

**UNIVERZITA KOMENSKÉHO V BRATISLAVE**  
**FAKULTA MANAGEMENTU**

**ALGORITMICKÉ OBCHODOVANIE FINANČNÝCH AKTÍV**

Diplomová práca

2025

Ing. Peter Macinský

**UNIVERZITA KOMENSKÉHO V BRATISLAVE**  
**FAKULTA MANAGEMENTU**

**ALGORITMICKÉ OBCHODOVANIE FINANČNÝCH AKTÍV**

Diplomová práca

Študijný program: manažment  
Študijný odbor: ekonómia a manažment  
Školiace pracovisko: Katedra ekonómie a financií  
Vedúci záverečnej práce: doc. Ing. Mgr. Urban Kováč, PhD.

**Bratislava 2025**

**Ing. Peter Macinský**



Univerzita Komenského v Bratislave  
Fakulta managementu

---

## ZADANIE ZÁVEREČNEJ PRÁCE

**Meno a priezvisko študenta:** Ing. Peter Macinský  
**Študijný program:** manažment (jednoodborové štúdium, magisterský II. st.,  
externá forma)  
**Študijný odbor:** ekonómia a manažment  
**Typ záverečnej práce:** diplomová  
**Jazyk záverečnej práce:** slovenský  
**Sekundárny jazyk:** anglický

**Názov:** Algoritmické obchodovanie finančných aktív  
*Algorithmic Trading of Financial Assets*

**Cieľ:** Cieľom práce je skúmanie algoritmických obchodných stratégií a ich aplikácia na finančné dáta.  
Navrhnite a vypracujte modely pre implementáciu algoritmických obchodných stratégií a zároveň ich otestujete na dátach z finančných trhov.

**Vedúci:** doc. Ing. Mgr. Urban Kováč, PhD.  
**Katedra:** FM.KEF - Katedra ekonómie a financií  
**FM vedúci katedry:** doc. PhDr. Paulína Mihaľová, PhD.

**Dátum zadania:** 11.09.2023

**Dátum schválenia:** 05.12.2023

doc. PhDr. Paulína Mihaľová, PhD.  
vedúci katedry

.....  
študent

.....  
vedúci práce

## Čestné vyhlásenie

Čestne vyhlasujem, že celú diplomovú prácu na tému *Algoritmické obchodovanie finančných aktív* vrátane všetkých jej príloh a obrázkov, som vypracoval samostatne, a to s použitím literatúry uvedenej v priloženom zozname a nástrojov umelej inteligencie. Vyhlasujem, že nástroje umelej inteligencie som použil v súlade s príslušnými právnymi predpismi, akademickými právami a slobodami, etickými a morálnymi zásadami za súčasného dodržania akademickej integrity a že ich použitie je v práci vhodným spôsobom označené.

Pri príprave tejto práce boli použité nástroje umelej inteligencie GitHub Copilot (na asistenciu pri programovaní v prostredí Sublime Text 4192), ChatGPT od OpenAI (na rešerš odbornej literatúry, návrh štruktúry práce, vysvetlenie teoretických konceptov a úpravu textov) a Microsoft Word (na kontrolu pravopisu, gramatiky a formálnej úpravy textu). Za správnosť výslednej podoby textu zodpovedá autor.

## Abstrakt

MACINSKÝ, Peter: *Algoritmické obchodovanie finančných aktív*. [Diplomová práca] – Univerzita Komenského v Bratislave. Fakulta managementu; Katedra ekonómie a financií – Vedúci: doc. Ing. Mgr. Urban Kováč, PhD. Bratislava: UK, 2025, 59 s.

Táto diplomová práca sa zaoberá problematikou algoritmického obchodovania na finančných trhoch, pričom jej cieľom je návrh, implementácia a testovanie vybraných algoritmických obchodných stratégií založených na technickej analýze. Práca sa sústreďuje na tri hlavné stratégie: stratégiu založenú na jednoduchých klzavých priemeroch (SMA), stratégiu využívajúcu oscilátor RSI a stratégiu založenú na momentovom indikátore. Pre každú z týchto stratégií boli navrhnuté aj modifikácie kombinujúce viacero technických indikátorov s cieľom zlepšiť ich výkonnosť. Metodológia práce zahŕňa aplikáciu týchto stratégií na historické dáta akciových indexov a individuálnych akcií (SPX, DAX, Apple, Microsoft, Tesla, US Steel) za obdobie od roku 2000 do roku 2025. Výkonnosť jednotlivých stratégií bola vyhodnocovaná pomocou ukazovateľov ako celkový výnos, Sharpeho pomer a maximálny pokles (drawdown). Výsledky ukazujú, že efektívnosť obchodných stratégií závisí od použitého finančného nástroja, dĺžky historického obdobia a nastavenia parametrov indikátorov. V závere práca hodnotí prínosy a obmedzenia jednotlivých stratégií a navrhuje možné smerovanie ďalšieho výskumu v oblasti algoritmického obchodovania.

Kľúčové slová: algoritmické obchodovanie, obchodné stratégie, technická analýza, finančné trhy, indikátory

## Abstract

MACINSKÝ, Peter: *Algorithmic Trading of Financial Assets*. [Master Thesis] – Comenius University Bratislava. Faculty of Management; Department of Economics and Finance – Supervisor: Urban KOVÁČ. Bratislava: Comenius University Bratislava, 2025, 59 pp.

This diploma thesis focuses on the issue of algorithmic trading in financial markets, with the aim of designing, implementing, and testing selected algorithmic trading strategies based on technical analysis. The work concentrates on three main strategies: a strategy based on simple moving averages (SMA), a strategy using the RSI oscillator, and a strategy based on a momentum indicator. For each of these strategies, modifications combining multiple technical indicators were also proposed in order to enhance their performance. The methodology includes the application of these strategies to historical data of stock indices and individual stocks (SPX, DAX, Apple, Microsoft, Tesla, US Steel) for the period from 2000 to 2025. The performance of the individual strategies was evaluated using metrics such as total return, Sharpe ratio, and maximum drawdown. The results show that the effectiveness of trading strategies depends on the financial instrument used, the length of the historical period, and the setting of indicator parameters. In conclusion, the thesis evaluates the benefits and limitations of each strategy and suggests possible directions for future research in the field of algorithmic trading.

Key words: algorithmic trading, trading strategies, technical analysis, financial markets, indicators

## Predhovor

Tému algoritmického obchodovania finančných aktív som si zvolil najmä z dôvodu dlhodobého záujmu o financie, investovanie a moderné technológie, ktoré umožňujú automatizáciu procesov na finančných trhoch. V roku 2016 som ukončil inžinierske štúdium v odbore Financie, bankovníctvo a investovanie na Technickej univerzite v Košiciach, kde som sa vo svojej diplomovej práci venoval oblasti teórie hier. Prvú licenciu Národnej banky Slovenska pre prácu vo finančnom sprostredkovaní som získal 15. apríla 2014, takže v tomto odbore aktívne pôsobím už takmer 11 rokov. Od roku 2016 podnikám vo vlastnej spoločnosti, v rámci ktorej sa venujem najmä investičnému poradenstvu.

Moje profesionálne aktivity zahŕňajú správu majetku klientov, pričom v súčasnosti spravujem investičný majetok v hodnote viac než 3 milióny eur pre vyše 600 klientov. Zároveň sa zaujímam o technologický aspekt investovania – už v roku 2006 som navrhol vlastný softvér na správu osobných financií. Hoci sa aktívnemu tradingu nevenujem profesionálne, mám skúsenosti s obchodovaním rôznych inštrumentov, vrátane forexu, akcií, indexov a komodít. Prvý obchod som uskutočnil 11.10.2016 a do konca roka 2023 som ich vykonal celkovo 1117. Zúčastnil som sa aj obchodnej súťaže, kde ma zaujala výkonnosť obchodníkov s vlastnými systémami, čo ešte viac podnietilo moju túžbu pochopiť princípy fungovania algoritmických stratégií.

Motiváciou k tejto práci bola túžba spojiť praktické skúsenosti s akademickým výskumom a získať hlbší pohľad do automatizovaných obchodných systémov. V minulosti som sa len okrajovo venoval nástrojom ako Metatrader, no až teraz som sa rozhodol dôslednejšie preskúmať problematiku návrhu, testovania a vyhodnocovania algoritmických stratégií. Práca je určená všetkým, ktorí sa zaujímajú o možnosti aplikácie technickej analýzy, programovania a kvantitatívneho prístupu v oblasti obchodovania s finančnými aktívami.

Vo svojej práci vychádzam z kombinácie slovenských aj zahraničných zdrojov, pričom aplikujem kvantitatívne metódy testovania obchodných stratégií na historických dátach. Moje hľadisko je orientované prakticky, so snahou o overenie skutočnej výkonnosti stratégií v rôznych trhových podmienkach.

Na tomto mieste by som sa chcel poďakovať vedúcemu mojej diplomovej práce, doc. Ing. Mgr. Urbanovi Kováčovi, PhD., za odborné vedenie, cenné rady a trezivosť počas celého procesu. Osobitná vďaka patrí mojej manželke Janke za vytvorenie harmonického rodinného prostredia, v ktorom som mohol skĺbiť prácu, podnikanie aj štúdium.

# Obsah

<b>ZOZNAM VZORCOV .....</b>	<b>9</b>
<b>ZOZNAM TABULIEK.....</b>	<b>9</b>
<b>ZOZNAM GRAFOV.....</b>	<b>10</b>
<b>ZOZNAM SKRATIEK A ZNAČIEK .....</b>	<b>12</b>
<b>ÚVOD.....</b>	<b>13</b>
<b>1 HISTÓRIA, PREHĽAD A SÚČASNÝ STAV ALGORITMICKÉHO OBCHODOVANIA.....</b>	<b>14</b>
1.1 Vývoj a definícia algoritmického obchodovania.....	14
1.2 Obchodné stratégie a prístupy .....	15
1.3 Technická a kvantitatívna analýza.....	16
1.3.1 <i>Technická analýza</i> .....	17
1.3.2 <i>Kvantitatívna analýza</i> .....	17
1.4 Využitie umelej inteligencie a strojového učenia.....	18
1.5 Vysokofrekvenčné obchodovanie (HFT) .....	19
1.6 Infraštruktúra a technológie používané pri vývoji obchodných systémov .....	20
1.7 Výzvy a riziká algoritmického obchodovania .....	21
1.8 Zhrnutie .....	22
<b>2 CIEĽ.....</b>	<b>24</b>
<b>3 METODIKA PRÁCE .....</b>	<b>25</b>
3.1 Charakteristika objektu skúmania .....	25
3.2 Pracovné postupy.....	25
3.3 Spôsob získavania údajov.....	26
3.4 Použité metódy vyhodnotenia a interpretácie výsledkov .....	26
3.4.1 <i>Stratégia 1 - SMA crossover stratégia</i> .....	26
3.4.2 <i>Stratégia 2 – RSI oscilátorová stratégia</i> .....	27
3.4.3 <i>Stratégia 3 – Momentová investičná stratégia</i> .....	30
3.4.4 <i>Návrh a implementácia momentovej stratégie</i> .....	31
3.5 Štatistické metódy.....	32
<b>4 VÝSLEDKY PRÁCE.....</b>	<b>33</b>
4.1 SMA crossover stratégia.....	33
4.1.1 <i>Analýza stratégie SMA 50/200</i> .....	33
4.1.2 <i>Modifikácie SMA crossover stratégie s rôznymi SMA priemermi</i> .....	35

4.1.3	<i>Analýza SMA crossover stratégie na podkladovom aktíve DAX40</i>	37
4.1.4	<i>Analýza SMA crossover stratégií na inom časovom horizonte</i>	39
4.1.5	<i>Zhrnutie pre SMA crossover stratégie</i>	44
4.2	<b>RSI oscilátorová stratégia</b>	44
4.2.1	<i>Analýza RSI oscilátorovej stratégie</i>	44
4.2.2	<i>Modifikácia RSI oscilátorovej stratégie – zmena prahových hodnôt</i>	48
4.2.3	<i>Modifikácia RSI oscilátorovej stratégie – zmena dĺžky RSI</i>	50
4.2.4	<i>Modifikácia RSI oscilátorovej stratégie – filtrovanie podľa trendu</i>	51
4.2.5	<i>Modifikácia RSI oscilátorovej stratégie – filtrovanie podľa objemu</i>	53
4.2.6	<i>Zhrnutie pre RSI oscilátorové stratégie</i>	54
4.3	<b>Momentová investičná stratégia</b>	56
4.3.1	<i>Analýza momentovej stratégie</i>	56
4.3.2	<i>Modifikácia momentovej stratégie pomocou filtra volatility</i>	57
4.3.3	<i>Modifikácia momentovej stratégie pomocou RSI filtra</i>	58
4.3.4	<i>Modifikácia momentovej stratégie s výnosovým filtrom</i>	59
4.3.5	<i>Zhrnutie momentovej stratégie</i>	60
<b>5</b>	<b>DISKUSIA</b>	<b>61</b>
5.1	<i>Zhrnutie práce</i>	61
5.2	<i>Výsledky testovania SMA crossover stratégie</i>	62
5.3	<i>Výsledky testovania RSI stratégie</i>	63
5.4	<i>Výsledky testovania momentovej stratégie</i>	65
5.5	<i>Diskusia k výsledkom</i>	66
5.5.1	<i>Efektívnosť trhu a hypotéza E. Famu</i>	66
5.5.2	<i>Momentum efekt a porovnanie s výskumom Jegadeesha &amp; Titmana</i>	67
5.5.3	<i>Záver k porovnaniu</i>	68
5.5.4	<i>Záver k hypotéze 1</i>	68
5.5.5	<i>Záver k hypotéze 2</i>	68
5.5.6	<i>Záver k hypotéze 3</i>	69
5.5.7	<i>Záver k hypotéze 4</i>	69
	<b>ZÁVER</b>	<b>70</b>
	<b>ZOZNAM POUŽITEJ LITERATÚRY</b>	<b>72</b>
	<b>PRÍLOHY</b>	<b>74</b>
5.6	<i>Python kód používaný pre analýzu SMA crossover stratégie</i>	74
5.7	<i>Python kód používaný pre analýzu RSI oscilátorovej stratégie</i>	76
5.8	<i>Python kód používaný pre analýzu momentovej stratégie</i>	78

## Zoznam vzorcov

Vzorec 1: Formálna definícia RSI indikátora .....	28
Vzorec 2: Výpočet 6-mesačného výnosu pre každú akciu ku koncu mesiaca .....	31

## Zoznam tabuliek

Tabuľka 1: Porovnanie výkonnosti a rizikovosti SMA50/200 stratégie so stratégiou Buy & Hold (S&P 500).....	34
Tabuľka 2: Porovnanie výkonnosti a rizikovosti modifikovaných SMA stratégií so stratégiou Buy & Hold (S&P 500).....	36
Tabuľka 3: Porovnanie výkonnosti a rizikovosti modifikovaných SMA stratégií so stratégiou Buy & Hold (DAX 40).....	38
Tabuľka 4: Porovnanie výkonnosti a rizikovosti modifikovaných SMA stratégií so stratégiou Buy & Hold po úprave sledovaného časového horizontu (S&P 500).....	40
Tabuľka 5: Porovnanie výkonnosti a rizikovosti modifikovaných SMA stratégií so stratégiou Buy & Hold po úprave sledovaného časového horizontu (DAX 40).....	42
Tabuľka 6: Porovnanie výkonnosti a rizikovosti RSI stratégie a jednotlivých aktív so stratégiou Buy & Hold .....	45
Tabuľka 7: Porovnanie výkonnosti RSI stratégií s rôznymi prahmi citlivosti RSI (Tesla) .....	49
Tabuľka 8: Porovnanie výkonnosti RSI stratégií s rôznymi prahmi citlivosti RSI (Apple) ....	49
Tabuľka 9: Porovnanie výkonnosti RSI stratégií s rôznymi prahmi citlivosti RSI (Microsoft) .....	49
Tabuľka 10: Porovnanie výkonnosti RSI stratégií s rôznymi prahmi citlivosti RSI (US Steel) .....	49
Tabuľka 11: Porovnanie výkonnosti RSI stratégií s rôznymi nastaveniami času (RSI 14 vs. RSI 30).....	50
Tabuľka 12: Porovnanie výkonnosti RSI stratégií s rôznymi nastaveniami času (RSI 14 vs. RSI 7).....	51
Tabuľka 13: Porovnanie výkonnosti RSI stratégie bez a s filtrovaním podľa trendu pomocou SMA 200 indikátora .....	52
Tabuľka 14: Porovnanie výkonnosti RSI stratégie bez a s filtrovaním podľa objemu .....	53

Tabuľka 15: Porovnanie metrík momentovej stratégie a S&P 500 (Buy & Hold) stratégie....	56
Tabuľka 16: Porovnanie metrík momentovej stratégie pred a po filtrovaní na základe volatility sledovaných akcií .....	58
Tabuľka 17: Porovnanie metrík momentovej stratégie pred a po filtrovaní na základe indikátora RSI14.....	59
Tabuľka 18: Porovnanie metrík momentovej stratégie pred a po filtrovaní na základe požadovaného výnosu .....	60

## Zoznam grafov

Graf 1: Detailný pohľad na generovanie obchodných signálov pre akciu Microsoft s vyobrazením hodnoty indikátora RSI.....	29
Graf 2: Vývoj ceny S&P500 s vyobrazením SMA50 a SMA200 a generovanými obchodnými signálmi v sledovanom období.....	33
Graf 3: Detailný pohľad na obdobie roka 2020 a generované obchodné signály v marci a júli .....	34
Graf 4: Porovnanie Sharpe ratio medzi modifikáciami SMA stratégie s Buy & Hold (S&P 500) .....	36
Graf 5: Porovnanie výkonnosti vybraných SMA stratégií s Buy & Hold (S&P500) .....	37
Graf 6: Porovnanie Sharpe ratio medzi modifikáciami SMA stratégie s Buy & Hold (DAX 40) .....	38
Graf 7: Porovnanie výkonnosti vybraných SMA stratégií s Buy & Hold (DAX 40) .....	39
Graf 8: Porovnanie výkonnosti vybraných SMA stratégií s Buy & Hold po úprave sledovaného časového horizontu (S&P 500) .....	41
Graf 9: Porovnanie výkonnosti vybraných SMA stratégií s Buy & Hold po úprave sledovaného časového horizontu (DAX 40) .....	43
Graf 10: Vývoj ceny akcie Tesla a generovanie obchodných signálov .....	45
Graf 11: Vývoj ceny akcie Apple a generovanie obchodných signálov .....	46
Graf 12: Vývoj ceny akcie Microsoft a generovanie obchodných signálov .....	46
Graf 13: Vývoj ceny akcie US Steel a generovanie obchodných signálov .....	47
Graf 14: Graf kumulatívnych výnosov pre každú akciu pri využití stratégií RSI vs. Buy & Hold .....	47

Graf 15: Vývoj ceny akcie Apple s vyobrazením obchodných signálov pri stratégii RSI 14 30/70 a aplikácii filtrovania pomocou trendového filtra SMA 200 .....	52
Graf 16: Vývoj ceny akcie Microsoft s vyobrazením obchodných signálov pri stratégii RSI 14 30/70 a aplikácii filtrovania pomocou objemového filtra .....	54
Graf 17: Porovnanie kumulatívnej výkonnosti momentovej stratégie a S&P 500 (Buy & Hold) stratégie s indikáciou kedy došlo k zmene v portfóliu momentovej stratégie .....	56

## **Zoznam skratiek a značiek**

AI	Artificial Intelligence
ARIMA	Autoregressive Integrated Moving Average
ML	Machine Learning
DBSCAN	Density-Based Spatial Clustering of Applications with Noise
ESMA	European Securities and Markets Authority
FPGA	Field-Programmable Gate Array
GARCH	Generalized AutoRegressive Conditional Heteroskedasticity
HFT	High-Frequency Trading
LFT	Low-Frequency Trading
NASDAQ	National Association of Securities Dealers Automated Quotations
MFT	Medium-Frequency Trading
MQL	MetaQuotes Language
RSI	Relative Strength Index
SEC	The Securities and Exchange Commission
SMA	Simple Moving Average
SVM	Support Vector Machines

## Úvod

Cieľom tejto diplomovej práce je analyzovať možnosti využitia algoritmických obchodných stratégií pri investovaní na finančných trhoch. V kontexte rastúcej dostupnosti finančných dát, výpočtového výkonu a vývoja programovacích nástrojov sa algoritmické obchodovanie stáva čoraz významnejším nástrojom pre investorov a obchodníkov. Automatizácia obchodného rozhodovania umožňuje rýchlejšie reagovať na trhové signály a eliminovať emocionálne faktory.

Táto práca sa preto zameriava na návrh, implementáciu a testovanie vybraných obchodných stratégií s cieľom posúdiť ich výkonnosť a praktickú použiteľnosť. Skúmané stratégie vychádzajú z technickej analýzy a behaviorálneho prístupu k trhu, pričom využívajú historické cenové a objemové dáta. V práci sa budeme zaoberať tromi typmi stratégií – trendovou stratégiou na báze kľzavých priemerov, oscilátorovou stratégiou na báze indikátora RSI a momentovou stratégiou vychádzajúcou z predchádzajúcej výkonnosti akcií.

Každá z týchto stratégií bude implementovaná v programovacom jazyku Python, pričom ich výkonnosť bude testovaná na historických dátach vybraných akciových indexov a individuálnych akcií. Výsledky budú vyhodnotené pomocou metrík ako celkový výnos, Sharpeho pomer či maximálny pokles portfólia a budú porovnávané so stratégiou pasívneho investovania Buy & Hold.

Ambíciou práce je prispieť k lepšiemu porozumeniu fungovania algoritmických prístupov a ich praktickej aplikácie v meniacich sa trhových podmienkach.

# 1 História, prehľad a súčasný stav algoritmického obchodovania

## 1.1 Vývoj a definícia algoritmického obchodovania

Algoritmické obchodovanie (angl. algorithmic trading) predstavuje spôsob obchodovania na finančných trhoch pri ktorom sa nákup a predaj finančných nástrojov uskutočňuje na základe vopred definovaných pravidiel implementovaných do počítačových algoritmov. Tieto algoritmy automatizujú rozhodovacie procesy a umožňujú rýchle a efektívne vykonávanie obchodov bez potreby manuálneho zásahu. Ide o použitie počítačových programov na realizáciu obchodných stratégií s cieľom dosiahnuť konzistentné zisky pri kontrolovanom riziku.

Začiatky algoritmického obchodovania siahajú do 70. a 80. rokov 20. storočia, keď boli burzy ako NASDAQ<sup>1</sup> digitalizované a umožnili elektronické zadávanie príkazov. Následne v 90. rokoch sa objavili prvé obchodné algoritmy, ktoré využívali základné pravidlá obchodovania ako reakciu na cenové pohyby alebo objem obchodov. Prudký rozvoj tejto oblasti nastal po roku 2000, kedy vysoká výpočtová sila a prístup k veľkému množstvu trhových dát umožnili vytvárať sofistikovanejšie kvantitatívne modely. Algoritmické obchodovanie nie je len o rýchlosti, ale aj o optimalizácii rozhodovacích procesov, ktoré môžu zohľadňovať množstvo faktorov ako cena, objem, čas alebo externé signály.

Medzi nástroje, ktoré prispeli k rozšíreniu algoritmického obchodovania, patrí dostupnosť platforiem ako napríklad MetaTrader 4 a MetaTrader 5<sup>2</sup>, ktoré umožňujú retailovým obchodníkom vytvárať, testovať a spúšťať vlastné algoritmy prostredníctvom programovacieho jazyka MQL<sup>3</sup>. V profesionálnej oblasti dominujú platformy ako Interactive Brokers<sup>4</sup>, Bloomberg Terminal<sup>5</sup> či open-source riešenia typu QuantConnect<sup>6</sup> a Backtrader<sup>7</sup>, ktoré podporujú algoritmický vývoj v jazykoch ako Python a C++.

---

<sup>1</sup> NASDAQ = National Association of Securities Dealers Automated Quotations

<sup>2</sup> MetaTrader je populárna obchodná platforma určená najmä pre online obchodovanie na finančných trhoch ako sú menové páry, komodity, indexy, akcie alebo kryptomeny. Dostupné sú online na <https://www.metatrader4.com/> resp. <https://www.metatrader5.com/>.

<sup>3</sup> MQL = MetaQuotes Language

<sup>4</sup> Interactive Brokers (IBKR) je jedna z najväčších a najuznávanejších globálnych brokerských spoločností, ktorá umožňuje investorom a obchodníkom prístup na viac ako 150 burz vo viac ako 30 krajinách sveta. Platforma umožňuje obchodovanie s aktívami: akcie, ETF, opcie, futures, forex, dlhopisy, fondy, kryptomeny.

<sup>5</sup> Bloomberg Terminal je profesionálny finančný informačný systém vyvinutý spoločnosťou Bloomberg, ktorý poskytuje v reálnom čase dáta z finančných trhov a rôzne analytické nástroje.

<sup>6</sup> QuantConnect je moderná platforma pre algoritmické obchodovanie, ktorá umožňuje vývoj, backtestovanie a nasadenie obchodných stratégií na trhoch v reálnom čase.

<sup>7</sup> Backtrader je populárny open-source Python framework na spätné testovanie a vývoj obchodných stratégií. Pomocou historických dát umožňuje simulovať ako by sa správala obchodná stratégia v minulosti.

Za historický míľnik možno považovať nástup firiem ako Renaissance Technologies, ktorej vlajkový fond Medallion Fund dosiahol medzi rokmi 1988 a 2018 priemerný ročný výnos 39 % po odpočítaní poplatkov<sup>8</sup>. Táto spoločnosť využívala striktné kvantitatívne prístupy, pričom detaily jej stratégií zostávajú prísne utajené. Ďalším známym príkladom je firma Two Sigma, ktorá kombinuje strojové učenie a veľké dáta pri vytváraní svojich stratégií.

Kým podľa Aldridge<sup>9</sup> tvorilo algoritmičné obchodovanie 25 % objemu obchodov v USA, dnes – o dekádu neskôr, ho mnohé výskumy odhadujú až na **viac ako 60 %**. Jeho význam neustále rastie nielen medzi profesionálnymi účastníkmi trhu, ale aj medzi jednotlivcami, ktorí využívajú stále dostupnejšie nástroje na vývoj a spätné vyhodnocovanie (backtestovanie).

## 1.2 Obchodné stratégie a prístupy

Algoritmičné obchodovanie zahŕňa široké spektrum obchodných stratégií, ktoré sa líšia podľa povahy vstupných dát, frekvencie obchodovania, časového horizontu aj cieľa. Niektoré sú založené na **technickej analýze**, iné na **kvantitatívnych modeloch**, pričom mnohé kombinujú oba prístupy.

Medzi najrozšírenejšie patrí skupina stratégií, ktoré predpokladajú, že cenový pohyb má tendenciu pokračovať v aktuálnom smere resp. trende, v angličtine označované ako „**trend following**“. Typickým príkladom je stratégia, kde sledujeme prekríženie kľzavých priemerov, angl. „**moving average crossover**“ stratégia, pri ktorej sa vstupné a výstupné signály generujú na základe prieniku dvoch kľzavých priemerov – krátkodobého a dlhodobého. Tieto stratégie sú obľúbené pre svoju jednoduchosť a transparentnosť, hoci ich výkonnosť býva silne závislá od parametrizácie a trhových podmienok.

Iné stratégie predpokladajú, že cena sa po extrémnych výkyvoch navracia k svojej „rovnovážnej“ hodnote. Stratégia návratu k priemeru sa v angličtine označuje ako „**mean reversion**“. Používajú sa tu techniky ako Bollingerove pásma (angl. Bolling Bands), RSI<sup>10</sup> alebo z-score. Tieto stratégie sú vhodné najmä v trhoch s bočným trendom alebo vyššou likviditou.

Ďalšou kategóriou sú **štatistické arbitrážne stratégie**, ktoré sa snažia využiť dočasné neefektívnosti na trhu medzi cenami súvisiacich finančných nástrojov. Pole opisuje túto

---

<sup>8</sup> ZUCKERMAN, Gregory. *The Man Who Solved the Market: How Jim Simons Launched the Quant Revolution*. New York: Penguin Books, 2019, s. 11. ISBN 9780735217980

<sup>9</sup> ALDRIDGE, Irene. *High-Frequency Trading*. 2. vydanie. Hoboken, New Jersey: Wiley, 2013, s. xi-xii ISBN 978-1118343500.

<sup>10</sup> RSI = Relative Strength Index

stratégiu ako systematický prístup založený na pravdepodobnosti a matematickej analýze, pričom často využíva **párové obchodovanie** (angl. pair trading).

V praxi sa čoraz viac uplatňujú aj **momentové stratégie**, ktoré využívajú informácie o predchádzajúcich ziskoch alebo stratách na predikciu budúcich pohybov. Ich účinnosť bola opakovane potvrdená v akademickej aj praktickej literatúre, pričom bývajú často kombinované s filtrami objemu a volatility.

Okrem vyššie uvedených existujú aj tzv. **novinkové stratégie** (angl. news-based trading), ktoré reagujú na fundamentálne alebo sentimentové informácie, často získavané prostredníctvom spracovania prirodzeného jazyka. Moderné algoritmy v tejto oblasti dokážu analyzovať správy v reálnom čase a rozhodovať o nákupoch alebo predajoch v priebehu milisekúnd.

Z hľadiska frekvencie obchodovania sa stratégie delia na nízkofrekvenčné (LFT), ktoré vykonávajú niekoľko obchodov za deň až týždeň, strednofrekvenčné (MFT) a vysokofrekvenčné (HFT), ktoré pracujú na úrovni milisekúnd. Johnson vo svojej knihe uvádza, že aj rozdiel v milisekundách môže pri HFT viesť k zásadným výhodám pri exekúcii obchodov<sup>11</sup>.

Pri výbere stratégie je kľúčové zohľadniť nielen **výnosový potenciál**, ale aj **maximálny pokles, volatilitu, páku, likviditu trhu a transakčné náklady**. Preto sa v praxi často používajú kombinované portfóliá stratégií a tzv. **metastratégie** riadenia rizika. Tie predstavujú nadstavbové systémy, ktoré monitorujú výkonnosť jednotlivých stratégií, dynamicky alokujú kapitál medzi ne, prípadne niektoré stratégie dočasne deaktivujú pri zhoršenej výkonnosti. Ich cieľom je zvýšiť robustnosť celého obchodného systému, znížiť volatilitu výnosov a zabezpečiť dlhodobu udržateľnú výkonnosť.

### 1.3 Technická a kvantitatívna analýza

Spojenie technickej a kvantitatívnej analýzy tvorí základ väčšiny moderných algoritmických stratégií. Ich účinnosť závisí od kvality vstupných dát, zvolenej metodiky a dôslednosti v procese validácie.

---

<sup>11</sup> JOHNSON, Barry. *Algorithmic Trading and DMA: An Introduction to Direct Access Trading Strategies*. 4Myeloma Press, 2010, s. 19. ISBN 978-0956399205.

### 1.3.1 Technická analýza

Technická analýza predstavuje jeden z najstarších a najrozšírenejších prístupov k analýze finančných trhov. Vychádza z predpokladu, že všetky relevantné informácie sú už zahrnuté v cene a že historické cenové pohyby majú tendenciu opakovať sa v dôsledku ľudského správania. Technická analýza sa často označuje aj ako „čítanie grafov“, keďže obchodníci sa pri rozhodovaní opierajú o vizuálnu interpretáciu cenových pohybov a objemov.

Základným nástrojom technickej analýzy sú **sviečkové grafy**, ktoré zobrazujú vývoj ceny v čase a poskytujú bohaté informácie o trhovom sentimente (nálade). Na ich základe sa identifikujú rôzne grafické formácie, ako napríklad **hlava a ramená**, **dvojité dno**, **trojuholníky**, **vlajky** alebo **kanály**. Tieto formácie slúžia na predikciu možných budúcich pohybov cien a často sú využívané ako signály pre vstup do alebo výstup z obchodných pozícií.

### 1.3.2 Kvantitatívna analýza

Kvantitatívna analýza ide o krok ďalej – jej cieľom je objektívne modelovanie trhového správania pomocou štatistiky, pravdepodobnosti a numerických metód. Pri návrhu algoritmických stratégií sa uplatňujú techniky ako **regresná analýza**, **časové rady** (ARIMA, GARCH), **klasifikácia dát**, alebo **optimalizácia portfólia**. V rámci validácie sa používajú metriky ako **Sharpeho pomer**, **maximálny pokles** (angl. maximum drawdown) a **výnos/volatilita**.

Zásadný význam má aj práca s historickými dátami a ich spätné vyhodnocovanie (backtestovanie). Dobre navrhnutý backtest pomáha overiť, či stratégia má štatisticky významný výnos pri akceptovateľnej úrovni rizika. Aronson zdôrazňuje, že obchodné signály by mali byť testované pomocou prísneho štatistického rámca, aby sa predišlo náhodným výsledkom a tzv. overfittingu<sup>12,13</sup>.

Dôležitú úlohu zohráva aj vizualizácia dát a ich interpretácia. Pomocou grafov a heatmap je možné lepšie pochopiť správanie stratégie v rôznych trhových podmienkach, napríklad v období vysokej volatility alebo po výrazných trhových udalostiach.

V posledných rokoch sa zvyšuje dôraz na automatickú detekciu vzorov v dátach a kombinovanie technických indikátorov s pokročilými modelmi strojového učenia, ako

---

<sup>12</sup> ARONSON, David. *Evidence-Based Technical Analysis: Applying the Scientific Method and Statistical Inference to Trading Signals*. Hoboken, New Jersey: Wiley, 2006, s. 49-50. ISBN 978-0470008744.

<sup>13</sup> Overfitting (po slovensky prílišné prispôbenie modelu) je jav, ktorý nastáva pri trénovaní modelov, najmä v strojovom učení alebo pri spätnom testovaní obchodných stratégií, keď sa model príliš dobre prispôbi historickým dátam, ale zlyháva na nových (neznámych) dátach.

napríklad **rozhodovacie stromy**, **náhodný les** alebo **neurónové siete**. Tieto modely dokážu spracovať nelineárne vzťahy, ktoré sú pre klasickú technickú analýzu ťažko zachytiteľné.

#### 1.4 Využitie umelej inteligencie a strojového učenia

S rastúcou výpočtovou kapacitou a dostupnosťou dát sa umelá inteligencia (AI) a strojové učenie (ML) stali významnou súčasťou algoritmického obchodovania. Tieto technológie umožňujú vytvárať modely, ktoré sa prispôbujú trhovým podmienkam, nachádzajú skryté vzory v dátach a generujú predikcie založené na nelineárnych vzťahoch, ktoré klasické modely nedokážu zachytiť.

V praxi sa najčastejšie využívajú metódy **učenia s učiteľom** (angl. supervised learning), ako napríklad **logistická regresia**, **rozhodovacie stromy**, **náhodný les**, **SVM** a **neurónové siete**. Tieto algoritmy sa učia z historických dát, kde vstupom sú technické indikátory, fundamentálne premenné alebo sentimentové dáta, a výstupom je napríklad pravdepodobnosť pohybu ceny určitým smerom alebo obchodný signál.

Na druhej strane, **učenie bez učiteľa** (angl. unsupervised learning) sa používa najmä na klasifikáciu trhových režimov, detekciu anomálií alebo zhlukovanie aktív do podobných skupín. V tejto oblasti sa uplatňujú algoritmy ako k-means, DBSCAN, alebo hierarchické zhlukovanie.

Špeciálnu kategóriu tvorí **učenie posilňovaním** (angl. reinforcement learning), ktoré sa zameriava na optimalizáciu rozhodovania v čase. V tomto prípade sa algoritmus učí z prostredia interaktívne – testuje rôzne akcie a za správne rozhodnutia dostáva „odmenu“. Tieto modely sú populárne najmä pri návrhu automatických obchodných agentov.

De Prado upozorňuje, že nasadenie strojového učenia v obchodovaní si vyžaduje veľkú opatrnosť – mnohé modely síce vykazujú výborné výsledky v backtestoch, no zlyhávajú pri reálnom nasadení z dôvodu pretrénovania modelov, dynamiky trhov a šumu v dátach<sup>14</sup>. Preto je nevyhnutné dôsledne aplikovať postupy ako **feature engineering** (t. j. vytváranie a transformácia vstupných premenných s cieľom zvýšiť predikčnú silu modelu), **výber relevantných premenných**, **normalizácia dát**, a **dôsledná validácia** (na out-of-sample vzorkách dát, ktoré neboli použité počas tréningu a slúžia na nezávislé overenie výkonnosti modelu).

---

<sup>14</sup> DE PRADO, Lopez Marco. *Advances in Financial Machine Learning*. Hoboken, New Jersey: Wiley, 2018, s. 151-154. ISBN 978-1119482086.

Zaujímavosťou je, že niektoré hedžové fondy ako Two Sigma, Citadel či Point72 zamestnávajú desiatky dátových vedcov a používajú výhradne AI-modely pri tvorbe obchodných rozhodnutí. Tieto spoločnosti analyzujú nielen cenové dáta, ale aj alternatívne dáta ako počasie, satelitné snímky parkovísk, náladu na sociálnych sieťach alebo ekonomické ukazovatele v reálnom čase<sup>15</sup>.

Využitie umelej inteligencie v obchodovaní teda otvára obrovský potenciál, no zároveň kladie vysoké nároky (okrem iného) na dátovú kvalitu, infraštruktúru a know-how vývojárov.

## 1.5 Vysokofrekvenčné obchodovanie (HFT)

Vysokofrekvenčné obchodovanie (angl. High-Frequency Trading) predstavuje špecifickú formu algoritmickeho obchodovania, ktorá sa vyznačuje extrémne krátkym časovým horizontom držania pozícií, vysokou frekvenciou obchodov a dôrazom na minimálne oneskorenie v exekúcii príkazov. V rámci HFT sa obchody realizujú v milisekundách až mikrosekundách a výnosy vyplývajú často z veľmi malých cenových rozdielov na obrovskom objeme transakcií<sup>16</sup>.

HFT systémy sa spoliehajú na špičkovú technologickú infraštruktúru vrátane kolokácie serverov priamo na burzách, optických liniek s nízkou latenciou, programovania v nízkoúrovňových jazykoch (napr. C++) a využitia FPGA<sup>17</sup> hardvéru na ešte rýchlejšie spracovanie dát. Každá mikrosekunda môže predstavovať konkurenčnú výhodu – preto firmy investujú milióny dolárov do optimalizácie rýchlosti.

Medzi najčastejšie stratégie HFT patrí:

- **Tvorba trhu** (angl. Market making) – poskytovanie likvidity tým, že algoritmus súčasne zadáva nákupné a predajné príkazy a zarába na rozdiel (angl. spread)
- **Časová arbitráž** (angl. Latency arbitrage) – využívanie oneskorení v prenose informácií medzi rôznymi burzami alebo obchodnými systémami
- **Štatistická arbitráž v mikromierke** – zameraná na veľmi krátkodobé odchýlky medzi súvisiacimi aktívami

---

<sup>15</sup> NARANG, K. Rishi. *Inside the Black Box: A Simple Guide to Quantitative and High-Frequency Trading*. 2. vydanie. Hoboken, New Jersey: Wiley, 2013, s. 146-149. ISBN 978-1118362419.

<sup>16</sup> JOHNSON, Barry. *Algorithmic Trading and DMA: An Introduction to Direct Access Trading Strategies*. 4Myeloma Press, 2010, s. 68. ISBN 978-0956399205.

<sup>17</sup> FPGA = Field-Programmable Gate Array

- **Predpovedanie vývoja objednávok** – predikcia správania sa knihy objednávok (napr. keď algoritmus detekuje veľkú neviditeľnú objednávku a reaguje na ňu).

Aldridge uvádza, že HFT systémy často držia pozície len niekoľko sekúnd alebo milisekúnd a ich cieľom nie je odhadovať smer trhu, ale využiť mikrovzory v knihe objednávok alebo výpočtové asymetrie<sup>18</sup>.

Zaujímavým príkladom je firma **Virtu Financial**, ktorá v prvých piatich rokoch svojej existencie vykázala zisk takmer každý obchodný deň – so stratou iba v 1 z 1238 dní<sup>19</sup>. Tento extrémny úspech je pripisovaný nielen rýchlosti a technológii, ale aj prísnej kontrole rizika a precíznemu obchodnému modelu.

Hoci HFT prispieva k zvýšeniu likvidity a efektívite trhov, jeho vplyv je predmetom diskusií. Kritici upozorňujú na riziko narušenia trhov, zvýšenú volatilitu a potenciál pre manipulatívne praktiky, ako sú napríklad „quote stuffing“ alebo „spoofing“ (obidve vysvetlené ďalej). Na tieto riziká reagujú regulátori prísnejšími požiadavkami na transparentnosť a monitoring algoritmov.

Možno povedať, že HFT predstavuje **technologický vrchol** algoritmického obchodovania, ktorý však kladie obrovské nároky na infraštruktúru, dátové zdroje a reguláciu.

## 1.6 Infraštruktúra a technológie používané pri vývoji obchodných systémov

Úspešná implementácia algoritmického obchodovania si vyžaduje vhodnú kombináciu technológií a nástrojov. Kľúčovými zložkami sú programovacie jazyky, obchodné platformy, historické dáta, a softvér na testovanie stratégií.

Najčastejšie využívaným programovacím jazykom je **Python**, a to vďaka svojej jednoduchej syntaxi a dostupnosti knižníc zameraných na analýzu dát a vývoj stratégií (napr. pandas, NumPy, TA-Lib, Backtrader). V oblastiach, kde je rozhodujúca rýchlosť – ako napríklad pri vysokofrekvenčnom obchodovaní – sa používajú aj jazyky ako C++ či Java.

Obchodníci pracujú buď s profesionálnymi platformami (napr. Interactive Brokers, Bloomberg Terminal) alebo s retailovými riešeniami ako MetaTrader 4/5, TradingView či NinjaTrader, ktoré umožňujú testovanie aj automatické obchodovanie.

---

<sup>18</sup> ALDRIDGE, Irene. *High-Frequency Trading*. 2. vydanie. Hoboken, New Jersey: Wiley, 2013, s. 13-14. ISBN 978-1118343500.

<sup>19</sup> LEWIS, Michael. *Flash Boys: A Wall Street Revolt*. New York: W. W. Norton & Company, 2015, s. 110. ISBN 978-0393351590.

Jedným z najdôležitejších komponentov každého algoritmu sú historické trhové dáta, ktoré slúžia na backtestovanie stratégií. Kvalita, granularita a rozsah týchto dát významne ovplyvňujú spoľahlivosť výsledkov. Dôležité je zohľadniť aj faktory ako **poplatky, likviditu, cenový sklz** (angl. slippage) a **realistické trhové podmienky**, aby sa predišlo skresleným výsledkom backtestu.

Pre výskumné účely a vývoj sa čoraz viac využívajú aj open-source riešenia a cloudové platformy ako QuantConnect alebo Backtrader, ktoré umožňujú simulovať stratégie na rôznych typoch aktív, časových rámcoch a dátových zdrojoch.

## 1.7 Výzvy a riziká algoritmického obchodovania

Napriek výrazným výhodám, ktoré algoritmické obchodovanie prináša – ako sú rýchlosť, presnosť a konzistentnosť – jeho využívanie prináša aj množstvo výziev a rizík. Tieto sa môžu týkať tak technických aspektov, ako aj samotného trhového prostredia.

Jedným z najčastejších problémov je tzv. **overfitting**, teda prílišné prispôbenie stratégie historickým dátam. Takáto stratégia síce dosahuje výborné výsledky v spätnom testovaní, no v reálnom prostredí často zlyháva, pretože bola „naučená“ reagovať na špecifické vzory, ktoré už na trhu nemusia existovať<sup>20</sup>. De Prado upozorňuje<sup>21</sup>, že práve pretrénovanie je najväčším nepriateľom kvantitatívnych obchodníkov a vyžaduje dôsledné použitie štatistických metód validácie na nezávislej vzorke dát, teda na dátach, ktoré neboli použité pri návrhu optimalizovaní obchodnej stratégie.

Ďalšou výzvou je **latencia a kvalita exekúcie**, ktoré môžu spôsobiť, že algoritmus síce identifikuje správny signál, ale kvôli oneskoreniu alebo zlej likvidite ho nedokáže realizovať za výhodnú cenu. To vedie k cenovému sklzu a znižuje efektívnosť stratégie. Vysokofrekvenčné stratégie sú na tieto faktory obzvlášť citlivé<sup>22</sup>.

Riziká algoritmického obchodovania sa netýkajú len technických problémov, ale aj extrémnych udalostí, ktoré môžu spôsobiť masívne straty. Príkladom je tzv. Flash Crash z roku

---

<sup>20</sup> ARONSON, David. *Evidence-Based Technical Analysis: Applying the Scientific Method and Statistical Inference to Trading Signals*. Hoboken, New Jersey: Wiley, 2006, s. 61-62. ISBN 978-0470008744.

<sup>21</sup> DE PRADO, Lopez Marco. *Advances in Financial Machine Learning*. Hoboken, New Jersey: Wiley, 2018, s. 113-114. ISBN 978-1119482086.

<sup>22</sup> CHAN, P. Ernest. *Quantitative Trading: How to Build Your Own Algorithmic Trading Business*. Hoboken, New Jersey: Wiley, 2009, s. 90. ISBN 9780470284889.

2010, keď v priebehu niekoľkých minút došlo k prudkému poklesu akciových indexov v USA v dôsledku interakcie viacerých algoritmov<sup>23</sup>.

Sofistikované algoritmy môžu navyše viesť k neželaným trhovým javom, ako sú „**quote stuffing**“ – zaplavovanie trhu príkazmi s cieľom spomaliť ostatných účastníkov alebo „**spoofing**“ – zadávanie falošných príkazov s úmyslom manipulovať trhom. Takéto praktiky sú nelegálne a podliehajú sankciám, no ich detekcia je náročná<sup>24</sup>.

Dôležitou otázkou je aj regulácia algoritmického obchodovania, ktorá sa líši podľa jurisdikcie. Vo viacerých krajinách existujú povinnosti týkajúce sa testovania algoritmov, uchovávanía záznamov o rozhodnutiach, ako aj zodpovednosti za prípadné škody spôsobené autonómnymi systémami. Orgány ako Európsky orgán pre cenné papiere a trhy (ESMA) a Komisia pre cenné papiere USA (SEC) zaviedli pravidlá pre prevádzku HFT systémov, vrátane požiadaviek na tzv. **trhové poistky** (angl. circuit breakers) a **stresové testovanie algoritmov**<sup>25</sup>.

Napokon, vývoj algoritmov je náročný aj z hľadiska komplexnosti a nákladov na vývoj, ktoré môžu byť značné. Najlepšie systémy sú výsledkom práce interdisciplinárnych tímov, ktoré spájajú znalosti z oblasti matematiky, informatiky, financií a psychológie trhu.

## 1.8 Zhrnutie

Algoritmické obchodovanie sa v posledných desaťročiach vyprofilovalo ako jeden z najvýznamnejších trendov vo finančnom sektore. Spojením informatiky, štatistiky a ekonomickej teórie umožňuje realizovať obchodné stratégie s vysokou presnosťou, rýchlou a mierou automatizácie, ktorá by bola pri manuálnom obchodovaní nepredstaviteľná.

V tejto kapitole bol predstavený prehľad vývoja algoritmického obchodovania, základných prístupov a typov stratégií, ako aj metód technickej a kvantitatívnej analýzy. Osobitná pozornosť bola venovaná pokročilejším prístupom využívajúcim umelú inteligenciu a strojové učenie, ako aj vysokofrekvenčnému obchodovaniu, ktoré predstavuje technologicky najnáročnejšiu formu tejto disciplíny.

Zároveň boli popísané technológie a infraštruktúra nevyhnutná pre návrh a testovanie obchodných systémov, ako aj výzvy a riziká, ktorým obchodníci čelia pri reálnom nasadení

---

<sup>23</sup> LEWIS, Michael. *Flash Boys: A Wall Street Revolt*. New York: W. W. Norton & Company, 2015, s. 81-82. ISBN 978-0393351590.

<sup>24</sup> ALDRIDGE, Irene. *High-Frequency Trading*. 2. vydanie. Hoboken, New Jersey: Wiley, 2013, s. 201-202. ISBN 978-1118343500.

<sup>25</sup> NARANG, K. Rishi. *Inside the Black Box: A Simple Guide to Quantitative and High-Frequency Trading*. 2. vydanie. Hoboken, New Jersey: Wiley, 2013, s. 197-199. ISBN 978-1118362419.

algoritmov – od problémov s overfittingom, cez sklzy, až po regulačné požiadavky a systémové riziká.

Získané poznatky predstavujú teoretický základ pre ďalšiu časť práce, v ktorej budú navrhnuté konkrétne algoritmické stratégie a následne ich budeme testovať na historických dátach. Cieľom bude overiť, do akej miery sú vybrané prístupy schopné generovať zisk pri kontrolovanom riadení rizika.

## 2 Cieľ

Cieľom diplomovej práce je skúmanie algoritmických obchodných stratégií a ich aplikácia na finančné dáta. Hlavnou úlohou je návrh na vypracovanie modelov pre implementáciu algoritmických obchodných stratégií a zároveň ich otestovanie na dátach z finančných trhov.

Dôraz bude kladený na vyhodnotenie výkonnosti jednotlivých stratégií v porovnaní s pasívnym investičným prístupom (Buy & Hold).

Konkrétne bude cieľom:

- navrhnúť a analyzovať tri algoritmické obchodné stratégie založené na technickej analýze
- otestovať ich výkonnosť na historických dátach rôznych finančných aktív (akcie, akciové indexy)
- porovnať ich s výnosmi referenčnej stratégie typu Buy & Hold
- vyhodnotiť efektivitu jednotlivých prístupov pomocou vybraných ukazovateľov výkonnosti

Následne budeme overovať nasledovné hypotézy:

- Hypotéza 1: Výkon SMA stratégií výrazne ovplyvňuje zvolená dĺžka kľzavých priemerov použitá pre testovanie.
- Hypotéza 2: Algoritmická stratégia založená na indikátore RSI dosahuje významne vyšší výnos než pasívne investovanie.
- Hypotéza 3: Momentová stratégia generuje vyššie výnosy v porovnaní s náhodným výberom aktív, čím spochybňuje teóriu efektívneho trhu.
- Hypotéza 4: Výkonnosť algoritmických stratégií je vyššia na amerických akciových trhoch než na nemeckom indexe DAX.

## 3 Metodika práce

### 3.1 Charakteristika objektu skúmania

Navrhované algoritmické obchodné stratégie boli skúmané a testované na historických dátach indexov S&P 500 a DAX 40 a ďalej na akciách spoločností Tesla, Microsoft, Apple a US Steel.

Skúmané boli v rôznych časových obdobiach. Časový horizont pri testovaní indexov sme zvolili 01.01.1975 do 31.01.2025, teda výkonnosť sme analyzovali na **50 ročných dátach**, neskôr na kratšom časovom horizonte so začiatkom **01.01.2000**.

Akciové tituly sme skúmali na časovom horizonte od **1. januára 2000 do 31. januára 2025**, s výnimkou akcie Tesla, ktorá sa verejne obchoduje od 29.06.2010, čo bolo pri testovaní zohľadnené.

Pre každú stratégiu boli vypočítané štandardné ukazovatele výkonnosti, najmä:

- Celkový výnos (% zhodnotenie)
- Sharpe ratio (výnos vzhľadom na volatilitu)
- Maximálny pokles (angl. drawdown, najväčší pokles portfólia od maxima po minimum)

Porovnanie s Buy & Hold stratégiou slúžilo ako referenčný základ na posúdenie efektívnosti a vhodnosti jednotlivých prístupov.

### 3.2 Pracovné postupy

Práca bola realizovaná v niekoľkých krokoch.

V úvode práce bol vykonaný rešerš odbornej literatúry z oblasti technickej analýzy, behaviorálnych financií a algoritmického obchodovania. Na základe štúdia relevantných výskumov (napr. Jegadeesh a Titman, 1993) boli zvolené tri obchodné stratégie na testovanie: SMA crossover, RSI stratégia a momentová stratégia.

Nasledoval zber a príprava dát.

Historické dáta akcií indexov (S&P 500, DAX 40) a akcií (Apple, Microsoft, Tesla, US Steel) boli získané vo forme CSV súborov z verejne dostupných zdrojov. Následne boli pomocou knižníc `pandas` a `numpy` v jazyku Python spracované do formátu vhodného na

testovanie: doplnené o denné zmeny, percentuálne výnosy, kľzavé priemery, RSI a iné potrebné indikátory.

Všetky stratégie boli implementované ako samostatné funkcie v jazyku Python s možnosťou parametrizácie vstupov parametrov (napr. dĺžka RSI, dĺžky SMA). Ďalej boli urobené výpočty požadovaných metrík výkonnosti ako celkový výnos, Sharpe ratio a maximálny pokles.

Používaná verzia Python bola 3.13.2 s aktuálnymi knižnicami. Programovanie prebiehalo v rozhraní Sublime Text 4, verzia 4192.

Stratégie boli testované na potrebnom historickom období (1.1.1975 – 31.1.2025) a porovnávané s benchmarkom (Buy & Hold stratégiou). Výsledky boli vizualizované pomocou knižnice `matplotlib` vo forme vývojových grafov alebo tabuliek výkonnosti.

Po otestovaní jednotlivých stratégií bola vykonaná analýza ich výkonnosti naprieč rôznymi aktívami a trhmi. Dôraz bol kladený na zistenie ako ovplyvňuje zmena parametrov a dĺžka dátového obdobia výsledky stratégií.

Na základe výsledkov boli overené definované hypotézy a následne sformulované závery o výkonnosti jednotlivých prístupov a ich využiteľnosti v praxi.

Textová časť diplomovej práce bola priebežne vypracovávaná popri programovaní a testovaní s dôrazom na systematické dokumentovanie metodiky, výsledkov a ich interpretácie. Zároveň bola dopĺňaná zaujímavými grafmi alebo tabuľkami pre lepšie zachytenie výsledkov.

### **3.3 Spôsob získavania údajov**

Použité boli historické OHLCV (Open, High, Low, Close, Volume) dáta z dobre verejne dostupných databáz alebo z platformy Yahoo Finance. Vybrané boli dáta s rôznou dĺžkou časového horizontu a periodicitou podľa návrhu konkrétnej obchodnej stratégie.

### **3.4 Použité metódy vyhodnotenia a interpretácie výsledkov**

#### **3.4.1 Stratégia 1 - SMA crossover stratégia**

##### ***3.4.1.1 Úvod do SMA stratégií***

Prvou analyzovanou stratégiou bola SMA crossover stratégia (Simple Moving Average), ktorá sme aplikovali na historické dáta indexov S&P 500 a DAX 40. Testované boli rôzne dĺžky krátkodobého a dlhodobého kľzavého priemeru a rôzne časové obdobia. Výsledky stratégií boli

porovnané s výkonnosťou Buy & Hold stratégie na rovnakých dátach. Cieľom bolo identifikovať či a kedy má SMA stratégia výkonnosťnú výhodu oproti pasívnemu prístupu.

Jednoduchý kĺzavý priemer (angl. Simple Moving Average, skratka SMA) patrí medzi najzákladnejšie a zároveň najpoužívanjšie technické indikátory v oblasti technickej analýzy. Ide o priemer uzatváracích cien za definovaný počet dní, napríklad 20, 50, 100 alebo 200.

SMA stratégie fungujú na princípe prieniku dvoch kĺzavých priemerov:

- **Krátkodobý SMA** – citlivejší na aktuálne cenové pohyby (napr. 50 dní)
- **Dlhodobý SMA** – hladší indikátor dlhodobejšieho trendu (napr. 200 dní)

SMA stratégie predpokladajú, že keď krátkodobý priemer prekročí dlhodobý smerom nahor ide o býčí signál a investor vstupuje do nákupnej long pozície. Signálu sa hovorí aj **zlatý kríž** (angl. golden cross). Naopak, keď krátkodobý priemer klesne pod dlhodobý priemer, ide o tzv. **smrťiaci kríž** (angl. death cross), čo je medvedí signál a investor z trhu vystupuje.

Výhodou je jednoduchosť a transparentnosť stratégií. Znižuje sa subjektívne rozhodovanie, hodí sa však skôr pre dlhšie investičné horizonty.

Nevýhodou je oneskorená reakcia stratégií, keďže reaguje až na zmenu trendu. Výsledky môže výrazne ovplyvniť aj nastavená dĺžka priemerov, čo sa prejaví aj pri našom testovaní.

### **3.4.1.2 Návrh stratégie SMA crossover**

SMA stratégiu sme implementovali ako prienik dvoch kĺzavých priemerov – **SMA50** teda 50-denný krátkodobý priemer a **SMA200**, 200-denný dlhodobý priemer.

Aplikovali sme ju na historických dátach indexu **S&P 500**.

Časový horizont sme zvolili od 01.01.1975 do 31.01.2025, teda analýzu sme vykonávali na **50 ročných dátach**. Prvý návrh stratégie sme nazvali **SMA 50/200**.

## **3.4.2 Stratégia 2 – RSI oscilátorová stratégia**

### **3.4.2.1 Úvod do RSI oscilátorových stratégií**

Druhá stratégia bola založená na indikátore RSI (Relative Strength Index), ktorý patrí medzi najpoužívanjšie oscilátory technickej analýzy. Stratégia bola testovaná na historických dátach akcií spoločností Tesla, Microsoft, Apple a US Steel. Boli preskúvané rôzne prahy citlivosti RSI pre generovanie nákupných a predajných signálov a zároveň sa stratégia

modifikovala pridaním filtrov. Cieľom bolo overiť výkonnosť RSI stratégie v porovnaní s Buy & Hold stratégiou a následne testovať jej správanie pri rôznych modifikáciách.

Relative Strength Index (RSI) je populárny technický indikátor, ktorý bol vyvinutý J. Wellesom Wilderom v roku 1978. RSI patrí medzi **oscilátory**, teda indikátory, ktoré oscilujú medzi dvoma pevne stanovenými hodnotami – v prípade RSI **medzi 0 a 100**. Cieľom tohto indikátora je identifikovať stavy **prekúpenosti** a **prepredanosti** aktíva, čo obchodníkom umožňuje načasovať vstupy a výstupy z trhu.

RSI vyjadruje pomer medzi priemernými ziskami a stratami za zvolené obdobie, najčastejšie je to **14 dní**.

Výpočet RSI sa riadi nasledovným vzorcom:

$$RSI = 100 - \frac{100}{(1 + RS)}, \text{ kde } RS = \frac{\text{priemerný zisk}}{\text{priemerná strata}}$$

#### Vzorec 1: Formálna definícia RSI indikátora

Ak hodnota RSI prekročí hranicu **70**, považuje sa aktívum za **prekúpené**, čo môže signalizovať potenciálny obrat smerom nadol. Naopak, hodnota RSI pod **30** signalizuje **prepredanosť**, teda možnosť obratu smerom nahor. Tieto úrovne sú však iba orientačné a môžu byť upravované v závislosti od konkrétneho aktíva, časového rámca či celkovej volatility trhu.

Vďaka svojej jednoduchej interpretácii a výpočtu sa RSI stal jedným z najpoužívanejších nástrojov v technickej analýze. Využíva sa nielen na generovanie obchodných signálov, ale aj ako doplnkový nástroj pri filtrovaní trendov alebo potvrdzovaní iných indikátorov.

Na podobnej báze a v spojení so sledovaním ďalších sentimentov dnes vznikajú aj rôzne iné nástroje ako investičné barometre alebo tzv. Fear & Greed indexy.

#### 3.4.2.2 Návrh RSI oscilátorovej stratégie

V rámci tejto práce sme sa zamerali na návrh a testovanie jednoduchšej RSI stratégie so štandardnými parametrami – **14-dňovým RSI** a prahovými hranicami **30 a 70**. Tieto hodnoty predstavujú najčastejšie používané nastavenia v praxi a slúžia na identifikáciu prepredaných a prekúpených stavov aktíva.

Stratégiu sme aplikovali na historické denné dáta štyroch akcií: **Tesla (TSLA)**, **Apple (AAPL)**, **Microsoft (MSFT)** a **US Steel (X)**, v období od **1. januára 2000 do 31. januára 2025**. Výber akcií bol uskutočnený s cieľom pokryť rôzne sektory – technologický (Apple, Microsoft), automobilový (Tesla) a priemyselný (US Steel). Zároveň sme vďaka rozdielnej

dĺžke historických dát mohli sledovať vplyv časového horizontu na výkonnosť stratégie, keďže akcia spoločnosti Tesla bola uvedená na burzu až 29. júna 2010.

Časový rozsah testovania bol zvolený aj na základe predchádzajúcich skúseností s testovaním stratégií typu SMA crossover, kde sa ukázalo, že po roku 2000 došlo na finančných trhoch k výraznejším zmenám vo výsledkoch. Výsledky stratégií testovaných v tomto období sú preto relevantnejšie a lepšie odzrkadľujú súčasné trhové podmienky.


Navrhovaná RSI stratégia sa riadila nasledovnými pravidlami:

**Nákupný signál (Buy):** Keď hodnota RSI klesne pod 30 a následne sa vráti nad 30, otvorí sa dlhá pozícia (nákup akcie) pri otváracíj cene nasledujúceho obchodného dňa.

**Predajný signál (Sell):** Keď hodnota RSI stúpne nad 70 a následne klesne pod 70, existujúca dlhá pozícia sa **zatvára** (predaj akcie) pri otváracíj cene nasledujúceho obchodného dňa.

V stratégii neuvažujeme transakčné náklady, sklz (angl. slippage) ani poplatky za držbu pozície. Obchodovanie bolo long-only, teda nevstupujeme do krátkych pozícií. Vždy bola otvorená maximálne jedna pozícia.

Cieľom tejto základnej stratégie bolo otestovať, či samotný RSI dokáže generovať ziskové obchodné signály pri rôznych typoch akcií a časových horizontoch. Neskôr sme túto stratégiu ďalej modifikovali a rozširovali, aby sme preskúmali možnosti jej zlepšenia a zvýšenia robustnosti.



Graf 1: Detailný pohľad na generovanie obchodných signálov pre akciu Microsoft s vyobrazením hodnoty indikátora RSI

Graf zobrazuje výseč z časovej osi pre akciu Microsoft a približuje detekciu obchodných signálov pri prekročení prahových hodnôt RSI. Zelená šípka smerom nahor znamená, že stratégia detekuje prepredanosť aktíva a vstupuje sa do nákupnej long pozície. Tá sa uzatvára po prekročení prahovej hodnoty pre prekúpenosť aktíva a jej uzatvorenie signalizuje červená šípka nadol.

Po návrhu RSI stratégie sme pristúpili k jej spätnej analýze (backtestovaniu) na historických dátach štyroch akcií: Tesla, Apple, Microsoft a US Steel. Cieľom analýzy bolo porovnať výkonnosť RSI stratégie so základnou stratégiou Buy & Hold a zhodnotiť rizikové parametre a úspešnosť obchodov.

Výkonnosť stratégie bude vyhodnocovaná prostredníctvom nasledovných metrik:

- **Celkový výnos (%)** – celková kumulovaná zmena hodnoty portfólia za sledované obdobie
- **Sharpe ratio** – pomer priemerného denného výnosu ku volatilitě výnosov, počítaný počas celého obdobia vrátane dní, keď nebola otvorená pozícia
- **Maximálny drawdown (%)** – najväčší pokles hodnoty portfólia od lokálneho maxima
- **Počet obchodov a úspešnosť (win rate)** – počet uzatvorených obchodov a percento ziskových

### 3.4.3 Stratégia 3 – Momentová investičná stratégia

#### 3.4.3.1 Úvod do momentovej stratégie

Tretia analyzovaná stratégia bola založená na princípe momenta (momentum), ktorý vychádza z predpokladu, že aktíva, ktoré v minulosti rástli, budú v raste pokračovať aj naďalej. V rámci tejto stratégie boli identifikované tituly s najvyšším pozitívnym momentom za zvolené obdobie a na ich základe boli generované nákupné signály. Testovanie prebiehalo na historických dátach vybraných akciových titulov (Tesla, Apple, Microsoft, US Steel).

Cieľom bolo overiť, či momentum stratégia dokáže prekonať trhovú priemer a či môže slúžiť ako vhodný nástroj na výber najvýkonnejších aktív v portfóliu.

**Momentové investovanie** (angl. momentum investing) patrí medzi populárne prístupy v oblasti algoritmického obchodovania, ktoré využívajú **zotrvačnosť** vývoja cien finančných aktív. Základnou myšlienkou tejto stratégie je predpoklad, že aktíva, ktoré v nedávnej minulosti vykazovali pozitívnu výkonnosť, budú s vysokou pravdepodobnosťou pokračovať v raste aj v

nasledujúcom období. Rovnako platí, že aktíva so zápornou výkonnosťou majú tendenciu pokračovať v poklese.

Tento prístup vychádza z empirických zistení behaviorálnej ekonómie, podľa ktorých investori nereagujú okamžite na nové informácie, čo spôsobuje oneskorené pohyby cien a vytvára obchodné príležitosti. Momentum stratégia sa tak nesnaží predpovedať budúci vývoj cien na základe fundamentálnych ukazovateľov, ale čisto sleduje historickú výkonnosť, ktorú považuje za indikátor budúceho trendu.

V tejto časti bola navrhnutá a implementovaná jednoduchá momentová stratégia, ktorá na základe historických výnosov vyberá najvýkonnejšie akcie do portfólia.

#### 3.4.4 Návrh a implementácia momentovej stratégie

Navrhovaná momentová stratégia bola založená na jednoduchom princípe absolútneho momenta. Pre každú akciu sme v mesačných intervaloch vypočítavali historickú výkonnosť **za predchádzajúcich 6 mesiacov**. Ak výnos prekročil určitý prah (napr. 0 %, t. j. pozitívna výkonnosť), daná akcia bola zaradená do portfólia na nasledujúci mesiac. V prípade negatívneho výnosu sa do portfólia nezaradila alebo sa nahradila iným titulom s vyšším momentom.

Používali sme nasledovný výpočet:

$$R_{6m} = \frac{P_t}{P_{t-6}} - 1,$$

**Vzorec 2: Výpočet 6-mesačného výnosu pre každú akciu ku koncu mesiaca**

kde  $P_t$  je zatváracia cena v aktuálnom mesiaci a  $P_{t-6}$  je cena pred 6 mesiacmi.

Akcie, ktoré dosiahli kladný výnos  $R_{6m} > 0$  sa kvalifikovali do výberu.

Na začiatku každého mesiaca sme investovali rovnakým dielom do všetkých kvalifikovaných akcií.

Sledovali sme kumulatívny výnos, Sharpe ratio, maximálny pokles portfólia.

Ako časový horizont pre testovanie sme zvolili obdobie 01.01.2000 – 31.01.2025. Testovali sme akcie Tesla, Apple, Microsoft a US Steel s mesačným rebalansovaním.

Keďže akcia Tesly sa začala obchodovať na burze až v polovici 2010, od januára 2011 stratégia už mohla zaraďovať do výberu aj akciu Tesly. Dovtedy sme pracovali len s tromi akciami.

Výsledky obchodnej stratégie sme porovnávali s pasívnym investičným prístupom a stratégiou Buy & Hold v indexe S&P 500.

### 3.5 Štatistické metódy

Pre vyhodnotenie výkonnosti obchodných stratégií boli použité štatistické metódy, ktoré umožnili porovnať efektívnosť jednotlivých prístupov a overiť formulované hypotézy.

Konkrétne boli využité nasledujúce metódy a ukazovatele:

- **Celkový výnos** - Celkový výnos vyjadruje percentuálnu zmenu hodnoty portfólia medzi počiatočným a koncovým dňom testovaného obdobia a vyjadruje zhodnotenie aktíva pri využití danej obchodnej stratégie
- **Sharpe ratio** - Sharpe ratio meria efektívnosť obchodnej stratégie vzhľadom na podstupované riziko. Vyjadruje, koľko výnosu nad bezrizikovú mieru prináša každá jednotka rizika, pričom vyššia hodnota Sharpe ratio naznačuje efektívnejšie riadenie rizika
- **Maximálny pokles** - Tento ukazovateľ ukazuje najväčší zaznamenaný pokles hodnoty portfólia od lokálneho maxima po následné minimum a poukazuje na riziko výraznej straty
- **Porovnanie s benchmarkom** (Buy and Hold) - stratégie boli porovnávané s pasívnym investičným prístupom, pričom sa posudzovalo či testovaná stratégia generuje vyšší výnos oproti benchmarku

## 4 Výsledky práce

V tejto časti práce boli obchodné stratégie aplikované na historické dáta finančných aktív a následne vyhodnotené. Cieľom bolo overiť ich výnosnosť a rizikovosť a porovnať ich s pasívnym prístupom k investovaniu.

### 4.1 SMA crossover stratégia

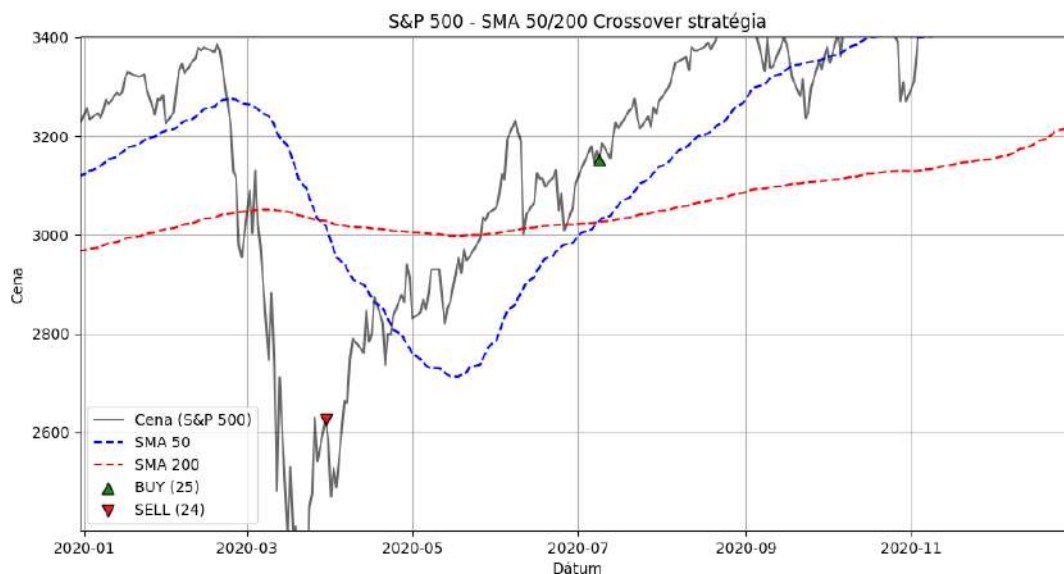
#### 4.1.1 Analýza stratégie SMA 50/200

Pomocou programovacieho jazyka Python sme vytvorili jednoduchú vizualizáciu, ktorá zobrazuje:

- cenu podkladového aktíva (čierna línia)
- krátkodobý kĺzavý priemer SMA50 (modrá čiarkovaná línia)
- dlhodobý kĺzavý priemer SMA200 (červená čiarkovaná línia)
- signály nákupu (BUY) a predaja (SELL) ako výsledok prekriženia týchto priemerov



Graf 2: Vývoj ceny S&P500 s vyobrazením SMA50 a SMA200 a generovanými obchodnými signálmi v sledovanom období



**Graf 3: Detailný pohľad na obdobie roka 2020 a generované obchodné signály v marci a júli**

Tento grafický výstup umožňuje jednoduchú vizuálnu kontrolu bodov vstupu a výstupu na základe zvolených parametrov SMA. Kľúčovým krokom v tejto implementácii bolo správne vyhodnotenie momentov prekríženia priemerov, ktoré následne generujú obchodné signály.

Graf 2 nám poskytuje celkový obraz o vývoji dlhodobých priemerov SMA50 a SMA200. Graf 3 je detailným priblížením vo vybranom období v roku 2020, kde vidno ako dochádza ku kríženiu priemerov a teda aj ku generovaniu obchodných signálov najprv pre výstup a neskôr pre vstup do obchodnej pozície.

Na základe historických dát indexu S&P 500 bola SMA stratégia spätne testovaná a porovnaná s pasívnym prístupom Buy & Hold. Výsledky ukazujú, že aj keď celkový výnos stratégie založenej na prieniku kľzavých priemerov nedosahuje výšku výnosu pri Buy & Hold, výrazne lepšie zvláda obdobia poklesu trhu, čo sa prejavuje v nižšom maximálnom drawdowne.

Metóda	Celkový výnos	Sharpeho pomer	Max. Drawdown
Buy & Hold	<b>8501,07 %</b>	0,51	-64,33 %
SMA stratégia	3978,39 %	<b>0,57</b>	<b>-36,10 %</b>

**Tabuľka 1: Porovnanie výkonnosti a rizikovosti SMA50/200 stratégie so stratégiou Buy & Hold (S&P 500)**

Z porovnania vyplýva:

- **Buy & Hold** dosahuje výrazne vyšší **absolútny výnos**, ale za cenu **výrazne vyššieho rizika** – takmer **dvojnásobný drawdown** oproti SMA stratégii.
- **SMA 50/200** síce dosahuje nižší výnos, ale **Sharpeho pomer je vyšší**, čo znamená, že ide o efektívnejšie využitie rizika
- **Maximálny pokles kapitálu** pri SMA 50/200 je takmer **o 30 percentuálnych bodov nižší**, čo je z pohľadu investora obrovský rozdiel v komforte a psychologickéj záťaži.

Tieto výsledky naznačujú, že SMA stratégia môže byť vhodná alternatíva pre investorov, ktorí kladú dôraz na ochranu kapitálu počas trhových výkyvov, aj za cenu nižšieho dlhodobého výnosu.

#### 4.1.2 Modifikácie SMA crossover stratégie s rôznymi SMA priemermi

V nasledujúcej časti boli testované a analyzované rôzne úpravy SMA crossover stratégie a hľadali sme tak výkonnejšiu obchodnú stratégiu.

Otestovali sme **rôzne kombinácie krátkodobých a dlhodobých priemerov**. Kombinácie sme skladali nasledovne: pre krátkodobé priemery sme použili 10, 20 a 50-denné priemery, pre dlhodobé priemery 50, 100 a 200-denné priemery. Pridali sme tiež špeciálne zvolené priemery a vytvorili sme bonusovú stratégiu SMA 27/86.

Výsledky ukazujú, že niektoré SMA stratégie dokázali významne znížiť riziko (drawdown) pri zachovaní relatívne atraktívneho výnosu.

Stratégia	Celkový výnos	Sharpeho pomer	Max. Drawdown
<b>Buy &amp; Hold</b>	<b>8501,07 %</b>	0,51	-64.33 %
SMA 10/50	1206,48 %	0,46	<b>-35.38 %</b>
SMA 10/100	1289,43 %	0,47	-39.70 %
<b>SMA 10/200</b>	<b>3247,71 %</b>	<b>0,58</b>	<b>-35.92 %</b>
SMA 20/50	844,67 %	0,40	-37.98 %
SMA 20/100	655,62 %	0,34	43.15 %
SMA 20/200	3094,29 %	<b>0,55</b>	-36.04 %

Stratégia	Celkový výnos	Sharpeho pomer	Max. Drawdown
SMA 50/100	1135,81 %	0,39	-39.67 %
<b>SMA 50/200</b>	<b>3978,39 %</b>	<b>0,57</b>	-36.10 %
SMA 27/86	908,02 %	0,40	<b>-33.68 %</b>


Tabuľka 2: Porovnanie výkonnosti a rizikovosti modifikovaných SMA stratégií so stratégiou Buy & Hold (S&P 500)

Pri kombinovaní rôznych priemerov vidíme, že:


- **Buy & Hold** priniesla najvyšší výnos, no aj najvyššie riziko vo forme najvyššieho drawdownu
- **Najlepší Sharpeho pomer:** SMA 10/200 (0,58), tesne za ním SMA 50/200 (0,57).
- Stratégia **SMA 27/86**, navrhnutá ako vlastná alternatíva, poskytla najnižší drawdown

Tieto výsledky naznačujú, že algoritmická SMA stratégia môže ponúknuť lepší pomer rizika a výnosu ako pasívne investovanie.

Pre maximalizovanie dlhodobého výnosu by bola odporúčaná stratégia Buy & Hold, najlepší pomer výnosu a rizika dosahuje SMA 10/200 a pre ochranu kapitálu a min. drawdown by sa hodila stratégia SMA 27/86.



Graf 4: Porovnanie Sharpe ratio medzi modifikáciami SMA stratégie s Buy & Hold (S&P 500)



**Graf 5: Porovnanie výkonnosti vybraných SMA stratégií s Buy & Hold (S&P500)**

Na Grafe 4 vidíme porovnanie Sharpeho pomeru pre jednotlivé stratégie, kde výrazne „vychádzajú“ z tohto pohľadu tri najlepšie stratégie, tie sú zvýraznené aj v Tabuľke 2. Graf 6 potom porovnáva výkonnosť obchodných stratégií SMA10/200 a SMA27/86 s pasívnym investičným prístupom.

#### 4.1.3 Analýza SMA crossover stratégie na podkladovom aktíve DAX40

Rovnaký backtest ako sme vykonali pre S&P 500 sme otestovali aj na nemeckom indexe DAX 40 aby sme uvideli, či rôzne modifikácie SMA crossover stratégie dosahujú porovnateľné výsledky aj pri inom podkladovom aktíve a teda či je stratégia prenositeľná aj na iné aktívum.


Stratégia	Celkový výnos	Sharpeho pomer	Max. Drawdown
<b>Buy &amp; Hold</b>	<b>5185,03 %</b>	0,39	-76,74 %
SMA 10/50	1511,92 %	0,43	-42,21 %
<b>SMA 10/100</b>	<b>3043,98 %</b>	<b>0,52</b>	<b>-31,96 %</b>
<b>SMA 10/200</b>	<b>3170,97 %</b>	<b>0,51</b>	-40,14 %
SMA 20/50	1247,36 %	0,39	-41,22 %
SMA 20/100	2035,04 %	0,46	<b>-33,22 %</b>
SMA 20/200	2910,06 %	<b>0,49</b>	-43,27 %

Stratégia	Celkový výnos	Sharpeho pomer	Max. Drawdown
SMA 50/100	2353,59 %	0,47	<b>-36,67 %</b>
SMA 50/200	1476,11 %	0,39	-53,47 %
SMA 27/86	1261,39 %	0,39	-38,64 %

Tabuľka 3: Porovnanie výkonnosti a rizikovosti modifikovaných SMA stratégií so stratégiou Buy & Hold (DAX 40)

Pri pohľade do výsledkov môžeme zhodnotiť nasledovné:

- **Najvyšší výnos** dosiahla opäť Buy & Hold stratégia (5185 %), ale s extrémnym drawdownom.
- **Najlepší Sharpeho pomer:** SMA 10/100 (0,52) – teda najlepší výnos upravený o riziko.
- **Najnižší drawdown:** SMA 10/100 (-31,96 %) – najšetrnejšia stratégia k riziku, ktoré podstupuje investor.



Graf 6: Porovnanie Sharpe ratio medzi modifikáciami SMA stratégií s Buy & Hold (DAX 40)



**Graf 7: Porovnanie výkonnosti vybraných SMA stratégií s Buy & Hold (DAX 40)**

Podobne ako na Grafoch 4 a 5, aj na Grafoch 6 a 7 vizualizujeme porovnanie Sharpe ratio a výkonnosti vybraných stratégií.

Pri vzájomnom porovnaní vidíme, že SMA crossover stratégie boli schopné efektívne fungovať na rôznych trhoch. Zatiaľ čo americký trh poskytuje vyššie výnosy, niektoré SMA kombinácie na európskom indexe DAX 40 poskytli lepší pomer výnosu a rizika, čo je kľúčové pri tvorbe stabilných algoritmickej portfólií. Výsledky podporujú myšlienku, že riadenie rizika cez technické indikátory môže mať praktický význam naprieč globálnymi trhami.

#### 4.1.4 Analýza SMA crossover stratégií na inom časovom horizonte

Testovanie SMA crossover stratégií na rôznych podkladových aktívach nám poskytlo predstavu o tom, aké výsledky môžu jednotlivé prístupy dosahovať.

Nakoľko test prebiehal na 50-ročných historických dátach, môžeme si klásť otázku, či tieto dáta sú ešte dostatočne relevantné a či zmena časového horizontu významne nezmení naše zistenia.

Ako by sa mohli zmeniť výsledky?

Ak odstránime dáta pred rokom **2000**, nebudeme mať informácie o **70. a 80. rokoch**, ktoré mohli obsahovať iné trhové podmienky. To znamená, že **stratégie budú optimalizované len na novšie trhové cykly** (dot-com bublina, finančná kríza 2008, COVID-19).

Ak boli staršie trhy menej volatilné, výnosy mohli byť stabilnejšie.

Ak bola v starších rokoch dlhodobá rastová fáza, mohlo to nafúknuť celkové výnosy Buy & Hold. Moderné trhy sú volatilnejšie, takže upravená stratégia môže vykazovať odlišné výnosy a Sharpe Ratio.

Ak chceme testovať **praktickú použiteľnosť stratégií**, môže byť **lepšie použiť dáta od roku 2000**, pretože lepšie odrážajú **moderné obchodné podmienky**.

Modifikovali sme teda časový horizont a následne sme testovali stratégie na dátach od 01.01.2000 a výsledky porovnali.

Namerané výsledky sú uvedené v nasledujúcej tabuľke.

Stratégia	Celkový výnos	Sharpeho pomer	Max. Drawdown
Buy & Hold	315,09 %	29,30 %	-64,33 %
SMA 10/50	119,12 %	27,99 %	-31,08 %
SMA 10/100	259,95 %	46,49 %	-28,62 %
SMA 10/200	<b>375,12 %</b>	<b>56,82 %</b>	<b>-22,87 %</b>
SMA 20/50	103,99 %	24,70 %	-32,22 %
SMA 20/100	202,87 %	38,62 %	<b>-23,65 %</b>
SMA 20/200	<b>380,71 %</b>	<b>52,84 %</b>	-36,04 %
SMA 50/100	234,09 %	39,03 %	-33,49 %
SMA 50/200	<b>425,90 %</b>	<b>53,29 %</b>	-36,10 %
SMA 27/86	184,49 %	35,88 %	<b>-26,44 %</b>

Tabuľka 4: Porovnanie výkonnosti a rizikovosti modifikovaných SMA stratégií so stratégiou Buy & Hold po úprave sledovaného časového horizontu (S&P 500)



**Graf 8: Porovnanie výkonnosti vybraných SMA stratégií s Buy & Hold po úprave sledovaného časového horizontu (S&P 500)**

Graf 8 ponúka porovnanie vybraných stratégií a ich porovnanie s pasívnym investovaním avšak už pre skrátené skúmané obdobie so začiatkom v roku 2000.

Výsledky testovania stratégií založených na prieniku jednoduchých kľzavých priemerov (SMA) na historických dátach indexu **S&P 500 od roku 2000** tentokrát ukázali, že **viacero SMA stratégií dokázalo prekonať pasívnu Buy & Hold stratégiu** z hľadiska výnosu, stability aj maximálneho poklesu kapitálu.

Napriek tomu, že **Buy & Hold** dosiahla kumulatívny výnos **315 %**, bola spojená s **výrazným maximálnym drawdownom (-64 %)**, čo je z pohľadu investora rizikovo veľmi náročné. V kontraste s tým viaceré SMA stratégie vykázali **vyšší výnos pri súčasne nižšom riziku**.

Najvýraznejšie výsledky:

- **SMA 50/200** dosiahla najvyšší výnos spomedzi všetkých stratégií (**425,90 %**) a porazila Buy & Hold o viac ako 100 percentuálnych bodov.
- **SMA 10/200** mala najlepší Sharpeho pomer (0,5682), čím preukázala najlepší rizikovo upravený výnos.
- **SMA 10/200** zároveň vykázala **najnižší maximálny drawdown (-22,87 %)**, čo z nej robí jednu z najvhodnejších stratégií z pohľadu riadenia rizika.

Ďalšie testované kombinácie ako **SMA 20/200** a **SMA 50/100** si taktiež viedli výrazne lepšie ako Buy & Hold, a to v rôznych aspektoch – či už ide o pomer výnos/riziko alebo mieru poklesu počas kríz.

Rovnaké testovanie sme vykonali opäť aj pre index DAX 40.

Stratégia	Celkový výnos	Sharpeho pomer	Max. Drawdown
Buy & Hold	221,92 %	20,44 %	-76,74 %
SMA 10/50	81,06 %	17,38	-41,56 %
SMA 10/100	233,16 %	36,44 %	<b>-29,43 %</b>
SMA 10/200	<b>334,88 %</b>	<b>44,40 %</b>	-33,30 %
SMA 20/50	89,39 %	18,24 %	-40,56 %
SMA 20/100	171,34 %	29,66 %	<b>-32,85 %</b>
SMA 20/200	<b>351,36 %</b>	<b>44,72 %</b>	<b>-29,81 %</b>
SMA 50/100	<b>245,83 %</b>	<b>36,58 %</b>	-36,67 %
SMA 50/200	220,73 %	33,57 %	-46,52 %
SMA 27/86	182,20 %	30,31 %	-34,36 %

**Tabuľka 5: Porovnanie výkonnosti a rizikovosti modifikovaných SMA stratégií so stratégiou Buy & Hold po úprave sledovaného časového horizontu (DAX 40)**



**Graf 9: Porovnanie výkonnosti vybraných SMA stratégií s Buy & Hold po úprave sledovaného časového horizontu (DAX 40)**

Graf 9 je ekvivalentom Grafu 8 pre sledovanie a porovnávanie výkonnosti stratégií tentokrát na indexe DAX 40.

Testovanie algoritmických stratégií typu **SMA crossover** na dátach indexu **DAX 40** od roku 2000 prinieslo zaujímavé výsledky. Hoci **celkový výnos tradičnej Buy & Hold stratégie (221,92 %)** bol nižší ako v prípade amerického indexu S&P 500, stále išlo o významný rast. Tento rast však bol spojený s veľmi **vysokým maximálnym drawdownom (-76,74 %)**, čo poukázalo na rizikovosť pasívneho investovania v prípade nemeckého trhu.

Na rozdiel od toho viaceré SMA stratégie preukázali schopnosť **výrazne obmedziť straty** počas poklesov trhu a zároveň dosiahli **porovnateľné alebo vyššie výnosy** než Buy & Hold.

Najvýraznejšie výsledky:

- **SMA 20/200** dosiahla najvyšší Sharpeho pomer (0,4472) a zároveň aj najvyšší výnos (351,36 %) spomedzi všetkých testovaných stratégií, čo z nej robí najúspešnejšiu stratégiu pre DAX 40 v danom období.
- **SMA 10/200** si taktiež viedla veľmi dobre s výnosom 334,88 % a Sharpe pomerom 0,4440, pričom dokázala udržať maximálny drawdown na relatívne prijateľnej úrovni (-33,30 %).
- **SMA 10/100** a **SMA 50/100** preukázali dobrý pomer výnosu a rizika, a sú vhodnými kandidátmi pre investorov, ktorí preferujú stabilnejšie stratégie.

Stratégia **SMA 27/86**, testovaná samostatne, dosiahla výnos 182,20 % a drawdown –34,36 %, čím sa zaradila medzi konzervatívnejšie stratégie s nižšou volatilitou a vyváženým výsledkom.

#### 4.1.5 Zhrnutie pre SMA crossover stratégie

Testovanie jednoduchých algoritmických stratégií založených na prieniku kľzavých priemerov (SMA crossover) potvrdilo ich praktickú využiteľnosť a schopnosť konkurovať tradičnému pasívnemu investovaniu. Všetky stratégie boli testované na historických dátach dvoch významných akciových indexov – **S&P 500 (USA)** a **DAX 40 (Nemecko)** – s cieľom zhodnotiť ich výkonnosť, stabilitu a rizikovosť.

Pri testovaní od **roku 1975** boli výsledky prirodzene ovplyvnené dlhším časovým horizontom a dlhodobým rastom trhov, najmä USA. Výnosy Buy & Hold aj SMA stratégií boli vyššie, no takisto aj maximálne poklesy v dôsledku starších kríz (napr. dot-com bublina, 1987).

Pri obmedzení testovania na obdobie **od roku 2000** sa naplno prejavila sila SMA stratégií pri ochrane kapitálu počas krízových období (2008, 2020), pričom niektoré stratégie (najmä SMA 10/200) vykazovali výrazne lepší rizikovo upravený výnos ako Buy & Hold.

Napriek kratšiemu obdobiu testovania od roku 2000 si viaceré SMA stratégie zachovali konzistentnú výkonnosť, čo potvrdzuje ich robustnosť a adaptabilitu aj v novších trhových podmienkach. Viaceré kombinácie pri testovaní po roku 2000 (napr. SMA 10/200, SMA 20/200, SMA 50/200) dosiahli vyšší výnos než Buy & Hold, a zároveň s nižším drawdownom.

Všeobecne možno konštatovať, že SMA stratégie boli **prenášateľné medzi trhmi**, no ich výkonnosť závisí od konkrétnej trhovej dynamiky a volatility daného indexu.

## 4.2 RSI oscilátorová stratégia

### 4.2.1 Analýza RSI oscilátorovej stratégie

Najvyššiu výkonnosť dosiahla RSI stratégia na akcii **Tesla**, pričom počas celého obdobia vykázala **výnos cez 11 000 %** a vysoké **Sharpe ratio 5,11**, čo poukázalo na vysokú výkonnosť vzhľadom na volatilitu.


Aj napriek nižšiemu celkovému výnosu oproti Buy & Hold (ktorý zahŕňal extrémne rally) sa RSI stratégia vyznačovala omnoho nižším **maximálnym poklesom hodnoty (drawdown - 25 %) vs. -74 %** pri pasívnom držaní.

Namerané výsledky uvádzame v nasledujúcej tabuľke.

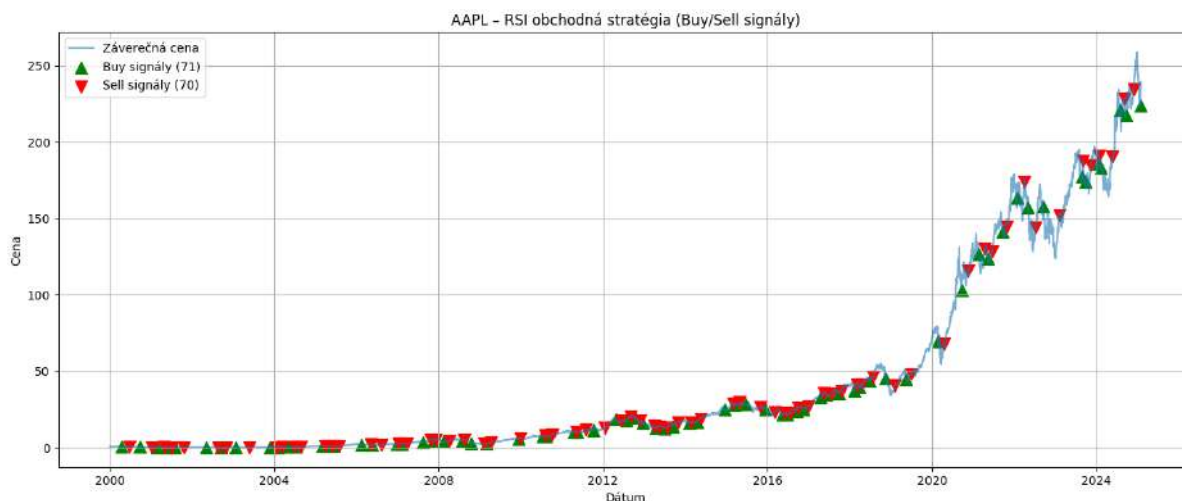
Akcia	Výnos RSI	Výnos B&H	Sharpe RSI	Sharpe B&H	Max DD RSI	Max DD B&H	Počet obchodov	Win Rate
Tesla	11 455 %	35 600 %	5,11	0,98	-25,20 %	-73,63 %	43	83,72 %
Apple	3 147 %	27 870 %	3,13	0,78	-69,03 %	-81,80 %	70	78,57 %
Microsoft	1 604 %	933 %	4,24	0,46	-42,08 %	-70,71 %	70	77,14 %
US Steel	440 %	36 %	1,08	0,30	-84,76 %	-97,23 %	68	70,59 %

Tabuľka 6: Porovnanie výkonnosti a rizikovosti RSI stratégie a jednotlivých aktív so stratégiou Buy & Hold

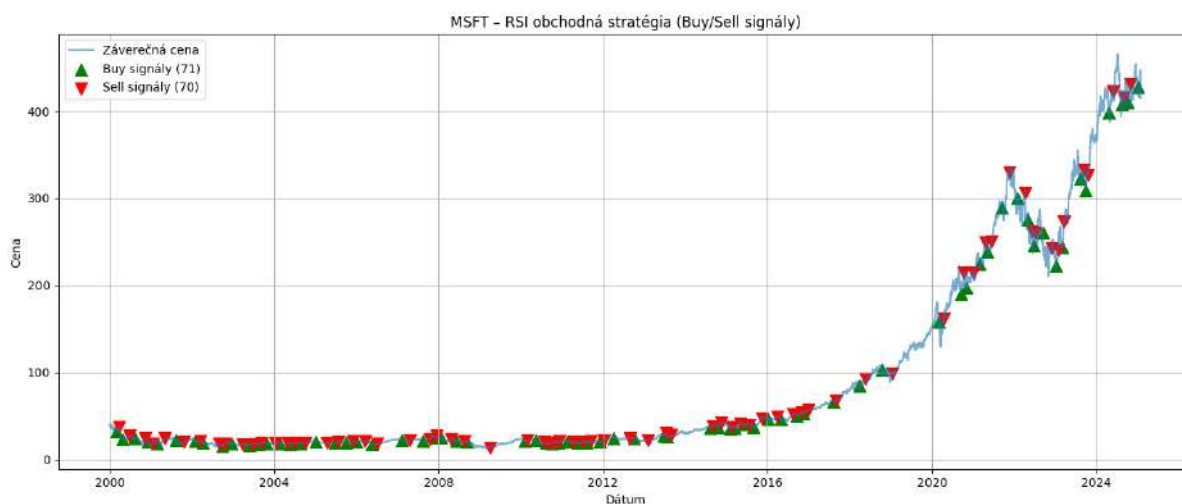
Podobne aj pre **Apple** a **Microsoft** dosiahla RSI stratégia nižšie drawdowny a vyššie Sharpe ratio ako Buy & Hold. Napriek tomu, že celkové výnosy boli nižšie než pri držaní akcie počas celého obdobia, stratégia lepšie **zvládala riziko a volatilitu**, čo je podstatné najmä pre konzervatívnejších investorov.



Graf 10: Vývoj ceny akcie Tesla a generovanie obchodných signálov



Graf 11: Vývoj ceny akcie Apple a generovanie obchodných signálov



Graf 12: Vývoj ceny akcie Microsoft a generovanie obchodných signálov


Grafy 10 až 13 zobrazujú vývoj hodnoty testovaných akcií a generovanie obchodných signálov. Zelená šípka nahor indikuje otvorenie nákupnej pozície pri detekcii prepredaného stavu, červená šípka nadol následne znamená uzatvorenie tejto long nákupnej pozície pri prekúpenosti aktíva.

V prípade **US Steel** bola RSI stratégia síce výnosnejšia než Buy & Hold (440 % vs. 36 %), ale výkonnosť bola volatilná a maximálny drawdown ostal veľmi vysoký. Tento prípad ukazuje, že stratégia funguje lepšie na likvidných a trendujúcich tituloch (ako technologické akcie), zatiaľ čo pri cyklických a menej predvídateľných akciách je menej stabilná.

Z pohľadu **úspešnosti obchodov (win rate)** dosahovala RSI stratégia veľmi dobré výsledky – pri všetkých akciách bola úspešnosť nad 70 %, pričom najvyššiu mala Tesla (takmer 84 % ziskových obchodov).



Graf 13: Vývoj ceny akcie US Steel a generovanie obchodných signálov



Graf 14: Graf kumulatívnych výnosov pre každú akciu pri využití stratégií RSI vs. Buy & Hold

Graf 14 vyobrazuje výkonnosť všetkých sledovaných stratégií a porovnáva ich s pasívnym investovaním na jednotlivých akciách. Plné čiary pre akcie Microsoftu a US Steelu sa dokázali dostať nad čiarkované, ktoré reprezentujú Buy & Hold prístup, čo znamená, že tieto dve stratégie dokázali byť úspešnejšie.

RSI stratégia ukázala schopnosť efektívne reagovať na krátkodobé výkyvy ceny a ochrániť investora pred najväčšími stratami. Jej celkové výnosy síce často nedosiahli extrémny Buy & Hold stratégie, ale v kombinácii s nižšou volatilitou a vysokou úspešnosťou obchodov ide o životaschopný prístup, ktorý môže tvoriť základ pre ďalšie rozširovanie a optimalizáciu.

#### 4.2.2 Modifikácia RSI oscilátorovej stratégie – zmena prahových hodnôt

Jednou z najčastejších modifikácií RSI stratégií je **úprava prahových hodnôt**, ktoré definujú prepredané a prekúpené stavy trhu. Kým štandardné nastavenie používa hodnoty **30 (prepredanosť)** a **70 (prekúpenosť)**, v tejto časti sme analyzovali účinnosť alternatívnych nastavení:

- **20/70** – prísnejší nákupný filter, ponechaný výstup ako pri štandarde (prepredanosť musí klesnúť až na úroveň 20)
- **30/80** – štandardný vstup, ale prísnejší výstup (neskorší výstup pri prekúpenosti až na úrovni 80)
- **20/80** – prísnejšie prahy pre nákup aj predaj

**Zníženie dolnej hranice (napr. 30 → 20)** zníži počet obchodov (trh je zriedkavejšie prepredaný), vedie k oneskoreným nákupným signálom – vstupujeme neskôr, ale často v stabilnejšej fáze, čoho výsledkom môže byť vyššia úspešnosť obchodov, ale nižší celkový výnos.

**Zvýšenie hornej hranice (napr. 70 → 80)** spôsobí, že predajné signály sa generujú neskôr, často až po vrchole trendu, môžeme zachytiť dlhší rastúci pohyb, ale riskujeme neskorší výstup počas korekcie, výsledkom môže byť nižší počet obchodov, ale opäť nie nutne vyšší výnos.

Výsledky zmien prahových hodnôt pre jednotlivé akcie sú zaznamenané v tabuľkách.

RSI prahy	Počet obchodov	Win Rate	Celkový výnos
30/70	43	83,72 %	11 456 %
20/70	25	92,00 %	1 635 %
20/80	17	76,47 %	1 100 %
30/80	24	79,17 %	1 676 %

**Tabuľka 7: Porovnanie výkonnosti RSI stratégií s rôznymi prahmi citlivosti RSI (Tesla)**

RSI prahy	Počet obchodov	Win Rate	Celkový výnos
30/70	70	78,57 %	3 147 %
20/70	32	84,38 %	381 %
20/80	25	72,00 %	323 %
30/80	49	79,59 %	2 052 %

**Tabuľka 8: Porovnanie výkonnosti RSI stratégií s rôznymi prahmi citlivosti RSI (Apple)**

RSI prahy	Počet obchodov	Win Rate	Celkový výnos
30/70	70	77,14 %	1 604 %
20/70	32	78,12 %	524 %
20/80	20	70,00 %	159 %
30/80	43	79,07 %	1 557 %

**Tabuľka 9: Porovnanie výkonnosti RSI stratégií s rôznymi prahmi citlivosti RSI (Microsoft)**

RSI prahy	Počet obchodov	Win Rate	Celkový výnos
30/70	68	70,59 %	440 %
20/70	47	72,34 %	613 %
20/80	32	68,75 %	167 %
30/80	39	61,54 %	-17,56 %

**Tabuľka 10: Porovnanie výkonnosti RSI stratégií s rôznymi prahmi citlivosti RSI (US Steel)**

Z porovnaní a tabuliek vo väčšine prípadov vyplýva, že štandardný prah 30/70 dosiahol najvyšší výnos a zachoval si veľmi slušnú úspešnosť. Tiež vidíme, že konzervatívnejšia stratégia 20/70 síce zvyšuje úspešnosť obchodov, ale tiež významne obmedzuje ziskovosť obchodnej stratégie.

Zaujímavosťou je správanie sa pri špecifickom type akcie akou je US Steel, kde konzervatívnejší prah 20/70 pracoval lepšie ako štandardný a prahové nastavenie 30/80 skončilo dokonca v strate.

#### 4.2.3 Modifikácia RSI oscilátorovej stratégie – zmena dĺžky RSI

Okrem zmeny prahových hodnôt môže mať významný vplyv na výkonnosť RSI stratégie aj **zmena dĺžky indikátora**. Najčastejšie používaná je **14-dňová verzia RSI**, ktorá zachytáva kratšie výkyvy trhu a reaguje pomerne rýchlo.

Alternatívou je **dlhší RSI – napr. 30-dňový**, ktorý viac vyhladzuje pohyby a znižuje počet falošných signálov, no za cenu oneskorenej reakcie.

Porovnali sme preto dve nastavenia – základné (RSI 14 dní s prahmi 30/70) a upravené s dlhším RSI (RSI 30 dní a prahy 30/70).

Akcia	Výnos 14d	Výnos 30d	Obchody 14d	Obchody 30d	Win Rate 14d	Win Rate 30d
Tesla	11 456 %	1 751 %	43	10	83,72 %	90,00 %
Apple	3 147 %	109 %	70	11	78,57 %	72,73 %
Microsoft	1 604 %	44 %	70	12	77,14 %	66,67 %
US Steel	440 %	81 %	68	20	70,59 %	60,00 %

Tabuľka 11: Porovnanie výkonnosti RSI stratégií s rôznymi nastaveniami času (RSI 14 vs. RSI 30)

Zmena dĺžky RSI zo 14 na 30 dní **výrazne znížila počet generovaných obchodov**, keďže indikátor reaguje pomalšie na krátkodobé zmeny. V niektorých prípadoch, ako napr. pri akcii Tesla, sa zvýšila úspešnosť obchodov (až na 90 %), no za cenu dramaticky nižšieho výnosu.

Agresívnejším prístupom vhodným napríklad pre aktívnejšiu obchodnú stratégiu môže byť **skrátene dĺžky RSI na 7 dní**. Takto bude stratégia rýchlejšie reagovať na zmeny ceny, generovať viac obchodných signálov, avšak jej spoľahlivosť môže klesnúť.

Výsledky takejto modifikácie sme opäť vyhodnotili v tabuľke.

Akcia	Výnos 14d	Výnos 7d	Obchody 14d	Obchody 7d	Win Rate 14d	Win Rate 7d
Tesla	11 456 %	27 678 %	43	118	83,72 %	73,73 %
Apple	3 147 %	9 860 %	70	181	78,57 %	78,45 %
Microsoft	1 604 %	5 637 %	70	180	77,14 %	74,44 %
US Steel	440 %	248 436 %	68	189	70,59 %	79,89 %

Tabuľka 12: Porovnanie výkonnosti RSI stratégií s rôznymi nastaveniami času (RSI 14 vs. RSI 7)

RSI 7-dňové generovali **výrazne viac obchodov** (takmer trojnásobne), čo viedlo k **veľmi vysokým výnosom** – najmä pri US Steel a Tesle. Napriek nižšej stabilite **výnos bol vyšší**, čo môže byť atraktívne pre aktívnych obchodníkov, ktorí sú schopní znášať vyššie riziko.

**Apple** dosiahol podobný win rate pri oboch dĺžkach, ale 7-dňové nastavenie prinieslo **trojnásobný výnos**. US Steel bol opäť špecifický – dosiahol **extrémny výnos** a bol ovplyvnený výnimočnými pohybmi na akcii.

Z týchto výsledkov vyplýva, že výber dĺžky RSI by mal zohľadniť **typ aktíva** a **preferencie obchodníka**. Voľba dĺžky RSI by mala reflektovať nielen typ aktíva, ale najmä **obchodný štýl** investora. Agresívny obchodník využije výhody RSI 7, zatiaľ čo investor s preferenciou stability a nižšej frekvencie ocení RSI 30. RSI 14 zostáva univerzálnou a výborne vyváženou voľbou pre väčšinu situácií.

#### 4.2.4 Modifikácia RSI oscilátorovej stratégie – filtrovanie podľa trendu

Jedným z možných spôsobov ako zvýšiť úspešnosť RSI stratégie je **zavedenie trendového filtra**, ktorý pomáha eliminovať vstupy **proti hlavnému trhu**. V tejto modifikácii sme použili **200-dňový jednoduchý kĺzavý priemer (SMA 200)** ako nástroj na identifikáciu trendu.

Pri ďalšej modifikácii stratégie sme ostali pri štandardnom nastavení RSI 14 30/70 avšak pridali sme **filter podľa dlhodobého trendu pomocou kĺzavého priemeru SMA 200**.

Nákupný signál sme generovali, keď RSI prešiel cez hranicu 30 zospodu (ako doteraz) a **zároveň bola cena nad 200-dňovým SMA** a teda sme boli v rastovom trende.

Predajný signál sa generoval len vtedy, ak sa RSI dostal pod 70 zhora (ako doteraz) a zároveň bola cena pod SMA 200 a teda sme boli v klesajúcom trende.

Akcia	Výnos bez filtra	Výnos s filtrom	Obchody bez filtra	Obchody s filtrom	Win Rate bez filtra	Win Rate s filtrom
Tesla	11 456 %	1 822 %	43	5	83,72 %	80,00 %
Apple	3 147 %	9 520 %	70	7	78,57 %	85,71 %
Microsoft	1 604 %	721 %	70	10	77,14 %	50,00 %
US Steel	440 %	-10,64 %	68	13	70,59 %	38,46 %

Tabuľka 13: Porovnanie výkonnosti RSI stratégie bez a s filtrovaním podľa trendu pomocou SMA 200 indikátora

Výsledky ukázali, že trendový filter môže výrazne ovplyvniť výkonnosť stratégie:

- V prípade **Apple** filter **výrazne zlepšil výsledky** – odstránil slabšie obchody počas korekcií a zvýšil výnos aj úspešnosť.
- Pri **Tesle** filter síce zvýšil presnosť, no dramaticky znížil počet obchodov a celkový výnos.
- Pre **Microsoft a US Steel** bol filter kontraproduktívny – obmedzil stratégiu natoľko, že výkonnosť klesla.



Graf 15: Vývoj ceny akcie Apple s vyobrazením obchodných signálov pri stratégii RSI 14 30/70 a aplikácii filtrovania pomocou trendového filtra SMA 200

Graf 15 je aktualizovaný oproti predošlým grafom a znakom X sú vyobrazené odmietnuté obchodné signály z dôvodu filtrovania na základe trendu. V legende v zátvorke vidíme, že ich počet je vysoký.

**Trendový filter pomocou SMA 200 môže zvýšiť kvalitu signálov, ale výrazne znížiť ich počet.** Použitie trendového filtra pomocou SMA 200 má zmysel **najmä pri akciách s dlhodobým stabilným rastovým trendom** ako je napríklad Apple. V iných prípadoch však môže príliš potlačiť aktivitu stratégie a tým znížiť jej výnosnosť. Tento typ modifikácie je vhodný skôr pre **konzervatívnych obchodníkov**, ktorí uprednostňujú vyššiu úspešnosť pred frekvenciou obchodov.

#### 4.2.5 Modifikácia RSI oscilátorovej stratégie – filtrovanie podľa objemu

Ďalším spôsobom, ako zvýšiť kvalitu obchodných signálov, je doplnenie RSI stratégie o **filter podľa objemu obchodovania** (angl. volume spike). Základná myšlienka spočíva v tom, že **výrazný objem často sprevádza silné pohyby na trhu**, ktoré majú vyššiu pravdepodobnosť pokračovania.

Pri tejto modifikácii sme akceptovali signály len vtedy, **ak denný objem obchodovania bol vyšší ako 1,5-násobok 20-dňového priemeru objemu.**

Týmto spôsobom sa snažíme odfiltrovať „tiché“ signály s nízkou presvedčivosťou a sústrediť sa na situácie, kde trh ukazuje silu cez zvýšený objem.

Akcia	Výnos bez filtra	Výnos s filtrom	Obchody bez filtra	Obchody s filtrom	Win Rate bez filtra	Win Rate s filtrom
Tesla	11 456 %	826 %	43	8	83,72 %	75,00 %
Apple	3 147 %	638 %	70	9	78,57 %	88,89 %
Microsoft	1 604 %	992 %	70	12	77,14 %	91,67 %
US Steel	440 %	3 106 %	68	9	70,59 %	88,89 %


Tabuľka 14: Porovnanie výkonnosti RSI stratégie bez a s filtrovaním podľa objemu

Objemový filter výrazne znížil počet obchodov, keďže na trhoch nie je každý deň vysoký objem. No kvalita obchodov sa zlepšila – v troch zo štyroch prípadov sa **úspešnosť obchodov zvýšila na takmer 90 %**, čo je veľmi výrazné zlepšenie.

Pri **Apple** a **Microsoft** bola aj výnosnosť solídna, napriek menšiemu počtu obchodov.

**US Steel** dosiahol s objemovým filtrom najvyšší výnos, naopak výnimkou bola **Tesla**, kde filter odstránil veľa úspešných obchodov, čo viedlo k zníženiu výkonnosti.

Objemový filter sa ukázal ako efektívna modifikácia RSI stratégie **najmä pre akcie s konzistentnou aktivitou a objemom**. Môže výrazne zvýšiť **presnosť signálov** a znížiť zbytočné obchody, čo z neho robí vhodný nástroj pre obchodníkov, ktorí preferujú kvalitu pred kvantitou.



**Graf 16: Vývoj ceny akcie Microsoft s vyobrazením obchodných signálov pri stratégii RSI 14 30/70 a aplikácii filtrovania pomocou objemového filtra**

Graf 16 je doplnený nielen o informáciu o filtrovaní obchodných signálov (teraz kvôli objemu), ale je tiež doplnený o objem obchodovania v spodnej časti. Tu červená čiara zobrazuje požadovaný objem obchodovania na to, aby bol obchodný signál prijatý.

#### 4.2.6 Zhrnutie pre RSI oscilátorové stratégie

V tejto časti práce sme navrhli a otestovali **základnú RSI stratégiu** s parametrami **14-dňový RSI** a prahovými hodnotami **30/70**, ktorá slúži ako jeden z najznámejších oscilátorových

prístupov k obchodovaniu. Následne sme analyzovali jej výkonnosť na historických dátach štyroch akcií: **Tesla, Apple, Microsoft a US Steel**, v období **2000 – 2025**.

Základná stratégia preukázala silné výsledky – najmä pri akciách s rastovým trendom a vyššou volatilitou (napr. Tesla, Apple), pričom dosahovala **vysoké výnosy a relatívne vysoký win rate**.

V rámci modifikácií sme otestovali viaceré prístupy:

- **Zmena prahových hodnôt RSI (20/70, 20/80, 30/80):**

Tieto úpravy znížili počet obchodov a v niektorých prípadoch zvýšili win rate, ale **vo väčšine prípadov znížili celkový výnos**. Výnimkou bola akcia **US Steel**, kde nastavenie 20/70 prinieslo najvyšší výnos aj úspešnosť.

- **Zmena dĺžky RSI (7, 14, 30 dní):**

**RSI 7 dní** generoval výrazne viac obchodov a pri niektorých akciách aj najvyšší výnos (US Steel, Apple). **RSI 30 dní** bol konzervatívnejší – menej obchodov, vyššia úspešnosť, ale nižší výnos. **RSI 14 dní** sa ukázal ako optimálny kompromis medzi aktivitou a výkonnosťou.

- **Filter podľa trendu (SMA 200):**

Tento filter zlepšil kvalitu signálov (najmä pri Apple), ale výrazne znížil počet obchodov. Pri niektorých akciách (napr. US Steel) bol kontraproduktívny.


- **Objemový filter (Volume Spike):**

Zameriavali sme sa len na dni s objemom väčším ako **1,5× 20-dňový priemer**. Výrazne **zvýšil úspešnosť obchodov (až nad 90 %)**, najmä pri Apple, Microsoft a US Steel. Počet obchodov síce klesol, ale v niektorých prípadoch filter zlepšil aj výnos.

Na základe uskutočnených testov môžeme zhrnúť, že: **základná RSI stratégia (14 dní, 30/70)** dosiahla **veľmi dobré výsledky** na väčšine akcií. **Modifikácie podľa trendu alebo objemu** môžu byť prínosné, ak sú aplikované na správne typy akcií. **Skutočná sila RSI stratégie spočíva v jej flexibilitate** – jednoduchý koncept možno prispôbiť rôznym podmienkam trhu pomocou filtrov, parametrov či kombinácií s inými indikátormi.

## 4.3 Momentová investičná stratégia

### 4.3.1 Analýza momentovej stratégie



**Graf 17: Porovnanie kumulatívnej výkonnosti momentovej stratégie a S&P 500 (Buy & Hold) stratégie s indikáciou kedy došlo k zmene v portfóliu momentovej stratégie**

Graf 17 poskytuje informácie o vývoji výkonnosti Momentovej a Buy & Hold stratégií. Znakom X sú označené situácie, keď došlo k zmene v portfóliu, tj. niektoré akcie boli vymenené. V tejto stratégii hovoríme aj o tzv. víťazoch a porazených, vidíme teda, kedy dochádza k obmenám v portfóliu a náhrade zaostávajúcich akcií za výkonnejšie.

Metrika	Momentum stratégia	S&P 500 (Buy & Hold)
Celkový výnos	+5971 %	+370 %
Priemerný ročný výnos	+33,6 %	+11,7 %
Volatilita	35,3 %	14,3 %
Sharpe ratio	0,99	0,85
Maximálny drawdown	-50,1 %	-24,8 %

**Tabuľka 15: Porovnanie metrik momentovej stratégie a S&P 500 (Buy & Hold) stratégie**

Základná momentová stratégia aplikovaná na vybrané akcie (AAPL, MSFT, X a od roku 2010 aj TSLA) preukázala **vysokú výkonnosť** počas obdobia rokov 2000 až 2025. Stratégia vyberala akcie s pozitívnym 6-mesačným výnosom a rovnomerne medzi ne rozdeľovala kapitál. Výber sa aktualizoval mesačne, pričom portfólio dynamicky reagovalo na zmeny trhového sentimentu.

Z porovnania s pasívnou stratégiou Buy & Hold v indexe S&P 500 vyplýva, že momentum prístup dosiahol násobne vyšší celkový výnos (+5971 % oproti +370 %) aj vyšší priemerný ročný výnos (+33,6 % oproti +11,7 %). Na druhej strane, za tieto výnosy investor zaplatil vyššou volatilitou (35,3 % vs. 14,3 %) a podstatne väčším maximálnym poklesom portfólia (-50,1 % vs. -24,8 %).

Sharpe ratio, ktoré zohľadňuje výnos vo vzťahu k riziku, bolo pri momentovej stratégii mierne vyššie (0,99) než pri S&P 500 (0,85), čo naznačuje, že aj napriek vyššiemu riziku bola stratégia schopná efektívne generovať výnosy.

Z týchto zistení vyplýva, že momentum stratégia môže byť veľmi výnosná, najmä v prostredí rastových trendov. Avšak jej nevýhodou je vyššia citlivosť na volatilitu trhu a potenciálne straty počas korekcií. V ďalšej časti sme sa preto zamerali na možné **modifikácie stratégie**, ktoré by mohli pomôcť znížiť riziko alebo zlepšiť selekciu aktív.

#### **4.3.2 Modifikácia momentovej stratégie pomocou filtra volatility**

Aj keď základná momentová stratégia dosiahla vysoký výnos, bola zároveň spojená s vysokou volatilitou a výraznými poklesmi počas nepriaznivých trhových období. V tejto časti sme navrhli modifikáciu, ktorá využíva **filter volatility** s cieľom znížiť rizikovosť portfólia a zlepšiť pomer výnos/riziko.

Stratégiu sme rozšírili o dodatočný krok, v ktorom sa vyradujú akcie s nadmernou volatilitou. Aplikovali sme filter volatility a v portfóliu ponechávali len tie akcie, ktorých volatilita bola **nižšia ako mediánová volatilita** v danom mesiaci.

Opäť rovnako sme rozdeľovali kapitál medzi vybrané akcie, ak žiadna nevyhovovala, portfólio zostávalo v hotovosti.

Výsledky tejto modifikácie sme porovnávali s pôvodnou momentovou stratégiou.

Metrika	Momentum stratégia bez filtra	Momentum stratégia s filtrovaním
Celkový výnos	+5971 %	+1835 %
Priemerný ročný výnos	+33,6 %	+23,3 %
Volatilita	35,3 %	19,5 %
Sharpe ratio	0,99	1,18
Maximálny drawdown	-50,1 %	-22,4 %

Tabuľka 16: Porovnanie metrik momentovej stratégie pred a po filtrovaní na základe volatility sledovaných akcií

Na základe porovnania sme zistili, že **celkový výnos** modifikovanej stratégie síce klesol z +5971 % na +1835 %, no zároveň sa znížila aj volatilita z 35,3 % na 19,5 %.

**Maximálny pokles** portfólia klesol z -50,1 % na -22,4 %, čo výrazne prispieva k ochrane kapitálu. **Sharpe ratio** sa zvýšilo z 0,99 na 1,18, čo naznačuje lepšiu efektivitu stratégie pri zohľadnení rizika.

Modifikácia pomocou filtra volatility ukázala, že aj jednoduchý dodatočný mechanizmus dokáže výrazne zlepšiť charakteristiky investičnej stratégie. Aj keď výsledná výnosnosť bola nižšia, stratégia bola omnoho stabilnejšia a menej náchylná na veľké výkyvy. Táto verzia je preto vhodnejšia pre konzervatívnejších investorov, ktorí hľadajú rovnováhu medzi výkonom a kontrolou rizika.

#### 4.3.3 Modifikácia momentovej stratégie pomocou RSI filtra

Ďalšou alternatívou modifikácie momentovej stratégie je využitie technického indikátora RSI (Relative Strength Index), ktorý slúži na identifikáciu prekúpenosti alebo prepredanosti finančných aktív. RSI sa pohybuje v intervale od 0 do 100 a podľa štandardného nastavenia sa hodnoty nad 70 považujú za signál prekúpenosti, zatiaľ čo hodnoty pod 30 signalizujú prepredanosť.

V tejto modifikácii sme do portfólia zaradili iba tie akcie, ktoré okrem podmienky výnosu mali zároveň hodnotu 14-dňového RSI nižšiu ako 70, teda neboli prekúpené.

Metrika	Momentum stratégia bez filtra	Momentum stratégia s filtrovaním
Celkový výnos	+5971 %	+3560 %
Priemerný ročný výnos	+33,6 %	+28,9 %
Volatilita	35,3 %	34,5 %
Sharpe ratio	0,99	0,90
Maximálny drawdown	-50,1 %	-55,4 %

Tabuľka 17: Porovnanie metrík momentovej stratégie pred a po filtrovaní na základe indikátora RSI14

Vidíme, že filtrovanie akcií s vysokým RSI (nad 70) viedlo k nižšiemu výnosu aj nižšiemu Sharpe ratio a zároveň **nepriaznivo ovplyvnilo maximálny drawdown**, ktorý bol ešte vyšší než pri pôvodnej stratégii. To naznačuje, že niektoré z najvýkonnejších akcií mali RSI nad 70, takže boli vyradené zo stratégie. Filter RSI znížil efektívnosť výberu aktív, ale **neznížil riziko** tak ako filter volatility.

Aj keď cieľom RSI filtra bolo obmedziť vstupy do prekúpených aktív a tým potenciálne znížiť volatilitu a riziko poklesov, výsledky ukázali opak. Výkon stratégie bol oslabený a zároveň došlo k prehĺbeniu maximálneho poklesu. To naznačuje, že v kontexte momentovej stratégie nie je vhodné obmedzovať výber len na základe úrovne RSI, keďže silné trendy často sprevádza aj prekúpenosť, ktorá môže pretrvávajúť dlhšie obdobie.

V porovnaní s predchádzajúcou modifikáciou (filter volatility), RSI filter nepriniesol očakávané zlepšenie a skôr oslabil výkonnosť aj stabilitu portfólia.

#### 4.3.4 Modifikácia momentovej stratégie s výnosovým filtrom

V tejto modifikácii bola základná momentum stratégia upravená zavedením **minimálneho prahu výnosu**, ktorý musela akcia dosiahnuť za posledných 6 mesiacov, aby bola zaradená do portfólia. Cieľom tejto úpravy bolo zvýšiť selektívnosť a vyberať len tie akcie, ktoré vykazovali **dostatočne silný rastový trend**.

V tejto modifikácii sme požadovali aspoň **6-mesačný výnos vyšší ako 7 %**.

Investícia prebiehala rovnomerne medzi všetky vybrané tituly, pričom v mesiacoch, keď žiadna akcia nespĺňala podmienku, zostalo portfólio v hotovosti. Rebalansovanie prebiehalo mesačne.

Metrika	Momentum stratégia bez filtra	Momentum stratégia s filtrovaním
Celkový výnos	+5971 %	+4020 %
Priemerný ročný výnos	+33,6 %	+30,0 %
Volatilita	35,3 %	37,2 %
Sharpe ratio	0,99	0,88
Maximálny drawdown	-50,1 %	-51,4 %

Tabuľka 18: Porovnanie metrik momentovej stratégie pred a po filtrovaní na základe požadovaného výnosu

Zavedenie prahovej hodnoty 7 % pre 6-mesačný výnos sa ukázalo ako menej efektívne, než sa očakávalo. Aj keď zámerom bolo zamerať sa na najsilnejšie rastúce akcie, výsledkom bola nižšia diverzifikácia v niektorých mesiacoch a tým aj nižšia výkonnosť. Volatilita a maximálny pokles portfólia neboli redukované, naopak – mierne sa zhoršili.

Táto modifikácia ukázala, že príliš prísna selekcia môže znížiť potenciál stratégie bez výrazného zlepšenia jej rizikového profilu.

#### 4.3.5 Zhrnutie momentovej stratégie

V tejto časti bola navrhnutá a testovaná **momentová investičná stratégia**, ktorá vychádza z predpokladu, že akcie s pozitívnou výkonnosťou v nedávnom období majú tendenciu pokračovať v raste aj v budúcnosti. Základná verzia stratégie pracovala s 6-mesačným výnosom ako hlavným rozhodovacím kritériom. Do portfólia boli mesačne zaradené tie akcie, ktorých výnos za posledných 6 mesiacov bol vyšší ako 0 %.

Výsledky základnej stratégie ukázali mimoriadne vysoký **celkový výnos (+5971 %, +33,6 % p.a.)**, pričom volatilita dosahovala 35,3 %. Sharpe ratio na úrovni 0,99 potvrdzuje atraktívny pomer výnosu k riziku, avšak zároveň sa vyskytol výrazný **maximálny pokles portfólia (-50,1 %)**.

Na zníženie rizikovosti a zlepšenie výberu aktív boli otestované štyri modifikácie základného modelu:

- **Filter volatility:** Zaradil len akcie s nižšou než mediánovou volatilitou. Výsledkom bolo **zníženie drawdownu na -22,4 %** a zlepšenie Sharpe ratio na **1,18**, čo bola najstabilnejšia modifikácia.
- **RSI filter:** Vyradil prekúpené akcie ( $RSI > 70$ ). Táto verzia však **nezlepšila rizikové parametre** a dosiahla ešte vyšší drawdown ( $-55,4 \%$ ), čím ukázala, že nie všetky technické indikátory sú pre momentum vhodné.
- **Výnosový filter (7 %):** Zaradil len akcie so 6-mesačným výnosom nad 7 %. Výkon stratégie sa znížil, volatilita mierne vzrástla a Sharpe ratio kleslo na 0,88, čo naznačuje, že prah bol zvolený príliš prísne a obmedzil diverzifikáciu.

Momentová stratégia preukázala silný potenciál pre nadvýnos. Z testovaných modifikácií sa najlepšie osvedčil **filter volatility**, ktorý výrazne zlepšil pomer výnosu k riziku a zároveň ochránil portfólio pred najhoršími poklesmi. Ostatné úpravy ukázali, že zvýšenie selektivity nemusí vždy viesť k zlepšeniu stratégie – v niektorých prípadoch naopak znižuje jej efektívnosť.

## 5 Diskusia

### 5.1 Zhrnutie práce

Hlavným cieľom tejto diplomovej práce bolo navrhnúť a implementovať algoritmické obchodné stratégie na vybrané finančné aktíva a následne ich otestovať na historických dátach. Cieľom analýzy bolo zistiť, či jednoduché technické indikátory ako kľzavé priemery (SMA) a index relatívnej sily (RSI) dokážu generovať ziskové obchodné signály a prekonávať pasívne investičné stratégie typu Buy & Hold.

V prvej fáze boli analyzované stratégie typu **SMA crossover**, ktoré generujú nákupné a predajné signály na základe kríženia dvoch kľzavých priemerov s rôznou dĺžkou. Tieto stratégie boli testované na historických dátach indexov **S&P 500** a **DAX 40**, a to za obdobie od 1. 1. 1975 do 31. 1. 2025. Následne bola vykonaná aj samostatná analýza so skráteným časovým obdobím od 1. 1. 2000, aby sa zistil vplyv dĺžky historických dát na výkonnosť stratégií.

V druhej časti práce bola navrhnutá a implementovaná **RSI oscilátorová stratégia**, ktorá bola testovaná na akciách **Tesla, Apple, Microsoft a US Steel** za obdobie od 1. 1. 2000 do 31. 1. 2025. Stratégia vychádzala zo známych hraníc RSI (30 a 70), pričom boli preskúmané aj jej modifikácie, ako napríklad kombinácia s trendovým filtrom alebo úprava prahových hodnôt.

Na vyhodnotenie výkonnosti jednotlivých stratégií boli použité nasledovné metriky:

- **Celkový výnos**
- **Sharpeho pomer**, ktorý hodnotí výnos vzhľadom na volatilitu
- **Maximálny pokles** (drawdown) ako miera rizika
- **Počet obchodov a ich úspešnosť** (win rate)

Ako tretia bola navrhnutá a testovaná **momentová stratégia**, ktorá vychádza z predpokladu, že aktíva, ktoré v nedávnej minulosti dosahovali vyššie výnosy, majú tendenciu pokračovať v raste aj v nasledujúcom období. Táto stratégia bola implementovaná formou výberu akcií s najvyšším mesačným výkonom za predchádzajúce obdobie (tzv. lookback period) a ich následného držania počas jedného mesiaca. Testovanie prebiehalo na rovnakom súbore akcií ako v prípade RSI stratégie, teda na tituloch Tesla, Apple, Microsoft a US Steel, v časovom intervale od 1. 1. 2000 do 31. 1. 2025. Stratégia bola vyhodnocovaná na základe rovnakých metrík ako predchádzajúce prístupy, s cieľom zistiť, či jednoduchý princíp hybnosti dokáže generovať nadpriemerný výnos v porovnaní s trhom aj inými technickými indikátormi. Zároveň boli sledované aj potenciálne riziká takejto stratégie, ako napríklad časté rebalansovanie a vyššia volatilita.

Testovanie stratégií prebiehalo formou backtestovania na historických dátach, bez započítania transakčných nákladov, cenového sklzu a dividend. Hoci takéto zjednodušenie môže skresliť výsledky v reálnom obchodovaní, umožňuje porovnať efektivitu jednotlivých stratégií v čistom technickom zmysle a identifikovať ich potenciálnu robustnosť.

## 5.2 Výsledky testovania SMA crossover stratégie

Testovanie SMA crossover stratégií na historických dátach indexov S&P 500 a DAX 40 prinieslo viacero zaujímavých zistení. Výsledky ukázali, že aj jednoduché technické stratégie dokážu efektívne riadiť riziko a v niektorých prípadoch prekonať pasívnu stratégiu Buy & Hold.

V prípade dlhého testovaného obdobia od roku 1975 dosiahla stratégia Buy & Hold na indexe S&P 500 najvyšší celkový výnos (8501 %), no bola spojená s výrazným maximálnym poklesom kapitálu (-64,33 %). Naopak, stratégia SMA 50/200 dosiahla nižší výnos (3978 %), ale preukázala lepšiu Sharpeho pomer (0,57) a podstatne nižší drawdown (-36,10 %). Rôzne kombinácie kľzavých priemerov vykázali odlišnú výkonnosť – stratégia SMA 10/200 sa ukázala ako efektívna z pohľadu pomeru výnosu a rizika, zatiaľ čo SMA 27/86 dosiahla najnižší drawdown (-33,68 %).

Pri testovaní na nemeckom indexe DAX 40 boli celkové výnosy nižšie ako na americkom trhu, no aj tu sa potvrdili výhody SMA stratégií pri riadení rizika. Buy & Hold priniesla síce výnos 5185 %, ale s extrémnym drawdownom (-76,74 %). SMA stratégie ako 10/100 či 10/200 dosiahli lepší Sharpeho pomer a nižšie maximálne straty, pričom napríklad SMA 10/100 prekonala Buy & Hold v oboch parametroch.

Zásadným zistením bolo, že zmena testovacieho obdobia mala významný vplyv na výkonnosť stratégií. Pri skrátení dát na obdobie po roku 2000 sa výkon Buy & Hold znížil na 315 % (S&P 500) a 221 % (DAX 40), pričom zároveň výrazne narástol význam riadenia rizika. Viaceré SMA stratégie, ako napríklad 10/200, 20/200 a 50/200, dosiahli vyšší výnos než Buy & Hold a zároveň nižší drawdown. Najlepšie rizikovo upravené výnosy vykázala stratégia SMA 10/200 (Sharpeho pomer 0,5682 pri S&P 500 a 0,4440 pri DAX 40).

Výsledky testovania tak poukazujú na nasledovné závery:

- **SMA crossover stratégie sú schopné znižovať riziko portfólia**, predovšetkým v období silných poklesov trhu.
- **Niektoré SMA kombinácie (najmä SMA 10/200)** dokážu dosahovať vyššie výnosy ako Buy & Hold, najmä v novších trhových podmienkach.
- **Prenositel'nosť medzi trhmi** je potvrdená – aj keď výnosy sa líšia podľa trhového prostredia, zlepšenie v pomere výnos/riziko je konzistentné.
- **Zmena časového horizontu významne ovplyvňuje výsledky** – pri moderných dátach sa efektívnosť SMA stratégií ešte viac prejavuje.

Tieto poznatky potvrdzujú, že aj jednoduché technické indikátory, ak sú správne implementované, môžu predstavovať efektívny nástroj v algoritmickej obchodovaní. Vhodnou kombináciou parametrov možno prispôbiť stratégiu konkrétnemu investičnému cieľu – maximalizácii výnosu, znižovaniu drawdownu alebo zlepšeniu rizikovo upraveného výnosu.

### 5.3 Výsledky testovania RSI stratégie

Testovanie RSI oscilátorovej stratégie na akciách Tesla, Apple, Microsoft a US Steel preukázalo, že aj jednoduchý indikátor dokáže generovať zmysluplné obchodné signály s potenciálom na dosahovanie nadpriemerných výnosov a riadenie rizika.

**Základná stratégia** (RSI 14 s prahmi 30/70) priniesla veľmi silné výsledky najmä pri technologických akciách, pričom:

- **Tesla** dosiahla výnos 11 456 % s výnimočne vysokým Sharpeho pomerom 5,11 a win rate 83,7 %.
- **Apple** a **Microsoft** síce nedosiahli vyšší výnos než Buy & Hold, ale prekonal ho z hľadiska volatility a stability – Sharpeho pomery boli 3,13 (Apple) a 4,24 (Microsoft).
- **US Steel** je špecifickým prípadom – RSI stratégia prekonala Buy & Hold aj vo výnose (440 % vs. 36 %), no stále mala vysoký drawdown, čo naznačuje rizikovosť tohto aktíva.

Vo všetkých prípadoch bola **úspešnosť obchodov nad 70 %**, pričom pri Tesle presiahla 83 %. To naznačuje, že RSI stratégia vie efektívne identifikovať krátkodobé extrémny a využiť ich vo svoj prospech.

Aplikovaním viacerých modifikácií sa ukázalo, že **výkonnosť RSI stratégie je možné výrazne ovplyvniť** zmenou nastavení a doplnkových filtrov.

- **Zmena prahových hodnôt RSI (napr. 20/70, 30/80)** mala rôzne účinky. Všeobecne platilo, že prísnejšie podmienky viedli k **nižšiemu počtu obchodov** a často aj **nižšiemu výnosu**, hoci win rate bol niekedy vyšší (napr. Tesla – 92 % pri prahoch 20/70). Výnimkou bol US Steel, kde prah 20/70 priniesol najvyšší výnos (613 %).
- **Zmena dĺžky RSI** preukázala silný vplyv na charakter stratégie. Kým **RSI 7 dní** výrazne zvýšil aktivitu (viac obchodov) a v prípade niektorých akcií dramaticky zvýšil výnos – až 27 678 % pri Tesle a 248 436 % pri US Steel, **RSI 30 dní** bol konzervatívnejší – menej obchodov, vyššia úspešnosť, ale nižší výnos.
- **Filter podľa trendu (SMA 200)** mal zmiešané výsledky. Zlepšil výnos aj úspešnosť napríklad pri Apple (výnos 9 520 %, win rate 85,7 %). Naopak, pri Microsofte a US Steel výkonnosť klesla, čo poukazuje na to, že tento filter je vhodnejší pre stabilne rastúce akcie.
- **Objemový filter (Volume Spike)** výrazne **zvýšil presnosť obchodov**, pričom win rate pri Apple, Microsoft a US Steel presiahol 88 %. Napriek nižšiemu počtu obchodov sa niekedy zvýšil aj výnos – najvýraznejšie pri US Steel (z 440 % na 3 106 %).

RSI stratégia s parametrami **14 dní 30/70** sa ukázala ako **robustná a univerzálne použiteľná**. Dosiahla solídnu výkonnosť na rôznych akciách a dobre odolávala volatilitu trhu.

**Kratšia RSI (7 dní)** je vhodná pre aktívnych obchodníkov ochotných znášať vyššiu frekvenciu obchodov a vyššie riziko výmenou za potenciálne zaujímavé nadvýnosy.

**Dlhšia RSI (30 dní) a filtre podľa trendu alebo objemu** sú efektívne pre konzervatívnejšie stratégie so zameraním na stabilitu a kvalitu signálov.

**Správanie stratégie je vysoko závislé od typu aktíva.** Zatiaľ čo technológie reagovali veľmi pozitívne, cyklické akcie ako US Steel si vyžadujú špecifické prístupy a prísnejšie podmienky vstupu/výstupu.

Výsledky testovania potvrdzujú, že **RSI oscilátorová stratégia predstavuje životaschopný algoritmický prístup** k obchodovaniu. Vďaka jej jednoduchej logike, širokej modifikovateľnosti a možnosti kombinácie s inými indikátormi (napr. SMA, objem) môže byť hodnotným nástrojom pre investorov so záujmom o technickú analýzu.

#### 5.4 Výsledky testovania momentovej stratégie

Testovanie momentovej investičnej stratégie ukázalo, že prístup založený na sledovaní historickej výkonnosti aktív dokáže generovať nadpriemerné výnosy, pričom zároveň poskytuje vysokú flexibilitu pri výbere a modifikácii vstupných podmienok. V porovnaní s pasívnou stratégiou Buy & Hold v indexe S&P 500 sa momentum stratégia ukázala ako výrazne výkonnejšia, hoci za cenu vyššej volatility.

Základná stratégia, ktorá mesačne zaradila do portfólia akcie s pozitívnym 6-mesačným výnosom (AAPL, MSFT, X a od roku 2011 aj TSLA), **dosiahla celkový výnos +5971 %**, s priemerným ročným výnosom 33,6 % a Sharpeho pomerom 0,99. V porovnaní s výkonom indexu S&P 500 (+370 %) bol tento rozdiel výrazný. Hlavnou nevýhodou však bola **vysoká volatility (35,3 %) a významný maximálny drawdown (-50,1 %)**, čo poukazuje na vysokú citlivosť stratégie počas krízových období.

V snahe zlepšiť stabilitu výkonnosti a znížiť rizikovosť portfólia boli otestované viaceré **modifikácie** základnej momentum stratégie:

- **Filter volatility** bol najefektívnejšou úpravou. Vylúčením akcií s nadpriemernou volatilityou sa znížil drawdown na -22,4 % a Sharpeho pomer sa zlepšil na 1,18. Výnos síce klesol na +1835 %, ale **pomerný výnos k riziku bol najlepší zo všetkých verzií.**
- **RSI filter** (vylúčenie prekúpených akcií s RSI > 70) **znížil výnos aj stabilitu stratégie**, pričom Sharpeho pomer klesol na 0,90 a drawdown sa zhoršil na -55,4 %. Tento výsledok naznačuje, že RSI nie je vhodným doplnkom pre momentum prístup, keďže môže vyradiť akcie v silnom trende, čo znižuje potenciál výnosu.
- **Výnosový filter** (minimálne +7 % za 6 mesiacov) znížil diverzifikáciu portfólia, čo sa prejavilo **poklesom výnosu aj efektivity stratégie** – Sharpeho pomer klesol na 0,88,

volatilita mierne vzrástla a maximálny pokles nebol výrazne znížený. Tento filter bol pravdepodobne príliš prísny a obmedzil prístup k inak výkonným titulom.

Momentum stratégia preukázala silný potenciál pre nadvýnos oproti indexovému investovaniu, no za cenu vyššej volatility a rizika poklesu.

Najlepšou modifikáciou z pohľadu vyváženia výnosu a rizika bol **filter volatility**, ktorý zachoval silnú výkonnosť pri výrazne zníženom riziku. Naopak, **filtre ako RSI alebo prahový výnos** nezlepšili stratégiu – buď znížili výnosy, alebo nedokázali znížiť rizikovosť, čím sa stali menej efektívnymi.

Momentum stratégia je vhodná najmä pre **aktívnejších investorov s ochotou znášať vyššiu volatilitu**, pričom vhodným doplnkom môže byť **konzervatívna verzia s filtrami** pre stabilnejších investorov.

Výsledky ukazujú, že momentum ako investičný princíp má **praktické využitie pri algoritmickej obchodovaní**, najmä ak je doplnený o mechanizmy riadenia rizika. Zároveň sa ukazuje, že **nie každá modifikácia automaticky vedie k zlepšeniu**, a preto je dôležité každú zmenu dôkladne testovať v kontexte konkrétnych trhových podmienok a obchodných cieľov investora.

## 5.5 Diskusia k výsledkom

V diskusii nadvižeme na kľúčové teoretické prístupy vo finančnej vede, predovšetkým na **hypotézu efektívneho trhu (EMH)**, ktorú formuloval Eugene **Fama** (1970)<sup>26</sup>, a na **empirické zistenia o momentovom efekte**, ktoré publikovali Narasimhan **Jegadeesh** a **Sheridan Titman** (1993)<sup>27</sup>. V tejto časti konfrontujeme ich závery s výsledkami algoritmickej stratégie testovaných v tejto práci.

### 5.5.1 Efektívnosť trhu a hypotéza E. Famu

Podľa Famu v rámci silnej formy hypotézy efektívneho trhu (Efficient Market Hypothesis) sú všetky dostupné informácie okamžite a efektívne zahrnuté v cenách finančných aktív. Z tohto predpokladu vyplýva, že žiadna forma technickej analýzy – vrátane obchodných

---

<sup>26</sup> FAMA, E. Efficient Capital Markets: A Review of Theory and Empirical Work, 1970. The Journal of Finance, Vol. 25, No. 2, s. 383-417

<sup>27</sup> JEGADEESH, N., TITMAN, S. Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency, 1993. The Journal of Finance, vol. 48, No. 1, s. 65-91

algoritmov založených na historických cenových vzorcoch – **nedokáže dlhodobo generovať nadmerné výnosy upravené o riziko.**

Testované stratégie však túto hypotézu spochybňujú. Napríklad:

- **SMA crossover stratégia** v rôznych nastaveniach preukázala možnosť dosahovať výnosy, ktoré prekonávali výkonnosť pasívneho benchmarku (S&P 500).
- **RSI stratégia**, hoci konzervatívnejšia, ukázala určitú mieru schopnosti identifikovať vhodné vstupy a výstupy na základe prepredanosti a prekúpenosti.
- **Najsilnejší protiargument voči EMH však predstavuje momentová stratégia**, ktorá v základnej forme dosiahla výnos +5971 % a Sharpe ratio 0,99 – teda nielen vysoký absolútny výnos, ale aj efektívne zhodnotenie pri zohľadnení rizika.

Tieto výsledky naznačujú, že **ceny na trhu nereagujú okamžite a dokonale na všetky informácie**, čím sa vytvára priestor pre využitie cenovej zotrvačnosti a technickej analýzy – v priamom rozpore s tvrdením Famu.

### 5.5.2 Momentum efekt a porovnanie s výskumom Jegadeesha & Titmana

**Jegadeesh a Titman** svojou prácou *Returns to Buying Winners and Selling Losers* významne spochybnili silnú formu EMH. Ich empirický výskum ukázal, že akcie, ktoré zažili pozitívny vývoj v posledných 3 až 12 mesiacoch, **majú tendenciu pokračovať v raste aj v nasledujúcich obdobiach** a naopak. Tento jav pomenovali ako **momentum efekt** a navrhli stratégiu „**buy winners, sell losers**“, ktorá v ich výskume prinášala abnormálne výnosy.

Testovaná momentum stratégia v tejto práci nadväzuje na ich metodológiu:

- Zvolili sme **6-mesačný výnos** ako kritérium pre zaradenie akcií do portfólia, pričom výber sa aktualizoval **mesačne**.
- Výsledky našej stratégie potvrdzujú zistenia Jegadeesha a Titmana – pozitívna výkonnosť v minulosti **bola silným indikátorom budúcich výnosov**.
- Navyše, najúspešnejšia modifikácia – **momentum stratégia s filtrom volatility** – preukázala **výrazné zlepšenie Sharpe ratio (1,18)** a zníženie drawdownu (-22,4 %), čo naznačuje, že momentum efekt možno ešte posilniť vhodným riadením rizika.

Tieto empirické dôkazy podporujú tvrdenia Jegadeesha a Titmana, že **trhy nevykazujú dokonalú efektívnosť**, a že **zotrvačnosť cien môže byť systematicky využívaná na tvorbu**

**výnosných stratégií.** Navyše, naše výsledky naznačujú, že jednoduché pravidlá výberu (napr. pozitívny výnos za 6 mesiacov) môžu byť rovnako efektívne ako komplexné modely, pokiaľ sú konzistentne aplikované.

### 5.5.3 Záver k porovnaniu

Porovnanie našich výsledkov s kľúčovými teoretickými rámcami prináša niekoľko záverov:

- Výsledky stratégie RSI a SMA čiastočne spochybňujú silnú formu EMH, no **najväčší rozpor predstavuje momentum stratégia**, ktorá potvrdzuje prítomnosť systematickej anomálie v trhovom správaní.
- Naše zistenia sú **v súlade s empirickými dôkazmi o momentum efekte**, ako ho opísali Jegadeesh a Titman, a zároveň ich ďalej rozvíjajú prostredníctvom testovania modifikácií.
- Hoci naše stratégie nevylučujú možnosť, že časť nadvýnosu môže byť výsledkom špecifického výberu aktív či obdobia, **systematickosť a konzistentnosť výsledkov naprieč stratégiami podporuje hypotézu, že trhy nie sú dokonale efektívne.**

### 5.5.4 Záver k hypotéze 1

Hypotéza: Výkon SMA stratégií výrazne ovplyvňuje zvolená dĺžka kľzavých priemerov použitá pre testovanie.

Záver: Hypotéza sa **potvrdila**. Pri porovnaní výkonu SMA stratégií na dátach od roku 1975 oproti dátam od roku 2000 boli pozorované výrazné rozdiely v celkových výnosoch, volatilita aj v efektívite stratégie. Kratšie obdobie vykazovalo často nadhodnotené výsledky (najmä počas silných býčích trhov), čo svedčí o riziku pretrénovania pri výbere parametrov na príliš úzkom vzorkovaní dát.

### 5.5.5 Záver k hypotéze 2

Hypotéza: Algoritmická stratégia založená na indikátore RSI dosahuje významne vyšší výnos než pasívne investovanie.

Záver: Táto hypotéza sa **nepotvrdila**. RSI stratégia síce v niektorých prípadoch (napr. akcia US Steel) dosiahla vyšší výnos než benchmark, avšak vo väčšine testovaných

akcií (napr. AAPL, MSFT) zaostávala za výkonom pasívneho investovania. Navyše, po zohľadnení rizika (Sharpe ratio) a drawdownu boli výsledky RSI stratégie menej presvedčivé. RSI stratégia sa teda javí ako málo robustná v porovnaní s jednoduchým pasívnym prístupom.

### 5.5.6 Záver k hypotéze 3

Hypotéza: Momentová stratégia generuje vyššie výnosy v porovnaní s náhodným výberom aktív, čím spochybňuje teóriu efektívneho trhu.

Záver: Hypotéza sa **čiastočne potvrdila**. Výsledky testovania momentum stratégie ukazujú, že pri vhodne zvolenom časovom rámci a periodicite rebalansovania možno dosiahnuť nadpriemerné výnosy. Momentum stratégia preukázala najlepšie výsledky spomedzi všetkých testovaných prístupov, najmä v podmienkach amerických trhov. Tieto výsledky podporujú závery Jegadeesha a Titmana (1993) o dočasnej predvídateľnosti výnosov, čo je v rozpore so teóriou efektívneho trhu.

### 5.5.7 Záver k hypotéze 4

Hypotéza: Výkonnosť algoritmickej stratégie je vyššia na amerických akciových trhoch než na nemeckom indexe DAX

Záver: Hypotéza sa **potvrdila**. Testovanie preukázalo, že všetky stratégie – RSI, SMA aj momentum – dosahovali **výrazne lepšie výsledky na amerických akciách** než pri aplikácii na index DAX. Na DAXe bol často zaznamenaný nižší výnos, vyššia volatilita a horší Sharpe ratio. Možné vysvetlenie spočíva v rozdielnej štruktúre trhu, likvidite a volatilitate medzi americkým a nemeckým trhom.

## Záver

Cieľom práce bolo preskúmať algoritmické obchodné stratégie a otestovať ich výkonnosť na historických dátach z finančných trhov. V práci sme implementovali tri rôzne typy stratégií: stratégiu prekročenia jednoduchých kľzavých priemerov (SMA), stratégiu založenú na RSI oscilátore a momentovú stratégiu, pričom každá bola testovaná na rôznych finančných aktívach a s viacerými modifikáciami.

Pri **SMA stratégii** sme sa zamerali na identifikáciu optimálnej kombinácie dĺžok krátkodobého a dlhodobého priemeru. Zistili sme, že vo všeobecnosti platí, že kratšie priemery reagujú citlivejšie na zmenu trendu, no sú náchylnejšie na generovanie falošných signálov. Naopak, dlhšie priemery poskytovali stabilnejšie signály, ale s oneskorením. V ďalšej fáze sme testovali, ako ovplyvní výsledky stratégie skrátenie časového obdobia – namiesto celého obdobia od roku 1975 sme analyzovali dáta od roku 2000. Výsledky ukázali, že dĺžka historického obdobia môže mať výrazný vplyv na výkonnosť stratégie, pričom v novších obdobiach boli niektoré nastavenia efektívnejšie než v dlhodobom priemere.

**RSI stratégia** bola testovaná na individuálnych akciách Tesla, Apple, Microsoft a US Steel. V rámci testovania sme porovnávali viaceré kombinácie dĺžky RSI indikátora a hraničných úrovní pre vstup a výstup z pozície. Okrem toho sme implementovali aj **dodatočné filtre** – konkrétne **trendový filter** a **filter objemu**, ktorých cieľom bolo eliminovať menej významné signály a zamerať sa na obchodné príležitosti v súlade s hlavným trendom. Ukázalo sa, že kombinácia RSI s týmito filterami dokáže mierne zlepšiť pomer výnosu a rizika, pričom efektívnosť stratégie bola výrazne ovplyvnená charakterom konkrétneho aktíva.

**Momentová stratégia**, založená na 6-mesačnom výnose, dosiahla v testovanom období výrazne vyšší výnos než porovnávaná stratégia s indexom S&P 500, no bola spojená s vysokou volatilitou a drawdownom. Z testovaných modifikácií sa ako najefektívnejšia ukázala verzia s **filtrum volatility**, ktorá znížila rizikovosť portfólia a zároveň zlepšila pomer výnosu k riziku. Naopak, **filter RSI** a **výnosový prah** výber aktív skôr zhoršili, keďže vylúčili niektoré výkonné tituly alebo znížili diverzifikáciu.

Výsledky ukazujú, že momentum prístup má potenciál generovať nadvýnosy, najmä v rastových trhových fázach, no jeho úspešnosť výrazne závisí od spôsobu výberu aktív a riadenia rizika. Rozumná filtrácia na základe volatility sa ukazuje ako najefektívnejší nástroj na zlepšenie stability takejto stratégie.

Diskusia výsledkov ukázala, že neexistuje univerzálne najlepšia stratégia, ktorá by jednoznačne dominovala všetkým trhom a obdobiam. Úspešnosť jednotlivých prístupov závisela od charakteristík testovaného aktíva a zvolených parametrov stratégie. Práca zároveň potvrdila, že aj jednoduché technické pravidlá môžu generovať nadpriemerné výnosy, no len za určitých podmienok. Efektivita stratégií bola rôznorodá, pričom v niektorých prípadoch sa algoritmické prístupy javia ako vhodný nástroj na systematické obchodovanie, najmä ak sú vhodne parametrizované a doplnené o dodatočné filtre alebo pravidlá.

V práci sme sa zamerali na vybrané indikátory a stratégie, pričom sme zámerne abstrahovali od obchodných nákladov, ako sú poplatky, spread či dane. Tie môžu mať v praxi zásadný vplyv na výsledky a ich zahrnutie by mohlo spresniť odhady reálnych výnosov.

Okrem toho sme neskúmali kombináciu viacerých technických indikátorov v rámci jednej stratégie – napríklad prepojenie RSI s indikátormi ako MACD, Bollinger Bands alebo ADX. V práci sme síce testovali RSI spolu s trendovým filtrom (SMA 200) a filtrom objemu, no ďalšie kombinácie by mohli zvýšiť robustnosť stratégií a znížiť počet falošných signálov.

Ďalším smerom tiež môže byť využitie pokročilejších metód ako sú strojové učenie alebo rozšírenie testovania o intradenné alebo vysoko-frekvenčné dáta.

## Zoznam použitej literatúry

1. ALDRIDGE, Irene. High-Frequency Trading. Druhé vydanie. Wiley, 2013. ISBN 978-1118343500.
2. ARONSON, David. Evidence-Based Technical Analysis: Applying the Scientific Method and Statistical Inference to Trading Signals. Wiley, 2006. ISBN 978-0470008744.
3. BELL, Steve. Quantitative Finance for Dummies. For Dummies, 2016. ISBN 978-1118769461.
4. CARTEA, Alvaro, JAINMUNGAL Sebastian a Jose PENALVIA. Algorithmic and High-Frequency Trading. Cambridge University Press, 2015. ISBN 978-1107091146.
5. COULLING, Anna. A Complete Guide To Volume Price Analysis: Read the book then read the market. Independently published, 2023. ISBN 979-8870675503.
6. DAVEY, J. Kevin. Building Winning Algorithmic Trading Systems. Wiley, 2014. ISBN 978-1118778982.
7. DE PRADO, Lopez Marco. Advances in Financial Machine Learning. Wiley, 2018. ISBN 978-1119482086.
8. DONADIO, Sebastien, GHOSH Sourav a Romain Rossier. Developing High-Frequency Trading Systems. Packt Publishing, 2022. ISBN 978-1803242811.
9. FAMA, E. Efficient Capital Markets: A Review of Theory and Empirical Work, 1970. The Journal of Finance, Vol. 25, No. 2
10. CHAN, P. Ernest. Quantitative Trading: How to Build Your Own Algorithmic Trading Business. Wiley, 2009. ISBN 9780470284889
11. CHAN, P. Ernest. Algorithmic Trading: Winning Strategies and Their Rationale. Wiley, 2013. ISBN 978-1118460146.
12. CHAN, P. Ernest. Machine Trading: Deploying Computer Algorithms to Conquer the Markets. Wiley, 2017. ISBN 978-1119219606.
13. JEGADEESH, N, & TITMAN, S. Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency, 1993. The Journal of Finance, vol. 48, No. 1, pp. 65-91
14. JOHNSON, Barry. Algorithmic Trading and DMA: An introduction to direct access trading strategies. 4Myeloma Press, 2010. ISBN 978-0956399205.

15. LEWIS, Michael. Flash Boys: A Wall Street Revolt. W. W. Norton & Company, 2015. ISBN 978-0393351590.
16. NARANG, K. Rishi. Inside the Black Box: A Simple Guide to Quantitative and High-Frequency Trading. Druhé vydanie. Wiley, 2013. ISBN 978-1118362419.
17. POLE, Andres. Statistical Arbitrage: Algorithmic Trading Insights and Techniques. Wiley, 2007. ISBN 978-0470138441.
18. TEALL, John. Financial Trading and Investing. Tretie vydanie. Academic Press, 2022. ISBN 978-0323909556.
19. WEIMING, James Ma. Mastering Python for Finance: Implement advanced state-of-the-art financial statistical applications using Python. Druhé vydanie. Packt Publishing, 2019. ISBN 978-1789346466.
20. WILLIAMS, E. Edward a John A. DOBELMAN. Quantitative Financial Analytics: The Path to Investment Profits. World Scientific Publishing Company, 2017. ISBN 978-9813224247.
21. ZUCKERMAN, Gregory. The Man Who Solved The Market: How Jim Simons Launched the Quant Revolution. New York: Penguin Books. 20019. ISBN 9780735217980

## Prílohy

### 5.6 Python kód používaný pre analýzu SMA crossover stratégie

```
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np

# Načítanie dát zo súboru SPX historical data.csv
file_path = "SPX historical data.csv"
data = pd.read_csv(file_path, parse_dates=['Date'], index_col='Date')

# Výpočet SMA indikátorov
data['SMA50'] = data['Close'].rolling(window=50).mean()
data['SMA200'] = data['Close'].rolling(window=200).mean()

# Generovanie signálov na základe SMA crossoveru
data['Signal'] = np.where(data['SMA50'] > data['SMA200'], 1, 0)
data['Position'] = data['Signal'].diff()

# Vykreslenie grafu
plt.figure(figsize=(12,6))
plt.plot(data.index, data['Close'], label="Cena (S&P 500)", color='black', alpha=0.6)
plt.plot(data.index, data['SMA50'], label="SMA 50", color='blue', linestyle='dashed')
plt.plot(data.index, data['SMA200'], label="SMA 200", color='red', linestyle='dashed')

# Identifikácia BUY a SELL signálov
crossovers = data[data['Position'] != 0]
buy_signals = crossovers[crossovers['Position'] > 0]
sell_signals = crossovers[crossovers['Position'] < 0]

# Vykreslenie crossover bodov
plt.scatter(buy_signals.index, buy_signals['Close'], color='green', marker='^', s=60,
            label=f"BUY ({len(buy_signals)})", edgecolor='black', alpha=0.9, zorder=3)
plt.scatter(sell_signals.index, sell_signals['Close'], color='red', marker='v', s=60,
            label=f"SELL ({len(sell_signals)})", edgecolor='black', alpha=0.9, zorder=3)

# Legenda a formátovanie
plt.title("S&P 500 - SMA 50/200 Crossover stratégia")
plt.xlabel("Dátum")
plt.ylabel("Cena")
plt.legend()
plt.grid()
plt.show()

# Výpočet denných log výnosov
data['Returns'] = np.log(data['Close'] / data['Close'].shift(1))

# Výnosy stratégie na základe signálov
data['Strategy Returns'] = data['Returns'] * data['Signal'].shift(1)

# Celkový výnos
cumulative_buy_hold = np.exp(data['Returns'].sum()) - 1
cumulative_strategy = np.exp(data['Strategy Returns'].sum()) - 1

# Sharpe Ratio
sharpe_strategy = data['Strategy Returns'].mean() / data['Strategy Returns'].std() *
np.sqrt(252)
sharpe_buy_hold = data['Returns'].mean() / data['Returns'].std() * np.sqrt(252)

# Max Drawdown - stratégia
cumulative_strategy_returns = (1 + data['Strategy Returns']).cumprod()
```

```

peak_strategy = cumulative_strategy_returns.cummax()
drawdown_strategy = (cumulative_strategy_returns - peak_strategy) / peak_strategy
max_drawdown_strategy = drawdown_strategy.min()

# Max Drawdown - Buy & Hold
cumulative_bh_returns = (1 + data['Returns']).cumprod()
peak_bh = cumulative_bh_returns.cummax()
drawdown_bh = (cumulative_bh_returns - peak_bh) / peak_bh
max_drawdown_bh = drawdown_bh.min()

# Výstup
print(f"Celkový výnos Buy & Hold: {cumulative_buy_hold:.2%}")
print(f"Celkový výnos SMA strategie: {cumulative_strategy:.2%}")
print(f"Sharpe Ratio Buy & Hold: {sharpe_buy_hold:.2f}")
print(f"Sharpe Ratio strategie: {sharpe_strategy:.2f}")
print(f"Maximální Drawdown Buy & Hold: {max_drawdown_bh:.2%}")
print(f"Maximální Drawdown strategie: {max_drawdown_strategy:.2%}")

```

## 5.7 Python kód používaný pre analýzu RSI oscilátorovej stratégie

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

# Funkcia na výpočet RSI
def compute_rsi(df, period=14):
    delta = df['Close'].diff()
    gain = np.where(delta > 0, delta, 0)
    loss = np.where(delta < 0, -delta, 0)
    avg_gain = pd.Series(gain).rolling(window=period).mean()
    avg_loss = pd.Series(loss).rolling(window=period).mean()
    rs = avg_gain / avg_loss
    rsi = 100 - (100 / (1 + rs))
    return rsi

# Funkcia na backtest a výpis signálov
def backtest_with_signals(df, period=14, lower=30, upper=70):
    df = df.copy()
    df['RSI'] = compute_rsi(df, period)
    df['Signal'] = 0
    df['Buy_Price'] = np.nan
    df['Sell_Price'] = np.nan

    position = 0

    for i in range(1, len(df)):
        if position == 0 and df['RSI'].iloc[i - 1] < lower and df['RSI'].iloc[i] > lower:
            df.at[df.index[i], 'Signal'] = 1
            df.at[df.index[i], 'Buy_Price'] = df['Open'].iloc[i]
            position = 1
        elif position == 1 and df['RSI'].iloc[i - 1] > upper and df['RSI'].iloc[i] < upper:
            df.at[df.index[i], 'Signal'] = -1
            df.at[df.index[i], 'Sell_Price'] = df['Open'].iloc[i]
            position = 0

    return df

# Funkcia na vykreslenie grafu bez textu RSI
def plot_signals(df, symbol):
    buy_signals = df.dropna(subset=['Buy_Price'])
    sell_signals = df.dropna(subset=['Sell_Price'])

    plt.figure(figsize=(14, 6))
    plt.plot(df['Date'], df['Close'], label='Záverečná cena', alpha=0.6)
    plt.scatter(buy_signals['Date'], buy_signals['Buy_Price'], marker='^', color='green',
label=f'Buy signály ({len(buy_signals)})', s=100)
    plt.scatter(sell_signals['Date'], sell_signals['Sell_Price'], marker='v', color='red',
label=f'Sell signály ({len(sell_signals)})', s=100)

    plt.title(f'{symbol} - RSI obchodná stratégia (Buy/Sell signály)')
    plt.xlabel('Dátum')
    plt.ylabel('Cena')
    plt.legend()
    plt.grid(True)
    plt.tight_layout()
    plt.show()

# Zoznam súborov a symbolov
files = {
    "TSLA": "tsla_historical_data.csv",
    "AAPL": "aapl_historical_data.csv",
```

```
"MSFT": "msft_historical_data.csv",
"X": "ussteel_historical_data.csv"
}

# Spracovanie a vykreslenie pre všetky akcie
for symbol, path in files.items():
    df = pd.read_csv(path)
    df['Date'] = pd.to_datetime(df['Date'])
    df = df[(df['Date'] >= '2000-01-01') & (df['Date'] <= '2025-01-31')]
    df = df.sort_values('Date').reset_index(drop=True)
    df_with_signals = backtest_with_signals(df)
    plot_signals(df_with_signals, symbol)
```

## 5.8 Python kód používaný pre analýzu momentovej stratégie

```
import pandas as pd
import numpy as np
from datetime import datetime

# 1. Načítanie a predspracovanie dát
tickers = {
    'TSLA': 'tsla_historical_data.csv',
    'AAPL': 'aapl_historical_data.csv',
    'MSFT': 'msft_historical_data.csv',
    'X': 'ussteel_historical_data.csv'
}

# Načítanie a zlúčenie dát podľa tickerov
price_data = {}
for ticker, file in tickers.items():
    df = pd.read_csv(file, parse_dates=['Date'])
    df = df[['Date', 'Close']].rename(columns={'Close': ticker})
    df.set_index('Date', inplace=True)
    price_data[ticker] = df

combined_df = pd.concat(price_data.values(), axis=1, join='inner').sort_index()

# Výpočet mesačných cien a indikátorov
monthly_prices = combined_df.resample('M').last()
momentum_returns = monthly_prices.pct_change(6)
daily_returns = combined_df.pct_change()
volatility_6m = daily_returns.rolling(window=126).std()
monthly_volatility = volatility_6m.resample('M').last()

# 2. Výpočet RSI indikátora
def compute_rsi(series, window=14):
    delta = series.diff()
    gain = delta.where(delta > 0, 0)
    loss = -delta.where(delta < 0, 0)
    avg_gain = gain.rolling(window=window).mean()
    avg_loss = loss.rolling(window=window).mean()
    rs = avg_gain / avg_loss
    rsi = 100 - (100 / (1 + rs))
    return rsi

# Vytvorenie RSI pre všetky tickery
rsi_data = {ticker: compute_rsi(combined_df[ticker]) for ticker in combined_df.columns}
rsi_df = pd.DataFrame(rsi_data).resample('M').last()

# 3. Funkcia na backtest stratégie
def backtest(momentum_threshold=0.0, use_volatility_filter=False, use_rsi_filter=False,
rsi_threshold=70):
    results = []

    for i in range(6, len(monthly_prices) - 1):
        date = monthly_prices.index[i]
        next_date = monthly_prices.index[i + 1]
        tickers_set = ['AAPL', 'MSFT', 'X'] if date < pd.to_datetime('2010-07-01') else ['AAPL',
'MSFT', 'X', 'TSLA']

        momentum = momentum_returns.iloc[i][tickers_set]
        selected = momentum[momentum > momentum_threshold]
```

```

    if use_volatility_filter:
        vol = monthly_volatility.loc[date, tickers_set]
        vol_filter = vol[vol <= vol.median()]
        selected = selected[selected.index.isin(vol_filter.index)]

    if use_rsi_filter:
        rsi = rsi_df.loc[date, tickers_set]
        rsi_filter = rsi[rsi < rsi_threshold]
        selected = selected[selected.index.isin(rsi_filter.index)]

    final_selection = selected.index.tolist()

    if final_selection:
        ret = monthly_prices.iloc[i + 1][final_selection] /
monthly_prices.iloc[i][final_selection] - 1
        results.append({'Date': next_date, 'Return': ret.mean()})
    else:
        results.append({'Date': next_date, 'Return': 0.0})

    df = pd.DataFrame(results).set_index('Date')
    df['Cumulative'] = (1 + df['Return']).cumprod()
    return df

# 4. Spustenie stratégie a výsledky
baseline = backtest()
vol_filter = backtest(use_volatility_filter=True)
rsi_filter = backtest(use_rsi_filter=True)
yield_filter = backtest(momentum_threshold=0.07)

# Zhrnutie výsledkov
results = {
    'Základná stratégia': baseline,
    'Filter volatility': vol_filter,
    'Filter RSI': rsi_filter,
    'Výnosový filter (7%)': yield_filter
}

# Výpis výsledkov
for name, df in results.items():
    print(f"{name}:")
    print(f" Konečná hodnota: {df['Cumulative'].iloc[-1]:.2f}")
    print(f" Sharpe ratio: {(df['Return'].mean() / df['Return'].std()) * np.sqrt(12):.2f}")
    print(f" Max drawdown: {(df['Cumulative'] / df['Cumulative'].cummax() - 1).min():.2%}")
    print()

```