 | 131,76 | 0 | -1,10 % | 0,6842 |
| 15.01.2025 | 69 | 136,24 | 1 | 3,40 % | 0,7070 |
| 16.01.2025 | 75 | 133,57 | 0 | -1,96 % | 0,7055 |
| 17.01.2025 | 73 | 137,71 | 6 | 3,10 % | 0,6752 |
| 21.01.2025 | 74 | 140,83 | 1 | 2,27 % | 0,2629 |
| 22.01.2025 | 74 | 147,07 | -20 | 4,43 % | -0,0396 |
| 23.01.2025 | 77 | 147,22 | -10 | 0,10 % | -0,0667 |
| 24.01.2025 | 78 | 142,62 | 20 | -3,12 % | 0,2393 |
| 27.01.2025 | 80 | 118,42 | -15 | -16,97 % | 0,3423 |
| 28.01.2025 | 72 | 128,99 | -12 | 8,93 % | 0,3486 |
| 29.01.2025 | 71 | 123,7 | 25 | -4,10 % | 0,4129 |
| 30.01.2025 | 73 | 124,65 | 2 | 0,77 % | 0,4907 |
| 31.01.2025 | 81 | 120,07 | 8 | -3,67 % | 0,5338 |
| 03.02.2025 | 76 | 116,66 | -5 | -2,84 % | 0,4922 |
| 04.02.2025 | 81 | 118,65 | 5 | 1,71 % | 0,1400 |

Zdroj: Vlastní zpracování

Analýza NVDA potvrzuje nestabilní korelaci mezi sentimentem a cenou akcií. Opět i zde lze pozorovat extrémní případy jako 22. ledna, kdy sentiment klesl o 20 bodů, ale akcie paradoxně vzrostly o 4,43 %, což vedlo k téměř nulové korelaci.

U OKLO je situace podobná – v některých dnech sentiment odpovídal pohybu cen, například 21. ledna, kdy sentiment vzrostl o 14 bodů a cena posílila o 19,96 %. Naopak 27. ledna sentiment oslabil jen o 5 bodů, ale akcie ztratila -25,61 %, což potvrzuje, že na cenu mají větší vliv jiné faktory, jak lze vidět v tabulce 5.

Tabulka 5: AltIndex analýza sentimentu OKLO

| OKLO | Sentiment skóre | Uzavírací cena | Změna sentimentu | Změna ceny | Korelace mezi sentimentem a cenou akcií |
|------------|-----------------|----------------|------------------|------------|---|
| 02.01.2025 | 76 | 21,85 | 0 | 2,92 % | -0,9252523 |
| 03.01.2025 | 72 | 27,25 | -3 | 24,71 % | -0,3672523 |
| 06.01.2025 | 77 | 30 | 0 | 10,09 % | 0,39513269 |
| 07.01.2025 | 76 | 29,5 | -1 | -1,67 % | 0,39122483 |
| 08.01.2025 | 69 | 26.led | -7 | -11,46 % | 0,39319347 |
| 10.01.2025 | 92 | 25,24 | 23 | -3,37 % | 0,46781428 |
| 13.01.2025 | 74 | 22,88 | -18 | -9,35 % | 0,36168833 |
| 14.01.2025 | 89 | 22,81 | 15 | -0,31 % | 0,2963321 |
| 15.01.2025 | 76 | 24,17 | -13 | 5,96 % | 0,30484634 |
| 16.01.2025 | 75 | 24,23 | -1 | 0,25 % | 0,26384501 |
| 17.01.2025 | 75 | 26,05 | 0 | 7,51 % | 0,35074825 |
| 21.01.2025 | 85 | 31,25 | 10 | 19,96 % | 0,3374356 |
| 22.01.2025 | 77 | 34,17 | -8 | 9,34 % | 0,06282564 |
| 23.01.2025 | 70 | 38,78 | -7 | 13,49 % | -0,1928568 |
| 24.01.2025 | 69 | 41,82 | -1 | 7,84 % | -0,233234 |
| 27.01.2025 | 70 | 31,11 | 1 | -25,61 % | -0,1992025 |
| 28.01.2025 | 77 | 34,12 | 7 | 9,68 % | -0,1643574 |
| 29.01.2025 | 82 | 35,3 | 5 | 3,46 % | -0,1881757 |
| 30.01.2025 | 74 | 41,91 | -8 | 18,73 % | -0,2071561 |
| 31.01.2025 | 85 | 41,61 | 11 | -0,72 % | -0,2557448 |
| 03.02.2025 | 75 | 45,93 | -10 | 10,38 % | -0,2635923 |
| 04.02.2025 | 71 | 46,89 | -4 | 2,09 % | -0,1107066 |

Zdroj: Vlastní zpracování

V případě ALTIndex TSLA dle tabulky 6 vykazuje nejméně stabilní vztah mezi změnou sentimentu a cenovou změnou, stejně jako v předchozí analýze přes Google Scripts.


Tabulka 6: AltIndex analýza sentimentu TSLA

| TSLA | Sentiment skóre | Uzavírací cena | Změna sentimentu | Změna ceny | Korelace mezi sentimentem a cenou akcií |
|-------------|-----------------|----------------|------------------|------------|---|
| 02.01.2025 | 70 | 379,28 | 6 | -6,08 % | -0,3092487 |
| 03.01.2025 | 71 | 410,44 | 1 | 8,22 % | -0,3739596 |
| 06.01.2025 | 75 | 411,05 | 4 | 0,15 % | -0,2493945 |
| 07.01.2025 | 58 | 394,36 | -17 | -4,06 % | -0,3127398 |
| 08.01.2025 | 53 | 394,94 | -5 | 0,15 % | -0,3542286 |
| 10.01.2025 | 53 | 394,74 | 0 | -0,05 % | -0,1769559 |
| 13.01.2025 | 74 | 403,31 | 21 | 2,17 % | -0,2207684 |
| 14.01.2025 | 56 | 396,36 | -18 | -1,72 % | -0,0293309 |
| 15.01.2025 | 78 | 428,22 | 22 | 8,04 % | 0,01907885 |
| 16.01.2025 | 67 | 413,82 | -11 | -3,36 % | 0,09695129 |
| 17.01.2025 | 52 | 426,5 | -15 | 3,06 % | 0,14607546 |
| 21.01.2025 | 64 | 424,07 | 12 | -0,57 % | 0,19064298 |
| 22.01.2025 | 57 | 415,11 | -7 | -2,11 % | 0,1915706 |
| 23.01.2025 | 61 | 412,38 | 4 | -0,66 % | 0,19105379 |
| 24.01.2025 | 60 | 406,58 | -1 | -1,41 % | 0,18410899 |
| 27.01.2025 | 55 | 397,15 | -5 | -2,32 % | 0,16205848 |
| 28.01.2025 | 59 | 398,09 | 4 | 0,24 % | 0,12153336 |
| 29.01.2025 | 51 | 389,1 | -8 | -2,26 % | 0,14683302 |
| 30.01.2025 | 62 | 400,28 | 11 | 2,87 % | 0,13383855 |
| 31.01.2025 | 31 | 404,6 | -31 | 1,08 % | -0,0499657 |
| 03.02.2025 | 40 | 383,68 | 9 | -5,17 % | 0,04455537 |
| 04.02.2025 | 58 | 392,21 | 18 | 2,22 % | 0,25994889 |

Zdroj: Vlastní zpracování

Z grafu sentimentální analýzy (obrázek 6) s pomocí AltIndex lze pozorovat, že NVDA měla opět nejsilnější korelaci mezi pohybem cen a změnou sentimentu.

Obrázek 6: Graf korelací mezi sentimentem a cenou akcií AltIndex



Zdroj: Vlastní zpracování

Analýza provedená přes Google Scripts s podporou AI modelů spolu s analýzou pomocí AltIndexu mají obdobné výsledky, což potvrzuje, že samotný sentiment není dostatečně spolehlivým prediktorem cenového vývoje akcií v krátkodobém horizontu jednoho měsíce. AltIndex pracuje s větším množstvím historických dat, což mu umožňuje přesnější výpočty a širší analýzu, avšak jeho využití je zpoplatněno. Na druhé straně první přístup umožňuje plnou kontrolu nad procesem, je levnější, ale vyžaduje více času, technických znalostí a úsilí.

Z praktického hlediska lze AltIndex považovat za efektivní nástroj pro ty, kteří chtějí rychlé a snadné řešení bez nutnosti technické implementace, nabízí širší škálu funkcí a možností, ale s vyššími náklady. Naproti tomu manuální sestavení systému s využitím Google Scripts, OpenAI API a jazykových modelů přináší nižší provozní náklady a hlubší porozumění datům, což může být přínosné pro uživatele, kteří chtějí detailněji analyzovat souvislosti.

Obě metody za pomoci umělé inteligence přispívají ke zjednodušení sběru velkého množství dat a zřehlednění procesu analýzy, avšak v rámci jednoho měsíce se sentiment ukazuje spíše jako doplňkový indikátor než hlavní faktor pro rozhodování.

Výběr mezi těmito přístupy závisí na individuálních preferencích – zda upřednostnit nižší náklady a větší kontrolu, nebo pohodlí a širší analytické možnosti za cenu předplatného.

4.3 Vývoj a komparace investičních strategií s využitím AI v prostředí TradingView

Tento projekt byl zaměřen na vývoj a komparaci obchodních strategií s využitím platformy TradingView, jazyka Pine Script a AI asistence v tomto případě 2 jazykových modelů Chat GPT a Deep Seek. TradingView je webová platforma pro technickou analýzu finančních trhů, která umožňuje obchodníkům a investorům sledovat cenové grafy, používat indikátory, analyzovat tržní data a vytvářet obchodní strategie. Nabízí také možnost programování vlastních indikátorů a strategií pomocí jazyka Pine Script a integraci s brokery pro přímé obchodování. TradingView nabízí zdarma omezenou verzi, která byla k tomuto účelu využita z hlediska minimalizace nákladů této práce.

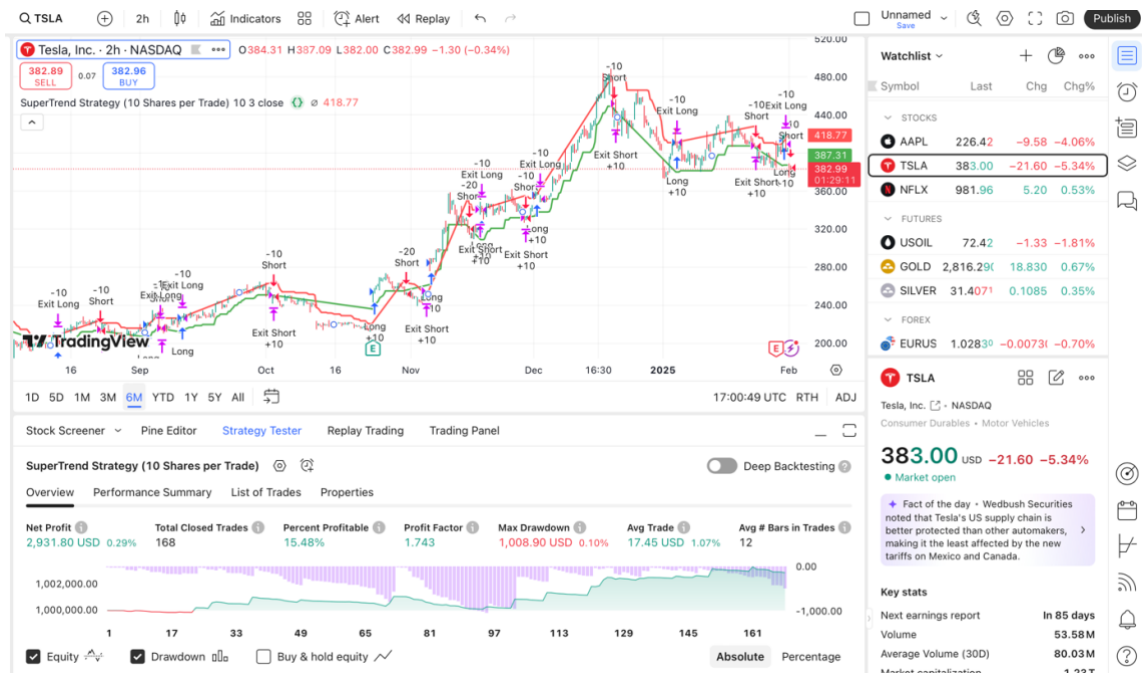
Cílem bylo vytvořit a následně vylepšit investiční strategii založenou na libovolném technickém indikátoru a komparovat doporučené strategie obou modelů. V tomto případě byl zvolen indikátor SuperTrend. Na základě tohoto indikátoru a podpory jazykových modelů byly sestrojeny strategie, které by efektivně otevíraly a uzavíraly obchody na základě tržních trendů. Proces zahrnoval několik kroků, včetně převodu indikátoru na strategii, ladění kódu, přizpůsobení velikosti pozic a analýzy dosažených výsledků. Pro tento postup byly zvoleny jazykové modely od Open AI tedy Chat GPT a Deep Seek, na základě vygenerovaných strategií z jednotlivých modelů byly komparovány výsledky signálů koupě či prodeje 4 akcií, konkrétně Nvidia, Tesla, Oklo a Apple. Strategie byly testovány a vyhodnocovány v různých časových horizontech – 1 měsíc, 3 měsíce a 6 měsíců. Testovací období bylo ukončeno 5. února 2025, přičemž šestiměsíční analýza zahrnovala data od 5. srpna 2024, tříměsíční období pokrývalo interval od 5. listopadu 2024 a jednoměsíční hodnocení probíhalo od 6. ledna 2025. Tento přístup umožnil nejen zhodnotit okamžitou efektivitu strategií, ale také posoudit jejich stabilitu a adaptabilitu v průběhu delšího časového rámce.

Proces tvorby strategie pomocí Chat GPT

Na začátku byl k dispozici indikátor SuperTrend napsaný ve starší verzi Pine Script v4, který byl k dispozici v dostupných indikátorech na platformě TradingView. Tento indikátor pouze

zobrazoval trendové linie a signalizoval potenciální nákupní a prodejní body. Prvním krokem proto bylo převedení indikátoru na plnohodnotnou obchodní strategii, která by zadávala příkazy na základě změny daného trendu. S pomocí jazykového modelu GPT byl přepsán skript do nejnovější verze Pine Script v5 a implementována funkce `strategy.entry()` a `strategy.exit()`, aby strategie mohla automaticky vstupovat do long a short pozic, dále bylo nutné přidat stop-loss, který by chránil kapitál při nepříznivém vývoji trhu.

Následně byl tento skript implementován do prostředí TradingView, jak lze vidět na obrázku 7. Během implementace se však objevily technické problémy spojené s kompatibilitou kódu a chybové logy. Problémový kód byl opět analyzován umělou inteligencí Chat GPT a bylo zjištěno, že první chybou bylo nesprávné definování funkce `max()`, která nebyla v Pine Script v5 dostupná v původní podobě, což vedlo k jejímu nahrazení funkcí `math.max()` a dalším problémem bylo nesprávné přiřazení datového typu bool proměnné definované jako float, což vyžadovalo úpravu inicializace proměnných a správné typování výpočtů. Po těchto opravách strategie fungovala bez chyb a byla plně kompatibilní s nejnovější verzí Pine Scriptu. Strategie však stále nebyla výnosná, jelikož byla pokaždé obchodována jen jedna akcie.



Obrázek 7: Ukázka z platformy TradingView po úspěšném vytvoření strategie

Zdroj: TradingView (2025)

Proto bylo následně důležité upravit přizpůsobení strategie pro obchodování konkrétního množství akcií, v tomto případě nebyl brán ohled na množství disponibilního kapitálu, a tak pro výzkumné účely byla strategie nastavena na 10 ks akcií na každý obchod.

Tabulka 7: Zhodnocení výkonu Supertrend strategie navržené modelem GPT (měsíční horizont)

| Měsíc | NVDA | TSLA | OKLO | AAPL |
|---------------------------------|---------|---------|---------|---------|
| Čistý zisk (USD) | 236 | 2262 | 24 | 565 |
| Počet uzavřených obchodů | 203 | 213 | 228 | 194 |
| Procentuální profitabilita | 16,75 % | 15,96 % | 10,53 % | 15,89 % |
| Profit faktor | 1,272 | 1,786 | 1,118 | 1,53 |
| Maximální pokles kapitálu (USD) | 178,8 | 464 | 65 | 294 |
| Průměrný obchod (USD) | 1,16 | 10,62 | 0,11 | 2,91 |
| Průměrný úspěšný obchod (USD) | 32,52 | 151,21 | 9,5 | 52,04 |
| Průměrný neúspěšný obchod (USD) | 5,3 | 16,45 | 1,38 | 6,72 |

Zdroj: Vlastní zpracování

Z tabulky 7 lze vidět, že v horizontu jednoho měsíce dosahovala strategie smíšených výsledků. TSLA dosáhla nejvyššího čistého zisku 2 262 USD, následovaná AAPL (565 USD), NVDA (236 USD) a OKLO (24 USD). Procentuální profitabilita byla velmi nízká, zejména u OKLO (10,53 %) a NVDA (16,75 %), což naznačuje, že strategie generovala velké množství obchodů, z nichž většina byla ztrátových, ale právě několik úspěšných obchodů mělo vysokou hodnotu.

Nejvyšší profit faktor vykazovala TSLA (1,786) a AAPL (1,53), zatímco OKLO měla pouze 1,118, což značí nízkou efektivitu této strategie na tomto titulu. Maximální pokles kapitálu byl nejvyšší u AAPL (294 USD).

V průměrných obchodech je patrné, že TSLA dosahovala nejvyšší hodnoty průměrných úspěšných obchodů (151,21 USD), zatímco OKLO a AAPL vykazovaly nízké hodnoty. Naopak průměrné neúspěšné obchody byly relativně malé, což snižovalo celkové ztráty a strategie byli výnosné i přes nízké hodnoty procentuální profitability.

Tabulka 8: Zhodnocení výkonu Supertrend strategie navržené modelem GPT (3 měsíce)

| 3 měsíce | NVDA | TSLA | OKLO | AAPL |
|---------------------------------|---------|---------|---------|---------|
| Čistý zisk (USD) | 398 | 1454 | -90 | 69 |
| Počet uzavřených obchodů | 192 | 168 | 136 | 177 |
| Procentuální profitabilita | 17,71 % | 18,45 % | 19,12 % | 12,43 % |
| Profit faktor | 1,535 | 1,339 | 0,612 | 1,06 |
| Maximální pokles kapitálu (USD) | 182,1 | 1110 | 164,3 | 350 |
| Průměrný obchod (USD) | 2,07 | 8,66 | -0,67 | 0,39 |
| Průměrný úspěšný obchod (USD) | 33,6 | 185,45 | 5,51 | 54,74 |
| Průměrný neúspěšný obchod (USD) | 4,93 | 32,29 | 2,92 | 7,57 |

Zdroj: Vlastní zpracování

Po třech měsících se ukázaly výrazné rozdíly mezi jednotlivými tituly. TSLA zůstala nejziskovějším aktivem s čistým ziskem 1 454 USD, zatímco NVDA se mírně zlepšila na 398 USD. OKLO se propadlo do ztráty (-90 USD), což naznačuje, že strategie zde v tomto období nefungovala dobře, a AAPL dosáhl pouze skromného zisku (69 USD), což ukazuje na jeho nízkou efektivitu v tabulce 8.

Úspěšnost obchodů byla poměrně nízká – pohybovala se mezi 12 % a 19 %, to znamená, že strategie generovala velké množství obchodů s relativně nízkou pravděpodobností úspěchu. TSLA vykazovala nejvyšší pokles kapitálu (1 110 USD), její volatilita tak potvrzuje nutnost efektivnějšího řízení rizik.

Z hlediska průměrných obchodů si TSLA udržela nejvyšší hodnoty, zatímco OKLO a NVDA vykazovaly velké množství malých a méně výnosných obchodů, což naznačuje, že strategie zde nebyla dostatečně efektivní.

Tabulka 9: Zhodnocení výkonu Supertrend strategie navržené modelem GPT (6 měsíců)

| 6 měsíců | NVDA | TSLA | OKLO | AAPL |
|---------------------------------|---------|---------|---------|---------|
| Čistý zisk (USD) | 156,1 | 2901 | -3,8 | 381 |
| Počet uzavřených obchodů | 180 | 169 | 85 | 175 |
| Procentuální profitabilita | 13,33 % | 15,38 % | 17,65 % | 18,29 % |
| Profit faktor | 1,183 | 1,73 | 0,978 | 1,27 |
| Maximální pokles kapitálu (USD) | 365,9 | 1008 | 156,8 | 274,9 |
| Průměrný obchod (USD) | 0,87 | 17,17 | -0,04 | 2,18 |
| Průměrný úspěšný obchod (USD) | 42,12 | 264,55 | 11,05 | 56,18 |
| Průměrný neúspěšný obchod (USD) | 5,9 | 28,61 | 3,08 | 10,17 |

Zdroj: Vlastní zpracování

Po šesti měsících se ukázalo, že výchozí strategie není dlouhodobě efektivní na všech titulech. TSLA si sice udržela nejvyšší zisk (2 901 USD), ale NVDA a AAPL skončily jen s mírnými zisky, zatímco OKLO se pohybovalo téměř na nulové úrovni (-3,8 USD). Výsledky tak poukazují na to, že strategie funguje lépe pouze u některých aktiv, zatímco u jiných nepřináší stabilní výkonnost (viz. tabulka č. 9).

Úspěšnost obchodů se pohybovala mezi 13 % a 18 %, což znamená, že většina obchodů skončila ztrátou. Profit faktor u TSLA dosáhl 1,73, což je stále solidní hodnota, ale u ostatních titulů NVDA (1,183), OKLO (0,978) a AAPL (1,27) byly výsledky slabší.

Výrazné poklesy kapitálu u TSLA (1 008 USD) a AAPL (274,9 USD) svědčí o vyšší volatilitě této strategie. Průměrný úspěšný obchod byl nejvyšší u TSLA (264,55 USD), zatímco OKLO dosáhlo pouze 11,05 USD, tento fakt potvrzuje nižší efektivitu strategie na tomto titulu.

Vylepšená strategie s ADX filtrem

Na základě těchto výsledků se ukázalo, že strategie v některých případech nevedla k dostatečné úspěšnosti a efektivitě, zejména u titulů s nižší profitabilitou. Proto byla na doporučení umělé inteligence navržena nová varianta s ADX filtrem, jehož úkolem bylo přesněji identifikovat

silné trendy a minimalizovat falešné signály. Nová strategie měla za cíl zvýšit přesnost obchodních vstupů a zajistit lepší výkonnost strategie v delším časovém horizontu.

Tabulka 10: Zhodnocení vylepšené Supertrend strategie s ADX filtrem model GPT (měsíc)

| Měsíc | NVDA | TSLA | OKLO | AAPL |
|---------------------------------|---------|---------|---------|---------|
| Čistý zisk (USD) | 282,4 | 2406 | - 90 | -115,4 |
| Počet uzavřených obchodů | 66 | 56 | 40 | 57 |
| Procentuální profitabilita | 53,03 % | 55,36 % | 47,50 % | 50,88 % |
| Profit faktor | 1,193 | 1,591 | 0,753 | 0,931 |
| Maximální pokles kapitálu (USD) | 584,08 | 1294,9 | 322,80 | 517 |
| Průměrný obchod (USD) | 4,28 | 42,98 | - 2,25 | -2,02 |
| Průměrný úspěšný obchod (USD) | 49,78 | 209,1 | 14,47 | 53,92 |
| Průměrný neúspěšný obchod (USD) | 47,10 | 163,01 | 19,21 | 59,97 |

Zdroj: Vlastní zpracování

Po provedení této strategie lze zaznamenat výrazné změny, a to konkrétně v profitabilitě jednotlivých titulů. Nejlepší výkon vykazala akcie TSLA, která dosáhla čistého zisku 2 406 USD při 55,36 % profitabilitě a profit faktoru 1,591. Na druhé straně NVDA zaznamenala mírně vyšší zisk než v předchozí strategii, avšak profit faktor 1,193 naznačuje, že rozdíl mezi výnosnými a ztrátovými obchody zůstal nevýrazný, což naznačuje omezenost její dlouhodobé efektivity.

Naopak OKLO a AAPL vykazaly ztrátu, přičemž OKLO dosáhlo -90 USD a AAPL dokonce -115,4 USD, detailní výsledky jsou uvedeny v tabulce 10. U těchto titulů nebyla strategie efektivní, což může naznačovat buď nevhodně nastavené vstupní parametry, nepříznivé tržní podmínky pro její použití, nebo příliš krátký časový horizont pro realizaci strategie.

Tabulka 11: Zhodnocení vylepšené Supertrend strategie s ADX filtrem model GPT (3 měsíce)

| 3 měsíce | NVDA | TSLA | OKLO | AAPL |
|---------------------------------|---------|---------|---------|---------|
| Čistý zisk (USD) | - 1,50 | 2960 | 145,80 | 1660 |
| Počet uzavřených obchodů | 48 | 59 | 28 | 45 |
| Procentuální profitabilita | 52,08 % | 52,54 % | 60,71 % | 57,78 % |
| Profit faktor | 0,999 | 1,444 | 1,699 | 2,301 |
| Maximální pokles kapitálu (USD) | 583,4 | 2340 | 294,30 | 437,50 |
| Průměrný obchod (USD) | - 0,03 | 50,17 | 5,21 | 36,89 |
| Průměrný úspěšný obchod (USD) | 56,5 | 310,3 | 20,84 | 112,93 |
| Průměrný neúspěšný obchod (USD) | 61,48 | 237,9 | 20,85 | 67,16 |

Zdroj: Vlastní zpracování

V delším časovém horizontu se projeví zajímavé změny ve výkonnosti jednotlivých titulů. TSLA nadále vykazovala silný růst s čistým ziskem 2 960 USD, i když její profitabilita mírně klesla na 52,54 %. Překvapivě se do zisku dostala také OKLO, která dosáhla 145,80 USD a zvýšila svou profitabilitu na 60,71 %, což svědčí o tom, že strategie v delším horizontu začíná lépe fungovat.

Největší pozitivní obrat však zaznamenal titul AAPL. Z původní ztráty v prvním měsíci přešel do zisku 1 660 USD s velmi vysokým profit faktorem 2,301. Výsledky naznačují, že strategie se na tomto titulu osvědčuje jako dlouhodobě výnosná a vykazuje stabilní růstový trend. Na druhé straně NVDA stagnovala s minimální ztrátou -1,5 USD, což ukazuje na omezený dlouhodobý potenciál této strategie. Podrobnější výsledky poskytuje tabulka 11.

Tabulka 12: Zhodnocení vylepšené Supertrend strategie s ADX filtrem model GPT (6 měsíců)

| 6 měsíců | NVDA | TSLA | OKLO | AAPL |
|---------------------------------|---------|---------|---------|---------|
| Čistý zisk (USD) | -468,60 | 4834 | 278 | 707 |
| Počet uzavřených obchodů | 42 | 57 | 18 | 60 |
| Procentuální profitabilita | 50,00 % | 59,65 % | 61,11 % | 60,00 % |
| Profit faktor | 0,684 | 1,797 | 4,29 | 1,416 |
| Maximální pokles kapitálu (USD) | 960,4 | 2421 | 192 | 538,4 |
| Průměrný obchod (USD) | -11,16 | 84,8 | 15,44 | 11,8 |
| Průměrný úspěšný obchod (USD) | 48,34 | 320,6 | 32,95 | 66,90 |
| Průměrný neúspěšný obchod (USD) | 70,65 | 263,75 | 12,07 | 70,87 |

Zdroj: Vlastní zpracování

Z hlediska šestiměsíční analýzy TSLA zůstala nejziskovějším titulem s celkovým výdělkem 4 834 USD, což potvrzuje její dlouhodobý růstový potenciál. Na druhou stranu vysoký maximální pokles kapitálu 2 421 USD (viz. tabulka 12) naznačuje, že ačkoliv strategie přináší zisky, je spojena s vyšší volatilitou a rizikem.

Velmi dobré výsledky vykázalo OKLO, které dosáhlo profit faktoru 4,29 a čistého zisku 278 USD. Tento vývoj ukazuje, že strategie na tomto titulu funguje dlouhodobě stabilně a efektivně. AAPL si rovněž udrželo pozitivní trend se ziskem 707 USD, avšak značný maximální drawdown (538,4 USD) vyvolává nutnost lepšího řízení rizika.

Naopak NVDA se propadla do výrazné ztráty (-468,60 USD), strategie je zde dlouhodobě nefunkční a pokračovat v jejím používání na tomto titulu by proto nebylo rozumné. Zde bychom možná našli větší uplatnění v analýze sentimentu, kdy korelace sentimentálních a cenových změn byla u tohoto titulu v průměru nejsilnější.

Tvorba strategie pomocí Deep Seek

Stejný postup i prompty byly využity při tvorbě strategie prostřednictvím modelu Deep Seek. Vzhledem k tomu, že Deep Seek je relativně nová umělá inteligence a zároveň open-source řešení, proces tvorby strategie byl časově náročnější. Model často odkazoval na přetížené

servery, což vedlo k omezené plynulosti práce a nižší uživatelské přívětivosti ve srovnání s modelem GPT.

Navzdory těmto omezením je však klíčové posoudit, zda výsledná strategie vykazuje lepší výkonnost než předchozí dvě strategie vytvořené pomocí modelu GPT. Následující část je proto zaměřena na analýzu dosažených výsledků a srovnání všech vytvořených strategií.

Strategie byla opět postavena na indikátoru SuperTrend, avšak model Deep Seek ji vylepšil několika klíčovými prvky. Na rozdíl od předchozích přístupů a strategií, Deep Seek zkombinoval SuperTrend s klouzavými průměry (SMA/EMA), ATR (Average True Range) a časovým filtrem, čímž vytvořil promyšlenější systém generující efektivnější obchodní signály.

Největší výhodou této strategie bylo použití dynamického stop-lossu a take-profitu, které se přizpůsobují volatilitě trhu tento prvek by měl lépe řídit riziko, ale zároveň umožnit maximalizování ziskovosti tím, že se přizpůsobil aktuálním tržním podmínkám.

Tabulka 13: Zhodnocení Supertrend strategie navrženou Deep Seek (měsíc)

| Měsíc | NVDA | TSLA | OKLO | AAPL |
|---------------------------------|---------|---------|---------|---------|
| Čistý zisk (USD) | 404,7 | 569,8 | -7,1 | 365 |
| Počet uzavřených obchodů | 115 | 130 | 128 | 122 |
| Procentuální profitabilita | 29,57 % | 24,62 % | 28,13 % | 40,16 % |
| Profit faktor | 0,61 | 1,148 | 0,966 | 1,243 |
| Maximální pokles kapitálu (USD) | 459 | 1494 | 92,6 | 418 |
| Průměrný obchod (USD) | -3,52 | 4,38 | 0,06 | 2,99 |
| Průměrný úspěšný obchod (USD) | 23,18 | 137,93 | 5,57 | 38,17 |
| Průměrný neúspěšný obchod (USD) | 24,85 | 75,37 | 2,93 | 25,51 |

Zdroj: Vlastní zpracování

Výsledky po měsíční implementaci, uvedené v tabulce 13, ukázaly opět rozdílnou efektivitu strategie na jednotlivých titulech. TSLA s nejvyšším čistým ziskem 569,8 USD potvrdila svůj růstový potenciál, avšak také s největším maximálním poklesem kapitálu (1 494 USD) ze všech

strategií, a poukazuje tak na vyšší míru rizika a možnou volatilitu, i přes pokus modelu tyto složky zmírnit. AAPL dosáhlo nejlepší profitability (40,16 %), což svědčí o efektivnějším fungování strategie při nižším riziku ve srovnání s titulem TSLA.

NVDA se sice umístila na druhém místě podle čistého zisku (404,7 USD), avšak nízký profit faktor (0,61) a záporný průměrný obchod (-3,52 USD) vypovídají o tom, že strategie zde nebyla dostatečně efektivní. Nejhorší výsledky vykázalo OKLO s celkovou ztrátou -7,1 USD. Zde se opět ukazuje, že v rámci jednoho měsíce není strategie pro tento titul optimálně nastavená. Přesto lze vnímat jedno pozitivum – ve srovnání se všemi předchozími strategiemi byla ztráta nejnižší.

Tabulka 14: Zhodnocení Supertrend strategie navrženou Deep Seek (3 měsíce)

| 3 měsíce | NVDA | TSLA | OKLO | AAPL |
|---------------------------------|---------|---------|---------|---------|
| Čistý zisk (USD) | 114 | 3160 | 240 | 928 |
| Počet uzavřených obchodů | 107 | 85 | 70 | 98 |
| Procentuální profitabilita | 29,91 % | 31,76 % | 35,71 % | 43,88 % |
| Profit faktor | 1,135 | 1,835 | 2,968 | 1,747 |
| Maximální pokles kapitálu (USD) | 391 | 892,9 | 81,1 | 507,2 |
| Průměrný obchod (USD) | 1,07 | 37,18 | 3,44 | 9,48 |
| Průměrný úspěšný obchod (USD) | 30,07 | 257 | 14,53 | 50,51 |
| Průměrný neúspěšný obchod (USD) | 20,2 | 135,1 | 4,08 | 36,56 |

Zdroj: Vlastní zpracování

Po třech měsících zůstala TSLA nejziskovějším titulem, přičemž v tomto časovém horizontu dosáhla nejvyššího výnosu ze všech strategií s celkovým ziskem 3 160 USD. AAPL si udrželo stabilní růst s 928 USD, zatímco OKLO začalo generovat zisk ve výši 240 USD, což bylo v rámci tříměsíčního období nejvyšší dosažené zhodnocení této strategie pro titul OKLO. NVDA s výsledkem 114 USD naopak opět potvrdila svou nižší efektivitu, což naznačuje, že strategie zde při delším, než měsíčním horizontu opět nefungovala optimálně. Detailní přehled těchto výsledků je uveden v tabulce 14.

Zajímavé je srovnání profit faktoru, který vykázal mimořádně vysoké hodnoty u TSLA (1,835) a OKLO (2,968), což svědčí o velmi efektivním řízení obchodů během tohoto období. Na druhé straně NVDA s hodnotou 1,135 vykazovala pouze minimální rozdíl mezi zisky a ztrátami, což potvrzuje její omezený potenciál v rámci této strategie.

Ačkoli se výnosy zvyšovaly, pokles kapitálu zůstal výrazný, zejména u TSLA (892,9 USD) a AAPL (507,2 USD). To ukazuje, že přestože strategie přinášela vyšší zisky, byla stále spojena s významným rizikem a je potřeba další optimalizace řízení kapitálu a nastavení stop-loss mechanismů.

Tabulka 15: Zhodnocení Supertrend strategie navrženou Deep Seek (6 měsíců)

| 6 měsíců | NVDA | TSLA | OKLO | AAPL |
|---------------------------------|---------|---------|---------|---------|
| Čistý zisk (USD) | -157 | 2562,2 | 106 | 70,6 |
| Počet uzavřených obchodů | 96 | 89 | 45 | 107 |
| Procentuální profitabilita | 29,17 % | 23,60 % | 33,33 % | 28,04 % |
| Profit faktor | 0,837 | 1,641 | 1,919 | 1,035 |
| Maximální pokles kapitálu (USD) | 387 | 940 | 109,2 | 488,9 |
| Průměrný obchod (USD) | 1,64 | 28,79 | 2,36 | 0,66 |
| Průměrný úspěšný obchod (USD) | 28,6 | 312,4 | 14,57 | 68,67 |
| Průměrný neúspěšný obchod (USD) | 26,01 | 114,2 | 6,41 | 42,33 |

Zdroj: Vlastní zpracování

Po šesti měsících se ukázalo, že strategie Deep Seek má smíšené výsledky v dlouhém horizontu, jak lze vidět v tabulce č. 15. TSLA zůstala nejvýnosnějším aktivem (2 562,2 USD), zatímco NVDA se propadla do ztráty (157 USD). OKLO dosáhlo pouze 106 USD a AAPL vykázal mírný zisk 70,6 USD a pokles výnosů. Profit faktor ukázal, že strategie je neúčinnější u OKLO (1,919) a TSLA (1,641), bylo zde však vysoké množství ztrátových obchodů. Nejvyšší pokles kapitálu zaznamenala TSLA (940 USD) a AAPL (488,9 USD), což potvrzuje vyšší volatilitu těchto aktiv. V průměrných hodnotách obchodů bylo patrné, že nejlepší výsledky měla TSLA (28,79 USD), zatímco AAPL měl pouze 0,66 USD.

Vyhodnocení všech navržených investičních strategií

Na základě analýzy výkonnosti tří obchodních strategií se jako nejefektivnější ukázalo, že model Deep Seek navrhnul strategii, která dosáhla nejlepších výsledků z hlediska profitability, profitu faktoru a vyváženého poměru mezi zisky a drawdownem. Nejvýraznějších úspěchů dosahovala na akcích TSLA, přičemž dlouhodobě vykazovala solidní výnosnost i na AAPL. Významnou předností této strategie je kvalitní řízení rizik, které bylo lepší než u strategie ADX SuperTrend GPT, a dosahovala zisků s nižší volatilitou, což je klíčový faktor pro obchodníky preferující stabilitu. Přesto bylo zjištěno, že na akcii NVDA strategie nevykazovala optimální výsledky, a proto by bylo vhodné zvážit úpravy parametrů pro tento konkrétní titul či použití jiných indikátorů k tvorbě strategie.

Na druhém místě se umístila SuperTrend strategie s ADX filtrem navržená modelem GPT, která sice dosahovala vysokých zisků, avšak za cenu výrazně vyššího drawdownu. Ve srovnání s první strategií, která byla bez ADX, byla tato strategie stabilnější a měla i lepší profitabilitu než Deep Seek, ale její vysoká volatilita ji staví až na druhé místo. Je tedy vhodná pro obchodníky, kteří se nebojí vyššího rizika a jsou ochotni akceptovat větší výkyvy kapitálu výměnou za potenciálně vyšší výnosy. Pro zlepšení výsledků by bylo vhodné optimalizovat řízení rizik a implementovat přísnější stop-loss mechanismy, což by mohlo snížit negativní dopady drawdownu (poklesu kapitálu).

Na třetím místě skončila původní prvně vytvořená Supertrend strategie bez ADX filtru, která se ukázala jako nejméně efektivní. Její profitabilita se pohybovala mezi 10–19 %, přičemž dosahovala nejnižšího profit faktoru a nedostatečné stability. I když měla nižší drawdown než strategie s ADX, její celkové zisky byly příliš nízké a počet ztrátových obchodů příliš vysoký. Vzhledem k těmto výsledkům není tato strategie vhodná pro dlouhodobé obchodování, protože nepřináší konzistentní zisky.

Je nutné upozornit, že tyto strategie byly backtestovány na historických datech, tudíž nezaručují budoucí profitabilitu. Tato však metodologie nachází uplatnění při vývoji obchodních aplikací, optimalizaci strategií a automatizaci obchodních procesů. Lze ji využít k tvorbě kódu pro obchodní boty, automatizované obchodování, trénování predikčních modelů a algoritmické obchodování. Dále lze tuto metodologii postupování využít pro libovolné indikátory technické analýzy a převést je do plně automatizovaných obchodních strategií.

4.4 Využití Google Cloud Platform pro sestavení autonomního obchodovacího bota s pomocí AI

V této části práce bylo analyzováno využití Google Cloud Platform (GCP) jako hostitelského prostředí pro skripty obchodního robota. GCP platforma byla zvolena na základě několika klíčových faktorů, mezi něž patří zejména nízké náklady na provoz, automatizované řízení procesů a škálovatelnost jednotlivých výpočetních operací.

Celkové náklady na provoz na GCP dosahovaly pouhých několika dolarů, což potvrdilo výhodnost této platformy pro testování obchodních strategií. Významným faktorem byla možnost plné automatizace algoritmů, díky níž mohl obchodní robot vykonávat operace bez zásahu člověka, čímž se eliminovala nutnost manuálního spouštění skriptů.

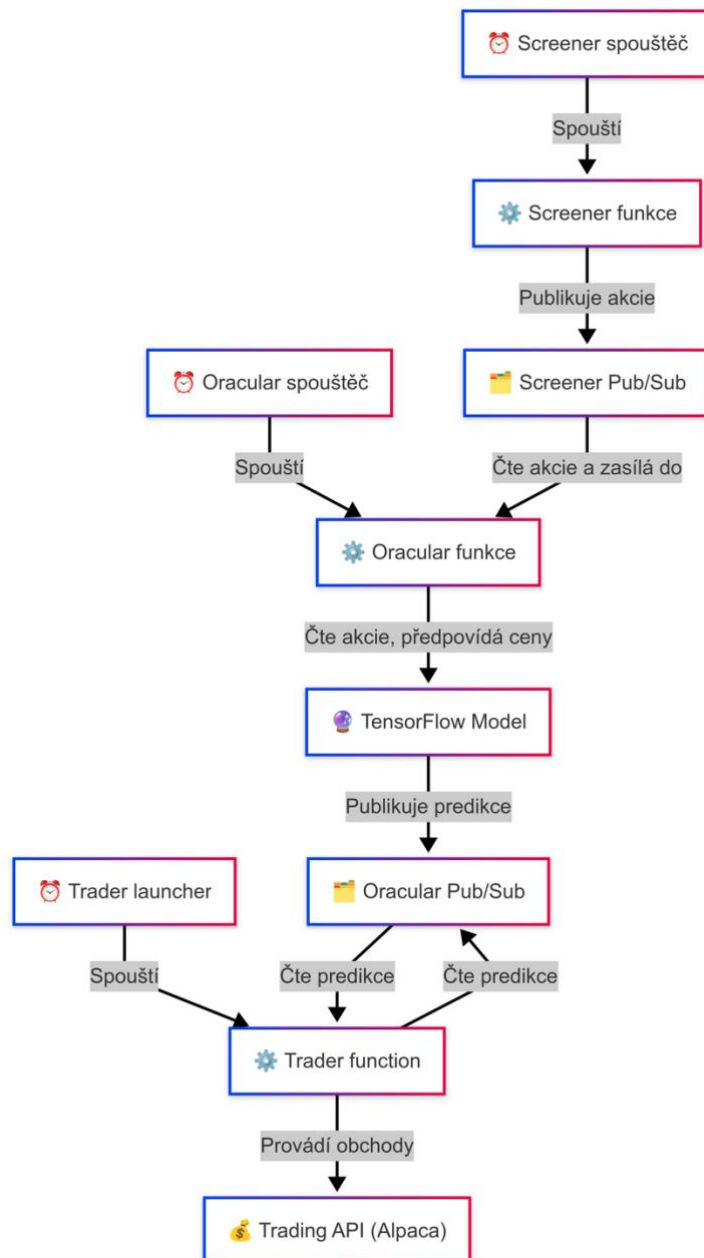
Infrastruktura

Hlavní komponenty obchodního robota byly rozděleny do tří skriptů, z nichž každý měl specifickou funkci. Prvním z nich byl Screener, který měl být odpovědný za skenování akcií na trhu a identifikaci obchodovatelných vzorců. V rámci tohoto procesu bylo analyzováno prvních 500 akcií indexu NASDAQ, přičemž byly využity dva technické indikátory: Bollingerova pásma (BBANDS) a index relativní síly (RSI).

Druhým skriptem byl Oracular, který měl provádět predikci cen akcií na následující tři dny. K této úloze byla využita neuronová síť LSTM (Long Short-Term Memory) implementovaná v TensorFlow. Pro účely učení modelu byla využita historická data akciových trhů z knihovny Yahoo Finance. Výsledné predikce by byly následně ukládány do specifické Pub/Sub infrastruktury, odkud by byly zpřístupněny dalším komponentám systému, zde se však začaly objevovat problémy, které jsou popsány v následující podkapitole.

Poslední částí systému byl Trader, jehož úkolem bylo realizovat obchodní příkazy na základě předem připravených seznamů akcií a jejich predikcí. Tento skript využíval Trading API z demo účtu na platformě Alpaca a automaticky měl provádět nákupy a prodeje podle definovaných obchodních pravidel. Data potřebná k obchodování měla být čerpána z Pub/Sub infrastruktury, kde byla předtím uložena skripty *Screener* a *Oracular*.

V rámci návrhu komunikační architektury bylo nejprve zajištěno, aby jednotlivé části systému fungovaly ve správném pořadí. Nejprve byl spuštěn skript *Screener*, který identifikoval relevantní akcie. Poté následoval *Oracular*, jenž na základě výběru vytvořil predikci cenového vývoje. Nakonec byl aktivován *Trader*, který uskutečňoval samotné obchodní transakce. Na obrázku č. 9 lze vidět strukturu celého systému.



Obrázek 9: Schéma infrastruktury Google Cloud

Zdroj: Vlastní zpracování

Pro efektivní propojení jednotlivých komponent byla v systému implementována Pub/Sub infrastruktura. Byly vytvořeny dva hlavní kanály pro přenos dat: *Screener topic*, do něhož měli být ukládány akcie nalezené v prvním kroku analýzy, a *Oracular topic*, který obsahoval cenové

predikce generované neuronovou sítí. Každé z těchto Pub/Sub témat bylo propojeno s odpovídajícími předplatnými (*Subscriptions*), čímž měla být zajištěna efektivní distribuce dat mezi jednotlivými částmi systému.

Nezbytnou součástí architektury byly také Google Cloud Functions na obrázku 10, které umožňovaly automatizované provádění jednotlivých výpočetních operací. Byly vytvořeny tři hlavní funkce odpovídající jednotlivým částem systému: *Shark-screener*, *Shark-oracular* a *Shark-trader*. Každá z těchto funkcí byla nasazena jako samostatná výpočetní jednotka s definovanými parametry paměti a časovým omezením. Funkce zodpovědné za predikce cen (*Oracular*) vyžadovaly vyšší alokaci paměti, neboť využívaly výpočetně náročné modely TensorFlow, to se také později ukázalo jako důvod nefunkčnosti systému.

The screenshot shows the Google Cloud console interface for Cloud Run functions. At the top, there is a navigation bar with the Google Cloud logo, the project name 'My First Project', and various utility icons. Below the navigation bar, the main heading is 'Cloud Run functions' with a sub-heading 'Functions (1st Gen)'. There are buttons for '+ CREATE FUNCTION', 'REFRESH', and 'LEARN'. A prominent warning message in a grey box states: 'This page only shows legacy 1st gen functions. We will be integrating Cloud Run functions into Cloud Run UI in the coming months. Starting August 2025, creating legacy 1st gen functions will only be possible using the gcloud CLI, API or Terraform. Please go to Cloud Run to manage all new function deployments.' Below the warning, there are links for 'LEARN MORE' and 'GO TO CLOUD RUN'. The main content area displays a table of functions with columns for Name, Last deployed, Region, Recommendation, Trigger, Runtime, and Memory allocated. Three functions are listed: Shark-oracular (1 GB memory), Shark-screener (512 MB memory), and Shark-trader (256 MB memory).

| <input type="checkbox"/> | Name ↑ | Last deployed | Region | Recommendation | Trigger | Runtime | Memory allocated |
|--------------------------|--------------------------------|--------------------------|-------------|----------------|---------|-------------|------------------|
| <input type="checkbox"/> | Shark-oracular | Jan 18, 2025, 4:02:02 PM | us-central1 | | HTTP | Python 3.10 | 1 GB |
| <input type="checkbox"/> | Shark-screener | Jan 18, 2025, 1:10:05 PM | us-central1 | | HTTP | Python 3.10 | 512 MB |
| <input type="checkbox"/> | Shark-trader | Jan 18, 2025, 3:42:46 PM | us-central1 | | HTTP | Python 3.10 | 256 MB |

Obrázek 10: Cloudové funkce obchodního bota

Zdroj: Google Cloud (2025)

K řízení celého procesu byl využit Google Cloud Scheduler, který umožňoval plánované spuštění jednotlivých funkcí podle předem definovaného harmonogramu (viz. obrázek 11). Bylo vytvořeno pět plánovačů (*Jobs*), které zajišťovaly pravidelné provádění obchodních operací. Například *Shark-screener-launcher* byl spuštěn každou hodinu v 50. minutě, aby připravil seznam akcii k predikci, zatímco *Shark-oracular-launcher* byl rozdělen na tři části, přičemž každá z nich zpracovávala predikci pro jinou akcii.

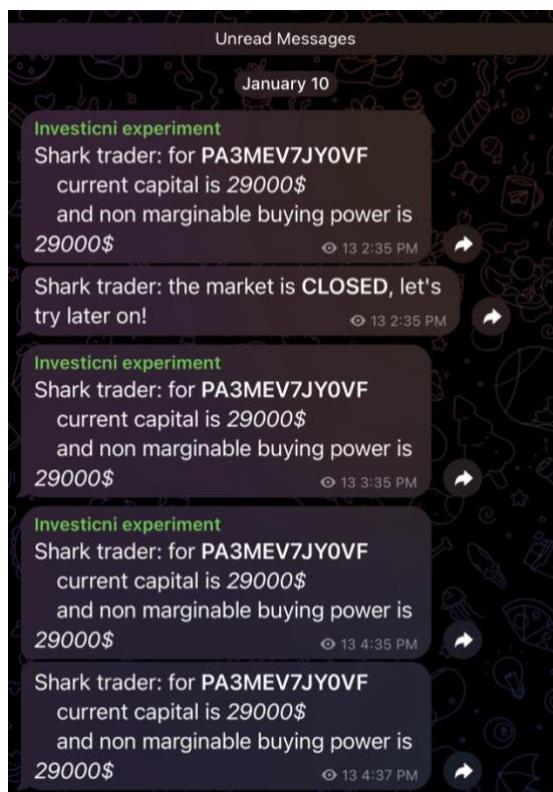
| <input type="checkbox"/> | Name ↑ | Status of last execution | Region | State | Description | Frequency |
|--------------------------|---|--------------------------|-------------|---------|-------------|--------------------------------------|
| <input type="checkbox"/> | Shark-oracular-launcher-1 | ✓ Success | us-central1 | Enabled | | 50 7-14 ** 1-5 (America/New_York) |
| <input type="checkbox"/> | Shark-oracular-launcher-2 | ✓ Success | us-central1 | Enabled | | 20 7-14 ** 1-5 (America/New_York) |
| <input type="checkbox"/> | Shark-oracular-launcher-3 | ✓ Success | us-central1 | Enabled | | 31 7-14 ** 1-5 (America/New_York) |
| <input type="checkbox"/> | Shark-screener-launcher | ✓ Success | us-central1 | Enabled | | 50 7-14 ** 1-5 (America/New_York) |
| <input type="checkbox"/> | Shark-trader-launcher | ✓ Success | us-central1 | Enabled | | 46 7-14 ** 1-5 (America/New_York) |

Obrázek 11: Cloud Scheduler spouštěč funkcí

Zdroj: Google cloud (2025)

Celý systém byl navržen s ohledem na minimalizaci nákladů a plnou automatizaci obchodních procesů.

Výsledkem nasazení této infrastruktury mělo být vytvoření plně automatizovaného obchodního robota, který mohl pracovat bez nutnosti manuálního zásahu, přičemž uživatel měl možnost sledovat výsledky prostřednictvím Telegram kanálu, jak lze vidět na obrázku 12.



Obrázek 12: Ukázka notifikací z Telegramu

Zdroj: Vlastní Telegram chatbot (2025)

Komplikace s nasazením na Google Cloud Platform

Navzdory teoretické robustnosti navrženého systému se během implementace vyskytlo několik zásadních problémů, které znemožnily jeho plné využití a vedly k celkovému neúspěchu obchodního bota. Hlavní komplikace se týkaly omezených výpočetních kapacit, problémů s komunikací mezi komponentami, složité autentizace API a nemožnosti propojení s klíčovou obchodní platformou Alpaca.

Jedním z nejzávažnějších omezení byla nedostatečná výpočetní kapacita pro neuronové sítě. Modely LSTM implementované v TensorFlow vyžadovaly pro svůj běh značné množství operační paměti, přičemž v základním nastavení Google Cloud Functions nebylo možné tento

požadavek efektivně splnit. Přestože bylo alokováno 1 GB paměti, stále docházelo k přetížení výpočetního prostředí, což vedlo k výpadkům predikčních výpočtů a zpomalení celého procesu. Omezení v dostupných výpočetních zdrojích tedy zásadně narušilo schopnost bota generovat spolehlivé cenové predikce.

Dalším významným problémem byla nefunkční komunikace mezi jednotlivými komponentami prostřednictvím Pub/Sub infrastruktury. Přestože Pub/Sub měl zajišťovat rychlý přenos dat mezi skripty *Screener*, *Oracular* a *Trader*, nedocházelo k doručení zpráv, což vedlo k situacím, kdy *Trader* neměl přístup k validním predikcím a nemohl provádět žádné obchody.

Jedním z nejzásadnějších omezení bylo také nemožné propojení s obchodní platformou Alpaca API. Paper účet na Alpaca nebylo možné přímo napojit na Pub/Sub infrastrukturu, což znamenalo, že obchodní příkazy nemohly být plně automatizovány.

Na základě těchto zjištění bylo konstatováno, že Google Cloud Platform nebyla vhodným prostředím pro tento typ obchodního bota. Omezení v oblasti výpočetního výkonu, problémy se synchronizací procesů a absence efektivní komunikace s obchodním API vedly k nefunkčnosti celého systému. Přestože byla platforma levná a umožňovala snadné škálování, její architektonická omezení neumožnila vytvoření plně autonomního obchodního bota.

K řešení řady problémů, které se během sestrojování robota vyskytly byl využit jazykový model Google Gemini, který značnou část technických problémů a problémů ve skriptech dokázal opravit, avšak nedokázal nabídnout relevantní opravy pro překonání všech technických problémů v projektu.

V závěru jedinou funkční součástí systému bylo propojení s Telegramem, které umožňovalo obchodnímu botovi zasílat notifikace o stavu *paper accountu* na Alpaca a informací o otevřeném či zavřeném trhu.

V důsledku těchto faktorů byl projekt po dvou měsících testování, úprav, analýzy problémů a konzultací v online komunitách ukončen, protože jeho další vývoj by vyžadoval celkové přepracování architektury a výkonnější výpočetní techniku.

Přestože Google Cloud Platform, byla finančně dostupnou a technologicky pokročilou platformou, nebyla vhodným prostředím pro tento typ aplikace. Omezení související s výkonem, autentizací a synchronizací procesů vedla k nutnosti hledání alternativního řešení.

4.5 Využití ChatGPT a Alpaca k automatizovanému obchodování

Vzhledem k neúspěchu předchozího přístupu na Google Cloud Platform byl nalezen alternativní přístup, který nejen odstranil technická omezení původního řešení, ale také eliminoval nutnost složitého programování. V reakci na předešlé problémy vznikl nový příklad zaměřený na automatizaci obchodování, přičemž i tentokrát se vyskytly určité komplikace, které však byly nakonec úspěšně vyřešeny.

V rámci této iniciativy byla zkombinována umělá inteligence (ChatGPT), automatizační nástroj Zapier a obchodní platforma Alpaca. Cílem bylo vytvořit autonomního obchodního bota schopného provádět investiční rozhodnutí na základě analýzy finančních zpráv. Implementace technické analýzy se ukázala jako příliš složitá, a proto bylo rozhodnuto využít sentimentální analýzu tržních zpráv jako hlavní metodu obchodní strategie.

Postup a implementace

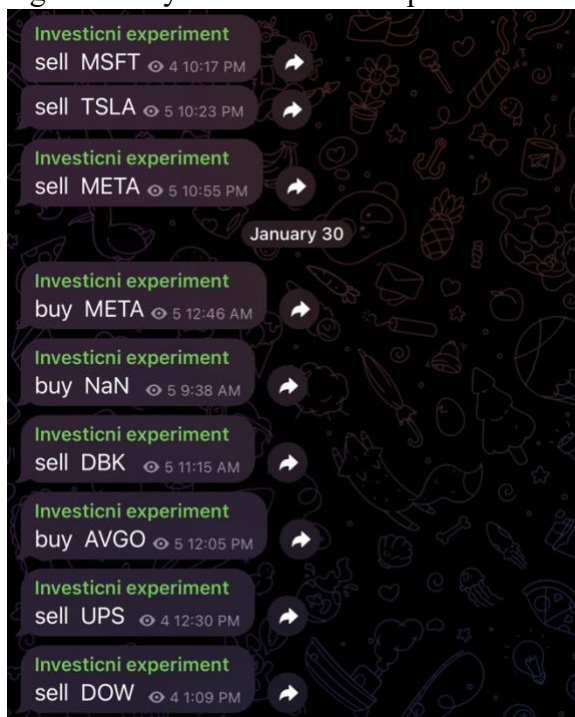
Prvním krokem bylo zřízení účtu na platformě Alpaca, která poskytuje API přístup k obchodování s akciemi a kryptoměnami. Díky integraci s *paper accountem* bylo možné provádět simulované obchody s fiktivním kapitálem v reálných tržních podmínkách. Po zřízení účtu následovalo propojení s platformou Zapier, jež měla umožnit automatizaci obchodních procesů mezi různými aplikacemi. V této fázi se však objevil zásadní problém – *paper account* nebylo možné propojit se Zapierem, který byl klíčovou komponentou pro automatizaci. Po konzultaci s technickou podporou bylo potvrzeno, že Zapier podporuje pouze propojení s reálným účtem, nikoliv s testovacím *paper accountem*. Z tohoto důvodu musela být integrace Alpaca odstraněna a veškeré obchody bylo nutné provádět ručně.

Po vyřešení tohoto omezení následovala integrace ChatGPT do Zapieru, což umožnilo přenos informací mezi umělou inteligencí, zpravodajskými zdroji a obchodní infrastrukturou. V rámci platformy Zapier byl navržen obchodní bot, který analyzoval finanční články a na základě sentimentální analýzy určoval, zda je vhodné nakoupit nebo prodat akcie. Aby měl bot přístup k aktuálním tržním informacím, byl propojen s RSS feedy poskytujícími nejnovější ekonomické zprávy. Jako hlavní zdroj byla zvolena platforma MarketWatch, a to kvůli pravidelným aktualizacím a širokému pokrytí finančních témat. RSS feedy byly nakonfigurovány tak, aby automaticky stahovaly nové články a okamžitě iniciovaly analýzu sentimentu. Při výběru zdrojů bylo klíčové zajistit, aby nebyly omezeny placeným přístupem, což předešlo výpadkům v automatizaci. Kromě základních tržních zpráv byly do systému

zahrnuty i specializované zdroje sledující IPO, komoditní trhy a makroekonomické indikátory, čímž došlo k rozšíření analytických možností obchodního bota.

Při zpracování nové zprávy bot postupoval podle předem stanoveného schématu (zobrazeném na další straně). Nejprve identifikoval obchodovaný instrument z titulku článku. Následně provedl sentimentální analýzu obsahu a přiřadil skóre v rozmezí 0 až 100, přičemž nízké hodnoty indikovaly negativní sentiment a vysoké hodnoty pozitivní tržní očekávání. Na základě těchto výsledků pak bot vyhodnotil obchodní signál a rozhodl o vhodnosti nákupu nebo prodeje dané akcie. Sentimentální analýza byla založena na klíčových frázích, celkové tonalitě textu a historických reakcích trhu, což umožnilo predikci možného vývoje cen.

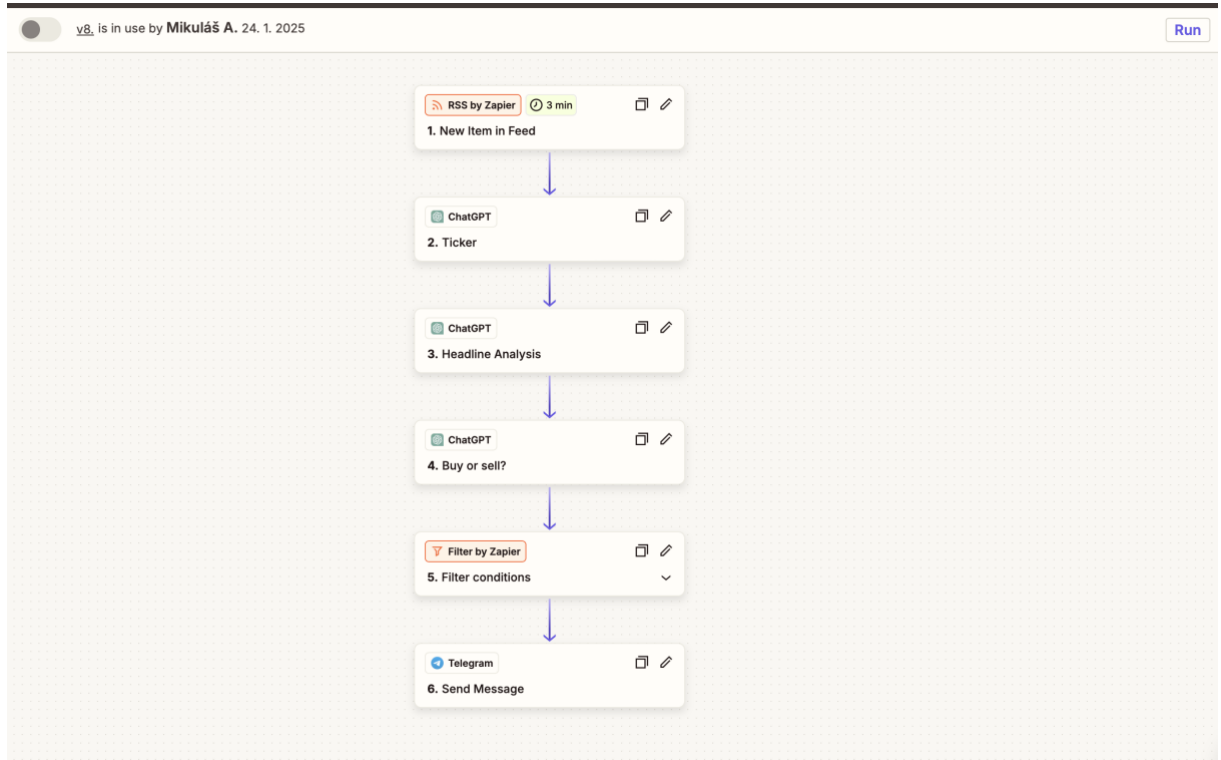
Obchodní logika byla nastavena tak, že skóre mezi 0 a 20 signalizovalo výrazně negativní sentiment, což znamenalo, že akcie by měla být prodána, pokud však doposud nebyla otevřena žádná pozice, byl tento signál vnímán jako vstup do *short* pozice. Naopak skóre nad 80 představovalo silně pozitivní tržní očekávání a znamenalo doporučení k nákupu nebo otevření *long* pozice. Pro zajištění transparentnosti a lepší kontroly nad obchodními rozhodnutími byla implementována notifikační funkce, která informovala obchodníka prostřednictvím Telegramu (obrázek 13). Pro tento účel byl vytvořen chatbot, jenž přijímal obchodní signály a odesílal je do specializovaného Telegram kanálu. Tato funkcionality umožnila manuální kontrolu generovaných obchodních doporučení.



Obrázek 13: Ukázka obchodních signálů v Telegram kanálu

Zdroj: Vlastní Telegram chatbot (2025)

Kvůli omezením Alpaca nebylo možné realizovat plně automatizované obchodování, a proto bylo nakonec rozhodnuto provádět všechny obchody ručně. Veškeré transakční údaje a výsledky byly systematicky zaznamenávány, aby bylo možné analyzovat úspěšnost strategie. Celková architektura z prostředí Zapier lze vidět na obrázku č. 14.



Obrázek 14: Schéma automatizovaného obchodního bota na platformě Zapier

Zdroj: Zapier (2025)

Je důležité zmínit, že strategie byla testována pouze během dvoutýdenního období od 23. ledna do 6. února 2025. Toto časové omezení bylo dáno podmínkami Zapieru, který umožňuje bezplatný běh skriptu pouze po dobu 14 dnů. Vzhledem k tomuto omezení nebylo možné provést dlouhodobé testování, což značně ovlivnilo možnosti optimalizace a hlubší analýzu strategie. Krátké testovací období znamenalo, že strategie nebyla dostatečně ověřena v různých tržních podmínkách, například během zvýšené volatility při makroekonomických událostech nebo v období nízké likvidity.

Další významnou skutečností bylo, že strategie nebyla zcela autonomní. Ačkoli obchodní signály byly generovány skriptem přes Zapier, samotné obchody byly realizovány manuálně. V případě, že *long* nebo *short* signál generoval solidní profit, docházelo k předčasnému uzavření obchodu manuálně, bez ohledu na původní pravidla strategie. Naopak pokud signál nebyl potvrzen, byla pozice uzavřena dříve, aby se minimalizovala potenciální ztráta. To znamená, že strategie nesloužila jako plně autonomní obchodní mechanismus, ale spíše jako

podpůrný nástroj pro rozhodování, který kombinoval automatizované signály s manuální intuicí obchodníka.

Celkově lze konstatovat, že tento přístup odstranil některé technické překážky spojené s předchozím pokusem o automatizaci, avšak stále existovala zásadní omezení, která bránila plné autonomii obchodního systému. V budoucnu by mohlo být vhodné zvážit jiné platformy pro automatizované obchodování, které umožňují přímou exekuci příkazů na *paper accountu* či poskytují delší testovací období bez nutnosti placeného přístupu.

Zhodnocení strategie

Strategie byla testována na vzorku 40 obchodů, přičemž zahrnovala jak long, tak short pozice. Celkový dosažený zisk činil 155,7 USD, přičemž úspěšnost obchodů se mezi oběma typy lišila. Short obchody vykázaly vyšší úspěšnost, kdy 16 obchodů bylo výherních a 8 ztrátových, což odpovídá win rate 66,67 %. Naopak long obchody měly méně stabilní výsledky, s 7 výherními a 9 ztrátovými obchody, což odpovídá úspěšnosti 43,75 %. Celková úspěšnost obchodů tak dosáhla 57,5 %, což naznačuje, že strategie byla výrazně úspěšnější na short signálech, zatímco long vstupy by mohly být optimalizovány.

Jedním z klíčových ukazatelů úspěšnosti strategie je profit faktor, který vyjadřuje poměr mezi celkovými zisky a ztrátami. V tomto případě profit faktor dosáhl hodnoty 2,11, což je považováno za velmi dobrý výsledek, neboť hodnota nad 2 naznačuje stabilní a efektivní obchodní strategii. Dalším důležitým ukazatelem je risk-reward ratio (RRR), které vyjadřuje poměr průměrného ziskového a průměrného ztrátového obchodu. Strategie dosáhla průměrného ziskového obchodu ve výši 12,91 USD a průměrného ztrátového obchodu 8,26 USD, což znamená RRR ve výši 1,56. Hodnota nad 1,5 svědčí o dobrém poměru mezi rizikem a odměnou, což ukazuje, že strategie má potenciál pro stabilní výkonnost.

Z hlediska rizika je důležité sledovat maximální drawdown, tedy největší pokles kapitálu během testovacího období. Pokud byl tento pokles 85 USD, lze považovat strategii za relativně stabilní, i když existuje prostor pro další optimalizaci, například úpravou velikosti pozic nebo přidáním efektivnějších stop-loss mechanismů. Strategie v průměru generovala 3,89 USD na obchod, což potvrzuje její ziskovost, ačkoli některé aspekty, zejména long obchody, by mohly být vylepšeny. Celkové výsledky strategie byly shrnuty v tabulce 16.

Tabulka 16: Výkonnostní metriky bota z platformy Zapier

| Metrika | Hodnota |
|----------------------------------|----------------|
| Celkový zisk (USD) | 155,7 |
| Počet obchodů | 40 |
| Procento úspěšných short obchodů | 66,67 % |
| Procento úspěšných long obchodů | 43,75 % |
| Celková úspěšnost | 57,5 % |
| Profit faktor | 2,11 |
| Risk-reward ratio | 1,56 |
| Maximální drawdown (USD) | 85 |
| Průměrný obchod (USD) | 3,89 |

Zdroj: Vlastní zpracování

Výsledky z tabulky č. 16 naznačují, že strategie je výnosná, především díky úspěšnosti short obchodů. Profit faktor 2,11 a risk-reward ratio 1,56 potvrzují efektivitu přístupu, ale zároveň ukazují prostor pro zlepšení v oblasti long pozic a řízení drawdownu. Vzhledem k tomu, že strategie byla testována pouze v krátkodobém horizontu, bylo by vhodnější další testování na delším vzorku dat, aby bylo možné lépe posoudit její stabilitu a robustnost v různých tržních podmínkách. Tato strategie se jeví jako perspektivní zejména v medvědím trhu, kde se short signály ukázaly jako nejefektivnější.

5 Doporučení pro investory a management podniku

Tato kapitola poskytuje doporučení pro investory, kteří chtějí efektivně využít umělou inteligenci k podpoře investičního rozhodování. Doporučení vychází z provedených analýz a testování různých AI nástrojů a obchodních strategií popsanych v předchozích kapitolách. Cílem práce bylo identifikovat a vyhodnotit přístupy, které mohou pomoci neprofesionálním investorům i podnikovému managementu při rozhodování, zda investici koupit, prodat či držet.

Analýza sentimentu finančních zpráv ukázala, že tento přístup může být užitečným doplňkem tradičních analytických metod, avšak není dostatečně spolehlivým samostatným nástrojem pro investiční rozhodování. Testování provedené pomocí Google Cloud Sheets a AI modelů naznačilo, že vztah mezi mediálním sentimentem a cenovým vývojem akcií je nestabilní a v krátkodobém horizontu nevykazuje konzistentní výsledky. Alternativní řešení v podobě platformy AltIndex pracuje s rozsáhlejšími historickými daty a nabízí uživatelsky přívětivější prostředí, avšak za cenu předplatného. Investorům, kteří hledají nízkonákladové řešení s možností individuálního přizpůsobení, lze doporučit manuální implementaci sentimentální analýzy, zatímco AltIndex je vhodný pro ty, kteří upřednostňují rychlý přístup k širší analytice bez nutnosti technických znalostí.

Testování obchodních strategií v prostředí TradingView přineslo cenné poznatky o efektivitě různých přístupů. Nejstabilnější výsledky přinesla strategie vytvořená modelem Deep Seek, která byla nejziskovější a vykazovala nejvyváženější poměr mezi zisky a drawdownem. Ukázala se jako nejvhodnější zejména pro akcie TSLA a AAPL, přičemž byla méně efektivní pro NVDA. Strategie založená na indikátoru SuperTrend s ADX filtrem, vytvořená modelem GPT, měla vyšší profitabilitu, ale byla spojena s vyšším drawdownem, což ji činilo rizikovější. Pro investory hledající stabilitu a efektivní řízení rizik se proto jako nejvhodnější jeví navrhování strategií přes Deep Seek.

Projekt automatizovaného obchodování v prostředí Google Cloud Platform ukázal, že i přes nízké provozní náklady a možnosti škálovatelnosti nemusí být tato platforma ideální pro běh komplexních AI modelů. Hlavní překážky spočívaly v nedostatečné výpočetní kapacitě pro neuronové sítě, nefunkční komunikaci mezi komponentami přes Pub/Sub infrastrukturu a nemožnosti propojení s obchodní platformou Alpaca. Přestože k řešení technických problémů byl využit jazykový model Google Gemini, nebylo možné překonat všechna omezení, což vedlo k ukončení projektu po dvou měsících testování. Investoři, kteří uvažují o automatizaci obchodování, by proto měli pečlivě volit technologickou platformu a ověřit její schopnost

zpracovávat složité výpočty a integrovat se s obchodními API. Vhodnější alternativou pro běh AI modelů se jeví VPS nebo dedikovaný server, který nabízí vyšší výpočetní výkon a flexibilitu.

V posledním testovaném přístupu bylo investování s AI realizováno prostřednictvím Zapier. Tento přístup odstranil některé technické překážky spojené s předchozím pokusem o automatizaci, avšak plná autonomie obchodního systému nebyla možná kvůli nemožnosti propojení Alpaca API s paper účtem. Veškeré obchody musely být prováděny manuálně, přičemž testování ukázalo, že ruční zásahy do obchodování přinesly lepší výsledky než čistě mechanické strategie. Short strategie se ukázaly jako úspěšnější než long obchody, což naznačuje, že v určitých tržních podmínkách může být vhodnější orientovat se na krátkodobé spekulace na pokles. Profit faktor 2,11 a risk-reward ratio 1,56 potvrzují solidní potenciál této strategie, avšak její výkonnost by mohla být dále zvýšena optimalizací vstupních parametrů a efektivnějším řízením rizik.

Celkově výsledky této práce ukazují, že umělá inteligence může být cenným nástrojem pro podporu investičního rozhodování, avšak její implementace vyžaduje pečlivé zvažování vhodných přístupů. AI nelze považovat za univerzální řešení, které samo o sobě zajistí úspěšné obchodování, ale může výrazně pomoci při analýze tržních dat, generování investičních signálů a automatizaci obchodních procesů. Pro investory je klíčové zvolit správnou kombinaci AI nástrojů, která odpovídá jejich obchodní strategii a toleranci k riziku. Plná automatizace obchodních strategií zůstává technologicky prozatím náročná, a proto je vhodnější kombinovat AI analytiku s lidským úsudkem. Jak ukázala testovaná strategie na Zapier, manuální zásahy mohou v některých případech přinést lepší výsledky než plně autonomní systémy.

Výzkum potvrdil, že AI je užitečná zejména jako podpůrný nástroj pro investory, kteří chtějí efektivně analyzovat tržní sentiment, optimalizovat obchodní strategie a automatizovat rutinní procesy. Klíčové je však využívat AI v kombinaci s tradičními metodami analýzy trhu a pečlivě testovat každý přístup před jeho implementací do reálného obchodování. Vývoj investičních strategií s využitím AI je procesem učení a neustálého zlepšování, který může vést k efektivnějším a ziskovějším investičním rozhodnutím v budoucnosti.

Závěr

Cílem práce bylo využít vybrané nástroje umělé inteligence, které usnadňují investiční rozhodování managementu podniku a neprofesionálním investorům včetně doporučení pro investory vyplývající z výsledků formulované umělou inteligencí, zda investici koupit, prodat či držet.

Práce se zaměřila na využití AI v oblasti analýzy sentimentu, tvorby obchodních strategií a automatizace obchodování. Výsledky výzkumu přinesly cenné poznatky o efektivitě jednotlivých metod a jejich využitelnosti v reálném investičním prostředí.

První kapitola se věnovala obecným teoretickým východiskům umělé inteligence a jejímu vlivu na finanční trhy. Byly popsány klíčové oblasti aplikace AI v investování, včetně změn v investování vlivem AI.

Další část diplomové práce se zaměřila na testování a hodnocení konkrétních investičních strategií vytvořených za pomoci AI. Nejprve byla provedena analýza sentimentu finančních zpráv s cílem zjistit, do jaké míry lze mediální pokrytí využít jako indikátor tržních pohybů. Byly porovnány dvě metody – vlastní implementace sentimentální analýzy pomocí Google Cloud Sheets a modelu Claude a hotové řešení AltIndex. Výsledky ukázaly, že sentiment sám o sobě není dostatečně spolehlivým prediktorem cenového vývoje akcií v krátkodobém horizontu, avšak může sloužit jako užitečný doplněk pro širší tržní analýzu.

Dále byla testována efektivita obchodních strategií vytvořených pomocí AI generativních modelů na platformě TradingView. Nejlepší výsledky dosáhla strategie vytvořená modelem Deep Seek, která vykazovala nejvyšší stabilitu a profitabilitu. Výsledky analýzy ukázaly, že využití AI pro tvorbu obchodních strategií má značný potenciál, avšak vyžaduje pečlivé testování a optimalizaci parametrů.

Třetí přístup měl za cíl vytvořit autonomního obchodního bota na Google Cloud Platform využívajícího Pub/Sub infrastrukturu a neuronové sítě pro predikci cen akcií. Během implementace se však ukázalo, že GCP není pro tento účel vhodná kvůli omezenému výpočetnímu výkonu, problémům s komunikací mezi komponentami a nemožnosti plně integrovat obchodní API. I přes opakované úpravy se nepodařilo tyto technické překážky překonat, a tento přístup byl po dvou měsících testování ukončen. Tento neúspěch přinesl cenné poznatky o omezeních GCP a nutnosti hledat alternativní řešení s vyšším výkonem a lepší podporou obchodních systémů.

Poslední příklad se zabýval automatizací obchodování pomocí Zapier a Alpaca, kde byl vytvořen obchodní bot využívající sentimentální analýzu k tvorbě obchodních signálů. Vzhledem k omezením Alpaca API nebylo možné plně automatizovat exekuci obchodních příkazů, což vedlo k nutnosti manuálního řízení obchodů. Strategie vykazovala vyšší úspěšnost u short obchodů než u long obchodů, přičemž profit faktor dosáhl hodnoty 2,11, což naznačuje solidní efektivitu této metody.

Na základě provedených analýz lze konstatovat, že umělá inteligence může výrazně usnadnit investiční rozhodování, avšak její plná autonomie je stále omezená technologickými faktory a nutností lidského dohledu. AI se ukázala jako užitečný nástroj pro analýzu trhů, tvorbu obchodních strategií a automatizaci obchodních procesů, avšak efektivita jednotlivých metod se liší v závislosti na konkrétním přístupu a implementaci.

Použité zdroje

- [1] ADDY, Wilhelmina, AJAYI-NIFISE, Adeola, BELLO, Binaebi, TULA, Sunday, ODEYEMI, Olubusola a FALAIYE, Titilola. Algorithmic Trading and AI: A Review of Strategies and Market Impact. *World Journal of Advanced Engineering Technology and Sciences* [online]. 2024, roč. 11, č. 1, s. 258–267. DOI: 10.30574/wjaets.2024.11.1.0054.
- [2] ALIBABACLOUD.COM, 2019. Announcing Hanguang 800: Alibaba's First AI-Inference Chip. *Alibabacloud.com* [online]. [cit. 2024-10-08]. Dostupné z: https://www.alibabacloud.com/blog/announcing-hanguang-800-alibabas-first-ai-inference-chip_595482
- [3] ALPHANOME.AI, 2023. Recurrent-neural-networks-rnns-for-investors. *Alphanome.ai* [online]. [cit. 2025-03-06]. Dostupné z: <https://www.alphanome.ai/post/recurrent-neural-networks-rnns-for-investors>
- [4] AMIN, Shalin, 2023. Embracing AI: Zumper's Journey Towards Smarter Rental Solutions. *Https://www.zumperrentals.com* [online]. [cit. 2025-03-04]. Dostupné z: <https://www.zumperrentals.com/blog/embracing-ai-zumpers-journey-towards-smarter-rental-solutions/>
- [5] AWS.AMAZON.COM, 2024. What is NLP. *Aws.amazon.com* [online]. [cit. 2025-03-06]. Dostupné z: <https://aws.amazon.com/what-is/nlp/>
- [6] BERKOW, Jonathan, 2024. AI Ethics and Regulation: How Investors Can Navigate the Maze. *Alliancebernstein.com* [online]. [cit. 2024-10-08]. Dostupné z: <https://www.alliancebernstein.com/corporate/en/insights/investment-insights/ai-ethics-and-regulation-how-investors-can-navigate-the-maze.html>
- [7] BODIE, Zvi, Alex KANE a Alan J. MARCUS, 2013. *Investments and portfolio management*. 9th edition, global edition. New York: McGraw-Hill/Irwin. ISBN 978-0-07-128914-6.
- [8] BROWN, Sara, 2021. Machine learning, explained. *Mitsloan.mit.edu* [online]. [cit. 2025-03-06]. Dostupné z: <https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained>
- [9] CB INSIGHTS, 2018. A look at 13 AI trends reshaping industries and economies. *Cbinsights.com* [online]. [cit. 2025-10-08]. Dostupné z: <https://www.cbinsights.com/research/report/artificial-intelligence-trends-2018/>
- [10] CB INSIGHTS, 2024. The AI 100 is CB Insights' annual list of the top private AI companies in the world. From new AI architectures to precision manufacturing, this year's winners are tackling some of the hardest challenges across industries. *Cbinsights.com* [online]. [cit. 2025-03-05]. Dostupné z: <https://www.cbinsights.com/research/report/artificial-intelligence-top-startups-2024/>

- [11] CFA INSTITUTE, 2022. Ethics and Artificial Intelligence in Investment Management: A Framework for Professionals. *Rpc.cfainstitute.org* [online]. [cit. 2025-10-08]. Dostupné z: <https://rpc.cfainstitute.org/research/reports/2022/ethics-and-artificial-intelligence-in-investment-management-a-framework-for-professionals>
- [12] CLAUDE.AI, 2025. *Claude* [online]. [cit. 2025-03-08]. Dostupné z: <https://claude.ai/new>
- [13] COURSEERA, 2024. What Is Machine Learning? Definition, Types, and Examples. *Coursera.org* [online]. [cit. 2025-03-06]. Dostupné z: https://www.coursera.org/articles/what-is-machine-learning?utm_medium=sem&utm_source=gg&utm_campaign=B2C_EMEA__coursera_FTC_OF_career-academy_pmax-multiple-audiences-country-multi-set2&campaignid=20882109092&adgroupid=&device=c&keyword=&matchtype=&network=x&devicemodel=&adposition=&creativeid=&hide_mobile_promo&gad_source=1&gbraid=0AAAAADdKX6aNeWQFBxQnH9hbzimRJJOLh&gclid=CjwKCAjwjsi4BhB5EiwAFAL0YIwQ3PObN_ndqXD27FFfVFNcfdEKOaicDXaXJHv1ixftuhnnnL5TyBoCWGoQAvD_BwE
- [14] DEEPSEEK.COM, 2025. *Deep Seek* [online]. [cit. 2025-03-08]. Dostupné z: <https://www.deepseek.com>
- [15] DUNIS, Christian, et al. Artificial intelligence in financial markets. London: Palgrave Macmillan, 2016, 344 s. ISBN 9781137488800
- [16] EVROPSKÁ KOMISE PRO EFEKTIVITU JUSTICE, 2024. Excellence and trust in artificial intelligence. *Commission.europa.eu* [online]. [cit. 2024-10-08]. Dostupné z: https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/europe-fit-digital-age/excellence-and-trust-artificial-intelligence_en
- [17] EVROPSKÁ KOMISE, 2024. European approach to artificial intelligence. *Digital-strategy.ec.europa.eu* [online]. [cit. 2025-03-05]. Dostupné z: <https://digital-strategy.ec.europa.eu/en/policies/european-approach-artificial-intelligence>
- [18] FERNANDO, Jason, 2024. What Are Commodities and Understanding Their Role in the Stock Market. *Investopedia.com* [online]. 27.06.2024 [cit. 2024-10-08]. Dostupné z: <https://www.investopedia.com/terms/c/commodity.asp>
- [19] GANTI, Akhilesh, 2024. Foreign Exchange Market: How It Works, History, and Pros and Cons. *Investopedia.cz* [online]. 05.09.2024 [cit. 2024-10-08]. Dostupné z: <https://www.investopedia.com/terms/forex/f/foreign-exchange-markets.asp#:~:text=The%20foreign%20exchange%20market%20is,closing%20only%20on%20the%20weekends>
- [20] GEEKSFORGEEKS, 2025. Support Vector Machine (SVM) Algorithm. *Geeksforgeeks.org* [online]. [cit. 2025-03-09]. Dostupné z: <https://www.geeksforgeeks.org/support-vector-machine-algorithm/>

- [21] GINIMACHINE, 2023. Real-World Applications of AI Credit Scoring Software. *Https://ginimachine.com* [online]. [cit. 2024-10-08]. Dostupné z: <https://ginimachine.com/blog/real-world-applications-of-ai-credit-scoring-software/>
- [22] GOOGLE GEMINI, 2025. *Google Gemini* [online]. [cit. 2025-03-08]. Dostupné z: <https://gemini.google.com/app>
- [23] GRAHAM, Benjamin. Inteligentní investor. Grada, 2007, 504 s. ISBN 978-80-247-1792-0.
- [24] GRAY, Catherine, 2022. How Amazon developed its famous virtual assistant, Alexa. *Aimagazine.com* [online]. [cit. 2024-10-08]. Dostupné z: <https://aimagazine.com/ai-applications/how-amazon-developed-its-famous-virtual-assistant-alexa>
- [25] HAYES, Adam, 2020. Issuer. *Investopedia.com* [online]. 26.06.2020 [cit. 2024-10-08]. Dostupné z: <https://www.investopedia.com/terms/i/issuer.asp>
- [26] HAYES, Adam, 2024. Financial Markets: Role in the Economy, Importance, Types, and Examples. *Investopedia.com* [online]. 05.08.2024 [cit. 2024-10-08]. Dostupné z: <https://www.investopedia.com/terms/f/financial-market.asp>
- [27] HAYES, Adam, 2024. Retail Investor: Definition, What They Do, and Market Impact. *Investopedia.com* [online]. 12.04.2024 [cit. 2024-10-08]. Dostupné z: <https://www.investopedia.com/terms/r/retailinvestor.asp>
- [28] HISTORYOFDATASCIENCE, 2021. Dartmouth Summer Research Project: The Birth of Artificial Intelligence. *Historyofdatascience.com* [online]. [cit. 2025-10-08]. Dostupné z: <https://www.historyofdatascience.com/dartmouth-summer-research-project-the-birth-of-artificial-intelligence/>
- [29] HOWELL, Stephen, 2024. The Future of AI Chatbots: Trends to Watch in 2025 and Beyond. *Medium.com* [online]. [cit. 2025-03-08]. Dostupné z: <https://medium.com/@Stephen-Howell/the-future-of-ai-chatbots-trends-to-watch-in-2025-and-beyond-8f87f27619b7>
- [30] HUANG, Kimberly, 2023. The 4 Types of AI (And Which Tools Email Marketers Use the Most). *Litmus.com* [online]. 22.09.2023 [cit. 2024-10-09]. Dostupné z: <https://www.litmus.com/blog/the-4-types-of-ai>
- [31] CHEN, James, 2024. Algorithmic Trading: Definition, How It Works, Pros & Cons. *Investopedia.com* [online]. [cit. 2025-03-07]. Dostupné z: <https://www.investopedia.com/terms/a/algorithmictrading.asp>
- [32] CHEN, James, 2024. Institutional Investor: Who They Are and How They Invest. *Investopedia.cz* [online]. 23.05.2024 [cit. 2024-10-08]. Dostupné z: <https://www.investopedia.com/terms/i/institutionalinvestor.asp>

- [33] CHEUNG, Matthew, 2024. How-chatgpt-and-chatbots-are-transforming-financial-markets. *Ipushpull.com* [online]. [cit. 2025-03-08]. Dostupné z: <https://ipushpull.com/blog/how-chatgpt-and-chatbots-are-transforming-financial-markets>
- [34] IBM, 2023. Support-vector-machine. IBM. *Ibm.com* [online]. [cit. 2025-03-06]. Dostupné z: <https://www.ibm.com/think/topics/support-vector-machine>
- [35] IBM, 2023. Understanding the different types of artificial intelligence. *Ibm.com* [online]. 12.10.2023 [cit. 2024-10-09]. Dostupné z: <https://www.ibm.com/think/topics/artificial-intelligence-types>
- [36] IBM, 2024. Deep Blue. *Ibm.com* [online]. [cit. 2024-10-08]. Dostupné z: <https://www.ibm.com/history/deep-blue>
- [37] IRELAND, Corydon, 2012. Alan Turing at 100. *News.harvard.edu* [online]. [cit. 2024-10-08]. Dostupné z: <https://news.harvard.edu/gazette/story/2012/09/alan-turing-at-100/>
- [38] JITESH, Sen, 2021. 5 CAPABILITIES OF ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING. *Digitalaptech.com* [online]. [cit. 2025-03-06]. Dostupné z: <https://digitalaptech.com/5-capabilities-of-artificial-intelligence-and-machine-learning/>
- [39] JOSHI, Naveen, 2024. 7 Types Of Artificial Intelligence. *Forbes.com* [online]. 14.04.2024 [cit. 2024-10-09]. Dostupné z: <https://www.forbes.com/sites/cognitiveworld/2019/06/19/7-types-of-artificial-intelligence/#487c98e2233e>
- [40] KNIHOVÁ, Ladislava, 2024. *AI Marketing Playbook – Jak ChatGPT a umělá inteligence mění svět marketingu*. Grada. ISBN 978-80-271-5226-1.
- [41] KOHOUT, Pavel. *Investice – Nová strategie*. 1. vydání. Grada, 2018, 216 s. ISBN 978-80-271-2101-4.
- [42] KUN.UZ, 2024. Samarkand and Tianjin plan \$1.6 billion industrial park with focus on electric vehicle parts and AI. *Kun.uz* [online]. [cit. 2024-10-08]. Dostupné z: <https://kun.uz/en/news/2024/09/09/samarkand-and-tianjin-plan-16-billion-industrial-park-with-focus-on-electric-vehicle-parts-and-ai>
- [43] LEEWAYHERTZ, 2024. AI for portfolio management: Overview, benefits, use cases, implementation and ethical considerations. *Leewayhertz.com* [online]. [cit. 2025-03-07]. Dostupné z: <https://www.leewayhertz.com/ai-for-portfolio-management/>
- [44] LI, Haolin, Shuyang JIANG, Lifeng ZHANG, Siyuan DU, Guangnan YE a Hongfeng CHAI, 2024. Fraud Detection with Binding Global and Local Relational Interaction. *Arxiv.org* [online]. [cit. 2025-03-08]. Dostupné z: <https://arxiv.org/html/2402.17472v1>
- [45] MARR, Bernard, 2018. How Much Data Do We Create Every Day? The Mind-Blowing Stats Everyone Should Read. *Forbes.com* [online]. [cit. 2024-10-08]. Dostupné z: <https://www.forbes.com/sites/bernardmarr/2018/05/21/how-much-data-do-we-create-every-day-the-mind-blowing-stats-everyone-should-read/#61c686d260ba>

- [46] MATHWORKS, 2024. What Is Long Short-Term Memory (LSTM)? Learn how LSTMs work, where to apply LSTMs, and how to design LSTMs. *Mathworks.com* [online]. [cit. 2025-03-06]. Dostupné z: <https://www.mathworks.com/discovery/lstm.html>
- [47] MCDONOUGH, Michael, 2024. Siri. *Britannica.com* [online]. [cit. 2024-10-08]. Dostupné z: <https://www.britannica.com/technology/Siri>
- [48] MCKINSEY GLOBAL INSTITUTE, 2017. CHINA'S DIGITAL ECONOMY A LEADING GLOBAL FORCE. *Mckinsey.com* [online]. [cit. 2024-10-08]. Dostupné z: <https://www.mckinsey.com/~media/mckinsey/featured%20insights/China/Chinas%20digital%20economy%20A%20leading%20global%20force/MGI-Chinas-digital-economy-A-leading-global-force.ashx>
- [49] MEDIUM, 2024. How JPMorgan Chase's COIN is Revolutionizing Financial Operations with AI. *Medium.com* [online]. [cit. 2025-03-07]. Dostupné z: https://medium.com/@the_AI_ZONE/how-jpmorgan-chases-coin-is-revolutionizing-financial-operations-with-ai-120a2938dab7
- [50] MIRJALILI, Seyedali, MIRJALILI, Seyed a LEWIS, Andrew. Grey Wolf Optimizer. *Advances in Engineering Software* [online]. 2014, roč. 69, s. 46–61. DOI: 10.1016/j.advengsoft.2013.12.007.
- [51] MISHRA, Shailendra. Exploring the Impact of AI-Based Cyber Security Financial Sector Management. *Applied Sciences* [online]. 2023, roč. 13, č. 10, s. 5875. DOI: 10.3390/app13105875. Dostupné z: <https://www.mdpi.com/2076-3417/13/10/5875>.
- [52] MIT, 2023. An Introduction to LSTMs in TensorFlow. *Ocw.mit.edu* [online]. [cit. 2025-03-06]. Dostupné z: <https://ocw.mit.edu/courses/res-9-008-brain-and-cognitive-sciences-computational-tutorials/pages/9-an-introduction-to-lstms-in-tensorflow/>
- [53] MITCHELL, Melanie, 2024. The Turing Test and our shifting conceptions of intelligence. *Science.org* [online]. [cit. 2025-10-08]. Dostupné z: doi:10.1126/science.adq9356
- [54] MOGHAR, Adil a HAMICHE, Mhamed. Stock Market Prediction Using LSTM Recurrent Neural Network. *Procedia Computer Science* [online]. 2020, roč. 170, s. 1168–1173. ISSN 1877-0509. DOI: 10.1016/j.procs.2020.03.049
- [55] MOHAMMED, Shariq, MUDALKAR, Pralhad, VERMA, Narinder, PARTHASARATHY, Karthikeyan a YADAV, Ajay. Stock Market Price Prediction Using Machine Learning. In: *2023 International Conference on Smart Systems and Internet of Things (ICSSIT)* [online]. IEEE, 2023, s. 823–828. DOI: 10.1109/ICSSIT55814.2023.10061120.
- [56] NOVOTNÝ, J. Investování na finančních trzích s podporou psychologické analýzy. Ostrava: Key publishing, 2018, 181 s. ISBN 978-80-7418-291-4.

- [57] NWEZE, Michael, AVICKSON, Eli a EKECHUKWU, Gerald. The Role of AI and Machine Learning in Fraud Detection: Enhancing Risk Management in Corporate Finance. *International Journal of Research Publication and Reviews* [online]. 2024, roč. 5. DOI: 10.55248/gengpi.5.1024.2902.
- [58] OPEN AI, 2025. <https://openai.com> [online]. [cit. 2025-03-08]. Dostupné z: <https://openai.com>
- [59] PATIL, Guarav, 2024. AI-Based Credit Scoring: Benefits And Use Cases. <https://ideausher.com> [online]. [cit. 2025-10-08]. Dostupné z: <https://ideausher.com/blog/ai-based-credit-scoring/>
- [60] PLUMMER, 2024. AI in Finance: Revolutionizing the Future of Financial Management. *Datacamp.com* [online]. [cit. 2025-10-08]. Dostupné z: <https://www.datacamp.com/blog/ai-in-finance>
- [61] PRABAKAR, S., KUMAR, Ankit, JAYAKARTHIK, R., VENKATESH, D., PRATHEEBA, S. a KHAN, Bhola. Empirical Evaluation of Stock Market Prediction System using Intelligent Learning Scheme with Data Processing Logic. In: 2024 5th International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV) [online]. Dayananda Sagar University: IEEE, 2024, s. 290–297. DOI: 10.1109/ICICV62344.2024.00050.
- [62] REJNUŠ, Oldřich, 2016. *Finanční trhy*. 20.07.2016. Grada, 384 s. ISBN 978-80-247-5871-8.
- [63] REZAEI, Hossein, BOZORG-HADDAD, Omid a CHU, Xuefeng. Grey Wolf Optimization (GWO) Algorithm. In: BOZORG-HADDAD, Omid. *Advanced Optimization by Nature-Inspired Algorithms* [online]. Singapore: Springer, 2018. DOI: 10.1007/978-981-10-5221-7_9.
- [64] RUIZ, Sebastián, 2024. The-revolution-of-ai-in-financial-services. *Interfaz.io* [online]. [cit. 2025-03-07]. Dostupné z: <https://interfaz.io/2024/08/the-revolution-of-ai-in-financial-services/>
- [65] SETH, Shobhit, 2023. Basics of Algorithmic Trading: Concepts and Examples. *Investopedia.com* [online]. 14.12.2023 [cit. 2024-10-09]. Dostupné z: <https://www.investopedia.com/articles/active-trading/101014/basics-algorithmic-trading-concepts-and-examples.asp>
- [66] SCHMIDT, Michael, 2024. Financial Regulators: Who They Are and What They Do. *Investopedia.com* [online]. 25.07.2024 [cit. 2024-10-08]. Dostupné z: <https://www.investopedia.com/articles/economics/09/financial-regulatory-body.asp>
- [67] SCHWAB, 2024. OTC Stocks and OTC Markets. *Schwab.com* [online]. [cit. 2025-03-05]. Dostupné z: <https://www.schwab.com/stocks/understand-stocks/otc-markets>

- [68] SIDDHARTH, 2024. Stock Price Prediction using LSTM and its Implementation. *Analyticsvidhya.com* [online]. [cit. 2025-03-06]. Dostupné z: <https://www.analyticsvidhya.com/blog/2021/12/stock-price-prediction-using-lstm/>
- [69] STOCKGEIST.AI, 2024. Financial chatbots— A personalized and intelligent stock market guide. *Stockgeist.ai* [online]. [cit. 2025-03-08]. Dostupné z: <https://www.stockgeist.ai/financial-chatbots-a-personalized-and-intelligent-stock-market-guide/#:~:text=Financial%20chatbots%20have%20emerged%20as,amounts%20of%20financial%20data%20swiftly.>
- [70] STROUKAL, Dominik a Jan BERKA, 2024. *Trhy*. Grada. ISBN 978-80-271-3623-0.
- [71] THEFINTECHMAG, 2023. The Promise and Challenges of AI-Based Credit Scoring. *Https://thefintechmag.com* [online]. [cit. 2024-10-08]. Dostupné z: <https://thefintechmag.com/the-promise-and-challenges-of-ai-based-credit-scoring/>
- [72] TRADING VIEW, 2025. *Trading View* [online]. [cit. 2025-03-09]. Dostupné z: <https://www.tradingview.com>
- [73] TUCCI, Linda a Lev CRAIG, 2024. What is machine learning? Guide, definition and examples. *Techtarget.com* [online]. [cit. 2025-03-06]. Dostupné z: <https://www.techtarget.com/searchenterpriseai/definition/machine-learning-ML>
- [74] VESELÁ, J. Investování na kapitálových trzích. 3. vydání. Praha: Wolters Kulwer, 2019, 952 s. ISBN 978-80-7598-212-4.
- [75] VONKO, Dima, 2022. Neural Networks: Forecasting Profits. *Investopedia.com* [online]. [cit. 2025-03-06]. Dostupné z: <https://www.investopedia.com/articles/trading/06/neuralnetworks.asp#toc-use-neural-networks-to-uncover-opportunities>
- [76] WHITBY, Blay, 2003. *Artificial Intelligence: A Beginner's Guide*. Oneworld, 144 s. ISBN 9781851683222.
- [77] YAHOO FINANCE, 2024. Global Generative AI Market 2024-2030: Trends and Analysis of Transformer Models (GPT-1, GPT-2, GPT-3, GPT-4, LaMDA) and Services by Modality, Application and Region. *Finance.yahoo.com* [online]. [cit. 2025-03-05]. Dostupné z: <https://finance.yahoo.com/news/global-generative-ai-market-2024-131800065.html>
- [78] YUAN, Shuhan, et al. Robust Fraud Detection via Supervised Contrastive Learning. *arXiv preprint* [online]. 2023, arXiv:2308.10055. Dostupné z: <https://arxiv.org/abs/2308.10055>.
- [79] ZHANG, PEI, ZHEN, LI a LIANG, 2024. Chat Generative Pre-Trained Transformer (ChatGPT) usage in healthcare. *Sciencedirect.com* [online]. s. 139-143 [cit. 2025-10-08]. Dostupné z: doi:<https://doi.org/10.1016/j.gande.2023.07.002>