

UNIVERZITA PARDUBICE

FAKULTA ELEKTROTECHNIKY A
INFORMATIKY

DIPLOMOVÁ PRÁCE

2026

David Kapeš

Univerzita Pardubice
Fakulta elektrotechniky a informatiky

Adaptivní investiční robo poradce
Diplomová práce

Univerzita Pardubice
Fakulta elektrotechniky a informatiky
Akademický rok: 2025/2026

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení:	Bc. David Kapeš
Osobní číslo:	I24275
Studijní program:	N0613A140007 Informační technologie
Téma práce:	Adaptivní investiční robo poradce
Zadávací katedra:	Katedra softwarových technologií

Zásady pro vypracování

Cílem diplomové práce bude navrhnout a otestovat možnosti adaptivního robo poradce pro investování. V teoretické části student provede rešerši klasických a robotických investičních přístupů a existujících robo-advisory platforem. Praktická část bude věnována otestování adaptivního přístupu k tvorbě robotického poradce založeného na historických datech a uživatelských investičních preferencích (například pomocí regrese, evolučních algoritmů, genetického programování, reinforcement learning apod.). Nakonec student navrhne experimenty, provede je a vyhodnotí jejich výsledky.

Rozsah pracovní zprávy: **50-60**
Rozsah grafických prací:
Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam doporučené literatury:

DANIEL, Gladiš. Akciové Investice. Grada Publishing, A.s, 2015. ISBN 8024753758.
REIDER, Rob a MICHALKA, Alex. Build a Robo-Advisor with Python (From Scratch): Automate Your Financial and Investment Decisions. Simon and Schuster, 2025. ISBN 978-1633439672.
HYNEK, Josef. Genetické algoritmy a genetické programování. Průvodce. Praha: Grada, 2008. ISBN 978-80-247-2695-3.
BROWN, Brandon a ZAI, Alexander. Deep Reinforcement Learning in Action. Simon and Schuster, 2020. ISBN 9781638350507.

Vedoucí diplomové práce: **Ing. Jan Merta, Ph.D.**
Katedra softwarových technologií

Datum zadání diplomové práce: **31. října 2025**
Termín odevzdání diplomové práce: **15. května 2026**

prof. Ing. Petr Doležal, Ph.D. v.r.
děkan

L.S.

Ing. Jan Fikejz, Ph.D. v.r.
vedoucí katedry

V Pardubicích dne 28. listopadu 2025

Prohlašuji:

Práci s názvem Adaptivní investiční robo poradce jsem vypracoval samostatně a uvedl v ní všechny použité literární a informační zdroje v souladu s právními předpisy, vnitřními předpisy a vnitřními normami Univerzity Pardubice.

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

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 7/2025 Pravidla pro odevzdávání, zpřístupňování závěrečných prací veřejnosti a jejich formální úpravu, bude závěrečná práce zpřístupněna veřejnosti prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 15. 07. 2026

David Kapeš

PODĚKOVÁNÍ

Rád bych poděkoval Ing. Janu Mertovi, Ph.D., za odborné vedení mé diplomové práce, cenné připomínky a dobré rady. Dále děkuji Barboře Haincové za podporu a rady při psaní práce. Poděkování patří také celé mé rodině za trpělivost, podporu a zázemí během studia i při zpracování této diplomové práce.

ANOTACE

Tato diplomová práce se zabývá návrhem, implementací a experimentálním ověřením adaptivního investičního robo-poradce. Cílem je ověřit, zda lze pomocí historických tržních dat, investičních preferencí a evolučních algoritmů přizpůsobovat složení portfolia tržnímu prostředí. Prototyp využívá genetický algoritmus a genetické programování a je porovnán s pravidelným rebalancováním a strategií buy-and-hold. Experimenty zahrnují různě riziková i záměrně nevhodně složená portfolia ve třech investičních univerzech: smíšeném multi-asset univerzu, globálních akciových ETF a amerických akciích. Hodnocena je výkonnost, riziko, stabilita výsledků, obrat portfolia a transakční náklady.

KLÍČOVÁ SLOVA

robo-poradce, investiční portfolio, adaptivní alokace aktiv, genetický algoritmus, genetické programování, rebalancování, řízení rizika, walk-forward testování

TITLE

Adaptive Investment Robo-Advisor

ANNOTATION

This thesis presents the design, implementation, and experimental evaluation of an adaptive investment robo-advisor. It examines whether historical market data, investment preferences, and evolutionary algorithms can adapt portfolio allocation to market conditions. The prototype uses a genetic algorithm and genetic programming and is compared with regular rebalancing and buy-and-hold strategies. The experiments cover portfolios with different risk levels and intentionally poor allocations across three investment universes: multi-asset instruments, global country equity ETFs, and individual U.S. stocks. The evaluation considers performance, risk, result stability, portfolio turnover, and transaction costs.

KEYWORDS

robo-advisor, investment portfolio, adaptive asset allocation, genetic algorithm, genetic programming, rebalancing, risk management, walk-forward testing

Obsah

SEZNAM ILUSTRACÍ, ROVNIC A TABULEK	11
SEZNAM ZKRATEK A ZNAČEK	13
TERMINOLOGIE	14
ÚVOD.....	16
1 Investiční poradenství a robo-advisory	17
1.1 Investiční poradenství a role investičního profilu.....	17
1.2 Klasické přístupy k sestavení portfolia	17
1.3 Robo-advisory platformy a jejich princip	18
1.4 Příklady existujících robo-advisory platforem	18
1.5 Limity statického robo-poradenství a motivace adaptivního přístupu.....	19
1.6 Rozdíl mezi existujícími platformami a navrženým řešením	20
2 Investiční portfolio a řízení rizika.....	21
2.1 Třídy aktiv a diverzifikace	21
2.2 Rebalancování portfolia.....	22
2.3 Ukazatele výnosu a rizika	22
2.4 Transakční náklady a turnover.....	23
2.5 Referenční strategie	23
3 Evoluční algoritmy	25
3.1 Princip evolučních algoritmů.....	25
3.2 Genetický algoritmus	25
3.3 Genetické programování	27
3.4 Silně typované genetické programování.....	28
3.5 Vhodnost evolučních metod pro investiční rozhodování	30
3.6 Srovnání s příbuznými pracemi	31
4 Návrh adaptivního robo-poradce	32
4.1 Cíl navrženého systému	32
4.1.1 Jednoduchý příklad baseline portfolia	33

4.2 Celková architektura	33
4.3 Vstupní data a jejich zarovnání.....	34
4.4 Tvorba tržních ukazatelů	35
4.5 Skórovací model a převod skóre na váhy	37
4.6 Řízení aktivního zásahu modelu	39
4.7 Investiční profily	40
4.8 Měsíční simulace portfolia.....	41
4.9 Referenční strategie v návrhu	42
4.10 Genetický algoritmus v navrženém systému	43
4.11 Genetické programování v navrženém systému	45
4.12 Behaviorální filtr GP.....	48
4.13 Fitness funkce	49
4.14 Robustní fitness.....	50
4.15 Walk-forward vyhodnocení	51
4.16 Výstup měsíčních doporučení.....	51
4.17 Omezení návrhu.....	52
5 Experimentální ověření.....	53
5.1 Cíl experimentu.....	53
5.2 Použité datasety	54
5.2.1 Dataset Macro24	54
5.2.2 Dataset GlobalCountry18	55
5.2.3 Dataset USBlueChip18	55
5.3 Testovaná portfolia	56
5.3.1 Profily datasetu Macro24.....	56
5.3.2 Profily datasetu GlobalCountry18	57
5.3.3 Profily datasetu USBlueChip18.....	57
5.4 Společné parametry experimentu.....	58
5.5 Walk-forward postup experimentu	60
5.6 Porovnávání strategie	60

5.7 Hodnocené metriky	61
5.8 Měsíční doporučení v experimentu.....	61
5.9 Reprodukovatelnost experimentu	62
5.10 Omezení experimentálního nastavení	63
6 Vyhodnocení výsledků	64
6.1 Souhrnný pohled na výsledky Macro24	64
6.2 Stabilita výsledků Macro24 a turnover	66
6.3 Vyhodnocení podle typu portfolia	68
6.3.1 Ověření na datasetu GlobalCountry18.....	69
6.3.2 Ověření na datasetu USBlueChip18	69
6.3.3 Srovnání napříč datasety	71
6.4 Případové grafy.....	71
6.5 Porovnání GA a GP	73
6.6 Konkrétní příklad investičního rozhodování modelu	75
6.7 Hlavní závěr experimentu	76
ZÁVĚR	77
POUŽITÁ LITERATURA	79
SEZNAM PŘÍLOH.....	81

SEZNAM ILUSTRACÍ, ROVNIC A TABULEK

Obrázek 1 – Základní cyklus genetického algoritmu	26
Obrázek 2 – Stromová reprezentace jedince v genetickém programování.....	27
Obrázek 3 – Platný strom ve STGP	29
Obrázek 4 – Neplatný strom ve STGP.....	29
Obrázek 5 – Vysokoúrovňová architektura a tok dat mezi vrstvami systému.....	33
Obrázek 6 – Měsíční proces rebalancování a role referenčních strategií	42
Obrázek 7 – Schéma optimalizace parametrického skórovacího modelu pomocí genetického algoritmu.....	44
Obrázek 8 – Schéma tvorby stromového skórovacího modelu pomocí genetického programování	47
Obrázek 9 – Rozhodovací postup behaviorálního filtru GP	48
Obrázek 10 – Průměrná konečná hodnota portfolia podle profilu v datasetu Macro24	65
Obrázek 11 – Ukázka úspěšného OOS průběhu adaptivního modelu	72
Obrázek 12 – Ukázka neúspěšného OOS průběhu adaptivního modelu	72
Tabulka 1 – Kompletní nastavení genetického programování v experimentu	46
Tabulka 2 – Aktiva datasetu Macro24	54
Tabulka 3 – Aktiva datasetu GlobalCountry18	55
Tabulka 4 – Aktiva datasetu USBlueChip18.....	55
Tabulka 5 – Přehled testovaných portfolií datasetu Macro24	56
Tabulka 6 – Výchozí složení profilů datasetu GlobalCountry18	57
Tabulka 7 – Výchozí složení profilů datasetu USBlueChip18	57
Tabulka 8 – Společné parametry experimentu	59
Tabulka 9 – Souhrn průměrné roční OOS výkonnosti datasetu Macro24.....	64
Tabulka 10 – Stabilita výsledků datasetu Macro24 a průměrný turnover	66
Tabulka 11 – Roční relativní výkonnost GA v datasetu Macro24 vůči monthly baseline	67
Tabulka 12 – Roční relativní výkonnost GP v datasetu Macro24 vůči monthly baseline.....	67
Tabulka 13 – Výsledky profilů datasetu GlobalCountry18.....	69
Tabulka 14 – Výsledky profilů datasetu USBlueChip18.....	70
Tabulka 15 – Souhrn výsledků napříč investičními univerzity.....	71
Rovnice 1 – Zápis vah portfolia.....	21
Rovnice 2 – Jednoduchý výnos portfolia.....	22
Rovnice 3 – Složená roční míra růstu	22
Rovnice 4 – Denní výnos aktiva	35
Rovnice 5 – Výnos aktiva za N obchodních dní.....	35
Rovnice 6 – Anualizovaná volatilita.....	36
Rovnice 7 – Cena vůči klouzavému průměru	36
Rovnice 8 – Z-score ceny vůči dvacetidennímu průměru	37
Rovnice 9 – Parametrické skóre aktiva.....	37
Rovnice 10 – Softmax převod skóre na váhy	38

Rovnice 11 – Smíchání baseline a modelových vah.....	39
Rovnice 12 – L1 vzdálenost dvou portfolií	39
Rovnice 13 – Postupné přiblížení k cílovým vahám	40
Rovnice 14 – Transakční náklad rebalancování	41
Rovnice 15 – Fitness jednoho validačního okna	49
Rovnice 16 – Penalizace překročení maximálního drawdownu	50
Rovnice 17 – Robustní fitness přes validační okna	50

SEZNAM ZKRATEK A ZNAČEK

Baseline – výchozí referenční portfolio nebo referenční strategie, vůči níž je porovnáván adaptivní model.

CAGR – Compound Annual Growth Rate, složená roční míra růstu.

CSV – Comma-Separated Values, textový formát pro tabulková data.

ETF – Exchange-Traded Fund, burzovně obchodovaný fond.

FINRA – Financial Industry Regulatory Authority.

GA – genetický algoritmus.

GIPS – Global Investment Performance Standards.

GP – genetické programování.

IOSCO – International Organization of Securities Commissions.

L1 – metrika založená na součtu absolutních rozdílů; v práci se používá zejména pro odchylku vah portfolio a turnover.

MDD – maximální drawdown, největší historický propad hodnoty portfolio.

OOS – out-of-sample, období mimo trénovací data.

SEC – U.S. Securities and Exchange Commission.

SMA – Simple Moving Average, jednoduchý klouzavý průměr.

STGP – Strongly Typed Genetic Programming, silně typované genetické programování.

TERMINOLOGIE

Aktivum – investiční nástroj, do kterého může být alokována část portfolia. V experimentu jde zejména o ETF reprezentující akcie, sektory, dluhopisy, komodity a drahé kovy.

Alokace aktiv – rozdělení kapitálu mezi jednotlivá aktiva. V práci je alokace popsána pomocí vah portfolia.

Baseline – výchozí referenční složení portfolia daného investičního profilu. Adaptivní model se od něj může odchylvat, ale baseline slouží jako neutrální kotva.

Buy-and-hold – referenční strategie, která na začátku období nakoupí výchozí portfolio a dále jej drží bez pravidelného rebalancování.

Drawdown – pokles hodnoty portfolia od předchozího maxima k následnému minimu. Maximální drawdown vyjadřuje největší takový propad ve sledovaném období.

Fitness funkce – účelová funkce používaná evolučními algoritmy k ohodnocení kvality kandidátního řešení. V práci kombinuje výnos, Sharpe ratio, turnover, náklady, drawdown a robustnost.

Investiční profil – soubor parametrů popisujících typ investora a jeho toleranci k riziku. V implementaci určuje baseline portfolio i limity chování modelu.

Long-only portfolio – portfolio bez krátkých pozic. Váhy aktiv jsou nezáporné a jejich součet je roven jedné.

Měsíční baseline – referenční strategie, která každý měsíc vrací portfolio zpět na výchozí váhy investičního profilu. V práci slouží jako hlavní praktický benchmark.

Modelové váhy – váhy portfolia odvozené ze skóre aktiv vypočteného optimalizovaným modelem.

Out-of-sample období – testovací období, které nebylo použito při trénování nebo optimalizaci modelu. Slouží k ověření schopnosti modelu fungovat na neviděných datech.

Portfolio – soubor aktiv držených investorem. V práci je portfolio reprezentováno vektorem vah jednotlivých aktiv.

Rebalancování – úprava vah portfolia směrem k požadovanému cílovému složení. Může jít o návrat k baseline nebo o přiblížení k vahám navrženým modelem.

Robo-poradce – digitální nástroj, který na základě vstupních informací a algoritmických pravidel doporučuje nebo spravuje investiční portfolio.

Robustní fitness – fitness upravená o nejhorší validační okno a rozptyl výsledků mezi okny. Cílem je preferovat stabilnější modely.

Skórovací model – model, který každému aktivu přiřazuje číselné skóre podle historických ukazatelů. Vyšší skóre znamená vyšší relativní atraktivitu aktiva.

Softmax – metoda převodu skóre na nezáporné váhy se součtem jedna. Vyšší skóre vede k vyšší váze, ale žádné aktivum není automaticky vyřazeno.

Transakční náklady – náklady spojené s provedením obchodů. V experimentu jsou modelovány jako procento z obchodované hodnoty.

Turnover – míra změny portfolia při rebalancování. V práci je počítán jako L1 vzdálenost mezi původními a novými vahami.

Validační okno – úsek trénovacích dat použitý k vyhodnocení kandidátního modelu během optimalizace. Více validačních oken pomáhá omezit přeučení.

Walk-forward testování – postup, při kterém se model opakovaně trénuje pouze na minulých datech a následně testuje na následujícím období.

Fallback – náhradní postup nebo předem definované řešení použité v případě, kdy hlavní algoritmus nemůže vytvořit platný či bezpečně použitelný výsledek. V této práci může jít například o použití výchozí alokace portfolia nebo náhradního nastavení výpočtu.

ÚVOD

Investování a správa osobních financí jsou oblasti, ve kterých se stále častěji uplatňuje automatizace a algoritmické rozhodování. Vedle tradičních forem investičního poradenství vznikají nástroje, které se snaží investorovi doporučit vhodné složení portfolia na základě jeho preferencí, rizikového profilu a dostupných tržních dat. Tato práce se zaměřuje na návrh a otestování adaptivního investičního robo-poradce, který nemá pouze staticky držet předem zadané váhy aktiv, ale má se pokusit upravovat portfolio podle historicky pozorovaného chování trhu.

Cílem diplomové práce je navrhnout prototyp robo-poradce využívající evoluční algoritmy a ověřit, zda tento přístup dokáže při pravidelném rozhodování o alokaci portfolia dosáhnout lepších výsledků než jednoduché referenční strategie. Práce se nezaměřuje na krátkodobé spekulativní obchodování ani na predikci přesných budoucích cen jednotlivých aktiv. Hlavní pozornost je věnována tomu, zda lze pomocí historických dat, vybraných tržních ukazatelů a investičních preferencí vytvořit model, který bude v některých typech portfolií představovat přidanou hodnotu oproti pasivnímu nebo pravidelně rebalancovanému přístupu.

Teoretická část práce se bude zabývat základními principy investování, tvorbou portfolia, vybranými ukazateli výkonnosti a rizika, existujícími přístupy k robotickému investičnímu poradenství a metodami, které jsou použity při návrhu vlastního řešení. Praktická část následně popíše implementovaný systém, použité datasety, konstrukci testovaných portfolií, návrh fitness funkce, průběh optimalizace pomocí genetického algoritmu a genetického programování a vyhodnocení dosažených výsledků.

Výsledkem práce bude zhodnocení, zda je navržený adaptivní přístup vhodný pro různé typy investorů a portfolií. Součástí vyhodnocení bude také diskuze omezení navrženého řešení, zejména z hlediska stability výsledků, transakčních nákladů a rozdílného chování modelu v různých tržních obdobích.

Při tvorbě práce byl využit nástroj umělé inteligence ChatGPT společnosti OpenAI, který sloužil jako podpůrný asistent při kontrole a optimalizaci zdrojového kódu a při stylistické kontrole a úpravě textu. Koncepce práce, odborný obsah, návrh řešení, metodika, implementace, provedení experimentů, interpretace výsledků a závěry jsou dílem autora, který provedl konečnou kontrolu všech výstupů a nese za práci plnou odpovědnost.

1 Investiční poradenství a robo-advisory

Investiční poradenství se obecně zabývá doporučením vhodného způsobu nakládání s finančními prostředky s ohledem na cíle, časový horizont, ochotu podstupovat riziko a další charakteristiky investora. V prostředí digitálních investičních služeb jsou tyto informace často získávány pomocí vstupního dotazníku, na jehož základě systém vytvoří nebo doporučí portfolio. Americká Komise pro cenné papíry a burzy například uvádí, že robo-adviser typicky sbírá informace o finančních cílech, investičním horizontu, příjmu, majetku a toleranci k riziku a na základě těchto údajů vytváří a spravuje investiční portfolio [1].

Pro tuto práci je důležité rozlišovat mezi samotným výběrem investičních nástrojů a poradenským procesem, který tento výběr zasazuje do profilu konkrétního investora. Stejně aktivum může být vhodné pro jednoho investora a nevhodné pro jiného, pokud se liší jejich investiční horizont, schopnost nést krátkodobé ztráty nebo očekávání výnosu. Z pohledu automatizovaného systému proto musí návrh alokace vycházet z profilu klienta; IOSCO zároveň upozorňuje, že krátký standardizovaný dotazník nemusí zachytit rozpory v odpovědích ani nestandardní situace [2].

1.1 Investiční poradenství a role investičního profilu

Investiční profil je zjednodušený popis investora, který slouží k převedení obecných informací o klientovi do konkrétní investiční strategie. V běžné praxi může zahrnovat například investiční cíl, horizont, zkušenosti, finanční situaci, očekávání výnosu a toleranci k poklesům hodnoty portfolio. U automatizovaných nástrojů je tento profil obvykle vytvářen prostřednictvím standardizovaných otázek, což zvyšuje škálovatelnost služby, ale zároveň omezuje schopnost zachytit nestandardní okolnosti konkrétního investora [1; 2].

Význam investičního profilu je patrný zejména při převodu obecných preferencí na složení portfolio. Konzervativní investor zpravidla očekává nižší kolísání hodnoty portfolio a větší zastoupení defenzivních aktiv, zatímco agresivní investor může přijmout vyšší kolísání výměnou za vyšší očekávaný výnos. FINRA ve své zprávě o digitálním investičním poradenství uvádí, že digitální poradenské nástroje typicky pokrývají činnosti jako profilování klienta, alokaci aktiv, výběr portfolio, provedení obchodů, rebalancování a případně daňovou optimalizaci [3].

Automatizované profilování však přináší i riziko zjednodušení. Pokud systém pracuje pouze s krátkým dotazníkem nebo neumožňuje dodatečné vysvětlení odpovědí, může dojít k situaci, kdy výsledný profil nereprezentuje skutečnou finanční situaci investora. IOSCO upozorňuje, že automatizovaný proces nemusí být schopen vyřešit rozpory v odpovědích nebo zahrnout neobvyklé okolnosti klienta, pokud je založen pouze na pevné sadě otázek [2].

1.2 Klasické přístupy k sestavení portfolio

Klasické investiční poradenství často vychází z rozdělení prostředků mezi různé třídy aktiv. Smyslem alokace je převést informace o investorovi do struktury portfolio. V kontextu robo-advisory se tento princip projevuje tím, že systém na základě profilu přiřadí předem sestavené portfolio a následně je spravuje a rebalancuje [2; 3].

V řadě digitálních poradenských nástrojů je základní portfolio tvořeno nízkonákladovými a likvidními nástroji, často burzovně obchodovanými fondy. Regulatorní materiály upozorňují,

že některé robo-advisory platformy pracují s omezenou nabídkou investičních produktů, například se široce diverzifikovanými ETF, a proto je důležité rozumět tomu, z jakého investičního prostoru systém portfolio skládá [1; 3].

FINRA popisuje digitální poradenské nástroje, které podle profilu klienta přiřazují předem sestavená portfolia a pravidelně je rebalancují. Takový postup podporuje standardizaci a opakovatelnost poradenského procesu. Bourgeron, Lezmi a Roncalli pak řeší robustní alokaci a rebalancování stovek portfolií bez přímého lidského zásahu [3; 4].

1.3 Robo-advisory platformy a jejich princip

Robo-advisory lze chápat jako digitalizovanou formu investičního poradenství a správy portfolia, ve které je velká část procesu realizována algoritmicky. Investor obvykle zadá vstupní informace prostřednictvím webového rozhraní nebo mobilní aplikace a systém následně doporučí nebo spravuje portfolio s omezenou mírou přímého zapojení lidského poradce. SEC tento typ služby popisuje jako automatizovaný digitální investiční poradenský program, který v typickém případě vytvoří a spravuje portfolio na základě informací poskytnutých investorem [1].

Z pohledu funkčnosti tvoří robo-advisory řetězec několika kroků: získání údajů o investorovi, vyhodnocení jeho profilu, sestavení vhodné alokace, provádění nebo doporučování obchodů, průběžné sledování portfolia a rebalancování. FINRA tento proces popisuje jako hodnotový řetězec digitálního investičního poradenství, který zahrnuje profilování klienta, alokaci aktiv, výběr portfolia, exekuci obchodů, rebalancování, tax-loss harvesting a analýzu portfolia [3].

Míra automatizace se mezi platformami liší. Některé systémy fungují téměř výhradně digitálně, jiné kombinují algoritmické doporučení s přístupem k lidskému poradci. SEC i FINRA upozorňují, že rozsah lidské interakce se může mezi službami výrazně lišit a že investor by měl rozumět tomu, zda pracuje s plně digitálním nástrojem, nebo s hybridním modelem doplněným o poradce [1; 3].

1.4 Příklady existujících robo-advisory platforem

Robo-advisory platformy se v praxi liší podle toho, zda se zaměřují pouze na automatizovanou správu investic, nebo zda kombinují algoritmické portfolio s dalšími nástroji, například finančním plánováním, daňovou optimalizací nebo možností konzultace s poradcem. Následující příklady nejsou úplným výčtem trhu, ale ukazují běžné rysy tohoto typu služeb: vstupní profilování klienta, modelové portfolio, automatizované rebalancování a různou míru lidské asistence.

Betterment patří mezi známé americké digitální investiční platformy. Ve své nabídce automatizovaného investování uvádí globálně diverzifikovaná portfolia, správu obchodů, rebalancování, reinvestování a daňové funkce. Platforma zároveň kombinuje automatizované portfolio s širší sadou produktů, například penzijními účty, hotovostními produkty nebo prémiovou službou s přístupem k finančnímu poradci [5].

Wealthfront prezentuje svůj automatizovaný investiční účet jako službu, která na základě odpovědi klienta vytvoří diverzifikované portfolio indexových fondů a následně jej automaticky spravuje. Uvádí také řízení portfolia podle rizikového skóre, automatické udržování rovnováhy portfolia, reinvestování dividend a důraz na dlouhodobé výnosy po zdanění [6].

Schwab Intelligent Portfolios je příkladem služby navázané na velkou finanční instituci. Platforma pracuje s cílovou alokací určenou podle cílů, investičního horizontu a rizikového profilu investora. Portfolio je následně automaticky sledováno a v případě odchylky od cílových vah rebalancováno prodejem a nákupem ETF v jednotlivých třídách aktiv [7].

Vanguard Digital Advisor představuje all-digital poradenskou službu zaměřenou na automatizované investování a finanční plánování. Služba začíná osobním vyhodnocením rizika, na jehož základě určuje vhodnou alokaci aktiv, a podle popisu platformy využívá investiční nástroje Vanguard, zejména ETF. Součástí nabídky jsou také nástroje pro práci s investičními cíli a finančním výhledem; u vybraných služeb Vanguard uvádí také tax-loss harvesting [8].

Na českém trhu lze jako příklad uvést platformu Portu. Ta prezentuje investování prostřednictvím portfolia sestaveného na míru, využívá investiční dotazník a pracuje s rizikovým profilem investora. Portu zároveň uvádí pasivní investiční přístup pod dohledem odborníků a nabízí také další produkty, například portfolio podle vlastního nastavení, investování v eurech, dětský účet nebo důchodový účet [9].

Dalším českým příkladem je Fondee. Platforma popisuje proces, ve kterém investor nejprve vyplní krátký online dotazník, systém na základě odpovědí navrhne investici odpovídající potřebám klienta a investor následně určuje výši a četnost vkladů. Fondee ve svých materiálech uvádí, že historické simulace portfolií vycházejí z cen ETF nebo jejich podkladových indexů [10].

Z uvedených příkladů vyplývá, že existující robo-advisory služby nejsou jednotným produktem. Některé zdůrazňují nízkonákladové pasivní portfolio, jiné širší finanční plánování, daňové funkce nebo hybridní model s lidským poradcem. Pro tuto práci je podstatné zejména to, že běžný robo-advisory proces se obvykle opírá o profil investora, cílovou alokaci a rebalancování. Navrhovaný systém se od těchto příkladů liší tím, že experimentálně zkoumá adaptivní úpravu vah portfolia podle historických tržních ukazatelů, nikoli pouze návrat k předem určeným modelovým vahám.

1.5 Limity statického robo-poradenství a motivace adaptivního přístupu

Automatizovaná správa může být užitečná pro levné, srozumitelné a disciplinované držení portfolia odpovídajícího profilu investora. Výzkumná otázka však nespočívá jen v návratu k předem určeným vahám: Bourgeron, Lezmi a Roncalli řeší také robustní optimalizaci a rebalancování stovek portfolií bez průběžného lidského zásahu [4].

Odborná literatura proto řeší personalizované a adaptivní formy robo-advisory, ve kterých se investiční strategie mění nejen podle statického profilu klienta, ale také podle tržních podmínek a vývoje preferencí investora. Capponi, Olafsson a Zariphopoulou popisují personalizované robo-advisory jako problém, ve kterém se poměr mezi rizikem a výnosem přizpůsobuje rizikovému profilu klienta, tržním výnosům a ekonomickým podmínkám [11].

Adaptivní přístup však současně zvyšuje nároky na návrh a kontrolu algoritmu. Čím větší volnost systém dostane, tím důležitější je ověřit, zda jeho rozhodování nezvyšuje zbytečně riziko, náklady nebo frekvenci obchodování. FINRA upozorňuje, že špatně navržený nebo nesprávně implementovaný algoritmus může systematicky produkovat výsledky odlišné od zamýšleného chování a negativně ovlivnit větší počet investorů [3].

IOSCO podobně řadí mezi rizika robo-advisory chyby algoritmů, přílišnou složitost, přílišné zjednodušení i práci se statickými klientskými informacemi [2].

Tato diplomová práce na uvedené limity navazuje návrhem experimentálního adaptivního robo-poradce. Navržený systém neřeší kompletní finanční plánování ani právně regulované poskytování investičního poradenství. Zaměřuje se na užší úlohu algoritmické úpravy vah portfolia podle historických tržních dat, rizikového profilu a měřitelných omezení, jako jsou maximální pokles, obrat portfolia a porovnání vůči referenční strategii.

1.6 Rozdíl mezi existujícími platformami a navrženým řešením

Existující robo-advisory platformy, například Portu nebo Fondee, řeší především kompletní službu pro koncového investora. Jejich úlohou je získat informace o klientovi, určit vhodný investiční profil, doporučit odpovídající portfolio a následně zajistit jeho dlouhodobou správu. Podle veřejného popisu Portu je tento přístup založen zejména na portfoliu sestaveném na míru, pasivním investování, široké diverzifikaci, automatizaci a odborném dohledu [9]. Podobně Fondee popisuje proces, ve kterém investor vyplní online dotazník a na základě odpovědí je mu navržena investice odpovídající jeho potřebám [10].

Navržený systém v této práci neřeší robo-advisory jako kompletní produktovou službu. Nezabývá se registrací klienta, právním posouzením vhodnosti investice, úschovou prostředků, daňovou optimalizací ani uživatelským rozhraním. Zaměřuje se pouze na rozhodovací jádro, tedy na otázku, zda lze nad předem zadaným portfoliem vytvořit adaptivní vrstvu, která bude měsíčně upravovat váhy aktiv podle historických tržních ukazatelů, rizikového profilu a výsledků optimalizace.

Hlavní rozdíl je proto v tom, že běžná robo-advisory služba obvykle vybere vhodné modelové portfolio a následně se snaží udržovat jeho dlouhodobou disciplínu, zatímco navržený robot experimentálně hledá pravidlo pro změnu vah v čase. Nesnaží se pouze rebalancovat portfolio zpět k původnímu poměru, ale může se od baseline dočasně odchýlit, pokud optimalizovaný model vyhodnotí některá aktiva jako relativně vhodnější nebo rizikovější. Tím se navržené řešení přibližuje výzkumným přístupům, které adaptují poměr rizika a výnosu podle rizikového profilu, tržních výnosů a ekonomických podmínek a současně řeší robustní automatizovanou správu většího počtu portfolií [4; 11].

Pro účely této práce je tedy navržený robot vhodné chápat jako experimentální adaptivní alokační model, nikoli jako přímou náhradu existujících robo-advisory platform. Praktická hodnota takového modelu nespočívá v tom, že by sám poskytoval kompletní investiční službu, ale v ověření, zda může být adaptivní rozhodovací vrstva přínosná nad rámec statického portfolia a pravidelného rebalancování.

2 Investiční portfolio a řízení rizika

Investiční portfolio je soubor aktiv, která investor drží jako celek. Výkonnost a riziko portfolio proto nelze hodnotit pouze podle samostatných vlastností jednotlivých aktiv, ale také podle jejich vzájemného vztahu. Základní myšlenkou moderní teorie portfolio je, že investor má sledovat očekávaný výnos portfolio společně s rizikem, a že riziko portfolio závisí nejen na rizikovosti jednotlivých aktiv, ale také na vzájemných vztazích mezi výnosy jednotlivých aktiv [12].

V kontextu této práce je portfolio chápáno jako vektor vah přiřazených jednotlivým aktivům. Váha aktiva vyjadřuje, jaká část celkové hodnoty portfolio je do daného aktiva alokována. Pokud portfolio obsahuje aktiva od 1 do n , lze jeho složení zapsat pomocí vah jednotlivých aktiv. V long-only portfolio jsou váhy nezáporné a jejich součet je roven jedné. Formální zápis portfolio uvádí rovnice 1.

$$w = (w_1, w_2, \dots, w_n), \sum_{i=1}^n w_i = 1, w_i \geq 0$$

Rovnice 1 – Zápis vah portfolio

Jednotlivé proměnné ze vzorce vyjadřují následující:

- w je vektor vah portfolio.
- w_i je váha i -tého aktiva v portfolio.
- n je počet aktiv v portfolio.
- $\sum_{i=1}^n w_i$ vyjadřuje součet všech vah portfolio.
- Podmínka $w_i \geq 0$ znamená, že portfolio neuvažuje krátké pozice.

Výnos portfolio v jednom období lze při tomto zjednodušení vyjádřit jako vážený součet výnosů jednotlivých aktiv.

2.1 Třídy aktiv a diverzifikace

Markowitz při výkladu diverzifikace připouští, že portfolio může být analyzováno nejen na úrovni jednotlivých cenných papírů, ale také na úrovni agregovaných skupin, například akcií, dluhopisů a nemovitostí. Praktické portfolio proto nevzniká výběrem jediného aktiva, ale kombinací více složek, jejichž očekávané výnosy, rozptyly a kovariance ovlivňují výsledné riziko portfolio [12].

Diverzifikace znamená rozložení investice mezi více aktiv nebo tříd aktiv. Jejím cílem není zaručit kladný výnos, ale snížit závislost výsledku portfolio na jednom aktivu, sektoru nebo tržním scénáři. Markowitz ukázal, že pokud se výnosy aktiv nepohybují dokonale stejným směrem, může kombinace více aktiv snížit rozptyl portfolio při dané úrovni očekávaného výnosu [12].

Z pohledu robo-poradce je diverzifikace důležitá i proto, že investiční profil klienta se obvykle nepřekládá do jednoho konkrétního aktiva, ale do určité struktury portfolio. Konzervativnější profil může obsahovat vyšší podíl defenzivních složek, zatímco agresivnější profil může připustit vyšší podíl akcií, sektorových ETF nebo jiných volatilnějších aktiv. V této práci je

výchozí struktura portfolia označována jako baseline, tedy referenční váhy, od kterých se adaptivní model může v omezené míře odchýlovat.

2.2 Rebalancování portfolia

Hodnoty jednotlivých aktiv se v čase mění rozdílným tempem. I když investor na začátku nastaví portfolio například na 60 % akcií a 40 % dluhopisů, po delším růstu akciového trhu může být skutečný podíl akcií výrazně vyšší. Portfolio se tím vzdálí původně zamýšlenému rizikovému profilu. Rebalancování je proces, při kterém se váhy portfolia vracejí zpět k cílové alokaci nebo blíže k ní [13].

V této práci je jako referenční strategie použito pravidelné měsíční rebalancování. Perold a Sharpe popisují dynamické strategie alokace aktiv jako předem stanovená pravidla, podle nichž se portfolio rebalancuje v reakci na změny hodnoty rizikových aktiv. Jednotlivé strategie se liší tím, zda a jak v průběhu vývoje trhu mění expozici portfolia vůči rizikovým aktivům [13].

V této práci je důležité rozlišit rebalancování a adaptivní změnu portfolia. Rebalancování samo o sobě znamená návrat k předem definovaným vahám. Adaptivní model naproti tomu může cílové váhy měnit podle tržních ukazatelů. Pokud se tedy portfolio vrací z aktuálních vah zpět na baseline, jde o rebalancování. Pokud model vyhodnotí, že je vhodné se od baseline dočasně odchýlit, jde o aktivní alokační rozhodnutí.

2.3 Ukazatele výnosu a rizika

Základní metrikou výkonnosti je výnos za určité období. Jednoduchý výnos porovnává hodnotu portfolia na konci období s hodnotou na jeho začátku. Výpočet formalizuje rovnice 2.

$$R_t = \frac{V_t}{V_{t-1}} - 1$$

Rovnice 2 – Jednoduchý výnos portfolia

Jednotlivé proměnné ze vzorce vyjadřují následující:

- R_t je jednoduchý výnos portfolia v období t .
- V_t je hodnota portfolia na konci období t .
- V_{t-1} je hodnota portfolia na začátku období, tedy v předchozím období.

Celkový výnos za delší období porovnává konečnou a počáteční hodnotu portfolia. Důraz na konzistentní výpočet a prezentaci investiční výkonnosti je základem také ve standardech GIPS, jejichž cílem je férová a srovnatelná prezentace historické výkonnosti [14].

Pro porovnání delších období se používá CAGR, tedy složená roční míra růstu. CAGR neříká, že portfolio rostlo každý rok stejným tempem, ale převádí celkový růst na ekvivalentní průměrné roční tempo. Pokud je počáteční hodnota portfolia označena jako V_0 , konečná hodnota jako V_T a délka období jako Y let, lze CAGR vyjádřit následujícím vztahem. Tento vztah zachycuje rovnice 3.

$$CAGR = \left(\frac{V_T}{V_0}\right)^{\frac{1}{Y}} - 1$$

Rovnice 3 – Složená roční míra růstu

Jednotlivé proměnné ze vzorce vyjadřují následující:

- CAGR je složená roční míra růstu.
- V_T je konečná hodnota portfolia.
- V_0 je počáteční hodnota portfolia.
- Y je délka sledovaného období v letech.

Samotný výnos nestačí k posouzení kvality investiční strategie, protože dvě strategie mohou dosáhnout stejného výnosu při velmi rozdílném kolísání. Volatilita vyjadřuje rozptyl nebo směrodatnou odchylku výnosů a v investiční praxi se často používá jako jedna ze základních aproximací rizika. V této práci je volatilita používána zejména jako doplňková metrika k výnosu a k výpočtu Sharpe ratio.

Sharpe ratio je ukazatel rizikově očištěného výnosu. Vyjadřuje, kolik nadvýnosu nad zvolenou referenční nebo bezrizikovou sazbu strategie dosahuje na jednotku volatility. Sharpe ve své pozdější formulaci pracuje s rozdílem výnosu aktiva nebo strategie vůči benchmarku a směrodatnou odchylkou tohoto rozdílu [15]. Při interpretaci Sharpe ratio je však nutná opatrnost, protože jeho odhad závisí na statistických vlastnostech výnosů, délce vzorku a případné autokorelaci výnosů [16].

Dalším důležitým ukazatelem je maximální drawdown. Magdon-Ismail et al. jej definují jako největší pokles od předchozího vrcholu k následujícímu dnu. V této práci slouží maximum drawdown jako doplňková metrika k volatilitě, protože přímo zachycuje velikost nejhoršího historického poklesu v testovaném období [17].

2.4 Transakční náklady a turnover

Každá změna vah portfolia může vést k obchodům. Ty mohou být spojeny s přímými poplatky, rozpětím mezi nákupní a prodejní cenou, daňovými dopady nebo dalšími náklady. Strategie, která často mění složení portfolia, proto může v hrubém výsledku vypadat dobře, ale po započtení nákladů může být méně výhodná než jednodušší strategie s nižším počtem obchodů. Výzkum optimalizace portfolia při transakčních nákladech ukazuje, že náklady a penalizace obratu mohou významně změnit výsledné optimální portfolio [18].

Turnover v této práci označuje míru změny portfolia při rebalančním kroku. V implementaci je sledován jako součet absolutních změn vah mezi původním a novým složením portfolia. Pokud se například část portfolia prodá a přesune do jiného aktiva, turnover roste. Vyšší turnover tedy neznamená automaticky špatnou strategii, ale znamená vyšší aktivitu, více obchodů a vyšší citlivost výsledku na transakční náklady.

Turnover má v experimentu dvojí význam. Zprvė vstupuje do nákladů, protože častější obchodování snižuje čistý výsledek strategie. Zadruhé slouží jako diagnostika stability modelu. Model, který dosahuje výsledku pouze díky častému přeskakování mezi aktivy, může být méně robustní než model, který se od baseline odchyluje jen v situacích, kdy má k tomu silnější signál. Z tohoto důvodu se ve fitness funkci pracuje nejen s výnosem a rizikem, ale také s penalizací obratu a nákladů.

2.5 Referenční strategie

Aby bylo možné vyhodnotit přínos adaptivního modelu, je nutné porovnávat jej s jednoduchými referenčními strategiemi. Bez benchmarku by samotný zisk nebo ztráta modelu

nebyly dostatečně vypovídající. Pokud například celý trh výrazně roste, může být zisková i velmi jednoduchá strategie. Naopak v krizovém roce může být relevantní otázkou, zda model ztratil méně než srovnatelná pasivní strategie.

První referenční strategií v této práci je buy-and-hold baseline. Ta na začátku období nakoupí aktiva podle výchozích vah a následně portfolio bez pravidelného rebalancování drží. Váhy portfolio se proto v čase přirozeně mění podle toho, jak se jednotlivým aktivům daří. Tento přístup je jednoduchý a má nízký turnover, ale může se postupně vzdálit původnímu rizikovému profilu [13].

Druhou referenční strategií je měsíční baseline. Ta vychází ze stejných počátečních vah, ale v pravidelném měsíčním kroku portfolio vrací k cílové alokaci. Díky tomu lépe udržuje zadaný rizikový profil, ale za cenu vyššího turnoveru a transakčních nákladů. V experimentech této práce je měsíční baseline důležitá proto, že představuje realistický fallback: pokud by adaptivní model nebyl použit, portfolio by mohlo být alespoň pravidelně rebalancováno podle profilu investora.

Adaptivní robot je následně porovnáván s oběma referencemi. Měsíční baseline slouží jako hlavní praktické srovnání, protože odpovídá jednoduché disciplinované správě portfolio. Buy-and-hold baseline je ponechána jako doplňková diagnostika, která ukazuje, zda aktivní zásahy a rebalancování skutečně přidávají hodnotu oproti pouhému držení počátečního portfolio. Toto rozlišení je důležité pro interpretaci výsledků: model nemusí být univerzálně lepší než každá pasivní varianta, aby měl praktický význam, ale měl by umět obhájit přidanou hodnotu vůči realistickému fallbacku.

3 Evoluční algoritmy

Evoluční algoritmy představují skupinu optimalizačních metod inspirovaných principy biologické evoluce. Místo toho, aby se algoritmus snažil zlepšovat pouze jedno řešení, pracuje s populací více kandidátních řešení. Tato řešení jsou opakovaně vyhodnocována, vybírána a upravována pomocí operátorů inspirovaných dědičností, křížením a mutací. Hynek uvádí mezi hlavní zástupce evolučních algoritmů genetické algoritmy, evoluční strategie, evoluční programování a genetické programování [19].

V této práci jsou použity dvě evoluční metody: genetický algoritmus a genetické programování. Obě metody pracují s populací řešení a s jejich opakovaným výběrem podle kvality, ale liší se tím, co vlastně považují za jedince. Genetický algoritmus v navrženém systému optimalizuje parametry předem daného skórovacího modelu, zatímco genetické programování hledá přímo strukturu rozhodovacího výrazu. Tato kapitola popisuje obecný princip obou metod; jejich konkrétní zapojení do navrženého robo-poradce je popsáno až v kapitole 4 *Návrh adaptivního robo-poradce*.

3.1 Princip evolučních algoritmů

Základní jednotkou evolučního algoritmu je jedinec, který reprezentuje jedno možné řešení daného problému. V závislosti na typu algoritmu může mít podobu řetězce hodnot, vektoru parametrů, permutace nebo stromové struktury. Skupina jedinců tvoří populaci. Každý jedinec je ohodnocen pomocí fitness funkce, která kvantitativně vyjadřuje, jak kvalitní je dané řešení vzhledem k řešené úloze [19].

Průběh evolučního algoritmu lze popsat jako opakování několika kroků. Nejprve je vytvořena počáteční populace, často náhodně nebo částečně podle znalosti problému. Následně jsou jedinci vyhodnoceni fitness funkcí. Z populace jsou vybíráni vhodnější jedinci, kteří se podílejí na vytvoření nové generace. Nová řešení vznikají pomocí genetických operátorů, typicky křížením a mutací. Tento cyklus se opakuje po stanovený počet generací nebo do splnění ukončovací podmínky [19].

Fitness funkce v evolučním algoritmu kvantifikuje kvalitu jedince vzhledem k řešené úloze a její hodnoty ovlivňují výběr jedinců pro další generaci. V praktické části práce je tento obecný princip aplikován na investiční úlohu pomocí vícekritériální funkce, která vedle výnosu zohledňuje riziko, náklady a stabilitu v čase [19].


Výhodou evolučních algoritmů je jejich obecnost a práce s celou populací kandidátních řešení. Hynek však upozorňuje, že tato obecnost neznamená univerzální převahu nad specializovanými metodami. Pokud pro daný problém existuje dobře navržený specializovaný algoritmus, může být rychlejší i přesnější než obecný evoluční přístup. Evoluční algoritmy jsou proto vhodné zejména pro úlohy, pro které není účinná specializovaná metoda k dispozici [19].

3.2 Genetický algoritmus

Genetický algoritmus je evoluční metoda, ve které je každé kandidátní řešení zakódováno do určité reprezentace, často označované jako chromozom. Tento chromozom může obsahovat například binární hodnoty, reálná čísla, pořadí prvků nebo jinak strukturované parametry. V každé generaci jsou jedinci ohodnoceni a na základě tohoto ohodnocení jsou vybíráni

k reprodukci. Z vybraných jedinců vzniká nová populace, která by měla v průměru obsahovat kvalitnější řešení než populace předchozí [19].

Obrázek 1 shrnuje typický průběh genetického algoritmu od vytvoření počáteční populace přes vyhodnocení jedinců až po opakované použití selekce, křížení a mutace. Schéma zároveň zachycuje ukončovací podmínku, po jejímž splnění je vybráno nejlepší nalezené řešení.



Obrázek 1 – Základní cyklus genetického algoritmu

Zdroj: autor

Selekce určuje, kteří jedinci mají větší šanci předat své vlastnosti do další generace. Lepší jedinci obvykle dostávají větší pravděpodobnost výběru, ale algoritmus by neměl příliš rychle ztratit rozmanitost populace. Pokud by se populace sjednotila příliš brzy kolem jednoho lokálně dobrého řešení, mohla by předčasně uvíznout v oblasti, která není globálně vhodná. Z tohoto důvodu se v genetických algoritmech kombinuje tlak na výběr kvalitních řešení s náhodností a mutací [19].

Křížení vytváří nového jedince kombinací částí dvou nebo více rodičů. Smyslem je využít skutečnost, že dva různě kvalitní jedinci mohou obsahovat užitečné části řešení, jejichž

kombinací vznikne jedinec lepší než každý z rodičů samostatně. Mutace naopak provádí menší náhodnou změnu jedince. Pomáhá udržovat rozmanitost populace a dává algoritmu možnost dostat se do oblastí prostoru řešení, která by samotným křížením nemusela být dosažitelná [19].

V této práci je genetický algoritmus vhodný pro úlohu ladění parametrů modelu. Struktura skórovacího modelu je předem dána a algoritmus nehledá nový program, ale vhodnou kombinaci hodnot jeho parametrů. To odpovídá situaci, kdy je znám přibližný tvar rozhodovacího mechanismu, ale není zřejmé, jak silně mají jednotlivé složky modelu ovlivňovat výsledné skóre aktiv. Konkrétní parametry a způsob jejich vyhodnocení jsou popsány v kapitole 4 *Návrh adaptivního robo-poradce*.


3.3 Genetické programování

Genetické programování rozšiřuje princip genetických algoritmů tím, že jedincem není pouze pevně strukturovaný chromozom, ale program nebo výraz. Hynek popisuje genetické programování jako rozšíření genetických algoritmů, ve kterém chromozomy nejsou řetězce pevné délky, ale hierarchicky strukturované počítačové programy představující možná řešení problému [19].

Montana popisuje reprezentaci genetického programování pomocí syntaktických stromů. Uzly stromu mohou reprezentovat funkce, proměnné a konstanty. Listy stromu jsou terminály, tedy prvky, které již nepřijímají další argumenty. Vnitřní uzly jsou funkce nebo operátory, které přijímají argumenty tvořené svými podstromy. Spuštění takového stromu znamená vyhodnocení jeho kořene a postupné vyhodnocení všech potřebných podstromů [20].

Obrázek 2 ukazuje jednoduchý příklad takové stromové reprezentace. Vstupní ukazatele Momentum, PriceVsSma a Volatility tvoří listy stromu a aritmetické operátory určují, jak jsou tyto vstupy složeny do výsledného skóre.

$$\text{score} = (\text{Momentum} + \text{PriceVsSma}) - \text{Volatility}$$



Obrázek 2 – Stromová reprezentace jedince v genetickém programování

Zdroj: autor

Uživatel genetického programování musí definovat množinu funkcí a množinu terminálů. Množina funkcí určuje, jaké operace může program používat, například aritmetické operace, porovnání nebo podmíněné konstrukce. Množina terminálů obsahuje vstupní proměnné

a konstanty, ze kterých může být výsledný výraz složen. Volba těchto množin zásadně ovlivňuje, jaká řešení může genetické programování nalézt [19; 20].

Genetické operátory v genetickém programování pracují se stromovou strukturou. Mutace typicky nahradí náhodně vybraný podstrom nově vygenerovaným podstromem. Křížení vybírá části dvou rodičovských stromů a jejich výměnou vytváří potomka. Montana upozorňuje, že tyto operátory se kvůli stromové reprezentaci liší od mutace a křížení používaných ve standardních genetických algoritmech [20].


Volba množiny funkcí a terminálů ovlivňuje nejen podobu možných řešení, ale také náročnost prohledávání. Hynek upozorňuje, že jejich nadbytečně široké vymezení dramaticky snižuje rychlost algoritmu, protože je nutné prohledávat větší prostor, než je nezbytné [19]. Montana u STGP uvádí, že typová omezení mohou výrazně zkrátit dobu hledání a zlepšit generalizační schopnost nalezených řešení. Současně označuje rychlý růst výpočetních nároků se složitostí problému za hlavní omezení STGP [20].

3.4 Silně typované genetické programování

Standardní genetické programování předpokládá, že funkce a terminály lze skládat tak, aby každý vzniklý strom šel vyhodnotit. Montana označuje tento předpoklad jako uzavřenost a upozorňuje, že u problémů s více datovými typy může být takové omezení nepřirozené nebo neefektivní. Pokud mají některé funkce pracovat například pouze s číselnými hodnotami, jiné s logickými hodnotami a další s vektory, náhodné skládání stromů může snadno vytvářet neplatné nebo nevhodné programy [20].


Silně typované genetické programování, označované zkratkou STGP, zavádí do genetického programování typová omezení. Každý terminál a každá funkce má přiřazený typ vstupu a výstupu. Strom je považován za platný pouze tehdy, pokud kořen vrací požadovaný typ a každý uzel vrací typ, který jeho rodič očekává jako argument. Montana tímto způsobem omezuje generování stromů pouze na typově konzistentní programy [20].

Rozdíl mezi typově platným a neplatným stromem znázorňují obrázky 3 a 4. První strom respektuje očekávané vstupní a výstupní typy jednotlivých uzlů, zatímco druhý strom ukazuje situaci, kdy je logický výsledek porovnání použit na místě, kde aritmetický operátor očekává číselnou hodnotu.



Obrázek 3 – Platný strom ve STGP

Zdroj: autor



Obrázek 4 – Neplatný strom ve STGP

Zdroj: autor

V platném stromu vrací podmínka logickou hodnotu typu Bool a obě větve podmíněného výrazu vrací číselnou hodnotu typu Real. V neplatném stromu je naopak výsledek porovnání typu Bool použit jako vstup aritmetického operátoru, který očekává číselnou hodnotu typu Real.

Typová omezení snižují počet nesmyslných kandidátních řešení, která by jinak musela být zahozena nebo penalizována. To může zkrátit prohledávání a současně zlepšit schopnost modelu generalizovat, protože algoritmus je veden k vytváření výrazů, které odpovídají logice domény. Montana zároveň rozšiřuje STGP o generické funkce a generické datové typy, které umožňují zachovat výhody silného typování a současně neztratit příliš mnoho flexibility [20].

Pro tuto práci je princip typování důležitý hlavně interpretačně. Navržený systém neřeší obecné programování v plném rozsahu, ale pracuje s výrazy nad tržními ukazateli, skóre aktiv a rizikovými charakteristikami. I zde je žádoucí, aby genetické programování nevytvářelo výrazy, které jsou sice syntakticky složité, ale z hlediska domény nedávají smysl. Myšlenka STGP proto podporuje návrh omezené a bezpečnější množiny operací, ze které lze rozhodovací pravidla skládat.

3.5 Vhodnost evolučních metod pro investiční rozhodování

Pro tuto práci jsou evoluční algoritmy relevantní tím, že pracují s populací kandidátních řešení a hodnotí je pomocí předem definované fitness funkce. V navrženém experimentu je tento obecný princip použit k hodnocení celého historického chování investiční strategie podle více výkonnostních a rizikových kritérií [19].

V navrženém robo-poradci je cílem najít rozhodovací pravidlo, které dokáže z historických ukazatelů vytvořit užitečné skóre aktiv a následně upravit váhy portfolia. Genetický algoritmus je vhodný pro ladění několika číselných parametrů pevného modelu. Genetické programování je vhodné pro hledání obecnějšího výrazu, který může kombinovat vstupní ukazatele flexibilněji. Tím vznikají dva odlišné přístupy, které lze v experimentální části porovnat.

Použití evolučních metod má však i rizika. Protože algoritmus optimalizuje podle historických dat, může nalézt pravidlo, které dobře fungovalo pouze v konkrétním období. Tento jev je v investičním kontextu obzvlášť nebezpečný, protože historická výkonnost sama o sobě nezaručuje budoucí výsledek. Proto je v návrhu systému důležité pracovat s walk-forward testováním, robustní fitness funkcí, penalizací rizika a porovnáním vůči jednoduchým referenčním strategiím.

Evoluční algoritmy tedy v této práci nejsou použity jako nástroj k nalezení jistě nejlepší investiční strategie. Jsou použity jako nástroj pro experimentální hledání adaptivních pravidel, která mohou být porovnána s pasivním držením a pravidelným rebalancováním. Jejich přínos se proto neposuzuje podle samotné schopnosti najít vysoký výnos na trénovacích datech, ale podle toho, zda nalezená pravidla dávají smysl i mimo trénovací období a zda zlepšují poměr mezi výnosem, rizikem a náklady.

3.6 Srovnání s příbuznými pracemi

Navržené řešení tematicky navazuje na práci Mousavi, Esfahanipoura a Fazela Zarandiho, kteří představili dynamický systém správy portfolia založený na multitree genetickém programování. Jejich model vytváří z technických ukazatelů soubor obchodních pravidel, jehož výstupem jsou průběžně aktualizované váhy jednotlivých akcií. Autoři zohledňují také transakční náklady a přístup ověřují na patnácti společnostech z rozvíjejícího se a patnácti společnostech z rozvinutého trhu. Výsledky porovnávají s tradičními modely statického i dynamického výběru portfolia [21].

Shodným rysem této diplomové práce je využití historických tržních ukazatelů, evolučního hledání a dynamické změny vah portfolia. Odlišná je však reprezentace rozhodovacího modelu. Zatímco uvedená práce používá soubor stromů a pravidel vytvářených pro jednotlivé akcie, zde genetické programování hledá společný skórovací výraz aplikovaný na všechna aktiva. Výsledná skóre jsou převedena na váhy a omezena vzhledem k výchozímu portfoliu investora. Navržený systém navíc porovnává genetické programování s genetickým algoritmem, pracuje s několika investičními profily a výsledky ověřuje pomocí walk-forward postupu vůči buy-and-hold a pravidelně rebalancované baseline.

V českém prostředí se podobnou problematikou zabýval Kuruc v bakalářské práci Optimalizace portfolia cenných papírů pomocí genetického algoritmu. Autor pomocí genetického algoritmu přímo hledal váhy akcií indexu DJIA maximalizující ukazatel Omega ratio. Optimalizace vycházela z pětiletých historických dat, pracovala s 29 akciami a omezovala maximální váhu jednoho titulu na 30 %. Výsledkem bylo statické portfolio šesti akcií s očekávaným ročním výnosem 27,22 % a hodnotou Omega ratio 1,18 [22].

Oproti této bakalářské práci navržený systém neoptimalizuje jednorázově přímo váhy portfolia. Genetický algoritmus nastavuje parametry skórovacího modelu, podle něhož jsou váhy měsíčně aktualizovány. Experiment zároveň zahrnuje více investičních univerz, různé profily investorů, genetické programování, transakční náklady, turnover, maximální drawdown a testování mimo trénovací období. Vlastní přínos proto spočívá především v začlenění evolučních metod do řízené adaptivní vrstvy nad výchozím portfoliem investora a v ověření, za jakých podmínek tato vrstva přináší hodnotu oproti jednoduchým referenčním strategiím.

4 Návrh adaptivního robo-poradce

Následující část popisuje návrh implementovaného prototypu adaptivního investičního robo-poradce. Předchozí text vysvětlil obecné principy investičního poradenství, tvorby portfolia, výnosových a rizikových metrik a evolučních algoritmů. Tyto poznatky jsou zde spojeny do konkrétního systému, který pracuje s historickými tržními daty, vypočítává tržní ukazatele, optimalizuje rozhodovací model a následně simuluje měsíční doporučení pro úpravu portfolia.

Navržený systém není zamýšlen jako plnohodnotná produkční robo-advisory platforma. Neřeší právní proces získání klienta, investiční dotazník, uživatelské rozhraní, daňové dopady ani napojení na brokera. Hlavním cílem je ověřit jádro rozhodovací logiky: zda může adaptivní model založený na historických datech a evolučních algoritmech upravovat váhy portfolia tak, aby v některých typech portfolií přinesl lepší poměr mezi výnosem, rizikem a náklady než jednoduché referenční strategie.

Z návrhového hlediska je důležité, že systém nefunguje jako krátkodobý obchodní robot. Nerozhoduje denně a nesnaží se predikovat přesnou cenu jednotlivých aktiv. Pracuje v měsíčním kroku a jeho výstupem je doporučené složení portfolia pro další měsíc. Toto rozhodnutí vychází pouze z informací, které byly dostupné před začátkem daného měsíce. Tím se omezuje riziko, že by backtest neúmyslně používal budoucí data.

4.1 Cíl navrženého systému

Cílem navrženého systému je vytvořit adaptivní vrstvu nad výchozím portfoliem investora. Každý investiční profil má přiřazenou baseline, tedy výchozí složení portfolia. Baseline odpovídá tomu, co by mohl používat jednoduchý statický robo-poradce: investor je zařazen do profilu a portfolio je následně pravidelně rebalancováno zpět na zadané cílové váhy.

Adaptivní robo-poradce tuto baseline neruší. Používá ji jako referenční bod, od kterého se může omezeně odchylovat. Smyslem není nechat model libovolně sázet celé portfolio na jedno aktivum, ale umožnit mu řízeně posílit aktiva, která podle aktuálních tržních ukazatelů vypadají příznivěji, a snížit váhu aktiv, která vypadají rizikověji nebo slaběji. Tento návrh odpovídá praktickému investičnímu problému: investor často nechce úplně opustit svůj rizikový profil, ale zároveň může dávat smysl, aby portfolio nebylo úplně statické.

Systém proto kombinuje tři vrstvy rozhodování. První vrstvu tvoří profil investora a jeho baseline. Druhou vrstvu tvoří skórovací model, který pro každé aktivum vypočítá číselné skóre na základě historických ukazatelů. Třetí vrstvu tvoří omezení exekuce, která určují, jak silně se model smí od baseline odchýlit, jak rychle se smí portfolio měnit a jak velkou váhu může mít jedno aktivum.

Návrh současně počítá s tím, že model nemusí být ve všech obdobích lepší než baseline. Proto není hodnocen pouze podle celkového zisku na jednom historickém úseku. Optimalizace pracuje s fitness funkcí, která porovnává model vůči měsíční baseline, penalizuje nadměrné riziko, vysoký obrat portfolia, transakční náklady a slabé chování v nejhorších validačních oknech. Tento přístup je důležitý zejména proto, že v investičních úlohách může být velmi snadné najít pravidlo, které dobře vypadá na minulosti, ale nefunguje stabilně v dalších obdobích.

4.1.1 Jednoduchý příklad baseline portfolia


Princip baseline lze ukázat na jednoduchém modelovém portfoliu složeném ze tří aktiv. Investor může mít například výchozí alokaci 60 % akcie, 30 % dluhopisy a 10 % zlato. Takové portfolio vyjadřuje základní investiční názor: většina kapitálu je určena pro růstovou složku, část portfolia má stabilizační funkci a malá část slouží jako doplňková diverzifikace.

Pokud by systém fungoval pouze jako statický poradce, každý měsíc by portfolio vracel zpět na poměr 60/30/10. Když akcie během měsíce výrazně vzrostou, jejich váha může například narůst na 64 %. Měsíční baseline by část akciové pozice prodala a vrátila se k původnímu poměru. Když akcie naopak klesnou, jejich váha se sníží a rebalancování je dokoupí zpět na cílovou hodnotu.

Adaptivní model pracuje jinak. Baseline 60/30/10 stále slouží jako výchozí kotva, ale model může podle aktuálních ukazatelů doporučit například posun na 55 % akcie, 35 % dluhopisy a 10 % zlato. Pokud se tržní prostředí zlepší, může naopak doporučit mírné navýšení akciové složky. Smyslem baseline tedy není zabránit změnám, ale určit neutrální stav, vůči kterému se aktivní doporučení posuzuje.

4.2 Celková architektura

Prototyp je implementován jako konzolová aplikace v jazyce C#. Aplikace je rozdělena do několika logických částí. Vrstva Data zajišťuje načtení a zarovnání časových řad. Vrstva Analytics počítá tržní ukazatele a převádí skóre modelu na váhy portfolia. Vrstva Backtesting a Advisory simuluje měsíční rozhodování, rebalancování a vývoj hodnoty portfolia. Vrstva Optimization obsahuje genetický algoritmus a genetické programování. Vrstva Experiments spojuje konfiguraci, investiční profily, trénovací a testovací roky a výstup reportů. Vztahy mezi vrstvami a tok dat zobrazuje obrázek 5.



Obrázek 5 – Vysokoúrovňová architektura a tok dat mezi vrstvami systému

Zdroj: autor

Zjednodušeně lze tok systému popsat následovně:

1. načtení cen aktiv z datasetu,
2. zarovnání časových řad na společné obchodní dny,
3. vytvoření investičních profilů a baseline portfolio,
4. výběr OOS roku, pro který se bude model testovat,
5. oříznutí trénovacích dat pouze do konce předchozího roku,
6. vytvoření validačních oken uvnitř trénovacích dat,
7. optimalizace modelu pomocí GA a GP,
8. spuštění měsíčního OOS testu na následujícím roce,
9. porovnání výsledků s měsíční baseline a buy-and-hold baseline,
10. výpis souhrnných výsledků, diagnostiky fitness a měsíčních doporučení.

Tato pipeline je postavena tak, aby oddělila trénování od testování. Pokud je například vyhodnocován rok 2020, model smí při optimalizaci použít pouze data do 31. 12. 2019. Výsledná strategie je potom aplikována na období 1. 1. 2020 až 31. 12. 2020. V dalším kroku se trénovací období posune a pro rok 2021 se model znovu optimalizuje pouze na datech dostupných do konce roku 2020. Tento postup je blízký tomu, jak by systém fungoval v praxi: před rozhodnutím o budoucím období nejsou známy budoucí ceny.

4.3 Vstupní data a jejich zarovnání

Vstupem systému jsou denní historické ceny jednotlivých aktiv. Data použitá v experimentální části byla stažena z webu Stooq [23]. Implementace umožňuje volit mezi více investičními univerzy; v experimentech této práce jsou použity smíšené multi-asset univerzum Macro24, globální akciové ETF GlobalCountry18 a jednotlivé americké akcie USBlueChip18. Přesný výběr aktiv a experimentálních portfolio je popsán v kapitole 5 Experimentální ověření. Z hlediska návrhu je podstatné, že systém nepracuje s jednou časovou řadou, ale s univerzem aktiv, ze kterého může model každý měsíc vytvářet relativní preference.

Po načtení dat jsou všechny časové řady zarovnány na společný kalendář. To znamená, že systém ponechá pouze takové obchodní dny, pro které existuje cena u všech aktiv v daném univerzu. Pro každý symbol je následně vytvořeno pole zavíracích cen a pole denních výnosů. Díky tomu mají všechna aktiva stejné indexování: hodnota s indexem t vždy odpovídá stejnému datu pro všechna aktiva.

Zarovnání dat má dvě praktické výhody. První výhodou je správnost backtestu. Pokud by některá aktiva měla jiné datumové indexy, mohlo by dojít k porovnávání hodnot z různých dnů. Druhou výhodou je rychlost. Evoluční algoritmy vyhodnocují velké množství kandidátních řešení, takže je výhodné mít ceny a výnosy uložené v polích, nikoli je opakovaně vyhledávat podle data v pomalejších datových strukturách.

Denní výnos aktiva je v systému počítán ze sousedních zavíracích cen. Výpočet uvádí rovnice 4.

$$r_t = \frac{Close_t}{Close_{t-1}} - 1$$

Rovnice 4 – Denní výnos aktiva

Jednotlivé proměnné ze vzorce vyjadřují následující:

- r_t je denní výnos aktiva v čase t ,
- $Close_t$ je zavírací cena aktiva v čase t ,
- $Close_{t-1}$ je zavírací cena aktiva v předchozím obchodním dni.

První den zarovnané řady nemá předchozí hodnotu, proto je jeho denní výnos nastaven na nulu. Tato hodnota nemá význam jako skutečný tržní výnos, ale umožňuje zachovat stejné délky polí cen a výnosů.

4.4 Tvorba tržních ukazatelů

Model nepracuje přímo se samotnou cenou aktiva. Cena je závislá na nominální úrovni konkrétního instrumentu a sama o sobě neříká, zda je aktivum relativně silné nebo slabé. Proto jsou pro každé aktivum a každý rozhodovací okamžik počítány tržní ukazatele, které popisují jeho nedávný vývoj, trend a rizikovost.

Výpočet ukazatelů probíhá v měsíčním rozhodovacím kroku. Pro daný měsíc se nejprve najde první obchodní den měsíce. Ukazatele se počítají k předchozímu obchodnímu dni, tedy k datu asOf. Pokud má systém rozhodovat o alokaci na únor, používá data dostupná nejpozději na konci ledna. Tím je zachována časová kauzalita.

Minimální historické okno je v implementaci nastaveno na 120 obchodních dní. Důvodem je, že nejdelší používaný výnosový ukazatel je 120denní návratnost. Dokud není k dispozici dostatečná historie, model v daném období nemůže počítat všechny potřebné ukazatele.

První skupinu ukazatelů tvoří návratnosti za různě dlouhá okna. Implementace používá Ret5, Ret10, Ret20, Ret60 a Ret120. Kratší okna reagují rychleji na nedávné změny, delší okna zachycují střednědobé momentum. V investičním kontextu momentum znamená tendenci aktiva pokračovat ve směru, ve kterém se v posledním období pohybovalo. Výnos za zvolené okno vyjadřuje rovnice 5.

$$RetN_t = \frac{Close_t}{Close_{t-N}} - 1$$

Rovnice 5 – Výnos aktiva za N obchodních dní

Jednotlivé proměnné ze vzorce vyjadřují následující:

- $RetN_t$ je výnos aktiva za posledních N obchodních dní,
- $Close_t$ je zavírací cena aktiva v čase t ,
- $Close_{t-N}$ je zavírací cena aktiva před N obchodními dny,
- N je délka sledovaného okna, například 5, 20, 60 nebo 120 dní.

Druhou skupinu tvoří ukazatele volatility. Implementace používá Vol20 a Vol60, tedy anualizovanou volatilitu z denních výnosů za posledních 20 a 60 obchodních dní. Volatilita slouží jako aproximace rizikovosti aktiva. Vyšší volatilita neznamena automaticky horší aktivum, ale znamená větší kolísání, a tedy vyšší nároky na investora. Anualizaci volatility uvádí rovnice 6.

$$VolN_t = std(r_{t-N+1}, \dots, r_t) * sqrt(252)$$

Rovnice 6 – Anualizovaná volatilita

Jednotlivé proměnné ze vzorce vyjadřují následující:

- $VolN_t$ je anualizovaná volatilita za posledních N obchodních dní,
- r_t je denní výnos v čase t,
- std je výběrová směrodatná odchylka denních výnosů,
- N je délka okna použitého pro výpočet volatility,
- 252 je přibližný počet obchodních dní v roce.

Třetí skupinu tvoří trendové ukazatele. PriceVsSma50 porovnává aktuální cenu s padesátidenním jednoduchým klouzavým průměrem. Pokud je hodnota kladná, cena je nad svým průměrem. Pokud je záporná, cena je pod svým průměrem. Tento ukazatel je záměrně jednoduchý, protože jeho cílem není přesná predikce ceny, ale rozlišení, zda se aktivum nachází nad nebo pod svým nedávným trendem. Relativní vzdálenost ceny formalizuje rovnice 7.

$$PriceVsSma50_t = \frac{Close_t}{SMA50_t} - 1$$

Rovnice 7 – Cena vůči klouzavému průměru

Jednotlivé proměnné ze vzorce vyjadřují následující:

- $PriceVsSma50_t$ je relativní vzdálenost ceny od padesátidenního klouzavého průměru,
- $Close_t$ je aktuální závěrečná cena aktiva,
- $SMA50_t$ je jednoduchý klouzavý průměr z posledních 50 závěrečných cen.

Čtvrtou skupinu tvoří režimové a normalizační ukazatele. $VolRatio20_60$ porovnává krátkodobou volatilitu s delší volatilitou. Pokud je hodnota výrazně vyšší než jedna, může to naznačovat zhoršené nebo stresové prostředí. $ZScore20$ vyjadřuje, jak daleko je aktuální cena od svého dvacetidenního průměru v jednotkách směrodatné odchylky. Tento ukazatel může zachycovat krátkodobé přestřelení ceny. Standardizaci ceny uvádí rovnice 8.

$$ZScore20_t = \frac{Close_t - SMA20_t}{Std20_t}$$

Rovnice 8 – Z-score ceny vůči dvacetidennímu průměru

Jednotlivé proměnné ze vzorce vyjadřují následující:

- $ZScore20_t$ je standardizovaná vzdálenost ceny od dvacetidenního průměru,
- $Close_t$ je aktuální závěrečná cena,
- $SMA20_t$ je jednoduchý klouzavý průměr za posledních 20 obchodních dní,
- $Std20_t$ je výběrová směrodatná odchylka závěrečných cen za posledních 20 obchodních dní.

Všechny tyto ukazatele jsou pro dané datum sdruženy do struktury `FeatureVector`. Pro všechna aktiva v univerzu vzniká `FeatureSnapshot`, který představuje kompletní stav trhu k jednomu rozhodovacímu datu. Skórovací model následně dostane pro každé aktivum jeho vlastní vektor ukazatelů a vrátí číselné skóre.

4.5 Skórovací model a převod skóre na váhy

Skórovací model je jádrem rozhodovací části systému. Jeho úkolem je přiřadit každému aktivu číslo, které vyjadřuje relativní atraktivitu aktiva v daném měsíci. Vyšší skóre znamená, že model považuje aktivum za vhodnější pro navýšení váhy. Nižší skóre znamená, že by aktivum mělo dostat menší váhu.

V návrhu jsou použity dva typy skórovacích modelů. První typ je parametrický model optimalizovaný genetickým algoritmem. Má pevně danou strukturu a evoluce hledá pouze hodnoty jeho čtyř koeficientů. Druhý typ je model tvořený stromem genetického programování. Ten nemá pevně daný tvar výrazu a evoluce hledá samotnou strukturu rozhodovacího pravidla.

Parametrický model používá momentum, trendový filtr a volatilitu. Jeho skóre je definováno následovně. Skórovací model zapisuje rovnice 9.

$$score_i = a * Ret60_i + b * Ret120_i + c * PriceVsSma50_i - d * Vol20_i$$

Rovnice 9 – Parametrické skóre aktiva

Jednotlivé proměnné ze vzorce vyjadřují následující:

- $score_i$ je skóre aktiva i ,
- $Ret60_i$ je šedesátidenní výnos aktiva i ,
- $Ret120_i$ je stodvacetidenní výnos aktiva i ,
- $PriceVsSma50_i$ je vzdálenost ceny aktiva i od padesátidenního klouzavého průměru,
- $Vol20_i$ je dvacetidenní anualizovaná volatilita aktiva i ,
- a, b, c a d jsou optimalizované parametry modelu.

Znaménka ve vzorci odpovídají základní investiční intuici. Vyšší střednědobé momentum a cena nad klouzavým průměrem skóre zvyšují. Vyšší krátkodobá volatilita skóre snižuje. Koeficienty ale nejsou pevně určeny ručně. Jejich hodnoty hledá genetický algoritmus podle fitness funkce na trénovacích datech.

Samotné skóre ještě není váha portfolia. Skóre může být záporné, kladné a nemusí mít žádný přirozený součet. Proto následuje normalizace skóre na long-only váhy, tedy váhy bez shortování a se součtem rovným jedné. Implementace podporuje dva režimy normalizace: softmax a rank.

Softmax převádí skóre na váhy exponenciálně. Aktiva s vyšším skóre dostanou vyšší váhu, ale všechna aktiva zůstávají v portfoliu s nezápornou vahou. Parametr SoftmaxTemperature určuje ostrost převodu. Nižší teplota vede ke koncentrovanějším vahám, vyšší teplota vede k rovnoměrnějšímu rozdělení. Převod skóre na váhy zachycuje rovnice 10.

$$z_i = \exp\left(\frac{score_i - maxScore}{T}\right)$$

$$w_i = \frac{z_i}{\sum_{j=1}^n z_j}$$

Rovnice 10 – Softmax převod skóre na váhy

Jednotlivé proměnné ze vzorce vyjadřují následující:

- z_i je pomocná exponenciální hodnota pro aktivum i ,
- z_j je pomocná exponenciální hodnota pro aktivum j ,
- w_i je modelová váha aktiva i ,
- $score_i$ je skóre aktiva i ,
- $maxScore$ je nejvyšší skóre ze všech aktiv v daném rozhodovacím kroku,
- T je softmax teplota,
- n je počet aktiv v univerzu.

Odečtení $maxScore$ nemění relativní poměr výsledných vah, ale zlepšuje numerickou stabilitu výpočtu. Bez této úpravy by u extrémních skóre mohly exponenciální hodnoty narůst příliš vysoko.

Rank normalizace postupuje jinak. Místo absolutní vzdálenosti skóre používá pořadí aktiv. Nejhorší aktivum dostane nejnižší rank, nejlepší aktivum nejvyšší rank a váhy jsou potom úměrné těmto rankům. Tento režim je odolnější vůči extrémním hodnotám skóre, protože nezáleží na tom, zda je nejlepší aktivum lepší jen nepatrně, nebo velmi výrazně. V konzervativnějších profilech je proto rank normalizace vhodná jako stabilnější převod signálu na váhy.

4.6 Řízení aktivního zásahu modelu

Po normalizaci skóre vzniknou čistě modelové váhy. Ty však nejsou přímo použity jako finální doporučení. Systém je míchá s baseline portfoliem investora pomocí parametru *ModelRisk*. Tento parametr určuje, jak velkou důvěru má systém dát modelu oproti výchozímu profilu. Smíchání vah formalizuje rovnice 11.

$$wTarget_i = (1 - modelRisk) * wBaseline_i + modelRisk * wModel_i$$

Rovnice 11 – Smíchání baseline a modelových vah

Jednotlivé proměnné ze vzorce vyjadřují následující:

- $wTarget_i$ je cílová váha aktiva i po smíchání baseline a modelu,
- $wBaseline_i$ je baseline váha aktiva i ,
- $wModel_i$ je váha aktiva i navržená modelem,
- *modelRisk* je parametr určující sílu aktivního zásahu modelu.

Pokud je *ModelRisk* roven nule, výsledkem je čistá baseline. Pokud je roven jedné, výsledkem je čistý model. Hodnoty mezi těmito extrémy představují kompromis. Konzervativní profil může mít nižší *ModelRisk*, protože u něj je důležitější stabilita a dodržení původního rizikového profilu. Agresivnější profil může dát modelu větší prostor.

Dalším omezením je *MaxSingleAssetWeight*, tedy maximální povolená váha jednoho aktiva. Bez tohoto omezení by model mohl při výrazném rozdílu skóre vytvořit příliš koncentrované portfolio. Implementace proto po výpočtu vah kontroluje, zda některé aktivum nepřekračuje povolený limit. Pokud ano, přebytečná váha je přerozdělena mezi ostatní aktiva.

Důležitým parametrem je také *MaxL1DeviationFromBaseline*. Ten omezuje celkovou vzdálenost cílového portfolia od baseline. Vzdálenost je měřena pomocí L1 normy, tedy součtem absolutních rozdílů vah. Vzdálenost portfolií vyjadřuje rovnice 12.

$$D_{L1}(w, v) = \sum_{i=1}^n |w_i - v_i|$$

Rovnice 12 – L1 vzdálenost dvou portfolií

Jednotlivé proměnné ze vzorce vyjadřují následující:

- $D_{L1}(w, v)$ je L1 vzdálenost mezi portfolií w a v ,
- w_i je váha aktiva i v prvním portfoliu,
- v_i je váha aktiva i ve druhém portfoliu,
- n je počet aktiv v portfoliu.

Stejný princip se používá i pro omezení měsíční změny portfolia. Parametr *MaxMonthlyTurnover* určuje maximální L1 pohyb, který může systém v jednom měsíci provést. Pokud by model navrhl větší změnu, cílové váhy jsou přiblíženy k aktuálním vahám pouze v takové míře, aby limit nebyl překročen. Toto omezení není deployment gate, která by model vypínala. Je to exekuční brzda přímo v procesu tvorby vah.

Po těchto omezeních systém ještě nepřechází na cílové váhy okamžitě. Používá parametr *RebalanceBlend*, který určuje, jak velká část rozdílu mezi aktuálním a cílovým portfoliem se

má skutečně provést. Tím se model stává plynulejším a méně citlivým na jednorázový signál. Měsíční přiblížení k cíli uvádí rovnice 13.

$$wNext_i = (1 - rebalanceBlend) * wCurrent_i + rebalanceBlend * wTarget_i$$

Rovnice 13 – Postupné přiblížení k cílovým vahám

Jednotlivé proměnné ze vzorce vyjadřují následující:

- $wNext_i$ je váha aktiva i po aplikaci měsíčního kroku,
- $wCurrent_i$ je aktuální váha aktiva i před rebalancováním,
- $wTarget_i$ je cílová váha aktiva i navržená modelem a omezeními,
- $rebalanceBlend$ je parametr určující, jak velká část změny se provede v jednom kroku.

Pokud je $RebalanceBlend$ roven jedné, portfolio se v daném měsíci přesune rovnou na cílové váhy. Pokud je například 0,25, provede se pouze čtvrtina rozdílu mezi aktuálním a cílovým portfoliem. Tato konstrukce je důležitá proto, že investiční signály mohou být šumové. Postupný přechod snižuje pravděpodobnost, že systém bude často přeskakovat mezi aktivy.

Parametr $MinDeltaL1ToAct$ naopak zabraňuje velmi malým obchodům. Pokud je rozdíl mezi aktuálními a cílovými vahami menší než zadaný práh, systém obchod neprovede a portfolio pouze drží. Malé změny by v praxi mohly být pohlceny transakčními náklady, spready nebo minimální velikostí obchodů.

4.7 Investiční profily

Investiční profil v návrhu systému určuje nejen baseline portfolio, ale také parametry, které omezují chování modelu. To je důležité, protože stejný skórovací model by neměl mít stejnou volnost u konzervativního a agresivního investora. Konzervativní profil má nižší toleranci k drawdownu, nižší sílu aktivního zásahu a přísnější omezení odchylky od baseline. Agresivní profil může připustit větší změny, vyšší koncentraci a vyšší volatilitu.

Každý profil obsahuje zejména tyto položky:

- $Baseline$ určuje výchozí váhy portfolio,
- $MddLimitAbs$ určuje tolerovanou absolutní velikost maximálního drawdownu ve fitness,
- $BetaTurnover$ určuje sílu penalizace nadměrného obratu portfolio,
- $ModelRisk$ určuje sílu aktivního zásahu modelu,
- $SoftmaxTemperature$ ovlivňuje koncentraci vah při softmax normalizaci,
- $RebalanceBlend$ určuje rychlost přechodu k cílovým vahám,
- $MaxSingleAssetWeight$ omezuje maximální váhu jednoho aktiva,
- $MinDeltaL1ToAct$ omezuje zbytečně malé obchody,
- $DMax$ nastavuje horní mez parametru d v parametrickém modelu,
- $MaxL1DeviationFromBaseline$ omezuje vzdálenost portfolio od baseline,
- $MaxMonthlyTurnover$ omezuje měsíční L1 změnu portfolio,
- $ScoreNormalization$ volí mezi softmax a rank převodem skóre,
- $UseAdaptiveTrust$ zapíná adaptivní snížení důvěry v model při vysokém nedávném obratu.

Parametr $UseAdaptiveTrust$ je v implementaci převeden na $UseAdaptiveModelRisk$. Pokud je zapnutý, systém sleduje průměrný turnover v posledních měsících. Jestliže se nedávný turnover

blíží nastavenému měsíčnímu limitu, efektivní ModelRisk se postupně snižuje. Tím se model automaticky zklidní v situaci, kdy by jeho doporučení vedla k příliš častým změnám. Pokud je turnover nízký, používá se původní hodnota ModelRisk.

Součástí návrhu je i validace profilů. Systém kontroluje, že součet baseline vah je roven jedné, že profil obsahuje váhu pro každé aktivum v univerzu, že parametry leží v přípustných intervalech a že maximální váha jednoho aktiva není nastavena tak nízko, aby nebylo možné portfolio vůbec složit. Tato validace chrání experiment před chybou konfigurace, která by jinak mohla být mylně interpretována jako selhání optimalizačního algoritmu.

4.8 Měsíční simulace portfolia

Měsíční simulace je část systému, která převádí doporučené váhy na vývoj hodnoty portfolia. Na začátku testovaného období je portfolio inicializováno z baseline vah a počátečního kapitálu. V aktuální konfiguraci je počáteční kapitál nastaven na 100 000 (typ měny zde nehraje roli, jedná se čistě o testovací záležitost). Následně systém prochází jednotlivé měsíce testovaného období.

V každém měsíci se nejprve určí rozhodovací datum asOf, což je poslední dostupný obchodní den před začátkem měsíce. K tomuto datu se vypočítají ukazatele pro všechna aktiva. Model z nich vytvoří skóre, skóre se převede na váhy, váhy se omezí podle profilu a systém rozhodne, zda se má rebalancovat nebo držet stávající portfolio.

Pokud je provedeno rebalancování, vzniká turnover. V této práci je turnover měřen jako L1 vzdálenost mezi původními a novými vahami. Pokud se například váha jednoho aktiva sníží o 10 procentních bodů a váha jiného aktiva se o 10 procentních bodů zvýší, L1 turnover je 0,20. Tato definice zachycuje celkovou velikost změny vah, nikoli počet jednotlivých obchodů.

Transakční náklady jsou modelovány jednoduše jako procento z hodnoty portfolia násobené turnoverm. Výpočet nákladu zachycuje rovnice 14.

$$cost = feeRate * turnover * portfolioValue$$

Rovnice 14 – Transakční náklad rebalancování

Jednotlivé proměnné ze vzorce vyjadřují následující:

- *cost* je náklad rebalancování,
- *feeRate* je sazba transakčních nákladů,
- *turnover* je L1 změna vah portfolia,
- *portfolioValue* je hodnota portfolia před odečtením nákladů.

Po odečtení nákladů je portfolio drženo do konce měsíce bez denního rebalancování. Denní výnosy aktiv mění hodnotu jednotlivých expozic a tím se přirozeně mění i váhy portfolia. Na začátku dalšího měsíce se celý postup opakuje. Díky tomu simulace zachycuje rozdíl mezi cílovými vahami po rebalancování a skutečnými vahami, které se v průběhu měsíce od cíle odchýlí vlivem rozdílného vývoje aktiv.

Systém současně ukládá pro každý měsíční krok informace, které jsou důležité pro interpretaci doporučení: datum rozhodnutí, období, pro které byly váhy použity, váhy před rebalancováním, cílové váhy, skutečně aplikované váhy, turnover, náklady, počáteční hodnotu a koncovou

hodnotu portfolia. Díky tomu lze vedle souhrnných výsledků sledovat i praktické rady, například zda systém doporučil držet portfolio, nebo které pozice navýšit a snížit.

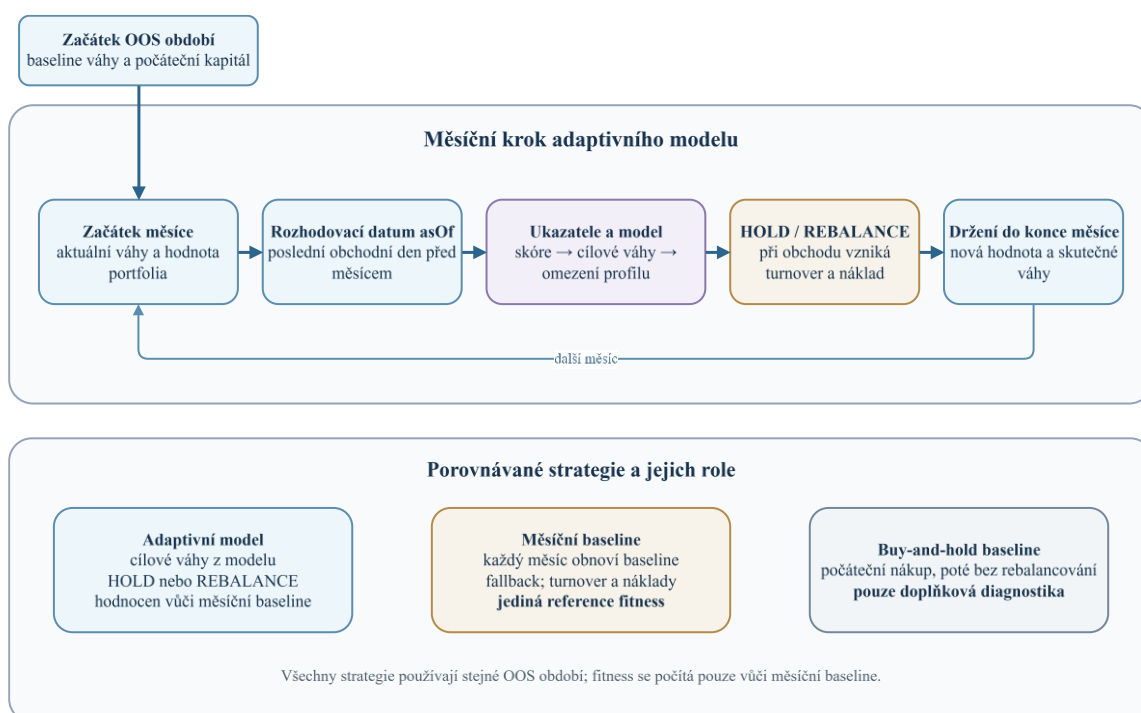
4.9 Referenční strategie v návrhu

Obecné principy referenčních strategií jsou popsány v kapitole 2.5 *Referenční strategie*. V navrženém systému plní měsíční rebalancování a strategie buy-and-hold rozdílné role.

Hlavní referencí při výpočtu fitness je měsíční baseline, která na konci každého měsíce obnovuje výchozí váhy investičního profilu. Představuje předem definovaný fallback pro případ, že by adaptivní model nebyl použit. Výkonnost kandidátních řešení je proto posuzována vůči jednoduché strategii, která zachovává stanovený rizikový profil pravidelným rebalancováním.

Buy-and-hold baseline je v systému použita pouze jako doplňková diagnostická reference. Po počátečním nákupu již portfolio nerebalancuje, takže se jeho váhy mění podle relativní výkonnosti jednotlivých aktiv. Umožňuje tak posoudit, zda pravidelné rebalancování a rozhodnutí adaptivního modelu přináší hodnotu oproti pouhému držení počátečního portfolia.

Při výpočtu fitness se zpětně nevybírání výhodnější z obou referenčních strategií. Takový postup by využíval informaci dostupnou až po skončení hodnoceného období a neodpovídal by reálnému nasazení systému. Jako jediná reference fitness je proto předem stanovena měsíční baseline, zatímco buy-and-hold slouží k doplňkové interpretaci výsledků v kapitole 6 *Vyhodnocení výsledků*. Celý měsíční postup a odlišné role obou referencí zobrazuje obrázek 6.



Obrázek 6 – Měsíční proces rebalancování a role referenčních strategií

Zdroj: autor

4.10 Genetický algoritmus v navrženém systému

Genetický algoritmus v systému slouží k optimalizaci parametrického skórovacího modelu. Jedinec v populaci je tvořen čtyřmi reálnými čísly a , b , c a d . Tato čísla určují váhu jednotlivých složek skóre v rovnici 9. Algoritmus tedy nehledá úplně nový výraz, ale hledá vhodné nastavení známého modelu.

Hodnoty parametrů jsou omezeny intervaly. Parametry a , b a c jsou v aktuálním návrhu hledány v intervalu od 0 do 1,5. Parametr d , který určuje sílu penalizace volatility, je hledán v intervalu od 0 do hodnoty D_{Max} definované v investičním profilu. Díky tomu lze u různých profilů nastavit, jak silně smí volatilita ovlivnit rozhodování modelu.

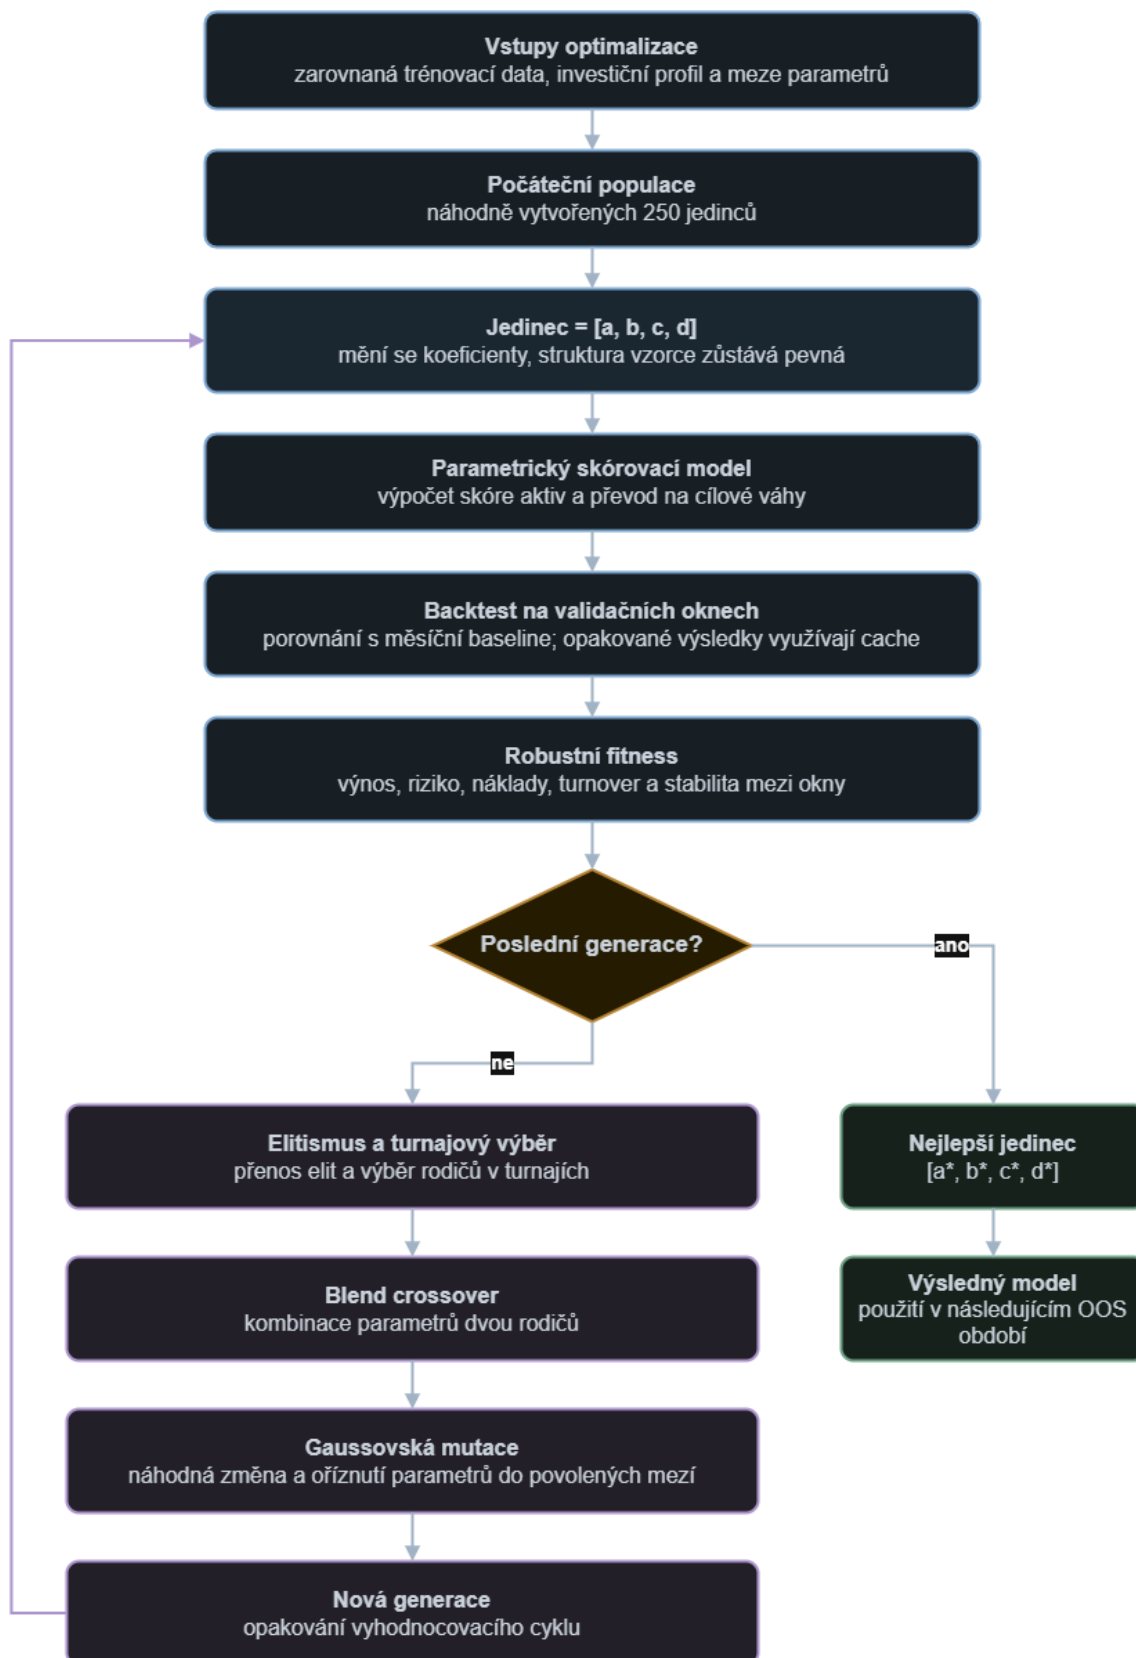
Optimalizace začíná náhodně vytvořenou populací. V aktuální konfiguraci má GA populace 250 jedinců a optimalizace probíhá 30 generací. Každý jedinec je vyhodnocen pomocí robustní fitness funkce nad validačními okny trénovacích dat. Výsledkem vyhodnocení je číslo, které vyjadřuje, jak dobře daná kombinace parametrů fungovala vůči měsíční baseline po započtení rizika, nákladů, obratu a robustnosti.

Selekce rodičů probíhá turnajovým výběrem. V turnaji se náhodně vybere několik kandidátů a jako rodič je zvolen ten s nejlepší fitness. Tento postup zachovává tlak na kvalitní řešení, ale zároveň ponechává v procesu náhodnost. V implementaci je velikost turnaje nastavena na 6.

Nová generace vzniká kombinací elitismu, křížení a mutace. Elitismus zajišťuje, že několik nejlepších jedinců přechází do další generace beze změny. Tím se snižuje riziko, že algoritmus ztratí dosud nejlepší nalezené řešení. Křížení kombinuje hodnoty parametrů dvou rodičů. Implementace používá blend crossover, při kterém je pro každý parametr potomka vybrána hodnota z intervalu odvozeného z hodnot obou rodičů. Mutace přidává ke koeficientům náhodnou změnu podle Gaussova rozdělení a výsledek je následně oříznut do povolených mezí.

Fitness jednotlivých jedinců je v rámci jedné optimalizace ukládána do cache. Klíč cache obsahuje zaokrouhlené hodnoty genů i parametry exekuce, například ModelRisk, RebalanceBlend, limit koncentrace a normalizační režim. Smyslem je nevyhodnocovat opakovaně prakticky stejný model, což je důležité zejména proto, že každé vyhodnocení znamená několik backtestů přes validační okna.

Výstupem genetického algoritmu je nejlepší nalezená kombinace parametrů a jí odpovídající parametrický skórovací model. Tento model je poté aplikován v OOS období daného roku a porovnán s referenčními strategiemi. Postup optimalizace zobrazuje obrázek 7.



Obrázek 7 – Schéma optimalizace parametrického skórovacího modelu pomocí genetického algoritmu

Zdroj: autor

4.11 Genetické programování v navrženém systému

Genetické programování v systému představuje flexibilnější variantu modelu. Zatímco genetický algoritmus pouze ladí čtyři parametry předem daného vzorce, genetické programování hledá celý výraz pro výpočet skóre. Jedinec tedy není vektor čísel, ale strom složený z funkcí, proměnných a konstant. Tento návrh vychází z obecného principu GP popsaného v kapitole 3 *Evoluční algoritmy*.

Použitou reprezentaci, funkční a terminální množinu, evoluční hyperparametry, omezení stromu i behaviorální konfiguraci shrnuje tabulka 1.

Počáteční stromy jsou vytvářeny modifikovanou metodou grow. Před dosažením maximální hloubky generátor zvolí s pravděpodobností 0,85 funkční uzel a s pravděpodobností 0,15 terminál. Na maximální hloubce vloží terminál vždy.

Použitými genetickými operacemi jsou subtree crossover (podstromové křížení), při němž se mezi rodiči vymění náhodně vybrané podstromy, a subtree mutation (podstromová mutace), která náhodně vybraný podstrom nahradí nově vygenerovaným podstromem.

Riziko přerůstání stromů (bloat) omezuje maximální hloubka a počet uzlů, opakovaná simplifikace a parsimony penalty za velikost. Menší strom má při srovnatelné robustní fitness přednost před větším.

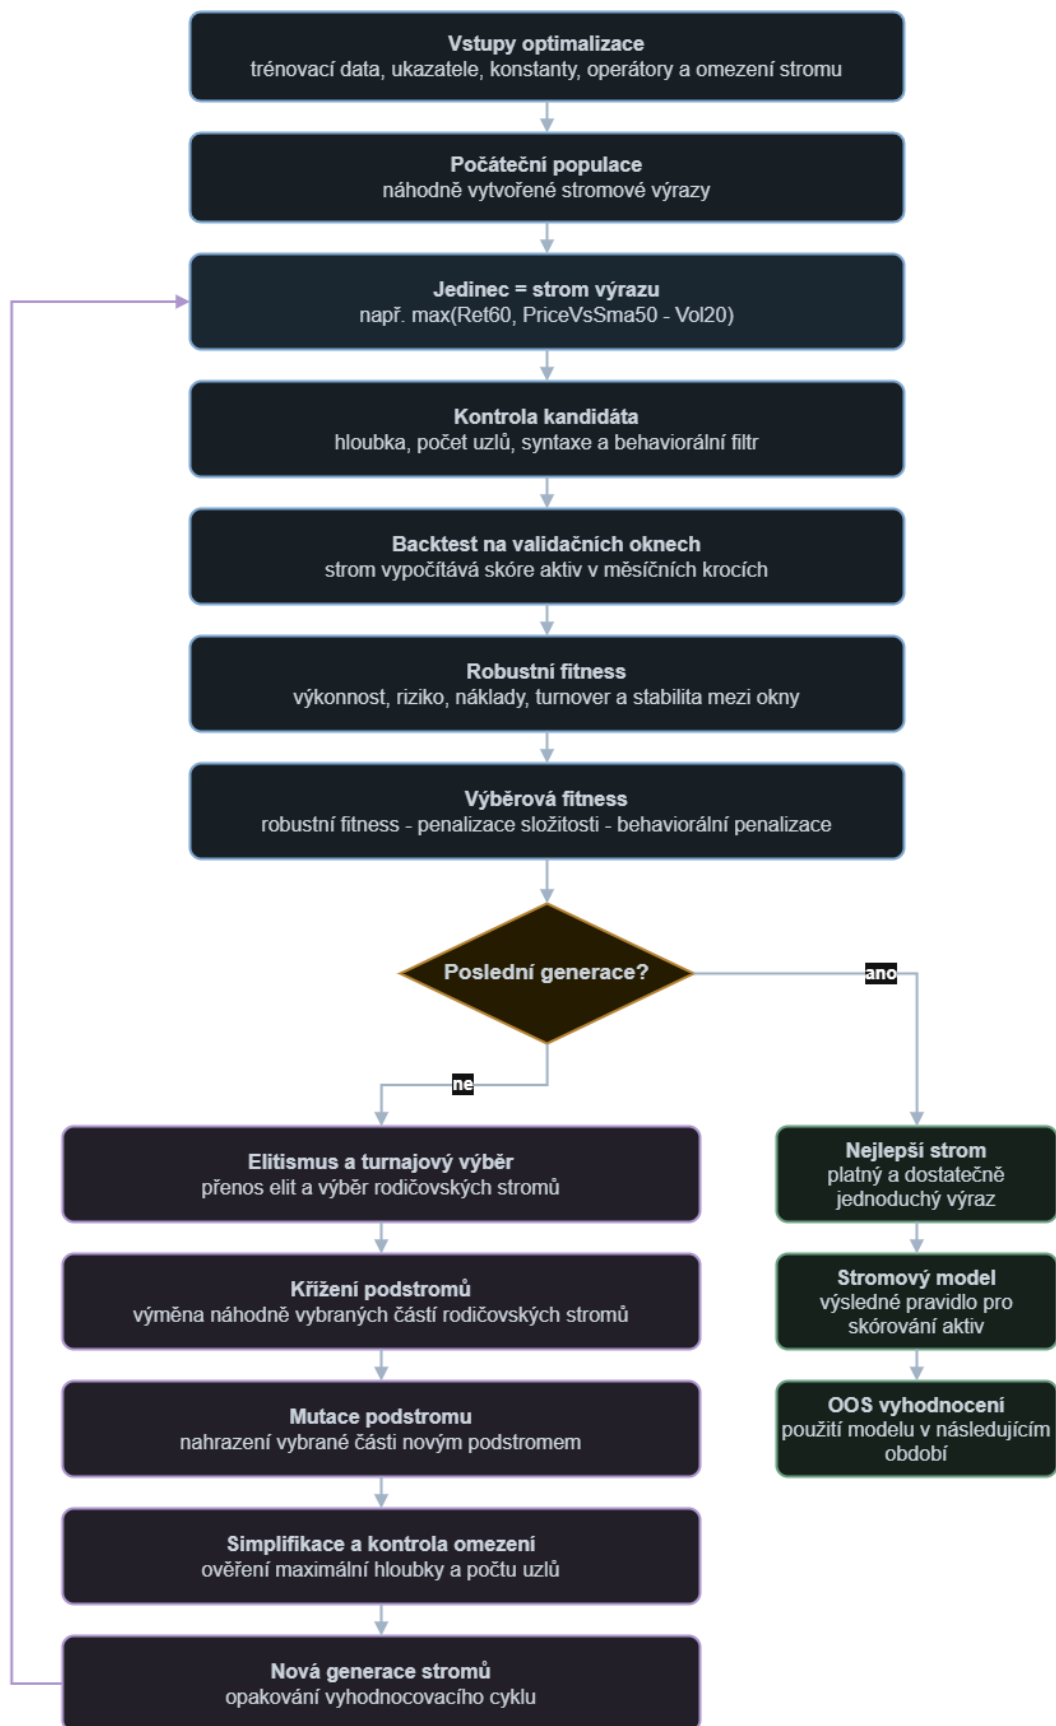
Systém proto rozlišuje BestFitness, tedy skutečnou robustní fitness kandidáta, a BestSelectionFitness používanou při selekci po odečtení penalizace složitosti a případné behaviorální penalizace. Při velmi podobné robustní fitness je upřednostněn jednodušší strom.

Tvorbu stromového skórovacího modelu a následné vyhodnocení shrnuje obrázek 8.

Kategorie	Položka	Použité nastavení
Reprezentace	Jedinec	Strom výrazu vracející číselné skóre aktiva
Inicializace	Metoda	Modifikovaná metoda grow; před maximální hloubkou operátor s pravděpodobností 0,85, jinak terminál; na maximální hloubce vždy terminál
Inicializace	Maximální počáteční hloubka	4
Funkční množina	Binární operátory	sčítání, odčítání, násobení, minimum a maximum
Funkční množina	Unární operátor	absolutní hodnota
Terminály	Tržní ukazatele	Ret5, Ret10, Ret20, Ret60, Ret120, Vol20, Vol60, PriceVsSma50, VolRatio20_60 a ZScore20
Terminály	Poměr výběru	90 % ukazatel, 10 % konstanta
Konstanty	Generování	rovnoměrně z intervalu -2 až 2
Evoluce	Populace a generace	200 stromů; 30 generací
Selekce	Turnaj a elitismus	velikost turnaje 6; elitismus 10 jedinců
Operátory	Subtree crossover (podstromové křížení)	pravděpodobnost 0,85; výměna náhodně zvolených podstromů rodičů
Operátory	Subtree mutation (podstromová mutace)	pravděpodobnost 0,35 pro každého potomka; náhrada zvoleného podstromu nově generovaným stromem
Omezení	Hloubka a velikost po operátorech	maximální hloubka 5; maximálně 14, 18 nebo 24 uzlů podle profilu a ModelRisk
Simplifikace	Zjednodušování stromu	zapnuto; nejvýše 8 průchodů
Parsimony	Penalizace velikosti	$\lambda = 0,0024 / 0,0021 / 0,0018$ podle profilu
Výběr	Tolerance shodné robustní fitness	0,0015 / 0,0012 / 0,0010 podle profilu
Výběr	Minimální přínos dalšího uzlu	0,00035 / 0,00030 / 0,00025 podle profilu
Behaviorální filtr	Počet snímků	minimálně 6, nejvýše 96
Behaviorální filtr	Mezní hodnoty	průměrná průřezová odchylka $\geq 10^{-5}$; alespoň 3 pořadí; podíl remíz $\leq 0,70$; téměř konstantních snímků $\leq 0,50$; oříznutých skóre $\leq 0,30$
Behaviorální filtr	Tolerance a penalizace	shoda 10^{-9} ; téměř konstantní rozsah 10^{-6} ; λ degenerace 0,02
Reprodukovatelnost	Seed	deterministicky z profilu a OOS roku; offset GP = 2000

Tabulka 1 – Kompletní nastavení genetického programování v experimentu

Zdroj: autor



Obrázek 8 – Schéma tvorby stromového skórovacího modelu pomocí genetického programování

Zdroj: autor


4.12 Behaviorální filtr GP

Samotná syntaktická platnost stromu nestačí. Strom může být technicky vyhodnotitelný, ale z hlediska investičního rozhodování nepoužitelný. Typickým příkladem je strom, který vrací téměř stejnou hodnotu pro všechna aktiva. Takový model sice vytvoří skóre, ale nedokáže aktiva smysluplně rozlišit. Jiným příkladem je výraz, který často vytváří extrémní hodnoty a ty jsou následně ořezány ochranným limitem skóre.

Z tohoto důvodu návrh obsahuje behaviorální filtr. Ten před plným backtestem analyzuje, jak se kandidátní GP model chová na vybraných měsíčních snímcích trénovacích dat. Pro každý snímek vypočítá skóre všech aktiv a sleduje několik diagnostik: průřezovou směrodatnou odchylku skóre, počet odlišných pořadí aktiv, podíl remíz mezi aktivy, podíl téměř konstantních snímků a podíl oříznutých skóre. Jedním snímkem se rozumí průřez skóre všech dostupných aktiv v daném měsíci.

Pokud model nevytváří dostatečně rozlišující skóre, je odmítnut ještě před nákladným backtestem. Stejně tak je odmítnut model, který vytváří příliš mnoho remíz, příliš často téměř konstantní výstupy nebo příliš často naráží na ořez skóre. Tento filtr pomáhá odstranit degenerované kandidáty, kteří by jinak zbytečně zabírali místo v populaci.

Behaviorální filtr nenahrazuje fitness funkci. Slouží jako předběžná kontrola smysluplnosti signálu. Model, který filtrem projde, musí stále obstát v robustním backtestu vůči baseline. Pokud však filtrem neprojde, není dále hodnocen a jeho výběrová fitness je nastavena jako neplatná. Rozhodovací postup filtru zobrazuje obrázek 9.



Obrázek 9 – Rozhodovací postup behaviorálního filtru GP

Zdroj: autor

4.13 Fitness funkce

Fitness funkce určuje, jaké chování optimalizační algoritmus považuje za žádoucí. V investičním systému je tato volba zásadní. Pokud by fitness sledovala pouze konečnou hodnotu portfolia, algoritmus by mohl preferovat strategie s extrémním rizikem, vysokým turnoverem nebo silným přeúčením na jedno období. Proto je fitness navržena jako kombinace výnosu, rizikově očištěného výnosu, nákladů, obratu a drawdownu.

Základní fitness jednoho validačního okna porovnává politiku modelu s měsíční baseline. Hlavními pozitivními složkami jsou rozdíl Sharpe ratio a rozdíl CAGR. Sharpe ratio zachycuje rizikově očištěný výnos a jeho interpretace byla popsána v kapitole 2 *Investiční portfolio a řízení rizika* podle Sharpa a Loa [15; 16]. CAGR zachycuje složený roční růst portfolia. Negativními složkami jsou penalizace turnoveru, transakčních nákladů, nadměrného turnoveru nad povolený násobek baseline, překročení MDD limitu a případná penalizace prázdného běhu. Výslednou fitness jednoho okna uvádí rovnice 15.

$$\text{fitness} = \text{deltaSharpe} + 4 * \text{deltaCagr} - \text{turnoverPenalty} - \text{costPenalty} \\ - \text{excessTurnoverPenalty} - \text{mddPenalty} - \text{emptyRunPenalty}$$

Rovnice 15 – Fitness jednoho validačního okna

Jednotlivé proměnné ze vzorce vyjadřují následující:

- fitness je výsledná hodnota fitness v jednom validačním okně,
- deltaSharpe je rozdíl Sharpe ratio modelu a měsíční baseline,
- deltaCagr je rozdíl CAGR modelu a měsíční baseline,
- turnoverPenalty je penalizace rozdílu turnoveru oproti měsíční baseline,
- costPenalty je penalizace rozdílu transakčních nákladů oproti měsíční baseline,
- excessTurnoverPenalty je dodatečná penalizace extrémně vysokého turnoveru,
- mddPenalty je penalizace překročení maximálního povoleného drawdownu,
- emptyRunPenalty je penalizace situace, kdy model nevytvoří žádný platný běh.

Váha u deltaCagr je v implementaci nastavena na 4. Důvodem je rozdílné měřítko jednotlivých složek. Rozdíl CAGR bývá číselně menší než rozdíl Sharpe ratio, ale z praktického hlediska je pro investora důležitý. Tato váha proto zajišťuje, že model není hodnocen pouze podle Sharpe ratio, ale musí přidávat i výnosovou hodnotu.

Penalizace turnoveru se počítá vůči měsíční baseline. Pokud má model nižší turnover než baseline, tato složka mu může fitness zlepšit. Pokud má vyšší turnover, fitness zhorší. Navíc existuje dodatečná penalizace za nadměrný turnover. Ta se aktivuje pouze tehdy, když roční turnover modelu překročí 1,5násobek ročního turnoveru měsíční baseline. Tato penalizace je kvadratická, takže mírné překročení má menší dopad než extrémní přeskokování mezi aktivy.

MDD penalizace sleduje, zda absolutní velikost maximálního drawdownu modelu překračuje limit profilu. Pokud je drawdown v povoleném limitu, penalizace je nulová. Pokud jej překročí, penalizace roste úměrně velikosti překročení. Maximální drawdown je zde používán jako omezení nejhoršího historického propadu portfolia, tedy jako doplněk k metrikám založeným na průměrném výnosu a volatilitě [17]. Její zápis formalizuje rovnice 16.

$$mddPenalty = \alpha Mdd * \max(0, \text{abs}(\maxDrawdownPolicy) - mddLimitAbs)$$

Rovnice 16 – Penalizace překročení maximálního drawdownu

Jednotlivé proměnné ze vzorce vyjadřují následující:

- $mddPenalty$ je penalizace za překročení drawdown limitu,
- αMdd je váha penalizace drawdownu,
- $\maxDrawdownPolicy$ je maximální drawdown modelové strategie,
- $mddLimitAbs$ je povolená absolutní velikost maximálního drawdownu,
- $\max(0, x)$ znamená, že penalizace vzniká pouze při překročení limitu.

Fitness funkce tedy neříká pouze to, zda model vydělal více peněz. Říká, zda model přidal hodnotu vůči realistickému fallbacku při zohlednění rizika, nákladů a stability. To je pro adaptivního robo-poradce důležité, protože cílem není za každou cenu obchodovat, ale zlepšit rozhodování v situacích, kde k tomu existuje dostatečně silný signál.

4.14 Robustní fitness

Kdyby byl model optimalizován pouze na jednom trénovacím období, mohl by se přizpůsobit konkrétnímu historickému úseku. Proto systém rozděluje trénovací data do více validačních oken. Pro každé OOS období jsou trénovací data oříznuta do konce předchozího roku a uvnitř těchto dat jsou vytvořena validační okna končící v předem daných letech. Implementace používá kandidátní konce 2014, 2016, 2018, 2020, 2022 a 2024 a vždy přidá také aktuální konec trénovacího období, pokud tam ještě není.

Pro každé validační okno se vypočítá fitness podle rovnice 15. Robustní fitness potom nevychází pouze z průměru těchto hodnot. Zohledňuje i nejhorší okno a rozptyl výsledků mezi okny. Tím systém preferuje modely, které nejsou dobré jen v jednom konkrétním období, ale mají stabilnější chování napříč trénovací historií. Agregaci validačních oken vyjadřuje rovnice 17.

$$robustFit = fitAvg - 0,30 * \max(0, fitAvg - worstFit) - 0,10 * stdFit$$

Rovnice 17 – Robustní fitness přes validační okna

Jednotlivé proměnné ze vzorce vyjadřují následující:

- $robustFit$ je výsledná robustní fitness použitá optimalizací,
- $fitAvg$ je průměrná fitness přes validační okna,
- $worstFit$ je nejhorší fitness ze všech validačních oken,
- $stdFit$ je výběrová směrodatná odchylka fitness přes validační okna,
- 0,30 je váha penalizace nejhoršího okna,
- 0,10 je váha penalizace rozptylu výsledků.

Hodnoty 0,30 a 0,10 byly zvoleny jako prakticky vyvážený poměr při orientačním posouzení průběhu fitness, nikoli jako obecně platné konstanty. Zvýšení váhy 0,30 by více trestalo jediné slabé validační okno a vedlo ke konzervativnějšímu výběru; její snížení by naopak dalo větší význam průměrné fitness. Vyšší váha 0,10 by silněji penalizovala kolísání mezi okny, nižší by tolerovala méně stabilní výsledky. Poměr 0,30 ku 0,10 proto dává nejhoršímu oknu větší vliv než celkovému rozptylu, ale nebyl ověřován hloubkovou optimalizací ani rozsáhlou citlivostní analýzou.

Tento návrh je kompromisem mezi výkonností a robustností. Model může mít vysokou průměrnou fitness, ale pokud má jedno velmi slabé okno, robustní fitness se sníží. Stejně tak se sníží, pokud jsou výsledky mezi okny velmi nestabilní. Robustní fitness tedy podporuje takové modely, které dokážou fungovat v různých režimech trhu, nikoli pouze v jednom období.

Je důležité rozlišovat mezi robustní fitness a OOS výsledkem. Robustní fitness je používána při trénování, tedy na historických datech dostupných před testovaným rokem. OOS výsledek je následný test na roce, který model při optimalizaci neviděl. V aktuálním návrhu není zavedena deployment gate, která by model s nekladnou robustní fitness automaticky nahradila baseline. Model je vždy otestován v OOS období, aby bylo možné objektivně porovnat chování GA a GP napříč profily a roky. Robustní fitness proto slouží jako trénovací kritérium a diagnostika, nikoli jako pravidlo pro vypnutí modelu.

4.15 Walk-forward vyhodnocení

Walk-forward vyhodnocení je hlavní mechanismus, kterým se systém snaží přiblížit reálnému použití. Pro každý testovaný rok je model trénován pouze na datech do konce předchozího roku. Poté je aplikován na následující rok v měsíčních krocích. Tento postup se opakuje pro více OOS let. V aktuální konfiguraci jsou testovány celé roky 2018 až 2025.

Pro každý rok se spouští dvě optimalizace: GA a GP. Obě používají stejné trénovací období, stejná validační okna, stejnou baseline a stejné exekuční parametry profilu. Díky tomu lze jejich výsledky porovnávat férově. Po optimalizaci se pro OOS rok spustí čtyři strategie: měsíční baseline, buy-and-hold baseline, GA model a GP model.

Výstupem OOS běhu je konečná hodnota portfolia, celkový turnover, celkové náklady, průběžná equity curve a měsíční kroky. Souhrnný report následně počítá vítěze daného roku, průměrné konečné hodnoty podle profilu, relativní výkonnost vůči baseline, počet pozitivních let a diagnostiku chování v letech, kdy baseline sama ztratila hodnotu.

Walk-forward vyhodnocení je důležité i pro interpretaci výsledků diplomové práce. Pokud model funguje pouze na trénovacích validačních oknech, ale selhává v OOS rocích, znamená to přeučení nebo nevhodnou fitness. Pokud naopak dokáže opakovaně zlepšovat měsíční baseline v OOS letech, je to silnější argument, že adaptivní vrstva má praktický potenciál.

4.16 Výstup měsíčních doporučení

Vedle souhrnných výsledků systém vypisuje také měsíční doporučení. Pro každý měsíc OOS běhu lze zobrazit, zda model doporučil držet stávající portfolio, nebo provést rebalancování. Výpis obsahuje rozhodovací datum, velikost turnoveru, odhad transakčních nákladů, koncovou hodnotu portfolia v backtestu, největší váhy a hlavní nákupy nebo prodeje.

Tento výstup je důležitý, protože přibližuje experiment praktickému použití robo-poradce. Konečný výsledek za rok sice ukazuje, zda strategie vydělala, ale neukazuje, jak se k výsledku dostala. Měsíční doporučení umožňuje sledovat, kdy model začal zvyšovat nebo snižovat určitou expozici, zda obchodoval často, zda jen jemně upravoval váhy a zda jeho chování odpovídá zvolenému rizikovému profilu.

V praxi by takové doporučení mohlo mít podobu investiční rady na další měsíc. Například systém by mohl doporučit zvýšit váhu krátkodobých dluhopisů a snížit váhu technologických akcií, pokud model vyhodnotí zvýšenou volatilitu a slábnoucí trend rizikových aktiv. V této

práci se doporučení nevykonávají na reálném účtu, ale jsou součástí backtestu a slouží k interpretaci chování modelu.

4.17 Omezení návrhu

Navržený systém má několik omezení. Prvním omezením je práce pouze s historickými cenami. Model nepoužívá fundamentální data, makroekonomické proměnné, odhady výnosů, úrokové sazby ani sentiment. To zjednodušuje experiment a umožňuje soustředit se na evoluční rozhodovací jádro, ale zároveň omezuje informační základnu modelu.

Druhým omezením je jednoduchý model transakčních nákladů. Náklady jsou reprezentovány pevnou sazbou z obchodované hodnoty. V reálném světě by záleželo na konkrétním instrumentu, likviditě, spreadu, velikosti objednávky, měně, daních a brokerovi. Pro porovnání strategií v rámci jedné experimentální konfigurace je však jednotný nákladový model dostatečný, protože všechny strategie jsou hodnoceny stejným způsobem.

Třetím omezením je long-only konstrukce portfolia. Model nemůže shortovat aktiva ani používat páku. To odpovídá konzervativnějšímu pojetí robo-poradenství, ale zároveň to omezuje možnosti ochrany portfolia v krizových obdobích. Pokud všechna aktiva v univerzu současně klesají, model může pouze přesouvat váhy mezi relativně méně špatná aktiva.

Čtvrtým omezením je závislost na zvoleném investičním univerzu. Adaptivní model může fungovat pouze s aktivy, která má k dispozici. Pokud je univerzum špatně sestavené nebo neobsahuje dostatečně defenzivní aktiva, systém nemusí mít možnost vytvořit vhodné portfolio. To je důležité zejména u záměrně špatných portfolií v experimentální části: cílem není dokázat, že robot umí opravit jakoukoli chybu, ale zjistit, v jakých typech špatného složení dokáže adaptivní vrstva pomoci.

Pátým omezením je riziko přeučení. Evoluční algoritmy prohledávají velký prostor možných řešení a mohou najít pravidla, která využívají náhodné historické vztahy. Návrh se tomu brání robustní fitness, walk-forward testováním, penalizací složitosti GP a behaviorálním filtrem, ale riziko přeučení nelze zcela odstranit. Proto je v této práci důležité vyhodnocení více profilů, více let a porovnání vůči jednoduchým referenčním strategiím.

5 Experimentální ověření

Experimentální část práce ověřuje, jak se navržený adaptivní robo-poradce chová na historických datech a zda dokáže v různých typech portfolií přidat hodnotu oproti jednoduchým referenčním strategiím. Cílem není prokázat existenci univerzálně nejlepší investiční strategie, ale systematicky porovnat několik přístupů za stejných podmínek. Všechny varianty používají v rámci jednoho běhu stejný dataset, stejná období, stejné počáteční hodnoty portfolia a stejné transakční náklady. Byly provedeny tři samostatné běhy nad datasey Macro24, GlobalCountry18 a USBBlueChip18.

Experiment je navržen tak, aby oddělil návrhovou logiku od výsledků. V této části jsou popsána data, testovaná portfolia, konfigurace běhu a způsob vyhodnocení. Samotné výsledky, jejich interpretace a závěr, zda byl adaptivní přístup přínosný, jsou ponechány do kapitoly 6 *Vyhodnocení výsledků*.

5.1 Cíl experimentu

Hlavním cílem experimentu je ověřit, zda adaptivní rozhodovací vrstva založená na genetickém algoritmu a genetickém programování dokáže zlepšit chování portfolia oproti měsíční baseline. Měsíční baseline představuje jednoduchý realistický fallback: portfolio je pravidelně rebalancováno zpět na výchozí váhy daného profilu. Pokud má mít adaptivní systém praktický význam, měl by být schopen alespoň v některých typech portfolií tuto referenci překonat nebo zlepšit její rizikové vlastnosti.

Experiment sleduje několik dílčích otázek:

1. zda adaptivní model přidává hodnotu u dobře složených portfolií s různou mírou rizika,
2. zda dokáže pomoci u záměrně špatně složených portfolií,
3. zda se genetický algoritmus a genetické programování chovají rozdílně,
4. zda případné zlepšení není vykoupeno nepřiměřeným turnoverem nebo náklady,
5. zda model funguje stabilně napříč více OOS roky, nikoli pouze v jednom výhodném období.
6. zda se charakter výsledků mění při přechodu mezi multi-asset, globálním akciovým a americkým akciovým univerzem.

Toto rozdělení je důležité pro interpretaci výsledků. Pokud by model překonal baseline pouze u jednoho profilu nebo jednoho roku, šlo by spíše o izolovaný nález. Silnější argument pro adaptivní přístup by vznikl tehdy, pokud by model opakovaně pomáhal v určitém typu portfolia, například u konzervativních nebo strukturálně nevyvážených alokací.

5.2 Použité datasety

Experiment byl proveden nad třemi datasety. Každý z nich představuje samostatné investiční univerzum a pro každý byly definovány odpovídající výchozí váhy všech osmi profilů. Optimalizační postup, OOS roky a ostatní společné parametry zůstaly stejné. Rozdíly mezi výsledky proto ukazují citlivost navrženého přístupu na charakter dostupných aktiv.

5.2.1 Dataset Macro24

Pro experiment byl vytvořen dataset Macro24, který obsahuje dvacet čtyři burzovně obchodovaných instrumentů. Data byla stažena ze služby Stooq [23]. Dataset zahrnuje široké americké akciové indexy, mezinárodní akcie, americké sektorové ETF, nemovitostní expozici, dluhopisy, drahé kovy a komodity. Záměrem bylo vytvořit univerzum, ve kterém jsou zastoupena jak růstová aktiva, tak defenzivní a alternativní složky portfolia.

Po zarovnání všech časových řad na společné obchodní dny má dataset rozsah od 28. 4. 2006 do 1. 7. 2026 a obsahuje 5071 společných obchodních dní. Společný začátek je určen nejmladšími aktivy v datasetu, zejména ETF zaměřenými na stříbro a ropu. I když některé instrumenty mají dostupnou historii dříve, systém používá pouze průnik datumů, aby všechna aktiva měla v každém kroku dostupnou cenu.

Skupina aktiv	Symbole	Účel v experimentu
Široké americké akcie	SPY, QQQ, IWM	Růstová složka, velké technologické firmy a menší společnosti
Mezinárodní akcie	EFA, EEM	Diverzifikace mimo americký akciový trh
Americké sektory	XLK, XLF, XLE, XLU, XLP, XLV, XLY, XLI, XLB	Možnost testovat sektorovou rotaci a koncentrovaná rizika
Nemovitosti	VNQ	Expozice na real estate segment
Dluhopisy	SHY, IEF, TLT, TIP, LQD	Defenzivní složka, durace, inflační dluhopisy a kredit
Drahé kovy	GLD, SLV	Alternativní a krizová diverzifikace
Komodity a ropa	DBC, USO	Reálná aktiva, komoditní cykly a volatilní expozice

Tabulka 2 – Aktiva datasetu Macro24

Zdroj: autor

Dataset je pro účely práce vhodný z několika důvodů. Obsahuje aktiva s odlišným rizikovým profilem, takže model má možnost přesouvat váhy mezi růstovou a defenzivní složkou. Obsahuje také aktiva, která se v některých obdobích chovají výrazně odlišně, například technologické akcie, dlouhodobé dluhopisy, zlato nebo ropa. Díky tomu lze testovat, zda model skutečně rozlišuje mezi aktuálně silnějšími a slabšími částmi trhu.

Současně je potřeba zdůraznit, že dataset není univerzálním investičním světem. Neobsahuje například hotovostní instrument, měnově zajištěné fondy, jednotlivé akcie, kryptoměny ani fundamentální data. To je vědomé omezení experimentu. Cílem je otestovat rozhodovací jádro na dostatečně pestrém, ale stále srozumitelném investičním univerzu.

5.2.2 Dataset GlobalCountry18

Dataset GlobalCountry18 obsahuje osmnáct amerických burzovně obchodovaných ETF, která reprezentují akciové trhy jednotlivých zemí. Vedle amerického trhu zastoupeného fondem SPY zahrnuje vyspělé i rozvíjející se trhy z Evropy, Asie, Ameriky, Austrálie a Afriky. Všechny časové řady byly po načtení zarovnány na 5369 společných obchodních dní od 25. 2. 2005 do 1. 7. 2026.

Region	Symbols	Účel v experimentu
Severní Amerika	SPY, EWC, EWW	USA, Kanada a Mexiko
Evropa	EWU, EWG, EWQ, EWL, EWN, EWP, EWI	Vyspělé evropské akciové trhy
Asie	EWJ, EWH, EWS, EWT, EWM	Japonsko, Hongkong, Singapur, Tchaj-wan a Malajsie
Ostatní trhy	EWA, EWZ, EZA	Austrálie, Brazílie a Jižní Afrika

Tabulka 3 – Aktiva datasetu GlobalCountry18

Zdroj: autor

Dataset umožňuje testovat geografickou rotaci bez přímého zastoupení dluhopisů, komodit nebo hotovosti. Jednotlivé fondy se obchodují v amerických dolarech, jejich hodnota však závisí také na měnovém a politickém riziku zastoupených zemí. I profil Low-Risk je proto konzervativní pouze relativně vůči ostatním profilům tohoto čistě akciového univerza.

5.2.3 Dataset USBlueChip18

Dataset USBlueChip18 obsahuje osmnáct jednotlivých akcií velkých amerických společností. Výběr pokrývá technologie, spotřební sektor, zdravotnictví, finance, energetiku, průmysl a utility. Po zarovnání obsahuje 5368 společných obchodních dní od 25. 2. 2005 do 1. 7. 2026. Společný začátek je určen nejkratší dostupnou řadou v univerzu.

Skupina	Symbols	Charakter expozice
Technologie	AAPL, MSFT, NVDA, INTC, CSCO	Růstové a technologické společnosti
Spotřební sektor	AMZN, MCD, WMT, PG, KO	Cyklická i defenzivní spotřeba
Zdravotnictví	JNJ, MRK, UNH	Defenzivnější zdravotnická expozice
Finance, energie, průmysl a utility	JPM, XOM, CVX, CAT, NEE	Cyklické a dividendové společnosti

Tabulka 4 – Aktiva datasetu USBlueChip18

Zdroj: autor

Tento dataset záměrně neobsahuje ETF ani bezrizikovou či dluhopisovou složku. Model zde neprovádí alokaci mezi třídami aktiv, ale výběr a změnu vah jednotlivých akcií. Výsledky proto ověřují jiný typ generalizace než GlobalCountry18: zda stejné rozhodovací jádro dokáže pracovat také s rozdíly v relativní síle konkrétních společností.

5.3 Testovaná portfolia

Experiment používá v každém datasetu stejných osm experimentálních rolí. První tři představují rozumně složené investiční profily s různou mírou rizika: Low-Risk, Medium-Risk a High-Risk. Další čtyři portfolia jsou záměrně problematická. Jejich účelem je ověřit, zda adaptivní model dokáže pomoci v situaci, kdy výchozí baseline obsahuje výrazné strukturální riziko. Poslední portfolio je naivní equal-weight varianta přes všechna aktiva daného datasetu. Názvy rolí, rizikové parametry i omezení obchodování zůstávají mezi běhy stejné, konkrétní aktiva a baseline váhy jsou však přizpůsobeny příslušnému univerzu.

Toto rozdělení je důležité, pouhé testování tří standardních profilů by mohlo ukázat, zda model překonává běžnou baseline, ale neukázalo by, jak se chová v případě špatného návrhu portfolia. Záměrně nevhodná portfolia slouží jako zátěžový test. Pokud model dokáže snížit škody u příliš koncentrovaného nebo nevhodně defenzivního portfolia, může být jeho přínos lépe obhajitelný.

5.3.1 Profily datasetu Macro24

Profil	Typ	Baseline složení	Smysl experimentu
Low-Risk	Dobře složené konzervativní portfolio	SHY 25 %, IEF 20 %, TIP 15 %, TLT 10 %, LQD 10 %, GLD 10 %, XLP 4 %, XLU 3 %, SPY 2 %, DBC 1 %	Ověřit, zda model zbytečně nerozbíjí defenzivní alokaci
Medium-Risk	Dobře složené vyvážené portfolio	SPY 22 %, QQQ 8 %, IWM 5 %, EFA 10 %, EEM 5 %, IEF 12 %, TLT 8 %, SHY 8 %, TIP 6 %, LQD 6 %, GLD 6 %, DBC 2 %, VNQ 2 %	Ověřit přidanou hodnotu u vyváženého profilu
High-Risk	Dobře složené agresivní portfolio	SPY 30 %, QQQ 18 %, IWM 10 %, EFA 10 %, EEM 7 %, XLK 8 %, XLY 5 %, XLE 4 %, GLD 3 %, TLT 3 %, SHY 2 %	Ověřit, zda model zvládá rizikovější akciovou alokaci
Bad-OverTech	Špatně složené koncentrované portfolio	QQQ 35 %, XLK 30 %, XLY 15 %, IWM 10 %, EEM 10 %	Test koncentrace do technologií a růstových aktiv
Bad-CrisisVulnerable	Špatně složené krizově citlivé portfolio	XLK 25 %, VNQ 25 %, EEM 20 %, IWM 15 %, LQD 15 %	Test portfolia citlivého na recesi, likviditu a kredit
Bad-OverSafe	Špatně složené příliš defenzivní portfolio	SHY 45 %, IEF 25 %, TIP 15 %, GLD 10 %, TLT 5 %	Test schopnosti přidat riziko u příliš opatrné baseline
Bad-CommodityTrap	Špatně složené komoditní portfolio	USO 35 %, DBC 25 %, XLE 15 %, GLD 15 %, SLV 10 %	Test volatilní komoditní koncentrace
Naive-EqualWeight	Kontrolní portfolio	Každé z 24 aktiv má přibližně 4,17 %	Ověřit, zda model umí vybírat z univerza bez investičního názoru baseline

Tabulka 5 – Přehled testovaných portfolií datasetu Macro24

Zdroj: autor

U dobře složených portfolií nelze automaticky očekávat výrazné překonání baseline. Pokud je baseline sama o sobě rozumná a diverzifikovaná, adaptivní vrstva má menší prostor pro zlepšení. Naopak u záměrně špatných portfolií existuje větší šance, že model najde přínos tím, že omezí nadměrnou koncentraci nebo přesune část expozice do vhodnějších aktiv.

5.3.2 Profily datasetu GlobalCountry18

U datasetu GlobalCountry18 byly stejné experimentální role převedeny na regionální akciové ETF. Profily Low-Risk, Medium-Risk a High-Risk zde vyjadřují relativní míru rizika uvnitř akciového univerza, nikoli stejnou absolutní rizikovost jako u datasetu Macro24.

Profil	Baseline složení
Low-Risk	EWL 18 %, SPY 18 %, EWJ 12 %, EWU 12 %, EWC 10 %, EWA 8 %, EWG 7 %, EWQ 7 %, EWN 5 %, EWS 3 %
Medium-Risk	SPY 15 %, EWJ 8 %, EWG 7 %, EWU 7 %, EWA 6 %, EWC 6 %, EWL 6 %, EWQ 6 %, EWT 5 %, EWZ 5 %, EWH 4 %, EWI 4 %, EWN 4 %, EWP 4 %, EWW 4 %, EWM 3 %, EWS 3 %, EZA 3 %
High-Risk	EWT 15 %, EWZ 15 %, EZA 12 %, EWW 10 %, EWH 8 %, EWM 8 %, EWI 6 %, EWP 6 %, EWA 5 %, EWC 5 %, EWG 4 %, EWN 3 %, SPY 3 %
Bad-OverTech	EWT 45 %, EWN 25 %, SPY 20 %, EWJ 10 %
Bad-CrisisVulnerable	EWP 25 %, EWI 25 %, EWZ 20 %, EZA 15 %, EWW 15 %
Bad-OverSafe	EWL 45 %, EWJ 25 %, EWU 15 %, EWS 15 %
Bad-CommodityTrap	EZA 30 %, EWZ 25 %, EWC 20 %, EWA 15 %, EWW 10 %
Naive-EqualWeight	Každé z 18 aktiv přibližně 5,56 %

Tabulka 6 – Výchozí složení profilů datasetu GlobalCountry18

Zdroj: autor

Role Bad-OverTech využívá země s vyšší technologickou koncentrací, zatímco Bad-CommodityTrap soustřeďuje váhy do zemí výrazně navázaných na těžbu, energetiku a komoditní cyklus. Jde tedy o funkční analogie původních profilů, nikoli o shodné expozice.

5.3.3 Profily datasetu USBlueChip18

V datasetu USBlueChip18 jsou všechny baseline sestaveny z jednotlivých amerických akcií. Také zde označení Low-Risk znamená pouze defenzivnější složení vůči ostatním akciovým profilům. Nejde o konzervativní portfolio ve smyslu kombinace akcií a dluhopisů.

Profil	Baseline složení
Low-Risk	PG 16 %, JNJ 15 %, KO 14 %, WMT 12 %, MRK 10 %, UNH 10 %, NEE 10 %, MCD 8 %, MSFT 3 %, JPM 2 %
Medium-Risk	MSFT 10 %, AAPL 8 %, JNJ 8 %, PG 8 %, JPM 7 %, CAT 6 %, KO 6 %, MRK 6 %, UNH 6 %, WMT 6 %, AMZN 5 %, CVX 5 %, MCD 5 %, NEE 5 %, XOM 5 %, NVDA 4 %
High-Risk	NVDA 20 %, AAPL 18 %, MSFT 18 %, AMZN 14 %, JPM 8 %, CAT 7 %, UNH 5 %, CVX 4 %, XOM 4 %, CSCO 2 %
Bad-OverTech	NVDA 30 %, AAPL 25 %, MSFT 20 %, CSCO 10 %, INTC 10 %, AMZN 5 %
Bad-CrisisVulnerable	JPM 30 %, CAT 20 %, AMZN 15 %, AAPL 10 %, CVX 10 %, XOM 10 %, INTC 5 %
Bad-OverSafe	PG 25 %, KO 25 %, JNJ 15 %, WMT 15 %, MRK 10 %, NEE 10 %
Bad-CommodityTrap	XOM 40 %, CVX 35 %, CAT 15 %, NEE 10 %
Naive-EqualWeight	Každé z 18 aktiv přibližně 5,56 %

Tabulka 7 – Výchozí složení profilů datasetu USBlueChip18

Zdroj: autor

Protože USBlueChip18 neobsahuje komodity, profil Bad-CommodityTrap zde představuje koncentraci do ropných a cyklických společností.

5.4 Společné parametry experimentu

Všechny profily jsou testovány se stejným základním nastavením běhu. Tím je zajištěno, že rozdíly ve výsledcích nejsou způsobeny odlišnou konfigurací optimalizace, ale rozdílným složením portfolia a rozdílnými profilovými omezeními. Parametry specifické pro profil, například ModelRisk, MddLimitAbs nebo MaxMonthlyTurnover, zůstávají součástí jednotlivých profilů.

Parametr	Hodnota	Význam
Datasey	Macro24; GlobalCountry18; USBBlueChip18	Tři samostatně testovaná investiční univerza
Počet aktiv	24; 18; 18	Počet instrumentů v jednotlivých datasetech
Společné období dat	28. 4. 2006 až 1. 7. 2026; 25. 2. 2005 až 1. 7. 2026; 25. 2. 2005 až 1. 7. 2026	Rozsah po zarovnání všech aktiv v daném datasetu
Počet společných obchodních dní	5071; 5369; 5368	Počet obchodních dní pro Macro24, GlobalCountry18 a USBBlueChip18
Počáteční kapitál	100 000	Startovní hodnota portfolia v každém běhu
Transakční náklad	0,1 %	Náklad z obchodované hodnoty podle turnoveru
OOS roky	2018 až 2025	Osm testovaných ročních období mimo trénovací data
GA populace	250	Počet jedinců genetického algoritmu
GA generace	30	Počet generací genetického algoritmu
GP populace	200	Počet stromů v populaci genetického programování
GP generace	30	Počet generací genetického programování
Adaptive turnover lookback	3 měsíce	Okno pro adaptivní snížení důvěry v model
Měsíční doporučení	zapnuto	Výpis rad GA a GP v OOS období
Samostatné datasetové běhy	3	Jeden kompletní experiment pro každý dataset
Profily v jednom datasetu	8	Tři standardní a pět záměrně problematických profilů
OOS testy profilu a roku	64 na dataset; 192 celkem	8 profilů × 8 OOS roků × 3 datasety
Evoluční optimalizační běhy	384 celkem	192 optimalizací GA a 192 optimalizací GP
Validační konce	2014, 2016, 2018, 2020, 2022, 2024 + aktuální konec tréninku	Použijí se pouze konce dostupné před daným OOS rokem
Robustní fitness	váha nejhoršího okna 0,30; váha rozptylu 0,10	Autorem zvolené návrhové hyperparametry
GA reprezentace a meze	a, b, c: 0 až 1,5; d: 0 až DMax	Čtyři reálné koeficienty parametrického skórovacího modelu
GA selekce a elitismus	turnaj 6; elita 12	Výběr rodičů a přenos nejlepších jedinců
GA operátory	blend crossover 0,85; Gaussova mutace 0,30; $\sigma = 0,08$ rozsahu genu	Křížení a mutace reálných koeficientů
GA vyhodnocení a seed	paralelní; deterministický seed, offset 1000	Reprodukovatelné vyhodnocení robustní fitness
GP reprezentace	strom; operátory +, −, ×, min, max, abs	Funkční množina genetického programování
GP terminály a konstanty	10 tržních ukazatelů; konstanty od -2 do 2; výběr: 90 % ukazatel, 10 % konstanta	Terminální množina a efemérní konstanty

Parametr	Hodnota	Význam
GP inicializace	modifikovaná grow; max. hloubka 4; operátor 0,85	Terminál je povinný na maximální hloubce
GP selekce a elitismus	turnaj 6; elita 10	Výběr rodičů a přenos nejlepších stromů
GP operátory	subtree crossover 0,85; subtree mutation 0,35	Podstromové křížení a podstromová mutace
GP omezení stromu	max. hloubka 5; max. 14 / 18 / 24 uzlů; simplifikace 8 průchodů	Ochrana proti nekontrolovanému růstu stromu
GP parsimony	Low-Risk: $\lambda = 0,0024$ Medium-Risk, Bad-OverSafe a Naive-EqualWeight: $\lambda = 0,0021$ High-Risk, Bad-OverTech, Bad-CrisisVulnerable a Bad-CommodityTrap: $\lambda = 0,0018$	Penalizace velikosti stromu; vyšší λ silněji zvýhodňuje kratší strom.
GP tie-break	Tolerance shodné robustní fitness / min. přínos uzlu: Low-Risk: 0,0015 / 0,00035 Medium-Risk, Bad-OverSafe a Naive-EqualWeight: 0,0012 / 0,00030 High-Risk, Bad-OverTech, Bad-CrisisVulnerable a Bad-CommodityTrap: 0,0010 / 0,00025	Při téměř shodné robustní fitness upřednostní jednodušší strom.
GP behaviorální filtr	6–96 snímků; $\text{std} \geq 10^{-5}$; pořadí ≥ 3 ; remízy $\leq 0,70$; konstantní $\leq 0,50$; ořez $\leq 0,30$; $\lambda = 0,02$	Předběžné odmítnutí degenerovaných stromů
GP seed	deterministický; offset 2000	Seed odvozený z profilu a OOS roku
Sdílené fitness koeficienty	AlphaMdd = 2,0; GammaCosts = 1,0; BetaTurnover dle profilu	Penalizace drawdownu, nákladů a turnoveru
Profilové exekuční parametry	ModelRisk, SoftmaxTemperature, RebalanceBlend, limity koncentrace, odchylky a turnoveru	Mění se podle investičního profilu, nikoli mezi GA a GP

Tabulka 8 – Společné parametry experimentu

Zdroj: autor

Transakční náklad 0,1 % je zjednodušený model nákladů. Neodpovídá konkrétnímu brokerovi ani konkrétnímu instrumentu, ale umožňuje porovnat strategie za jednotných podmínek. Důležité je, že náklad platí pro adaptivní modely i pro měsíční baseline. Strategie s vyšším turnoverm proto musí dosáhnout dostatečné přidané hodnoty, aby náklady obhájila.

5.5 Walk-forward postup experimentu

Experiment používá walk-forward postup. Pro každý profil a každý testovaný rok se nejprve vytvoří trénovací dataset končící 31. 12. předchozího roku. Pokud je například testován rok 2020, trénovací data obsahují pouze období do 31. 12. 2019. Model tedy nemá přístup k cenám z roku 2020, které budou použity pro OOS vyhodnocení.

Uvnitř trénovacích dat jsou vytvořena validační okna. Implementace používá konce let 2014, 2016, 2018, 2020, 2022 a 2024, ovšem pouze ty, které leží uvnitř dostupného trénovacího období. Pokud poslední konec trénovacího období není mezi těmito daty, je přidán také jako další konec validačního okna. Tím se zajistí, že robustní fitness vždy hodnotí kandidátní model na více úsecích trénovací historie.

Pro každý profil a rok proběhne následující postup:

1. oříznou se data pouze do konce předchozího roku,
2. vytvoří se validační okna pro robustní fitness,
3. optimalizuje se parametrický model pomocí GA,
4. optimalizuje se stromový model pomocí GP,
5. v OOS roce se spustí měsíční baseline,
6. v OOS roce se spustí buy-and-hold baseline,
7. v OOS roce se spustí GA model,
8. v OOS roce se spustí GP model,
9. výsledky se uloží do souhrnného reportu a CSV souboru.

Každý OOS rok je tedy nezávislým testem. Model pro rok 2018 není použit pro rok 2019. Pro každý rok se znovu optimalizuje podle dat dostupných do konce předchozího roku. Tento postup je výpočetně náročnější, ale lépe odpovídá praktickému použití, protože model by se v čase pravidelně přeučoval na nově dostupných datech.

5.6 Porovnávání strategie

V každém OOS roce jsou porovnávány čtyři strategie. První strategií je měsíční baseline, která každý měsíc rebalancuje portfolio zpět na výchozí váhy profilu. Druhou strategií je buy-and-hold baseline, která na začátku roku nakoupí výchozí portfolio a dále ho bez rebalancování drží. Třetí strategií je model optimalizovaný genetickým algoritmem. Čtvrtou strategií je model optimalizovaný genetickým programováním.

Měsíční baseline je hlavní praktickou referencí. Představuje jednoduchý poradenský přístup, který udržuje rizikový profil investora. Buy-and-hold baseline slouží jako doplňková diagnostika. V některých obdobích může být výhodnější nic nerebalancovat, zejména pokud rostoucí aktiva přirozeně zvětšují svou váhu. V jiných obdobích může pravidelné rebalancování pomoci udržet riziko pod kontrolou.

GA a GP modely jsou hodnoceny proti stejným referencím. V OOS období nejsou vypínána podle toho, zda jejich trénovací robustní fitness vyšla kladná nebo záporná. Toto rozhodnutí je záměrné. Cílem experimentu je porovnat skutečné chování modelů, nikoli zavádět dodatečnou bránu, která by v horších případech automaticky vrátila výsledek na baseline.

5.7 Hodnocené metriky

Pro každý běh se sleduje konečná hodnota portfolia, celkový turnover, celkové transakční náklady a vítězná strategie daného roku. Konečná hodnota portfolia ukazuje přímý ekonomický výsledek. Turnover a náklady ukazují, jak aktivně strategie obchodovala a kolik ji tato aktivita stála.

Vedle OOS výsledků se ukládají také diagnostiky z trénovací fitness. U GA i GP je k dispozici robustní fitness, průměrná fitness, nejhorší validační okno, penalizace nejhoršího okna, penalizace rozptylu, příspěvek rozdílu Sharpe ratio, příspěvek rozdílu CAGR, penalizace turnoveru, penalizace nadměrného turnoveru, penalizace nákladů a penalizace maximálního drawdownu.

Tyto diagnostiky jsou důležité pro interpretaci. Pokud model v OOS období selže, samotná konečná hodnota portfolia neříká, proč se tak stalo. Rozpad fitness může ukázat, zda model trpěl nízkým výnosem, vysokým rizikem, přílišným turnoverem, vysokými náklady nebo nestabilitou napříč validačními okny.

Souhrnný report dále počítá relativní výkonnost vůči měsíční baseline a buy-and-hold baseline. Díky tomu lze odlišit situace, kdy model vydělal nominálně, ale zaostal za jednoduchým benchmarkem, od situací, kdy skutečně přidal hodnotu. V investičním vyhodnocení je toto rozlišení zásadní, protože samotný zisk nemusí být úspěchem, pokud stejný trh umožnil vyšší zisk jednodušší strategií.

5.8 Měsíční doporučení v experimentu

Součástí běhu je také výpis měsíčních doporučení pro GA a GP model. Pro každý měsíc OOS období se vypisuje rozhodovací datum, akce HOLD nebo REBALANCE, velikost turnoveru, odhad nákladů, hodnota portfolia na konci období, největší váhy a hlavní nákupy nebo prodeje.

Tento výstup není hlavní metrikou experimentu, ale slouží k lepší interpretaci chování modelu. Umožňuje sledovat, zda model mění portfolio postupně, nebo dělá prudké změny. Zároveň ukazuje, zda jsou doporučení ekonomicky srozumitelná. Například u krizově citlivého portfolia lze pozorovat, zda model v rizikových obdobích snižuje expozici na akcie, nemovitostních aktiv nebo kredit a přesouvá váhy do defenzivnějších aktiv.

Měsíční doporučení jsou užitečná i pro kontrolu praktické použitelnosti. Model může mít přijatelný roční výsledek, ale pokud by každý měsíc navrhoval velmi výrazné změny, byl by pro reálného investora hůře použitelný. Proto je vhodné sledovat nejen konečný výsledek, ale i cestu, kterou se k němu strategie dostala.

5.9 Reprodukovatelnost experimentu

Reprodukovatelnost experimentů je zajištěna uchováním vstupních dat, explicitní konfigurací a deterministickým nastavením optimalizačních algoritmů. Všechny tři použité datasety jsou uloženy jako samostatné sady CSV souborů v adresářích RoboAdvisor/Data/Macro24, RoboAdvisor/Data/GlobalCountry18 a RoboAdvisor/Data/USBlueChip18. Výchozí váhy portfolií a parametry jednotlivých investičních profilů jsou definovány přímo ve zdrojovém kódu v souboru InvestorProfiles.cs.

Zdrojový kód je implementován jako konzolová aplikace pro platformu .NET 9. Z kořenového adresáře repozitáře lze jednotlivé experimenty spustit následujícími příkazy:

1. dotnet run --project RoboAdvisor/RoboAdvisor.csproj -- Macro24
2. dotnet run --project RoboAdvisor/RoboAdvisor.csproj -- GlobalCountry18
3. dotnet run --project RoboAdvisor/RoboAdvisor.csproj -- USBlueChip18

Po spuštění aplikace se načtou a časově zarovnají data vybraného datasetu, vytvoří se odpovídající investiční profily a následně proběhne optimalizace pomocí GA a GP spolu s OOS vyhodnocením. Průběh experimentu a dosažené výsledky jsou průběžně vypisovány do konzole.

Hlavní parametry experimentu jsou soustředěny v souboru ExperimentConfig.cs. Lze zde upravit zejména počet generací, velikost populací GA a GP, počáteční kapitál, sazbu transakčních nákladů a testované OOS roky. Soubor Program.cs zpracovává volbu datasetu z argumentu příkazové řádky, omezení běhu na konkrétní investiční profil prostřednictvím vlastnosti OnlyProfile a zapnutí výpisu měsíčních doporučení. Hodnota OnlyProfile = null spustí experiment pro všechny definované profily, zatímco zadáním názvu profilu lze běh omezit na jedinou variantu. Po změně konfigurace nebo parametrů profilů stačí aplikaci znovu spustit jedním z uvedených příkazů.

Optimalizační algoritmy používají deterministické seedy odvozené z názvu investičního profilu, testovaného roku a rozdílného offsetu pro GA a GP. Při použití stejné verze zdrojového kódu, stejné konfigurace a totožných vstupních dat je proto možné zopakovat experiment se stejným průběhem optimalizace.

Každý běh vytváří dva výstupní soubory: detailní CSV soubor určený pro další zpracování a textový souhrn umožňující rychlou interpretaci výsledků. Výstupy použité v této práci jsou rozděleny podle datasetu do adresářů:

1. RoboAdvisor/Results/Macro24
2. RoboAdvisor/Results/GlobalCountry18
3. RoboAdvisor/Results/USBlueChip18

5.10 Omezení experimentálního nastavení

Experimentální nastavení má několik omezení, která je nutné zohlednit při interpretaci výsledků. Prvním omezením je výběr aktiv. Ani jeden ze tří datasetů nepředstavuje úplný investiční svět. Pokud v určitém období neexistuje v daném univerzu vhodné defenzivní aktivum, model nemůže vytvořit takovou ochranu, kterou by mohl mít při širší nabídce instrumentů. Toto omezení je zvláště významné u GlobalCountry18 a USBlueChip18, které jsou čistě akciové.

Druhým omezením je roční struktura OOS testu. Model se pro každý rok optimalizuje znovu a následně se testuje na celém kalendářním roce. V praxi by bylo možné model přeučovat častěji nebo naopak méně často. Roční režim byl zvolen jako kompromis mezi výpočetní náročností a dostatečně realistickým oddělením trénovacích a testovacích dat.

Třetím omezením je transakční nákladový model. Použitý náklad 0,1 % z obchodované hodnoty je jednotný pro všechna aktiva a všechny roky. Ve skutečnosti by se náklady lišily podle instrumentu, likvidity a brokera. Výsledky proto nelze přímo chápat jako přesnou simulaci obchodování u konkrétního poskytovatele, ale jako srovnání strategií za jednotných experimentálních podmínek.

Čtvrtým omezením je absence daní, měnových dopadů a dividendového zacházení nad rámec dostupných cenových dat. Práce se soustředí na návrh a ověření rozhodovací logiky, nikoli na kompletní finanční plánování. Tato omezení budou zohledněna při interpretaci výsledků v závěrečných kapitolách.

Pátým omezením je pouze částečná srovnatelnost stejně pojmenovaných profilů mezi datasety. Jejich role a řídicí parametry jsou shodné, konkrétní aktiva a výchozí váhy se však liší. Například Low-Risk v čistě akciovém univerzu nemá stejnou absolutní rizikovost jako Low-Risk v Macro24 a Bad-CommodityTrap v USBlueChip18 neobsahuje přímo komodity. Srovnání napříč datasety proto slouží jako test přenositelnosti rozhodovacího jádra, nikoli jako kontrolovaný experiment měnící jedinou proměnnou.

Šestým omezením je možné výběrové zkreslení a zkreslení přeživších (survivorship bias) datasetu USBlueChip18. Výběr obsahuje současné velké společnosti s dostatečně dlouhou dostupnou historií a nezahrnuje firmy, které během sledovaného období zanikly, byly vyřazeny z významných indexů nebo dlouhodobě ztratily význam. Zpětný test proto může nadhodnocovat výsledky, kterých by bylo dosaženo při historicky reálném výběru akcií bez znalosti budoucích vítězů.

Sedmým omezením je počet osmi OOS roků na profil a vzájemná závislost testů, protože profily v jednom roce používají stejná tržní data a často i stejná aktiva. Souhrnných 64 testů v datasetu proto nelze chápat jako 64 nezávislých statistických pozorování. Práce hodnotí ekonomickou velikost, medián a četnost zlepšení, neprovádí však formální test statistické významnosti.

Popsané experimentální nastavení vytváří základ pro vyhodnocení v kapitole 6 Vyhodnocení výsledků. Díky stejným OOS rokům, stejným referenčním strategiím a uloženým diagnostikám lze posoudit nejen to, zda adaptivní model vydělal, ale také v jakých typech portfolio, investičních univerzech a za jakou cenu byl jeho přínos dosažen.

6 Vyhodnocení výsledků

Vyhodnocení vychází ze tří kompletních běhů experimentu uložených ve výsledkových souborech uvedených v příloze C. V každém datasetu bylo osm profilů testováno v letech 2018 až 2025, celkem tedy vzniklo 192 samostatných OOS testů profilu a roku. Pro každý OOS rok byly modely GA a GP znovu natrénovány pouze na historických datech dostupných před začátkem testovaného roku a následně byly porovnány s referenčními strategiemi monthly baseline a buy-and-hold. Pro přehlednost jsou prezentované hodnoty zaokrouhleny. Výpočty a interpretace vycházejí z hodnot v plné přesnosti.

Hlavním referenčním bodem je v této části monthly baseline. Důvodem je, že monthly baseline představuje reálný fallback navrženého poradce: portfolio se drží podle předem definovaných vah a pouze se měsíčně rebalancuje zpět k cílové alokaci. Strategie buy-and-hold je ponechána jako doplňková diagnostika, protože ukazuje, jak by se portfolio vyvíjelo bez průběžného rebalancování. Pro posouzení přínosu adaptivního modelu je však důležitější otázka, zda model překoná prakticky použitelnou pasivní správu, nikoli pouze zcela neaktivní držení aktiv.


6.1 Souhrnný pohled na výsledky Macro24

Tabulka 9 shrnuje výsledky osmi samostatných ročních OOS testů datasetu Macro24 za období 2018 až 2025. Každý roční test začínal s počátečním kapitálem 100 000; model byl před daným rokem znovu optimalizován a následně vyhodnocen pouze na tomto roce. Sloupce Monthly baseline, GA a GP uvádějí aritmetický průměr konečných hodnot portfolio dosažených na konci jednotlivých ročních testů. Sloupce relativní výkonnosti uvádějí průměr procentních rozdílů GA a GP vůči monthly baseline vypočítaných samostatně pro každý OOS rok. Nejde tedy o kumulativní výsledek jednoho osmiletého investičního období. Stejně srovnání konečných hodnot vizualizuje obrázek 10.

Profil	Monthly baseline	GA	GP	GA vůči monthly	GP vůči monthly
Low-Risk	102 721	103 615	103 627	+0,86 %	+0,86 %
Medium-Risk	107 718	107 743	107 863	+0,12 %	+0,23 %
High-Risk	114 050	110 653	109 198	-2,37 %	-3,50 %
Bad-OverTech	119 108	111 898	110 520	-4,33 %	-5,30 %
Bad-CrisisVulnerable	106 451	107 885	106 752	+1,63 %	+0,57 %
Bad-OverSafe	101 858	104 283	104 204	+2,33 %	+2,25 %
Bad-CommodityTrap	109 176	109 932	111 667	+2,48 %	+3,91 %
Naive-EqualWeight	109 140	109 008	108 876	-0,04 %	-0,17 %

Tabulka 9 – Souhrn průměrné roční OOS výkonnosti datasetu Macro24

Zdroj: autor



Obrázek 10 – Průměrná konečná hodnota portfolia podle profilu v datasetu Macro24

Zdroj: autor

Výsledky se výrazně liší podle výchozího složení portfolia. Alespoň jedna z adaptivních metod dosáhla kladné průměrné relativní výkonnosti u pěti z osmi profilů. Nejvyšší průměrné zlepšení vykazuje profil Bad-CommodityTrap. GA zde překonalo monthly baseline o 2,48 % a GP o 3,91 %. Výsledek naznačuje, že adaptivní změny vah mohou být přínosné u portfolia výrazně orientovaného na komodity, jejichž výkonnost se může podstatně měnit v závislosti na tržním režimu. Ze samotného průměru však nelze určit, zda bylo zlepšení rovnoměrné, nebo zda bylo soustředěno do několika mimořádně úspěšných roků.

Výrazně pozitivní výsledek dosáhl také profil Bad-OverSafe. GA překonalo monthly baseline o 2,33 % a GP o 2,25 %. Velmi podobný výsledek obou metod ukazuje, že přínos nebyl omezen pouze na jeden způsob optimalizace. Výsledek je v souladu s předpokladem, že adaptivní vrstva může pomoci portfoliu, které je ve výchozím stavu příliš defenzivní a neposkytuje dostatečný prostor pro využití příznivého vývoje rizikovějších aktiv.

U profilu Bad-CrisisVulnerable dosáhlo GA průměrného zlepšení o 1,63 %, zatímco GP pouze o 0,57 %. Obě hodnoty jsou kladné, ale rozdíl mezi metodami ukazuje, že parametrický model GA byl u tohoto typu portfolia úspěšnější než flexibilnější stromový model GP. U profilu Low-Risk dosáhly obě metody shodného zlepšení o 0,86 %. Přestože je toto zlepšení menší než u profilů Bad-CommodityTrap a Bad-OverSafe, vzájemná blízkost výsledků GA a GP naznačuje, že průměrný přínos nebyl závislý pouze na jedné optimalizační metodě.

U profilu Medium-Risk je výsledek pouze mírně pozitivní. GA překonalo monthly baseline o 0,12 % a GP o 0,23 %. Takto malý rozdíl nelze bez dalšího posouzení stability, rizika a turnoveru považovat za jednoznačný praktický přínos. Adaptivní model zde v průměru výsledek zásadně nezhoršil, ale zároveň nevytvořil výraznou výhodu oproti pravidelnému rebalancování.

Naopak u profilů High-Risk a Bad-OverTech bylo adaptivní řízení zřetelně horší než monthly baseline. U High-Risk zaostalo GA v průměru o 2,37 % a GP o 3,50 %. U Bad-OverTech dosáhlo GA relativní výkonnosti -4,33 % a GP -5,30 %. Tyto výsledky ukazují, že aktivní změny vah nepomáhají portfoliím automaticky. U silně růstově nebo technologicky

orientovaných portfolií může model snížit zastoupení úspěšných aktiv příliš brzy a připravit portfolio o část jejich dalšího růstu.

Profil Naive-EqualWeight skončil přibližně na úrovni monthly baseline. GA zaostalo o 0,04 % a GP o 0,17 %, takže rozdíly jsou z praktického hlediska velmi malé. Rovnoměrně rozložené portfolio je již ve výchozím stavu široce diverzifikované a adaptivní model v něm nemá zjevnou strukturální slabinu, kterou by mohl jednoduše napravit.

6.2 Stabilita výsledků Macro24 a turnover

Samotný průměrný výsledek nestačí. Model může dosáhnout dobrého průměru díky jednomu velmi úspěšnému roku, ale v ostatních letech být horší než baseline. Tabulka 10 proto uvádí počet kladných OOS roků a průměrný turnover. Kladný rok znamená, že daný model v konkrétním roce překonal monthly baseline. Turnover vyjadřuje objem provedených změn v portfoliu; čím vyšší je hodnota, tím více model obchodoval.

Profil	GA kladné roky	GP kladné roky	GA turnover	GP turnover	GA / monthly	GP / monthly
Low-Risk	7 / 8	7 / 8	0,17	0,18	1,11x	1,18x
Medium-Risk	3 / 8	4 / 8	0,52	0,45	2,09x	1,82x
High-Risk	2 / 8	2 / 8	0,99	1,32	4,70x	6,29x
Bad-OverTech	2 / 8	2 / 8	1,47	1,95	8,77x	11,63x
Bad-CrisisVulnerable	6 / 8	5 / 8	1,29	1,63	5,33x	6,74x
Bad-OverSafe	7 / 8	7 / 8	0,94	0,88	8,58x	7,99x
Bad-CommodityTrap	6 / 8	6 / 8	1,60	1,96	3,64x	4,46x
Naive-EqualWeight	4 / 8	4 / 8	0,90	0,80	2,70x	2,41x

Tabulka 10 – Stabilita výsledků datasetu Macro24 a průměrný turnover

Zdroj: autor

Pro podrobnější posouzení stability uvádějí tabulky 11 a 12 relativní výkonnost GA a GP vůči monthly baseline v jednotlivých OOS letech. Kladná hodnota znamená, že adaptivní model v daném roce baseline překonal, zatímco záporná hodnota znamená zaostání. Sloupec Průměr odpovídá průměrné relativní výkonnosti uvedené v tabulce 9.

Profil	2018	2019	2020	2021	2022	2023	2024	2025	Průměr
Low-Risk	-1,09 %	+0,61 %	+1,35 %	+2,00 %	+0,77 %	+0,38 %	+1,09 %	+1,73 %	+0,86 %
Medium-Risk	+0,16 %	-0,42 %	-0,16 %	+1,35 %	+2,57 %	-1,29 %	-0,31 %	-0,93 %	+0,12 %
High-Risk	+1,03 %	-3,89 %	-7,83 %	-1,64 %	+7,73 %	-8,57 %	-4,16 %	-1,59 %	-2,37 %
Bad-OverTech	+0,16 %	-7,37 %	-15,19 %	-3,93 %	+16,55 %	-15,38 %	-6,77 %	-2,69 %	-4,33 %
Bad-CrisisVulnerable	+2,82 %	-1,61 %	+0,85 %	+0,38 %	+7,02 %	+0,99 %	-0,63 %	+3,20 %	+1,63 %
Bad-OverSafe	-2,66 %	+3,45 %	+5,02 %	+6,16 %	+0,32 %	+2,15 %	+2,30 %	+1,91 %	+2,33 %
Bad-CommodityTrap	+7,61 %	+1,13 %	+25,84 %	-8,28 %	-15,12 %	+6,97 %	+0,15 %	+1,56 %	+2,48 %
Naive-EqualWeight	+1,59 %	-1,52 %	+1,06 %	-1,89 %	+0,99 %	-1,19 %	-0,65 %	+1,32 %	-0,04 %

Tabulka 11 – Roční relativní výkonnost GA v datasetu Macro24 vůči monthly baseline

Zdroj: autor

Profil	2018	2019	2020	2021	2022	2023	2024	2025	Průměr
Low-Risk	-0,99 %	+0,59 %	+1,89 %	+2,26 %	+0,36 %	+0,43 %	+0,95 %	+1,38 %	+0,86 %
Medium-Risk	+0,16 %	-0,45 %	-0,17 %	+1,18 %	+2,65 %	-1,48 %	-0,32 %	+0,25 %	+0,23 %
High-Risk	+2,41 %	-8,26 %	-12,92 %	-2,27 %	+7,39 %	-8,72 %	-4,30 %	-1,30 %	-3,50 %
Bad-OverTech	+0,37 %	-9,18 %	-19,96 %	-4,56 %	+17,17 %	-16,05 %	-6,99 %	-3,20 %	-5,30 %
Bad-CrisisVulnerable	+3,03 %	-2,57 %	-5,26 %	+0,37 %	+6,29 %	+0,02 %	-0,70 %	+3,35 %	+0,57 %
Bad-OverSafe	-3,07 %	+3,51 %	+5,04 %	+5,91 %	+0,46 %	+1,73 %	+2,14 %	+2,28 %	+2,25 %
Bad-CommodityTrap	+7,36 %	+0,98 %	+25,00 %	-8,78 %	-15,46 %	+6,38 %	+0,93 %	+14,86 %	+3,91 %
Naive-EqualWeight	+1,63 %	-1,52 %	+0,98 %	-1,93 %	+0,45 %	-2,04 %	-0,25 %	+1,34 %	-0,17 %

Tabulka 12 – Roční relativní výkonnost GP v datasetu Macro24 vůči monthly baseline

Zdroj: autor

Low-Risk je z hlediska praktické použitelnosti nejpřesvědčivější profil. Modely překonaly baseline v 7 z 8 let a turnover byl pouze mírně vyšší než u monthly baseline. To znamená, že zlepšení nebylo dosaženo agresivním přeskokováním mezi aktivy, ale spíše menšími adaptivními úpravami vah.

Medium-Risk je podstatně slabší. Průměrná výkonnost je sice mírně kladná, ale GA překonalo baseline jen ve 3 z 8 let a GP ve 4 z 8 let. Takový výsledek je spíše neutrální než silně pozitivní. Model zde občas pomáhá, ale nemá konzistentní převahu.

U High-Risk a Bad-OverTech je důležitá kombinace dvou negativních jevů: modely dosahují záporné relativní výkonnosti a současně mají výrazně vyšší turnover. To je prakticky nejhorší varianta, protože investor podstupuje více změn, platí vyšší transakční náklady, a přesto získává horší výsledek. Z experimentu proto vyplývá, že u agresivních růstových portfolií je adaptivní model potřeba používat velmi opatrně.

U profilů Bad-OverSafe, Bad-CrisisVulnerable a Bad-CommodityTrap je vyšší turnover naopak částečně odůvodněn lepším výsledkem. Přesto jej nelze ignorovat. Například u Bad-OverSafe je turnover přibližně osmkrát vyšší než u monthly baseline. Model zde dokázal zvýšit výnos, ale udělal to za cenu výrazně aktivnější správy. Pro praktické nasazení by proto bylo nutné řešit, zda dodatečný výnos dostatečně kompenzuje vyšší obchodní aktivitu, daňové dopady a horší srozumitelnost doporučení pro investora.

6.3 Vyhodnocení podle typu portfolia

Výsledky datasetu Macro24 dobře ukazují rozdíl mezi portfolii, která jsou pouze konzervativní nebo diverzifikovaná, a portfolii, která jsou strukturálně problematická.

U Low-Risk portfolia lze adaptivní model hodnotit pozitivně. Portfolio je složeno tak, aby bylo defenzivnější, a model do něj přidává omezenou aktivní složku. Výsledkem je malé, ale stabilní zlepšení. Pro tuto práci je tento výsledek podstatný, protože podporuje tvrzení, že adaptivní robo-poradce může přinášet hodnotu i bez toho, aby musel dramaticky měnit chování portfolia.

Medium-Risk představuje hraniční případ. Výsledek je mírně kladný, ale ne dostatečně silný. Model zde není vyloženě škodlivý, ale jeho přínos je malý. V praxi by takové zlepšení muselo být posouzeno proti nákladům, daňovým dopadům a požadavku na vysvětlitelnost. Z pohledu experimentu je ale důležité, že model nepřekonává baseline automaticky jen proto, že má k dispozici více volnosti.

High-Risk portfolio model nezvládlo. Baseline má už sama o sobě vysokou expozici na riziková aktiva, především akcie. Pokud trh v daném období růstová aktiva odměňuje, adaptivní model může svými přesuny riziko naopak snížit ve špatný okamžik. Výsledek ukazuje, že u agresivních portfolií může být nejlepší strategií prosté držení zvolené rizikové expozice. Adaptivní zásah zde nemusí být přidanou hodnotou.

Bad-OverSafe je opačný případ. Portfolio je příliš opatrné, a proto má model prostor zvyšovat rizikovou složku v obdobích, kdy je to podle vstupních indikátorů vhodné. Výsledek GA +2,33 % a GP +2,25 % vůči monthly baseline naznačuje, že adaptivní model umí pomoci portfoliu, které je zbytečně defenzivní. Tento profil je pro práci důležitý, protože ukazuje schopnost robota nejen snižovat riziko, ale také ho v rozumných situacích přidávat.

Bad-CrisisVulnerable ukazuje schopnost reagovat na nevhodnou skladbu v rizikových obdobích. GA zde dosáhlo zlepšení o 1,63 % a překonalo baseline v 6 z 8 let. GP je slabší, ale stále mírně pozitivní. Tento výsledek podporuje myšlenku, že adaptivní model může pomoci u portfolia, které je citlivé na krize a poklesy rizikových aktiv.

Bad-CommodityTrap je nejvýraznější pozitivní případ z hlediska průměrného zlepšení. GP zde dosáhlo +3,91 % a GA +2,48 % vůči monthly baseline. Zároveň jde ale o profil s velkými rozdíly mezi jednotlivými roky. Model dokázal velmi dobře využít některá období, zejména rok 2020, ale v jiných letech byl naopak výrazně slabší. Výsledek proto není možné interpretovat jako stabilní převahu v každém období, ale spíše jako schopnost zachytit určité režimy trhu.

Naive-EqualWeight nepřineslo významné zlepšení. Rovnoměrné rozdělení mezi mnoho aktiv je sice jednoduché, ale samo o sobě poměrně diverzifikované. Model zde neměl zjevnou strukturální chybu, kterou by mohl snadno opravit. Výsledek kolem nuly proto dává smysl: adaptivní model není univerzální nástroj, který automaticky zlepší každou diverzifikovanou alokaci.

6.3.1 Ověření na datasetu GlobalCountry18

Dataset GlobalCountry18 ověřuje, zda se výsledky přenesou z multi-asset univerza na geografickou alokaci mezi akciovými trhy jednotlivých zemí. Tabulka 13 uvádí průměrnou relativní OOS výkonnost vůči monthly baseline, počet kladných roků a průměrný roční turnover obou adaptivních metod.

Profil	GA vůči monthly	Kladné roky GA	GA turnover	GP vůči monthly	Kladné roky GP	GP turnover
Low-Risk	-0,10 %	3 / 8	0,10	-0,14 %	2 / 8	0,08
Medium-Risk	-0,24 %	2 / 8	0,51	-0,21 %	2 / 8	0,41
High-Risk	+0,22 %	3 / 8	0,57	+0,64 %	5 / 8	0,80
Bad-OverTech	-2,76 %	2 / 8	1,33	-2,87 %	2 / 8	1,73
Bad-CrisisVulnerable	+0,35 %	5 / 8	1,07	+0,32 %	5 / 8	1,35
Bad-OverSafe	-0,18 %	5 / 8	1,06	+0,06 %	4 / 8	0,96
Bad-CommodityTrap	+1,21 %	5 / 8	1,17	+1,29 %	5 / 8	1,35
Naive-EqualWeight	-0,28 %	3 / 8	1,07	-0,38 %	4 / 8	0,77

Tabulka 13 – Výsledky profilů datasetu GlobalCountry18

Zdroj: autor

V souhrnu všech 64 kombinací profilu a roku dosáhlo GA průměrné relativní výkonnosti -0,22 % a GP -0,16 %. Mediány byly rovněž mírně záporné, -0,13 % u GA a -0,11 % u GP. GA překonalo monthly baseline ve 28 z 64 případů a GP ve 29 z 64 případů. Monthly baseline byla zároveň nejčastějším absolutním vítězem a dosáhla nejvyšší konečné hodnoty ve 22 z 64 testů; GA zvítězilo v 16 a GP v 15 testech. Na úrovni celého datasetu proto nelze prokázat obecnou výhodu adaptivní geografické rotace.

Nejpříznivěji dopadl profil Bad-CommodityTrap, u něhož GA překonalo monthly baseline v průměru o 1,21 % a GP o 1,29 %, v obou případech v pěti z osmi let. Mírně pozitivní byly také Bad-CrisisVulnerable a High-Risk, zejména GP u High-Risk s průměrem +0,64 % a pěti kladnými roky. Naproti tomu standardní profily Low-Risk a Medium-Risk skončily lehce pod baseline. U Low-Risk přitom oba modely dosáhly nižšího turnoveru než monthly baseline s hodnotou 0,19, takže zde nižší obchodní aktivita nevedla k lepšímu výnosu.

Výsledek Bad-OverSafe ukazuje význam společného hodnocení četnosti a velikosti rozdílů. GA bylo lepší než baseline v pěti z osmi let, přesto jeho průměrná relativní výkonnost činila -0,18 %, protože ztráty v neúspěšných letech převážily častější malá zlepšení. Nejhorším profilem zůstal Bad-OverTech, kde GA zaostalo o 2,76 % a GP o 2,87 % a obě metody překonaly baseline pouze ve dvou letech. Globální country univerzum tedy původní negativní závěr pro technologicky koncentrované portfolio potvrzuje, ale pozitivní výsledky ostatních profilů z Macro24 zobecňuje jen omezeně.

6.3.2 Ověření na datasetu USBlueChip18

Dataset USBlueChip18 testuje stejný rozhodovací mechanismus při přerozdělování vah mezi jednotlivými americkými akcemi. Výsledky v tabulce 14 jsou výrazně příznivější než u předchozích dvou univerz.

Profil	GA vůči monthly	Kladné roky GA	GA turnover	GP vůči monthly	Kladné roky GP	GP turnover
Low-Risk	+0,76 %	5 / 8	0,18	+1,11 %	6 / 8	0,23
Medium-Risk	+0,79 %	5 / 8	0,46	+1,13 %	6 / 8	0,51
High-Risk	-0,78 %	3 / 8	1,75	+1,10 %	6 / 8	2,24
Bad-OverTech	-0,55 %	3 / 8	2,44	+3,13 %	5 / 8	2,96
Bad-CrisisVulnerable	+4,36 %	6 / 8	1,78	+4,85 %	6 / 8	2,71
Bad-OverSafe	+3,16 %	6 / 8	1,01	+4,02 %	6 / 8	1,01
Bad-CommodityTrap	+11,03 %	5 / 8	2,23	+18,38 %	5 / 8	3,29
Naive-EqualWeight	+1,35 %	4 / 8	0,97	+1,73 %	6 / 8	0,97

Tabulka 14 – Výsledky profilů datasetu USBBlueChip18

Zdroj: autor

Napříč 64 testy dosáhlo GA průměrné relativní výkonnosti +2,51 % a GP +4,43 %. Kladný výsledek není dán pouze několika extrémy: medián jednotlivých OOS rozdílů činil +0,86 % u GA a +2,70 % u GP. GA překonalo monthly baseline v 37 z 64 případů, zatímco GP ve 46 z 64 případů. GP bylo také nejčastějším absolutním vítězem s 31 vítězstvími; monthly baseline zvítězila devětkrát, buy-and-hold třináctkrát a GA jedenáctkrát.

GP dosáhlo kladné průměrné relativní výkonnosti u všech osmi profilů a u standardních profilů Low-Risk, Medium-Risk i High-Risk překonalo baseline vždy v šesti z osmi let. Výsledek Bad-OverTech se liší od Macro24 i GlobalCountry18: GP zde dosáhlo +3,13 % a pěti kladných roků, zatímco GA zůstalo mírně záporné. V univerzu jednotlivých akcií tak flexibilnější stromový model dokázal měnit relativní váhy technologických společností úspěšněji než parametrický model GA.

Nejvyšší průměr vykazuje Bad-CommodityTrap, kde GA dosáhlo +11,03 % a GP +18,38 %. Tento výsledek je však současně nejméně stabilní. GP v roce 2023 překonalo monthly baseline o 86,88 %, zatímco v roce 2022 zaostalo o 30,66 %; kladných bylo pouze pět z osmi let. Vysoký průměr proto nelze interpretovat jako rovnoměrný každoroční nadvýnos. Profil má navíc nejvyšší průměrný turnover, 2,23 u GA a 3,29 u GP. Přínos modelu zde vzniká za cenu výrazně aktivnější správy a vysoké citlivosti na tržní režim.

U Low-Risk a Medium-Risk jsou výsledky praktičtější. Obě metody mají mírnější relativní zlepšení, ale nižší turnover. U Low-Risk je turnover GA i GP dokonce nižší než turnover monthly baseline 0,36 a u Medium-Risk se hodnoty adaptivních metod pohybují blízko monthly baseline 0,50. Výsledek USBBlueChip18 tedy není omezen pouze na záměrně špatná portfolia, přesto jeho velikost i stabilita zůstávají silně závislé na konkrétním profilu.

6.3.3 Srovnání napříč datasety

Souhrn v tabulce 15 porovnává všechny tři datasety stejným způsobem. Průměry jsou počítány přes 64 kombinací profilu a OOS roku v každém investičním univerzu.

Dataset	GA vůči monthly	Kladné testy GA	GA turnover	GP vůči monthly	Kladné testy GP	GP turnover
Macro24	+0,09 %	37 / 64	0,98	-0,14 %	37 / 64	1,15
GlobalCountry18	-0,22 %	28 / 64	0,86	-0,16 %	29 / 64	0,93
USBBlueChip18	+2,51 %	37 / 64	1,35	+4,43 %	46 / 64	1,74

Tabulka 15 – Souhrn výsledků napříč investičními univerzy


Zdroj: autor

Porovnání ukazuje, že přínos adaptivního modelu není přenositelný automaticky. V Macro24 a GlobalCountry18 se celková průměrná relativní výkonnost pohybuje blízko nuly, zatímco v USBBlueChip18 je zřetelně kladná, zejména u GP. Současně ve všech třech datasetech platí, že GP má vyšší průměrný turnover než GA. Vyšší flexibilita stromového modelu tedy přináší větší prostor pro zlepšení, ale také aktivnější správu.

Ze 192 testů dosáhlo nejvyšší konečné hodnoty GP v 63 případech, GA ve 44, buy-and-hold ve 43 a monthly baseline ve 42 případech. Ani tento počet však nepředstavuje důkaz univerzální převahy GP: téměř polovinu jeho vítězství tvoří USBBlueChip18 a některé průměry jsou ovlivněny mimořádně úspěšnými roky. Výsledky spíše naznačují, že evoluční výběr vah má větší potenciál v univerzu s výraznými rozdíly mezi jednotlivými akciemi než při rotaci mezi zeměmi nebo při správě již diverzifikovaného multi-asset portfolio. Protože se mezi datasety mění také konkrétní baseline portfolio, jde o interpretaci pozorovaného vzorce, nikoli o kauzální důkaz.

6.4 Případové grafy


Pro ilustraci chování modelů byly vybrány dva konkrétní OOS průběhy. Obrázek 11 ukazuje úspěšný případ u profilu Bad-CommodityTrap v roce 2020. V tomto období dokázaly oba adaptivní modely zakončit rok výrazně nad monthly baseline i buy-and-hold. Graf je zajímavý také tím, že průběh roku nebyl hladký: portfolio nejprve výrazně pokleslo, ale modely se následně dokázaly zotavit a zachytit příznivější vývoj.



Obrázek 11 – Ukázka úspěšného OOS průběhu adaptivního modelu

Zdroj: autor

Obrázek 12 ukazuje neúspěšný případ u profilu Bad-OverTech v roce 2020. U technologicky koncentrovaného portfolia byla rozhodující růstová expozice. Adaptivní modely sice reagovaly na průběžné změny trhu, ale konečný výsledek byl horší než referenční strategie. Tento příklad dobře vysvětluje, proč profil Bad-OverTech dopadl v souhrnu negativně: model mohl být z pohledu rizika opatrnější, ale opatrnost v daném tržním režimu znamenala ztrátu části výnosu.



Obrázek 12 – Ukázka neúspěšného OOS průběhu adaptivního modelu

Zdroj: autor

Obrázky 11 a 12 společně ukazují hlavní vlastnost navrženého přístupu. Model se skutečně chová adaptivně a v některých situacích dokáže výrazně zlepšit výsledek. Zároveň však tato adaptivita není zárukou lepší výkonnosti. Pokud tržní prostředí odměňuje setrvání v původní rizikové expozici, může aktivní přeskupování portfolia výsledek zhoršit.

6.5 Porovnání GA a GP

Genetický algoritmus a genetické programování se v experimentech nechovaly totožně. GA optimalizuje parametry pevně daného skórovacího modelu, zatímco GP hledá samotný tvar výrazu. GP proto má větší volnost, ale zároveň vyšší riziko, že nalezený výraz bude fungovat jen v části tržních režimů.

Konkrétní podobu vytvořených modelů lze ukázat na běhu Macro24 pro profil Bad-CommodityTrap a OOS rok 2020, který je současně zachycen na Obrázku 11. Modely byly optimalizovány pouze na datech dostupných do 31. 12. 2019 a jejich přesný zápis je uložen v detailním výsledkovém souboru v příloze C. Nejlepší jedinec GA v tomto běhu představoval následující parametrický model:

$$score_i = 0,0836 \cdot Ret60_i + 0,3556 \cdot Ret120_i + 0,0000 \cdot PriceVsSma50_i - 1,4087 \cdot Vol20_i$$

Model tedy přikládal větší kladnou váhu stodvacetidennímu než šedesátidennímu výnosu, trendový ukazatel PriceVsSma50 v daném běhu nepoužíval a výrazně penalizoval dvacetidenní volatilitu. Nulový koeficient trendového ukazatele nebyl nastaven předem, ale vznikl evoluční optimalizací parametrů.

Genetické programování pro stejný profil, trénovací období a OOS rok vytvořilo tento stromový výraz, zde ponechaný nejprve v přesném zápisu generovaném aplikací:

$$(((Ret20 - (VolRatio20_{60} - -1.7506)) - abs((Ret60 + Ret60)))) \\ * max(Vol60, abs((Ret20 + (Ret20 + Ret60))))$$

Dvojitě minus v tomto strojovém zápisu vzniká odečtením záporné konstanty a nejde o chybu výstupu. Po algebraickém zjednodušení lze stejný model zapsat čitelněji:

$$score_i = (Ret20_i - VolRatio20_{60i} - 1,7506 - |2 \cdot Ret60_i|) \\ \cdot max(Vol60_i, |2 \cdot Ret20_i + Ret60_i|)$$

Na rozdíl od GA jde o nelineární model, který násobí dvě části výrazu a používá absolutní hodnotu i funkci maxima. Absolutní úroveň výsledného skóre sama o sobě neurčuje váhu aktiva; rozhodující jsou rozdíly mezi skóre jednotlivých aktiv a jejich následný převod pomocí softmax. Oba modely v tomto běhu používaly ModelRisk 0,75, softmax teplotu 0,70 a RebalanceBlend 0,60, takže uvedené výrazy představují skórovací jádro, nikoli samostatnou kompletní strategii bez profilových a exekučních omezení.

GP dosáhlo na trénovacích validačních oknech vyšší robustní fitness 0,6515 oproti 0,6102 u GA, ale v neviděném roce 2020 skončilo mírně hůře. Měsíční baseline zakončila rok na 75 322, GA na 94 784 a GP na 94 155. Relativně vůči měsíční baseline tak GA dosáhlo +25,84 % a GP +25,00 %. GP mělo současně vyšší OOS turnover 2,31 oproti 1,85 u GA. Tento konkrétní běh ukazuje, že vyšší tréninková fitness a složitější tvar GP nemusí automaticky znamenat lepší OOS výsledek.

V některých profilech GP dosáhlo lepšího průměrného výsledku. Nejvýraznější je to v Macro24 u Bad-CommodityTrap, kde GP překonalo monthly baseline o 3,91 %, zatímco GA o 2,48 %. Naopak u Bad-CrisisVulnerable bylo lepší GA, které dosáhlo +1,63 %, zatímco GP pouze +0,57 %. V GlobalCountry18 jsou celkové výsledky metod téměř shodné a mírně záporné: GA -0,22 % a GP -0,16 %. Tento dataset proto neposkytuje přesvědčivý argument pro převahu jedné metody.

Největší rozdíl mezi metodami vznikl v USBBlueChip18. GP zde dosáhlo průměrné relativní výkonnosti +4,43 % oproti +2,51 % u GA, překonalo monthly baseline ve 46 z 64 testů a bylo absolutním vítězem v 31 případech. GP bylo lepší zejména u profilů High-Risk a Bad-OverTech, kde GA zůstalo v průměru záporné. Výsledek naznačuje, že možnost hledat nelineární tvar skórovacího výrazu může být užitečná při výběru mezi jednotlivými akcemi s výrazně odlišnou dynamikou.

Z hlediska turnoveru je GP ve všech třech datasetech v průměru agresivnější. V Macro24 dosáhl jeho průměrný turnover 1,15 oproti 0,98 u GA, v GlobalCountry18 0,93 oproti 0,86 a v USBBlueChip18 1,74 oproti 1,35. To odpovídá větší flexibilitě genetického programování: model může najít výraz, který je na trénovacích datech silnější, ale v testovacím období vede k aktivnějším a někdy méně stabilním změnám.

Výsledky proto neukazují univerzálního vítěze mezi GA a GP. Genetické programování je zajímavé tam, kde může objevit nelineární vztah mezi indikátory, který pevný model GA neumí zachytit, a v USBBlueChip18 tuto výhodu skutečně využilo. Jeho náskok však není přenesen do GlobalCountry18 a část vysokých průměrů vznikla v několika extrémních letech. Genetický algoritmus je naopak lépe kontrolovatelný, protože optimalizuje pouze parametry známé struktury a obvykle vytváří nižší turnover. Pro praktický systém by dávalo smysl používat obě metody jako dvě různé varianty rozhodovacího jádra a jejich výsledky posuzovat podle investičního univerza, profilu investora a stability v OOS testech.

6.6 Konkrétní příklad investičního rozhodování modelu

Konkrétní způsob rozhodování robo-poradce lze ukázat na modelu GA pro dataset Macro24, profil Bad-CommodityTrap a OOS rok 2020. Výchozí portfolio tohoto profilu bylo záměrně silně koncentrováno do komoditních a energetických aktiv. Obsahovalo USO s váhou 35 %, DBC s váhou 25 %, XLE a GLD po 15 % a SLV s váhou 10 %. Model byl optimalizován pouze na datech dostupných do konce roku 2019 a následně rozhodoval v měsíčních krocích bez znalosti dalšího vývoje roku 2020.

Zvolenou strategii lze charakterizovat jako kombinaci výnosového momenta a výrazné penalizace krátkodobé volatility. Model zvýhodňoval aktiva s příznivým šedesátidenním a stodvacetidenním výnosem a snižoval skóre aktiv s vysokou dvacetidenní volatilitou. Nešlo tedy o jednoduché pravidlo typu nakoupit konkrétní aktivum po propadu. Robot každý měsíc porovnal relativní skóre všech aktiv, převedl je na cílové váhy a výsledné portfolio smíchal s výchozími vahami profilu. Jeho rozhodnutí proto představovala postupnou rotaci portfolia, nikoli jednorázovou sázku na jeden tržní scénář.

Při prvním rozhodnutí pro leden 2020, založeném na datech k 31. 12. 2019, model výrazně omezil původní komoditní koncentraci. Váhu USO snížil z 35 % na 24,3 %, DBC z 25 % na 17,9 %, XLE z 15 % na 11,1 % a GLD z 15 % na 11,3 %. Váha SLV se snížila z 10 % na 7,9 %. Celková váha původních pěti aktiv tak klesla ze 100 % na 72,5 % a zbývajících 27,5 % model rozdělil mezi ostatní aktiva datasetu. Tento první krok měl turnover 0,55 a představoval maximální změnu povolenou profilem.

V průběhu ledna a února model v omezování komoditní expozice pokračoval. Pro únor snížil váhu USO na 15,3 %, DBC na 12,5 % a XLE na 8,0 %. Pro březen následovalo další snížení na 12,3 % u USO, 10,7 % u DBC a 6,4 % u XLE. Toto rozhodnutí odpovídalo vstupním ukazatelům modelu. K 28. 2. 2020 vykazovalo USO šedesátidenní výnos přibližně -19,0 %, stodvacetidenní výnos -19,7 % a dvacetidenní anualizovanou volatilitu přibližně 34,0 %. U XLE byly oba výnosy rovněž přibližně -20 % a volatilita dosahovala 35,5 %. Naproti tomu krátkodobý dluhopisový fond SHY měl oba výnosové ukazatele kladné a jeho volatilita činila pouze přibližně 1,6 %. Model proto přiřazoval energetickým aktivům podstatně horší skóre než stabilnějším částem investičního univerza.

Po prudkém březnovém poklesu model pro duben vytvořil smíšenější portfolio. Mezi jeho největší pozice patřily DBC s váhou 12,0 %, USO s 10,5 %, GLD s 10,4 %, SHY s 8,2 % a IEF s 6,4 %. Při tomto rebalancování zvýšil váhu SHY o 3,2 procentního bodu a IEF o 1,7 procentního bodu. Současně částečně přikoupil USO, jehož skutečná váha se po mimořádném cenovém propadu dostala výrazně pod novou cílovou hodnotu. Tento nákup proto nelze interpretovat jako čisté pravidlo přikupování po propadu. Šlo o kombinaci návratu k omezené cílové váze, vlivu výchozího portfolia a současného posílení defenzivních pozic.

Přínos zvolené strategie se projevil především během první části roku 2020. Na konci března měla strategie GA hodnotu 72 910, zatímco monthly baseline pouze 57 695. Na konci dubna činila hodnota modelového portfolia 73 935 oproti 52 204 u baseline. Rozhodující náskok tedy vznikl v období prudkého propadu komoditních a energetických aktiv, kdy model již nebyl plně koncentrován v původním portfoliu.

V následujících měsících se rozdíl částečně měnil, ale model si většinu získané výhody udržel. Rok zakončil na hodnotě 94 784, zatímco monthly baseline skončila na 75 322 a buy-and-hold baseline na 77 867. GA tak překonalo monthly baseline o 25,84 %.

Příklad ukazuje, že robot v tomto případě nepředpověděl pandemii ani další vývoj cen ropy. Pomohlo mu pravidlo, které již před největším propadem omezilo koncentraci do volatilních komoditních aktiv a při zhoršování jejich momenta pokračovalo v přesunu části portfolia do stabilnějších pozic. Výsledek rovněž nelze připsat jedinému obchodu. Vznikl posloupností měsíčních rozhodnutí, kombinací modelového skóre s výchozím profilem a dodržováním omezení velikosti jednotlivých změn.

6.7 Hlavní závěr experimentu

Tři experimenty potvrzují, že navržený adaptivní robo-poradce není univerzální nástroj pro překonání baseline v každém portfoliu a investičním univerzu. V Macro24 se jeho přínos objevil hlavně tam, kde mělo výchozí portfolio zřetelnou strukturální slabinu, například bylo příliš defenzivní, krizově citlivé nebo silně závislé na komoditním cyklu. U High-Risk a Bad-OverTech naopak adaptivní zásahy vedly k horším výsledkům.

GlobalCountry18 původní pozitivní závěr zobecnilo pouze částečně. Bad-CommodityTrap a některé rizikovější profily dosáhly kladných výsledků, ale celkový průměr i medián obou metod zůstaly mírně záporné a nejčastěji vítězila monthly baseline. Samotné rozšíření výběru o akciové trhy různých zemí tedy nestačilo k vytvoření stabilní výhody geografické rotace.

USBlueChip18 naopak ukázalo výrazný potenciál adaptivního výběru mezi jednotlivými akciami. GA bylo v průměru o 2,51 % a GP o 4,43 % nad monthly baseline, přičemž GP překonalo baseline ve 46 z 64 OOS testů. Ani zde však nelze výsledek chápat jako automatický nadvýnos. Nejvyšší zlepšení byla spojena s vysokým turnoverem a v některých profilech s velkým rozpětím mezi úspěšnými a neúspěšnými roky.

Hlavním závěrem proto není převaha jedné evoluční metody nebo jednoho typu profilu, ale silná závislost výsledku na dostupném investičním univerzu. Evoluční algoritmy mohou být pro robo-advisory použitelné jako řízená adaptivní vrstva, zejména pokud mají k dispozici aktiva s dostatečně rozdílným vývojem. Praktické použití však vyžaduje samostatnou OOS validaci pro konkrétní univerzum, sledování četnosti úspěchu vedle průměrného výnosu, kontrolu turnoveru a možnost zůstat u baseline, pokud adaptivní model neprokazuje stabilní přínos.

ZÁVĚR

Tato diplomová práce se zabývala návrhem, implementací a experimentálním ověřením adaptivního investičního robo-poradce. Cílem bylo ověřit, zda lze pomocí historických tržních dat, investičních profilů a evolučních algoritmů vytvořit model, který dokáže v měsíčních krocích upravovat složení portfolia a v některých případech překonat jednoduché referenční strategie. Práce se nezaměřovala na vytvoření produkční investiční služby, ale na ověření rozhodovacího jádra a na posouzení, zda adaptivní přístup může mít v oblasti robo-advisory praktický smysl.

V teoretické části byly popsány základní principy investičního poradenství, tvorby portfolia, rebalancování, měření výkonnosti a řízení rizika. Součástí byl také popis existujících robo-advisory platform a vymezení rozdílu mezi běžnou statickou robo-advisory službou a navrženým experimentálním řešením. Dále byly vysvětleny evoluční algoritmy, zejména genetický algoritmus, genetické programování a princip silně typovaného genetického programování.

Praktická část práce popsala implementovaný prototyp robo-poradce. Systém pracuje s výchozím baseline portfoliem, nad kterým vytváří adaptivní vrstvu. Tato vrstva pomocí tržních ukazatelů vypočítává skóre jednotlivých aktiv, převádí skóre na modelové váhy a následně je míchá s výchozí alokací investora. Genetický algoritmus optimalizuje parametry pevně daného skórovacího modelu, zatímco genetické programování hledá přímo strukturu rozhodovacího výrazu. Součástí návrhu jsou také limity koncentrace, omezení měsíční změny portfolia, transakční náklady, robustní fitness a walk-forward testování.

Experimentální ověření bylo provedeno na třech investičních univerzech. Macro24 kombinuje akciové indexy, sektory, dluhopisy, komodity, drahé kovy a realitní expozici; GlobalCountry18 obsahuje akciové ETF jednotlivých zemí a USBlueChip18 jednotlivé akcie velkých amerických společností. V každém datasetu bylo testováno osm profilů a osm OOS roků 2018 až 2025, celkem tedy 192 samostatných testů profilu a roku.

Výsledky ukázaly, že adaptivní model není univerzálně lepší než baseline. V Macro24 byl nejstabilnější pozitivní výsledek dosažen u konzervativního profilu Low-Risk, kde GA i GP překonaly měsíční baseline v sedmi z osmi let. Přínos se objevil také u profilů Bad-OverSafe, Bad-CrisisVulnerable a Bad-CommodityTrap. Naopak High-Risk a Bad-OverTech ukázaly, že model může opustit výnosnou expozici příliš brzy a zaostat za jednodušší referenční strategií.

GlobalCountry18 tento pozitivní obraz nepotvrdilo plošně. Průměrná relativní výkonnost GA činila $-0,22\%$ a GP $-0,16\%$ a nejčastějším vítězem zůstala monthly baseline. Výrazně odlišný výsledek přineslo USBlueChip18, kde GA dosáhlo průměrného zlepšení $+2,51\%$ a GP $+4,43\%$. GP zde překonalo monthly baseline ve 46 z 64 testů. Nejvyšší zlepšení však byla spojena s vyšším turnoverm a velkými rozdíly mezi roky, takže ani tento výsledek nelze interpretovat jako stabilní nadvýnos bez dalšího ověření. Závěr je navíc omezen možným zkreslením přeživších v seznamu amerických akcií.

Za hlavní přínos práce lze považovat návrh a ověření kompletní experimentální pipeline, která propojuje investiční profily, historická data, evoluční optimalizaci, měsíční simulaci portfolia a vyhodnocení vůči referenčním strategiím. Práce zároveň ukazuje, že evoluční algoritmy mohou být pro adaptivní robo-advisory použitelné, pokud nejsou chápány jako samostatný

nástroj pro maximalizaci výnosu, ale jako řízená adaptivní vrstva nad výchozím portfoliem. Pro další rozvoj by bylo vhodné otestovat více časových období a nezávislých sad aktiv, doplnit realističtější model nákladů, daní a dividend a dále zkoumat, kdy má být adaptivní zásah silnější a kdy je vhodnější držet se blíže baseline. Důležitým směrem je také validační brána, která by adaptivní model použila pouze tehdy, pokud v předchozích OOS oknech prokazuje dostatečně stabilní přínos.

POUŽITÁ LITERATURA

- [1] U.S. SECURITIES AND EXCHANGE COMMISSION. *Investor Bulletin: Robo-Advisers*. Online. Investor.gov, 23. února 2017. Dostupné z: <https://www.investor.gov/introduction-investing/general-resources/news-alerts/alerts-bulletins/investor-bulletins-45>. [cit. 2026-07-04].
- [2] INTERNATIONAL ORGANIZATION OF SECURITIES COMMISSIONS. *IOSCO Research Report on Financial Technologies (Fintech)*. Online. Madrid: IOSCO, 2017. Dostupné z: <https://www.iosco.org/library/pubdocs/pdf/IOSCOPD554.pdf>. [cit. 2026-07-04].
- [3] FINANCIAL INDUSTRY REGULATORY AUTHORITY. *Report on Digital Investment Advice*. Online. Washington, D.C.: FINRA, 2016. Dostupné z: <https://www.finra.org/sites/default/files/digital-investment-advice-report.pdf>. [cit. 2026-07-04].
- [4] BOURGERON, Thibault, Edmond LEZMI a Thierry RONCALLI. *Robust Asset Allocation for Robo-Advisors*. Online, preprint. arXiv, 20. února 2019. Dostupné z: <https://doi.org/10.48550/arXiv.1902.07449>. [cit. 2026-07-04].
- [5] BETTERMENT. *Automated Investing*. Online. [2026]. Dostupné z: <https://www.betterment.com/investing>. [cit. 2026-07-04].
- [6] WEALTHFRONT. *Automated Investing Account*. Online. [2026]. Dostupné z: <https://www.wealthfront.com/investing>. [cit. 2026-07-04].
- [7] CHARLES SCHWAB. *Schwab Intelligent Portfolios*. Online. [2026]. Dostupné z: <https://www.schwab.com/intelligent-portfolios>. [cit. 2026-07-04].
- [8] VANGUARD. *Robo-Advisor - Automated Investing Services*. Online. [2026]. Dostupné z: <https://investor.vanguard.com/advice/robo-advisor>. [cit. 2026-07-04].
- [9] WOOD RETAIL INVESTMENTS. *Portu - Lepší místo pro peníze*. Online. Portu, © 2026. Dostupné z: <https://www.portu.cz/>. [cit. 2026-07-04].
- [10] DIRECT FONDEE. *Investování, kterému rozumíte*. Online. © 2026. Dostupné z: <https://www.fondee.cz/>. [cit. 2026-07-04].
- [11] CAPPONI, Agostino, Sveinn OLAFSSON a Thaleia ZARIPHOPLOU. *Personalized Robo-Advising: Enhancing Investment through Client Interaction*. Online, preprint, verze 2. arXiv, 24. listopadu 2020. Dostupné z: <https://arxiv.org/abs/1911.01391v2>. [cit. 2026-07-04].
- [12] MARKOWITZ, Harry M. Portfolio Selection. Online. *The Journal of Finance*. 1952, vol. 7, no. 1, s. 77–91. Dostupné z: <https://doi.org/10.2307/2975974>. [cit. 2026-07-04].
- [13] PEROLD, André F. a William F. SHARPE. Dynamic Strategies for Asset Allocation. Online. *Financial Analysts Journal*. 1988, vol. 44, no. 1, s. 16–27. Dostupné z: <https://doi.org/10.2469/faj.v44.n1.16>. [cit. 2026-07-04].
- [14] CFA INSTITUTE. *GIPS Standards for Firms*. Online. CFA Institute, 2020. Dostupné z: <https://www.gipsstandards.org/standards/gips-standards-for-firms/>. [cit. 2026-07-04].

- [15] SHARPE, William F. The Sharpe Ratio. Online. *The Journal of Portfolio Management*. 1994, vol. 21, no. 1, s. 49–58. Dostupné z: <https://doi.org/10.3905/jpm.1994.409501>. [cit. 2026-07-04].
- [16] LO, Andrew W. The Statistics of Sharpe Ratios. Online. *Financial Analysts Journal*. 2002, vol. 58, no. 4, s. 36–52. Dostupné z: <https://doi.org/10.2469/faj.v58.n4.2453>. [cit. 2026-07-04].
- [17] MAGDON-ISMAIL, Malik, Amir F. ATIYA, Amrit PRATAP a Yaser S. ABU-MOSTAFA. On the Maximum Drawdown of a Brownian Motion. Online. *Journal of Applied Probability*. 2004, vol. 41, no. 1, s. 147–161. Dostupné z: <https://doi.org/10.1239/jap/1077134674>. [cit. 2026-07-04].
- [18] HAUTSCH, Nikolaus a Stefan VOIGT. *Large-Scale Portfolio Allocation Under Transaction Costs and Model Uncertainty*. Online, preprint. arXiv, 19. září 2017. Dostupné z: <https://arxiv.org/abs/1709.06296>. [cit. 2026-07-04].
- [19] HYNEK, Josef. *Genetické algoritmy a genetické programování*. 1. vyd. Praha: Grada, 2008. Průvodce. ISBN 978-80-247-2695-3.
- [20] MONTANA, David J. Strongly Typed Genetic Programming. Online. *Evolutionary Computation*. 1995, vol. 3, no. 2, s. 199–230. Dostupné z: <https://doi.org/10.1162/evco.1995.3.2.199>. [cit. 2026-07-06].
- [21] MOUSAVI, Somayeh, Akbar ESFAHANIPOUR a Mohammad Hossein FAZEL ZARANDI. A novel approach to dynamic portfolio trading system using multitree genetic programming. Online. *Knowledge-Based Systems*. 2014, vol. 66, s. 68–81. Dostupné z: <https://doi.org/10.1016/j.knosys.2014.04.018>. [cit. 2026-07-28].
- [22] KURUC, Igor. *Optimalizace portfolia cenných papírů pomocí genetického algoritmu*. Online. Brno, 2020. Bakalářská práce. Vysoké učení technické v Brně, Fakulta podnikatelská, Ústav ekonomiky. Vedoucí práce Zuzana Chvátalová. Dostupné z: <http://hdl.handle.net/11012/195339>. [cit. 2026-07-28].
- [23] STOOQ. *Stooq*. Online. [2026]. Dostupné z: <https://stooq.com/>. [cit. 2026-07-08].

SEZNAM PŘÍLOH

Příloha A: Zdrojový kód implementovaného prototypu

Příloha B: Datasets použité v experimentech

Příloha C: Automaticky generované výsledkové soubory experimentů

PŘÍLOHA A: Zdrojový kód implementovaného prototypu

Příloha obsahuje zdrojový kód implementovaného prototypu adaptivního robo-poradce. Součástí jsou zejména třídy pro načítání a zarovnání tržních dat, definice investičních profilů, implementace backtestu, fitness funkce, genetického algoritmu, genetického programování a experimentálního běhu.

PŘÍLOHA B: Datasets použité v experimentech

Příloha obsahuje datové sady Macro24, GlobalCountry18 a USBlueChip18. Datasets jsou tvořeny CSV soubory s historickými denními cenami. Macro24 reprezentuje více tříd aktiv, GlobalCountry18 akciové trhy jednotlivých zemí a USBlueChip18 jednotlivé akcie velkých amerických společností. Data byla získána ze služby Stooq.

PŘÍLOHA C: Automaticky generované výsledkové soubory experimentů

Příloha obsahuje výsledkové soubory všech tří experimentů, které aplikace generuje po dokončení běhu. Pro každý dataset se ukládá detailní CSV soubor s výsledky jednotlivých OOS testů a textový souhrn výsledků podle profilů. Tyto soubory slouží k následné kontrole a tvorbě tabulek použitých ve vyhodnocení.