



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV MANAGEMENTU

INSTITUTE OF MANAGEMENT

INVESTIČNÍ MODELY V PROSTŘEDÍ FINANČNÍCH TRHŮ

THE INVESTMENT MODELS IN AN ENVIRONMENT OF FINANCIAL MARKETS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Jan Krňávek

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jan Budík, Ph.D.

BRNO 2017

Zadání diplomové práce

Ústav:	Ústav managementu
Student:	Bc. Jan Krňávek
Studijní program:	Ekonomika a management
Studijní obor:	Řízení a ekonomika podniku
Vedoucí práce:	Ing. Jan Budík, Ph.D.
Akademický rok:	2016/17

Ředitel ústavu Vám v souladu se zákonem č. 111/1998 Sb., o vysokých školách ve znění pozdějších předpisů a se Studijním a zkušebním řádem VUT v Brně zadává diplomovou práci s názvem:

Investiční modely v prostředí finančních trhů

Charakteristika problematiky úkolu:

Úvod
Cíle práce, metody a postupy
Teoretická východiska práce
Analýza problému
Vlastní návrhy řešení
Závěr
Seznam použité literatury

Cíle, kterých má být dosaženo:

Navržení investičního modelu dle pravidel technické analýzy, jeho testování na historických datech a optimalizace vybraných parametrů s cílem maximalizace zisku a stability.

Základní literární prameny:

DOSTÁL, P. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě. Brno: CERM, 2008. 432 s. ISBN 978-80-7204-605-8.

GOLDBERG, D. Genetic Algorithms in Search, Optimization, and Machine Learning. USA: Addison-Wesley, 1989. 412 p. ISBN 978-0201157673.

GRAHAM, B. Inteligentní investor. Praha: Grada, 2007. 504 s. ISBN 978-80-247-1792-0.

REJNUŠ, O. Finanční trhy. Ostrava: KEY Publishing, 2008. 548 s. ISBN:978-80-87-8.

WILLIAMS, L. Long-Term Secrets to Short-Term Trading. USA: Wiley-Interscience, 1999. 255 p. ISBN 0-471-29722-4.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2016/17

V Brně dne 28.2.2017

L. S.

doc. Ing. Robert Zich, Ph.D.
ředitel

doc. Ing. et Ing. Stanislav Škapa, Ph.D.
děkan

Abstrakt:

Diplomová práce se zabývá optimalizací vybraného investičního portfolia. Řešitel navrhne automatizovaný investiční model, který bude využívat pokročilých algoritmů na bázi umělé inteligence a principů technické analýzy. Optimalizace parametrů a ověření výkonnost investičního modelu je realizováno na historických datech. Výsledkem diplomové práce je optimalizovaný investiční model s důrazem na maximalizaci zisku a stability. Diplomová práce je realizována v prostředí programovacího jazyka Python a volně dostupných analytických knihoven.

Klíčová slova:

optimalizace portfolia, investiční model, technická analýza, umělá inteligence, strojové učení, Python

Abstrakt - anglicky:

The thesis deals with the optimization of the selected investment portfolio. Solver suggests automated investment model that will use advanced algorithms based on artificial intelligence and principles of technical analysis. Optimization of parameters and verifying the performance of the investment model is realized on historical market data. The result of this thesis is optimized investment model with an emphasis on maximizing profits and stability. The thesis is realized in an environment Python programming language and freely available analytical libraries.

Klíčová slova - anglicky:

portfolio optimization, investment model, technical analysis, artificial intelligence, machine learning, Python

Bibliografická citace

KRŇÁVEK, J. *Investiční modely v prostředí finančních trhů*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2017. 122 s. Vedoucí diplomové práce Ing. Jan Budík, Ph.D..

Čestné prohlášení

Prohlašuji, že předložená diplomová práce je původní a zpracoval jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná, že jsem ve své práci neporušil autorská práva (ve smyslu Zákona č. 121/2000 Sb., o právu autorském a o souvisejících s právem autorským).

V Brně dne 20. března 2017

.....

Bc. Jan Krňávek

Poděkování

Rád bych poděkoval Ing. Janu Budíkovi, Ph.D. za odborné vedení a podmětné připomínky při vedení mé diplomové práce.

Obsah

ÚVOD.....	11
1. CÍLE PRÁCE, METODY A POSTUPY.....	13
2. TEORETICKÉ VÝCHODISKO PRÁCE.....	15
2.1. Finanční trhy.....	15
2.2. Technická analýza.....	18
2.2.1. Princip technické analýzy.....	20
2.2.2. Trendy.....	21
2.2.3. Podpora a rezistence.....	22
2.2.4. Časové rámce.....	23
2.2.5. Cenové rozpětí.....	24
2.2.6. Cenový tick.....	24
2.2.7. Volume.....	25
2.2.8. Technické indikátory.....	26
2.2.9. Moving Average indikátor (MA).....	27
2.2.10. Vzorec pro jednoduchý klouzavý průměr (SMA).....	28
2.2.11. Vzorec pro exponenciální klouzavý průměr (EMA).....	28
2.2.12. Relative Strength index Indikátor (RSI).....	30
2.2.13. Vzorec pro výpočet Relative Strength Index indikátoru (RSI).....	31
2.2.14. Moving Average Convergence Divergence indikátor (MACD).....	32
2.2.15. Vzorec pro výpočet Moving Average Convergence Divergence indikátoru (MACD), signální křivky a sloupcového histogramu:.....	34
2.2.16. Stochastic Oscillator indikátor (SO).....	35
2.2.17. Vzorec pro výpočet Stochastic Oscillator indikátoru (SA).....	35
2.2.18. Bollinger Band indikátor (BB).....	37
2.2.19. Vzorec pro výpočet Bollinger Band indikátoru (BB).....	37
2.2.20. On-Balance Volume indikátor (OBV).....	38
2.2.21. Vzorec pro výpočet On-balance Volume indikátoru (OBV).....	39
2.3. Strojové učení.....	42
2.3.1. Algoritmy strojového učení.....	43

2.3.2. Optimalizace hyperparametrů modelů.....	46
2.3.3. Příprava dat.....	47
3. ANALÝZA SOUČASNÉHO STAVU.....	50
4. NÁVRH VLASTNÍHO ŘEŠENÍ.....	54
4.1. Použité technologie.....	56
4.1.1. Hardware.....	56
4.1.2. Python.....	56
4.1.3. Pandas.....	57
4.1.4. Numpy.....	57
4.1.5. Scipy.....	58
4.1.6. Scikit-learn.....	58
4.1.7. Tpot.....	58
4.1.8. PostgreSQL.....	61
4.2. Implementace indikátorů a ukazatelů v jazyku Python.....	62
4.2.1. Jednoduchý klouzavý průměr (SMA) a exponenciální klouzavý průměr (EMA).....	62
4.2.2. Relative Strength index z exponenciálního klouzavého průměru (RSI EMA).....	64
4.2.3. Sortino ratio.....	65
4.2.4. Volatilita.....	65
4.2.5. Maximal Drawdown.....	66
4.2.6. Sharpe ratio.....	66
4.3. Investiční modely TECH a ML.....	67
4.3.1. Obchodní strategie Larry Connors RSI 2.....	67
4.3.2. Obchodní strategie AOS.....	69
4.3.3. Investiční model TECH.....	70
4.3.4. Investiční model ML.....	71
4.3.5. Selektování portfolia.....	72
Smyčka selektování portfolia na denní bázi (kroky):.....	72
4.3.6. Komponenty AOS.....	74
4.3.7. Spuštění a konfigurace systému AOS.....	76

4.3.8. Historická burzovní data.....	79
4.4. Optimalizace investičních modelů.....	82
4.4.1. Metoda dopředné optimalizace a testování.....	82
4.4.2. Genetické algoritmy.....	83
4.4.3. Optimalizace investičního modelu TECH.....	83
4.4.4. Optimalizace investičního modelu ML.....	89
4.5. Vyhodnocení výkonnosti investičních modelů.....	91
4.5.1. Metodika metody backtesting.....	91
4.5.2. Investiční model TECH selektuje portfolio z S&P 100 v období 2005 - 2016	93
4.5.3. Investiční model TECH selektuje portfolio z S&P 100 v období krize 2007 – 2011.....	95
4.5.4. Investiční model TECH selektuje portfolio z S&P 500 v období 2005 – 2016.....	98
4.5.5. Investiční model TECH selektuje portfolio z S&P 500 v období krize 2007 – 2011.....	100
4.5.6. Investiční model ML selektuje portfolio z S&P 100 v období 2005 – 2016	103
4.5.7. Investiční model ML selektuje portfolio z S&P 100 v období krize 2007 – 2011.....	105
4.5.8. Investiční model ML selektuje portfolio z S&P 500 v období 2005 – 2016	107
4.5.9. Investiční model ML selektuje portfolio z S&P 500 v období krize 2007 – 2011.....	109
4.5.10. Vyhodnocení.....	111
ZÁVĚR.....	114
SEZNAM POUŽITÉ LITERATURY.....	116
SEZNAM TABULEK.....	119
SEZNAM OBRÁZKŮ.....	120
SEZNAM GRAFŮ.....	123
DODATEK A – CD ROM.....	124

ÚVOD

Možnost participace na finančních trzích se z pohledu drobného investora v posledních deseti letech dramaticky změnila.

Rozvoj a dostupnost internetu a výpočetní techniky umožnil vznik mnoha on line zprostředkovatelům - makléřům, kteří za přijatelné poplatky umožňují přístup na finanční trhy miliónům individuálních obchodníků a malým podnikům. (1)

Drobný obchodník, investor (*trader*) tak může z pohodlí domova nebo kanceláře při relativně malém investičním rozpočtu smysluplně obchodovat s různými cennými papíry a deriváty na všech významných světových burzách. (3)

Ještě v raných 90tých letech bylo obchodování na burze doménou institucionálních investorů jako jsou banky, hedgeové a penzijní fondy, fondy kvalifikovaných investorů nebo individuální movití obchodníci. Samotné uzavírání kontraktů, neboli obchodování na základě nabídky a poptávky ostatních účastníků trhu, probíhalo tak, že investor přes svého placeného prostředníka - brokera umísťoval obchodní příkazy na burzu a očekával jejich úspěšné plnění, tedy nákup nebo prodej zájmového investičního instrumentu. (5)

Broker musel být registrován u konkrétní burzy a musel mít licenci pro uzavírání kontraktů pro třetí osoby. Broker také musel být fyzicky přítomen v obchodních prostorách burzy na tzv. prodejním místě - patře, kde byl v telefonickém kontaktu se zákazníkem a prováděl jeho jménem obchodní příkazy. Broker zákazníkovi zajišťoval informační a poradní servis, informoval jej o stavu prováděných transakcích, nestandardních situacích a stavu trhu. (7)

Tento zákaznický servis si samozřejmě nechal zaplatit formou fixních a procentních provizí z ceny transakce, takže i malé obchody stály zákazníka na poplatcích minimálně vyšší desítky až stovky dolarů. Pokud si zákazník chtěl vytvořit vlastní investiční portfolio s několika desítkami titulů a toto portfólio pravidelně optimalizovat, musel do něj investovat minimální částku ve stovkách tisících dolarů, která byla schopna absorbovat vysoké poplatky a umožnila tak dosahovat čistého zisku.

Dalším kritériem určujícím minimální požadavky na kapitál investora byl minimální objem investičního instrumentu obchodované v rámci jedné transakce, tzv. lotu. Velikost lotu byla stanovována burzou nebo jiným státním úřadem, a například pro akcie byl nejmenší obchodovatelný objem od 100 akcií na transakci. (3)

V dnešní době je situace díky on line brokerům naprosto jiná. Například u běžného nízko nákladového brokera si může zájemce přes internet založit testovací obchodní účet, stáhnout zdarma softwarovou obchodní platformu a vyzkoušet obchodování nanečisto. V obchodní platformě má přístup na významnější burzy světa, k dispozici nabídku tisíců investičních instrumentů včetně realtime cen a základních sad nástrojů technické analýzy. Přes obchodní platformu lze testovat výkonnost vlastních obchodních strategií na historických datech a samozřejmě realizovat obchodní příkazy k nákupu či prodeji investičních instrumentů.

Příkladem nízko nákladového brokera je Interactive Brokers, který je jeden z nejznámějších internetových brokerů se sídlem v USA Chicago, nabízí svým zákazníkům demo účet, nezpožděná tržní cenová data, zdarma obchodní on line platformu Trade Workstation a nízké poplatky za uzavřený kontrakt. Pro skutečné obchodování broker vyžaduje vložit na účet minimální částku 10 000 dolarů, ze které jsou hrazeny jak samotné obchody tak i transakční poplatky, které k únoru 2017 byly jeden dolar za obchod. Broker také zdarma na svůj účet zajišťuje službu transparentního rozdělení lotu mezi více zákazníků, takže lze nakupovat akcie i po jedné. (7)

1. CÍLE PRÁCE, METODY A POSTUPY

Cílem diplomové práce je návrh a realizace investičních modelů, které s využitím principů technické analýzy a algoritmů strojového učení budou predikovat vývoj akciového trhu a generovat investiční doporučení. Výsledkem bude optimalizované akciové portfolio vybrané (selektované) z titulů zastoupených v akciovém indexu S&P 500, respektive S&P 100.

V první kapitole se seznámíme s teoretickými předpoklady a důležitými pojmy, které využijeme při návrhu a tvorbě investičních modelů. Projdeme si základní pojmy a principy technické analýzy včetně oblíbených technických indikátorů, ukazatelů míry rizika a stability investičních instrumentů. Seznámíme se ze základy strojového učení, kde si představíme vhodné klasifikační algoritmy pro finanční a ekonomické úlohy. Zhodnotíme jejich výkonost, chybovost a přesnost. Také si demonstrováme ukázkový postup využití vybraných algoritmů pro predikci trendu trhu na základě časových burzovních řad.

V praktické části práce provedeme syntézu výše uvedených teoretických předpokladů, ze kterých vyjdeme při návrhu vlastního řešení. Pomocí programovacího jazyka Python, analytických a statistických knihoven Pandas, Numpy, Scipy a knihovny strojového učení Scikit-learn vytvoříme dva investiční modely TECH a ML, které budou sledovat různé strategie. Vstupem obou investičních modelů je seznam akciových titulů v indexu S&P 100 nebo S&P 500, formule pro výpočet technických indikátorů a aktuální burzovní cenová data. Výstupem je pak sada signálů pro nákup konkrétních akciových titulů. První model je založen na sadě technických indikátorů, podpůrných statistických výpočtů a *long hold* investiční strategii RSI 2. Druhý investiční model vychází s prvního, ke kterému navíc přidává prediktivní složku vycházející z algoritmů strojového učení naučených na historických burzovních datech. Oba modely projdou procesem optimalizace konfiguračních parametrů, hyperparametrů a časových oken. Optimalizace pomocí softwarových smyček prohledá stavový prostor všech možností a na základě nejlepších hodnot metrik výnosnosti a

stability vybere nejlepší nastavení algoritmů a technických identifikátorů. Dalším krokem je aplikace metody backtesting, která spočívá v provedení simulovaného obchodování na denní bázi. Znamená to, že Automatický obchodní systém (AOS) projde historická burzovní data den po dni, kdy realizuje fiktivní nákupy či prodeje jednotlivých akciových titulů a výsledky transakcí průběžně zapisuje do logu. Vlastně tak vytváří a optimalizuje akciové portfolio.

Výsledné portfolio porovnáme s benchmarkem, který je představován fiktivní investicí do investičního instrumentu, které kopíruje známý akciový index S&P 500, respektive S&P 100, které jsou ve finančních odborných kruzích uznávány a používány jako akciový benchmark. Zajímavé bude sledovat výkonost obou modelů v krizových letech 2007 až 2011, kdy akciové trhy zažily propady v desítkách procent.

V závěrečné kapitole bude zhodnocena úspěšnost obou modelů a přínos diplomové práce.

2. TEORETICKÉ VÝCHODISKO PRÁCE

Každá diplomová práce musí být vystavena na řádném teoretickém základu. V této části se seznámíme s problematikou finančních trhů, technické analýzy a strojového učení.

2.1. Finanční trhy

Nejprve si musíme definovat, co je to finanční systém.

Finanční systém je soubor trhů, institucí, zákonů, regulací a technik, s jejichž pomocí jsou obchodovány akcie, obligace a jiné cenné papíry. Finanční systém tak zajišťuje soustředování dočasně volných peněžních prostředků a jejich následnou alokaci procesem přeměny úspor v investice. Finanční systém plní svou funkci prostřednictvím finančního trhu.(1)

Finanční trh je systém institucí a instrumentů, zabezpečující pohyb peněz a kapitálu ve všech jeho formách mezi různými ekonomickými subjekty na základě poptávky a nabídky. (1)

Finanční trh je širokým pojmem popisujícím jakýkoli trh, kde se kupující a prodejci účastní obchodu s aktivy, jako jsou akcie, dluhopisy, měny a deriváty. Finanční trhy jsou typicky definovány transparentním stanovením cen, základními obchodními pravidly, náklady a poplatky a tržními silami určujícími ceny obchodovaných cenných aktiv.(3)

Finanční trhy se nacházejí téměř v zemi na světě. Některé jsou velmi malé a jen s málo účastníky, naopak například burza New York Stock Exchange (NYSE) a forexové trhy obchodují s biliony dolarů denně.(3)

V České republice se obchodování na finančních trzích v různé formě objevuje už od roku 1861 a v současné době je spojováno s nejvýznamnější burzou v zemi - Burzou cenných papírů Praha a. s. (BCPP), která byla založena v Praze v roce 1991 a provozuje hlavní trh s akciemi. Burzovní index spravovaný pražskou burzou má název PX a zahrnuje nejlikvidnější akcie obchodované na pražském trhu a k 1.1.2017 zahrnoval 13 akcií. (2)

Klasifikace finančních trhů

- **Akciový trh** - je finanční trh, který umožňuje investorům nakupovat a prodávat akcie veřejně obchodovaných společností. Na primárním akciovém trhu se poprvé nabízí nová emise akcií. Jakékoliv následné obchodování s cennými papíry se uskutečňuje na sekundárním trhu. Akciový trh obsahuje primární i sekundární trh. (3)
- **Trh „Over-The-Counter“ (OTC)** - je příkladem sekundárního trhu. OTC trh zajišťuje výměnu veřejných akcií, které nejsou kótovány na burze v New Yorku nebo na americké burze cenných papírů. Společnosti, jejichž akcie jsou obchodovány na OTC trhu, jsou obvykle menší organizace, neboť tento finanční trh je méně regulovaný. (3)
- **Trh dluhopisů** - dluhopis je investiční instrument, kdy investor půjčuje peníze dlužníkovi na určitou dobu s předem stanovenou úrokovou sazbou. Dluhopisy jsou vydávány nejen společnostmi, ale mohou být také emitovány municipalitami nebo vládou. (6)
- **Peněžní trh** - je součástí finančního trhu, který obchoduje s vysoce likvidními a krátkodobými aktivy. Záměrem peněžního trhu je krátkodobé půjčování a nákup cenných papírů se splatností obvykle méně než jeden rok. Trh krátkodobých úvěrů je ovládán zejména bankami a jinými finančními institucemi, které podléhají licenci, ale nalezneme zde i jiné podnikatelské subjekty (například podnikatelé poskytující si zboží vzájemně na faktury). Patří zde i krátkodobé vklady u bank, směnky, depozitní certifikáty či pokladniční poukázky. (1)
- **Trh s deriváty** - je finanční trh, který obchoduje s cennými papíry, které odvozují svou hodnotu od svého podkladového aktiva. Hodnota derivátů je určena tržní cenou podkladové aktiva. Tento finanční trh obchoduje s deriváty včetně forwardových kontraktů, futures, opcí, swapů a smluv o rozdílu. (1)
- **Forexový (měnový) trh** - je mezibankovní trh, na kterém jsou obchodovány měny formou valut nebo deviz. Tento finanční trh je nejlikvidnějším trhem na

světě, protože hotovost je nejvíce likvidní aktivum. Mezibankovní trh je finanční systém, kde se obchoduje s měnou mezi bankami. (3)

- **Trh drahých kovů** – má doplňkové postavení a za nejdůležitější trh drahých kovů je považován trh zlata, dále již méně významný trh stříbra, platiny nebo paladia. Ve všech případech se jedná o komoditní trhy. (3)

Oba investiční modely TECH a ML jsou určeny obchodování na akciovém trhu, kde budou v rámci metody backtesting provádět simulované transakce za účelem vytváření portfolia a jeho následné optimalizace v dlouhodobém investičním horizontu.

2.2. Technická analýza

Technická analýza je soubor grafických a matematických metod určený pro predikci cenového vývoje investičního instrumentu na základě historických a současných cenových pohybů na finančním trhu.(10)

Základem technické analýzy je ohodnocení zkoumaného cenného papíru na základě tržních informací jako je cena nebo objem obchodů. Výsledky technické analýzy mohou být použity jako podklady pro investiční rozhodnutí.(6)

Metody technické analýzy dělíme do dvou hlavních skupin dle způsobu interpretace cenových dat (11):

- **Grafické metody** – výsledkem jsou grafy, ve kterých uživatelé hledají vzory a formace s daným významem. Grafy jsou základním kamenem vizuální analýzy.
- **Technické indikátory** – představují vypočítané hodnoty na základě tematických vzorců a doporučených způsobů interpretace výsledku.



Obrázek 1: Svíčkový graf indexu S&P 500

(Zdroj: StockCharts.com)

Na obrázku 1 je zobrazen analytický svíčkový graf zachycující cenový vývoj pro Index S&P 500 v časovém rozmezí 1.1.2015 až 31.12.2016, graf je doplněn o dva technické indikátory, klouzavý průměr SMA 50 (červená čára) a klouzavý průměr SMA 200 (modrá čára).

Díky moderní výpočetní technice je zcela běžné využívání obou metod současně, takže na do zobrazovaného grafu jsou online doplňovány hodnoty technických indikátorů. (*overlapping*)

V diplomové práci nebudeme popisovat a využívat grafickou metodou, protože není vhodná pro strojové zpracování a tím pádem i pro řešení naší hlavní úlohy.

První stopy o využití technické analýzy můžeme vystopovat do Japonska 18ho století, kdy tehdejší obchodníci s komoditami využívaly jednoduché svíčkové grafy pro určení budoucích cenových trendů. Svíčkové grafy patří v současné době mezi nejvíce oblíbené grafické metody. (19)

Na přelomu 19ho a 20ho století se objevuje Dowova teorie, což je práce pana Charlese Dowa - soubor spisů, matematických vzorečků a pozorování trhů, který dnešní obchodníci považují za základ současné technické analýzy. (10)

Díky rozvoji výpočetních prostředků je moderní technická analýza široce používána pro odhad začátku a konce cenového trendu nebo změny trendu samotného u zkoumaného finančního aktiva. Technickou analýzu můžeme uplatnit na akcie, komodity, indexy, futures a další obchodovatelné instrumenty, bez znalosti fundamentálního základu a pouze na základě historického cenového vývoje a aktuálního stavu trhu. (11)

Výsledkem technické analýzy není přesná budoucí cena, ale informace o předpokládaném cenovém pohybu s určitou mírou jistoty. Je na obchodníkovi, aby na základě svých zkušeností tuto informaci posoudil a zapracoval do obchodního plánu. Je zcela běžné, že dva obchodníci, vycházející ze stejných výsledků technické analýzy, budou mít zcela opačný názor na budoucí vývoj trhu. (10)

2.2.1. Princip technické analýzy

Technická analýza využívá data z finančních trhů, zajímají ji historické a současné cenové pohyby a ukazatel Volatility. Fundamentální informace o zkoumaném aktivu nebere v potaz a například zpráva o neúrodě v důsledku špatného počasí není zohledňována při predikci cenového vývoje pšenice. (10) Cena aktiva jednoduše odpovídá nejvyšší hodnotě, kterou je ochoten zaplatit jakýkoliv účastník trhu.

Uživatelé technické analýzy věří ve tři předpoklady:

- **Trh obsahuje všechny cenotvorné informace** - cena aktiva je výsledek nabídky a poptávky jednotlivých účastníků trhu po investičních instrumentech, kteří do potencionálních kontraktů vstupují pod vlivem širokých ekonomických faktorů, fundamentálních informací, psychologickou náladou trhu a dalšími faktory. Dle zastánců technické analýzy je plně dostatečné analyzovat cenový pohyb, protože všechny důležité informace jsou již v ceně obsaženy. Tento bod je často terčem kritiky odpůrců technické analýzy, protože ti na základě Teorie efektivních trhů fundamentální faktory v analýze postrádají. (9)
- **Ceny se pohybují v trendech** – uživatelé technické analýzy věří, že i přes krátkodobé cenové fluktuace se vytvářejí takzvané cenové trendy a předpokládá se, že když se cena aktiva do trendu dostane, má tendenci v něm určitou dobu setrvat. Cena aktiva může následovat trend vzestupný nebo sestupný, případně jít do takzvané do boku. Při určitých matematicky vyjádřitelných podmínkách lze určit tzv. průraz, kdy se trend z velkou pravděpodobností otočí. Této skutečnosti obchodníci využívají při vytváření obchodních plánů. (9)
- **Historie se opakuje** - na základě dlouhodobého pozorování až 100letých grafů bylo zjištěno, že vývoj finančních trhů má tendenci se opakovat. V grafech na různých časových škálách jsou často nalézány stejné grafické vzory, což tento předpoklad do jisté míry potvrzuje. Zastánci technické analýzy si to vysvětlují tak, že lidé při stejných tržních událostech mají tendenci se chovat podobně jako v minulosti. Úkolem technické analýzy je pak tyto formace včas odhalit a využít například pro generování vstupních a výstupních tržních signálů. (9)

2.2.2. Trendy

Trend v pojetí technické analýzy představuje převládající směr, ve kterém se pohybuje cena investičního instrumentu nebo celého trhu. Pro obchodníka je výhodné obchodovat v souladu s trendem a nejt proti němu a proto je zásadní určit jak silný trend je, zda je začínající, končící nebo má tendenci k obratu. (10)

Trendy rozlišujeme dle směru na (19):

- **vzestupné** - aktuální vrchy a dna jsou vyšší než předcházející vrchy a dna,
- **sestupné** – aktuální vrchy a dna jsou nižší než předcházející vrchy a dna,
- **do strany** - trend pojmenovaný do strany nebo „bez trendu“ se vyznačuje tím, že nelze určit jasný trend, vrchy a dna jsou rozloženy náhodně.



Obrázek 2: Ukázka trendu vzestupného, sestupného a do boku
(Zdroj: vlastní zpracování)

Trendy můžeme klasifikovat i podle délky trvání (19):

- **dlouhodobé** - sem spadají trendy na škále od mnoha let až po 3 měsíce,
- **střednědobé** - zde řadíme trendy o délce 1 až 3 měsíce,
- **krátké** – trendy trvající maximálně 1 měsíc.

Dlouhé trendy bývají složeny z několika střednědobých trendů, které jsou charakteristické opozičním směrem, tzv. korekcemi a často tvoří lokální minima a

maxima neboli „zuby“. Krátké trendy nejrychleji reagují na aktuální tržní situaci a jsou předmětem zájmu intradenních a swingových obchodníků.

2.2.3. Podpora a rezistence

Koncept podpory a rezistence je uživateli technické analýzy přirovnáván k souboji nabídky a poptávky neboli nákupních a prodejních příkazech obchodníků. O úrovni rezistence mluvíme v případě, kdy cena instrumentu není schopna překonat určitou cenovou úroveň a u podpory kdy cena není schopna klesnout pod nižší cenovou úroveň. Je téměř jisté, že na jakémkoliv časovém rámci je přítomna alespoň jedna cenová úroveň, ale spíše obě. (19)


Vznik podpory a rezistence úzce souvisí s psychologií trhu, pro úroveň podpory platí, že je na trhu dostatek obchodníků, kteří jsou za tuto cenu ochotni nakupovat a při rezistenci prodávat. Svoji roli také hrají tzv. „magická pěkná“ čísla 10, 25, 50, 100, 1000 [3] a další..., pokud se cena číslům přiblíží, obchodníci mají sklon k větší aktivitě a více nakupují nebo prodávají. (8)

V případě průlomu podpory nebo rezistence trh začne hledat nový rovnovážný stav a nastane tzv. prohození role (*switching*) - proražení cenové hladiny, z rezistence je podpora a z podpory rezistence. (10)

Z pohledu technické analýzy je zajímavé zjištění, že pokud cena aktiva několikrát otestuje úroveň podpory a rezistence tak v takto cenově vymezeném rozpětí setrvá i blízké budoucnosti. Úrovně podpory a rezistence díky aktivitě obchodníků představují oblasti zvýšené Volatility a s tím je třeba při obchodním rozhodnutí počítat. Například plánovat vstup do pozice (*order entry*) a umístit *stop-loss order* je vhodné až pod úroveň rezistence, tzn. mimo oblast zvýšené Volatility. (8)

Stop-loss order je obchodní příkaz, kterým obchodník limituje riziko obchodování. Příkaz stop-loss order obchodník umísťuje pro určitou cenovou úroveň a pokud cena investičního aktiva během obchodní seance klesne na tuto úroveň, tak se obchodní pozice automaticky uzavře. (5)

Prohození úrovní - z rezistence na podporu



Obrázek 3: Prohození cenových úrovní z rezistence na podporu

(Zdroj: vlastní zpracování)

Obrázek 3 zachycuje situaci prohození cenových úrovní, trend v bodech 1 a 2 stanovuje úroveň rezistence, následně ji proráží a ta se mění v úroveň nové podpory, bod 3 a 4.

Teorie efektivních trhů

Je teorie, která se pokouší popsat chování kurzů akcií. Předpokládá se, že kurzy akcií jsou ovlivněny pouze informacemi o očekávaných ziscích a dividend. Tržní cena pak představuje hodnotu, která akcie správně oceňuje. Na trhu pak nelze najít podhodnocené nebo nadhodnocené akcie. (19)

2.2.4. Časové rámce

Koncept časového rámce¹ v technické analýze chápeme jako časový interval, pro který počítáme z cenových dat aktiva vybraný technický indikátor nebo provádíme vizuální analýzu na grafu o vhodné šířce, tzn. větší než je šířka rámce. Například při výpočtu jednoduchého klouzavého průměru SMA 100 zvolíme pro vizualizaci roční graf, protože vzorec pro SMA 100 počítá z 100 po sobě jdoucích denních cenových dat a výslednou křivku uvidíme nejlépe na ročním grafu. (8)

1 V praktické části diplomové práce ve strategii AOS použijeme dvě základní velikosti časových rámců - *short* a *long* o velikosti 200 a 5 časových jednotek.



Obrázek 4: Čárový graf akcie firmy Apple s aplikací indikátoru SMA 100

(Zdroj: StockCharts.com)

Na obrázku číslo 4. je zobrazen čárový graf zachycující cenový vývoj pro akcii AAPL (Apple, Inc.) v časovém rozmezí 1.1.2016 až 31.12.2016., graf je doplněn o ukazatel SMA 100 (modrá linka).

2.2.5. Cenové rozpětí

Cenové rozpětí (*price range*) odpovídá rozsahu vymezeném nejvyšší a nejnižší ceně aktiva za určitý časový rámec, například za 5 sekund, 60 minut, den, měsíc nebo rok. Cenové rozpětí můžeme interpretovat jako Volatilitu, tzn. čím větší Volatilita tím větší cenové rozpětí. Dále platí, že při zvětšování časového rámce se zvětšuje i cenové rozpětí, tzn. cenové rozpětí na denním rámci bude menší než rozpětí na měsíčním rámci. (11)

2.2.6. Cenový tick

Pojem cenový tick nebo jen tick je měřítkem minimální změny ceny za určité období nebo mezi dvěma po sobě jdoucími obchodními kontrakty (akciiovými obchody). Například pokud je obchodován akciiový kontrakt za cenu 500 a následující kontrakt za cenu 502, tak hovoříme o vzestupném ticku o velikosti 2 dolarů. (6)

2.2.7. Volume

Indikátor volume představuje množství uzavřených kontraktů během určité časové doby, nejčastěji během jednoho dne. Hodnota volume je součástí burzovních dat a mimo cenu aktiva je to druhý nejčastější vstup pro technickou analýzu. Volume můžeme v daném kontextu interpretovat jako potvrzení trendu nebo jeho blížící se změnu. Například pokud při změně trendu pozorujeme nadprůměrné volume, lze otočení trendu více důvěřovat než pokud je volume průměrné nebo podprůměrné. U vzestupném nebo sestupného trendu nadprůměrný volume indikuje jeho pravděpodobnější zesilování a pokračování a při podprůměrném volume jeho budoucí oslabení.(8)

Z pohledu psychologie trhu ukazatel volume odráží stádovité chování davu. Například při obrácení trendu ze sestupného na vzestupný chce řada obchodníků této situace využít a sází na cenový vzestup a uzavírá kontrakty do dlouhé pozice (*long position*), to vede k dalšímu nárůstu volume, to přiláká další obchodníky, kteří svými nově uzavřenými kontrakty volume dále navyšují a tak stále dokola. (3)



Obrázek 5: Čárový graf akcie IBM doplněný o indikátor Volume
(Zdroj: StockCharts.com)

Na obrázku 5 je zobrazen čárový graf zachycující cenový vývoj pro akcii IBM (International Business Machines Co.) v časovém rozmezí 1.1.2016 až 31.12.2016., graf je doplněn o indikátor Volume (spodní zelený sloupcový graf). Oba grafy sdílejí stejnou časovou osu. Za povšimnutí stojí skutečnost, že když se klesající trend obrací na stoupající, tak je volume nadprůměrné.

2.2.8. Technické indikátory

Technické indikátory představují soubor statistických metod, které na základě cenových tržních dat pomáhají hledat trendy, tržní sentiment, cenové fluktuace, změny Volatility a tržní momentum u zkoumaného investičního instrumentu, nejčastěji u akcií. Technické identifikátory obchodníci využívají k potvrzení hledaného vzoru v grafu nebo ke generování nákupních a prodejních signálů, k předpovídání trendů nebo k upozornění na mimořádné situace na trhu. (11)

Z matematického hlediska technické identifikátory představují sérii datových bodů vypočítaných pomocí vzorce z cenových dat (*price data*) a případně i hodnoty objemu obchodů (*volume*). (16)

Cenová data představují pro dané časové období čtyři hodnoty - *open*, *high*, *low*, *close*. Některé identifikátory mohou být počítány pouze z *close* hodnoty, zatímco jiné zahrnují všechny čtyři a navíc i objem obchodů (*volume*). (16)

Technické indikátory dělíme podle časového zaměření na (8):

- **Dopředné (*pretend*)**- dopředné indikátory se snaží předcházet cenový vývoj aktiva a předpovídat jeho budoucí vývoj. Nejvíce jsou užitečné v období kdy trh netrenduje, tzn. jde do boku, protože mohou predikovat vzestupný nebo sestupný trendový průraz.
- **Zpožděné (*lagging*)** – zpožděné indikátory kopírují cenové pohyby a slouží jako potvrzovací signál, například pro potvrzení síly nebo směru trendu. Tyto indikátory se uplatní v období kdy trh trenduje, protože mohou signalizovat jeho oslabení nebo zesílení v daném směru.

Technické indikátory dále dělíme dle typu a interpretace výsledku (8):

- **Oscilátory (*oscilators*)** - oscilátory jsou nejběžnější typ indikátorů a jejich výsledek nabývá hodnot z určitého rozsahu. Například indikátor RSI může nabývat hodnot od 0 do 100, kde hodnoty blízké 0 signalizují přeprodané a 100 překoupené aktivum, hodnoty blízké 50 neutrální aktivum.
- **Neomezené indikátory (*non-oscilators*)** – neomezené indikátory jsou méně časté a jejich výsledná hodnota není omezena hranicemi. Typickým představitelem je klouzavý průměr MA, který je často používán jako doplňkový indikátor. Neohraničené indikátory v kombinaci s dalším indikátory generují signály pro vstupy nebo výstupy z pozic nebo potvrzují sílu trendu na základě konvergence nebo divergence. Pokud se trend aktiva od hodnot indikátoru vzdaluje, tak trend oslabuje a naopak pokud se přibližuje, tak trend aktiva posiluje.

V následujících odstavcích si představíme nejběžnější technické indikátory a některé z nich využijeme v našem vlastním řešení. Téměř každý indikátor vychází z určité hypotézy kterou zkoumal jeho tvůrce a ten stanovil i vzorec pro výpočet indikátoru a doporučený způsob interpretace výsledků. Uživatelé technické analýzy si často indikátory parametrizují a upravují dle svých potřeb a vznikají tak nové odvozené indikátory nebo způsob využití indikátoru je jiný než byl původně tvůrcem zamýšlen.

2.2.9. Moving Average indikátor (MA)

Moving Average indikátor, neboli klouzavý průměr, je typický představitel zpožděného neomezeného indikátoru. Jeho aplikací dosáhneme vyhlazení cenových dat díky eliminaci drobných cenových fluktuací. Velikost zpoždění indikátoru je dána počtem cenových bodů, na kterých je průměr počítán. Například klouzavý průměr 10 má menší zpoždění než klouzavý průměr 200. (10)

Při technické analýze se setkáváme nejčastěji se třemi typy klouzavého průměru a jednoduchý klouzavý průměr (SMA), exponenciální klouzavý průměr (EMA) a vážený klouzavý průměr (WMA). Základní rozdíl mezi nimi je ten, že vážený a exponenciální klouzavý průměr klade při výpočtu větší důraz na nejmladší cenové body a tím pádem

rychleji reaguje na cenové změny, zatímco jednoduchý klouzavý průměr přiřazuje všem cenovým bodům stejnou váhu a proto má pomalejší reakce na změny trendu. Nelze říci, který z klouzavých průměrů je lepší, záleží na zkušenostech uživatele technické analýzy, aby pro svůj obchodní plán správně zvolil vhodný typ. (10)

Délka klouzavého průměru, tzn. počet kalkulovaných cenových bodů, by měla odpovídat délce trendu nebo velikosti obchodního okna. Pro krátkodobé trendy volíme velikost mezi 5 až 20, pro střednědobé trendy 20 až 70 a pro dlouhé trendy 100 a více. Mezi uživateli jsou oblíbené hodnoty 5, 10, 20, 50, 100 a 200. (25)

2.2.10. Vzorec pro jednoduchý klouzavý průměr (SMA)

$$SMA = \frac{\text{suma cenových bodů}}{\text{počet cenových bodů}}$$

Například pro SMA 50 sečteme 50 po sobě jdoucích cenových bodů a podělíme 50 a získáme jednoduchý klouzavý průměr pro časový rámec o šířce 50 cenových bodů. Okno pak dále posouváme po jedno časovém bodu směrem k aktuálnímu datu a celý výpočet opakujeme. (25)

2.2.11. Vzorec pro exponenciální klouzavý průměr (EMA)

$$EMA = \text{aktuální cena} \times R + \text{předcházející EMA} \times (1 - R), R = \frac{2}{1 + \text{časový rámec}}$$

Date	Volume	Close	SMA 5	EMA 5
2016-12-01	4635700	158.566	NA	NA
2016-12-02	2740900	158.765	NA	NA
2016-12-05	3447100	158.586	NA	NA
2016-12-06	2859000	159.092	NA	NA
2016-12-07	4435100	163.497	159.701	160.62
2016-12-08	3266400	164.063	160.801	161.878
2016-12-09	3146900	165.214	162.09	163.059
2016-12-12	3392300	164.202	163.213	163.455
2016-12-13	5932300	166.97	164.789	164.658
2016-12-14	4124200	167.188	165.527	165.516
2016-12-15	3388600	166.702	166.055	165.916
2016-12-16	7120600	165.422	166.097	165.75
2016-12-19	2955900	165.372	166.331	165.624
2016-12-20	2174600	166.285	166.194	165.845
2016-12-21	3575700	166.017	165.96	165.902
2016-12-22	2802600	165.749	165.769	165.851
2016-12-23	1701200	165.402	165.765	165.702
2016-12-27	1397500	165.829	165.857	165.744
2016-12-28	1757500	164.886	165.577	165.458
2016-12-29	1663500	165.293	165.432	165.403
2016-12-30	2952800	164.688	165.22	165.165

Tabulka 1: Ukázka hodnot indikátoru SMA 5 a EMA 5 na 21 denních periodách
(Zdroj: vlastní zpracování)

V tabulce 1 lze vidět jak exponenciální klouzavý průměr rychleji než jednoduchý klouzavý průměr na změnu ceny close.



Obrázek 6: Čárový graf akcie GE a indikátorů SMA20, SMA200
(Zdroj: StockCharts.com)

Na obrázku 6 je zobrazen čárový graf zachycující cenový vývoj pro akcii GE (General Motors Co.) v časovém rozmezí 1.1.2016 až 31.12.2016., graf je doplněn o dva

indikátory jednoduchý klouzavý průměr 50 (modrá čára) a 200 (červená čára). Za povšimnutí stojí skutečnost, že když je SMA 50 nad SMA 200, tak je trend vždy stoupající a naopak.

Aplikace klouzavého průměru potvrzuje trend a určuje jeho sílu, definuje možné body průlomu a úrovně podpory a rezistence, generuje obchodní signály, které odpovídají křížením krátkého a dlouhého klouzavého průměru (*moving average crossover*) nebo překřížením klouzavého průměru a ceny (*price crossover*). (8)

Klouzavý průměr často najdeme v kombinaci s oscilátorem RSI nebo jako vstupní parametr při kalkulaci složitějších indikátorů, například u Bollinger Bands nebo MACD. (8)

2.2.12. Relative Strength index Indikátor (RSI)

Relative Strength Index (RSI) je populární dopředný oscilátor, vyvinutý J. Welles Wilderem, který slouží k měření rychlosti změny a síly cenových pohybů aktiva. V kombinaci s dalšími nástroji (např. překřížení s klouzavým průměrem) je schopen predikovat změnu trendu nebo změnu úrovně podpory a rezistence. (10)



Obrázek 7: Čárový graf akcie IBM s indikátorem RSI

(Zdroj: StockCharts.com)

Na obrázku 7 je zobrazen čárový graf zachycující cenový vývoj pro akcii IBM v časovém rozmezí 1.1.2016 až 31.12.2016., graf je doplněn o oscilátor RSI 14 (spodní graf). Oba grafy sdílejí stejnou časovou osu.

Výstupu Relative Strength Index indikátoru osciluje na škále 0 až 100 s centrováním na 50. Podle tvůrce rozeznáváme dvě pásma zájmu (11):

- 0 až 30, **pásmo přeprodání** (*oversold*) – odpovídá situaci, kdy je pozitivní momentu aktiva tak vysoké, že dlouhodobě není udržitelné a bude korigováno změnou do vzestupného trendu, tzn. cena investičního instrumentu poroste.
- 70 až 100, **pásmo překoupení** (*overbought*) - odpovídá situaci, kdy je pozitivní momentu aktiva tak nízké, že dlouhodobě není udržitelné a bude korigováno změnou do sestupného trendu, tzn. cena investičního instrumentu bude klesat.

Uživatelé technické analýzy počítají RSI indikátor nejčastěji pro časový rámec 7,14 nebo 21, s nižším časovým rámcem stoupá u indikátoru citlivost, ale i náchylnost na ovlivnění nahodilými cenovými fluktuacemi. Například RSI 7 dříve zaznamená úroveň překoupení, ale s větší mírou falešného signálu než RSI 14. (8)

Další možnost jak zvýšit citlivost indikátoru je zúžení pásem přeprodání a překoupení. Ověřené hodnoty z trhu jsou 0 až 20, respektive 80 až 100. (8)

Je však na uživateli, aby si zvolil vhodný kompromis časového rámce nebo šířky pásma dle svých zkušeností a účelu použití indikátoru. Každý obchodní plán je individuální a proto je žádoucí prověřit více hodnot indikátorů RSI.

2.2.13. Vzorec pro výpočet Relative Strength Index indikátoru (RSI)

$$RSI = 100 - \frac{100}{(1 + RS)}, RS = \text{průměr zisků} / \text{průměr ztrát}$$

Například pro RSI(14) počítáme na 14 po sobě jdoucích cenových bodech podíl průměru zisků a průměru ztrát, výsledek doplníme zbytkem do vzorce a získáme RSI

indikátor pro časový rámec o šířce 14 cenových bodů. Výsledek RSI osciluje v rozmezí 0 až 100 a krajních hodnot 0 a 100 nikdy nenabude.

Date	Volume	Close	RSI SMA 5	RSI EMA 5
2016-12-01	4635700	158.566	NA	NA
2016-12-02	2740900	158.765	NA	NA
2016-12-05	3447100	158.586	NA	NA
2016-12-06	2859000	159.092	NA	NA
2016-12-07	4435100	163.497	NA	NA
2016-12-08	3266400	164.063	96.949	98.614
2016-12-09	3146900	165.214	97.376	99.046
2016-12-12	3392300	164.202	86.753	70.216
2016-12-13	5932300	166.97	89.78	86.426
2016-12-14	4124200	167.188	82.292	87.247
2016-12-15	3388600	166.702	73.416	72.581
2016-12-16	7120600	165.422	51.807	43.623
2016-12-19	2955900	165.372	62.19	42.634
2016-12-20	2174600	166.285	38.384	64.713
2016-12-21	3575700	166.017	30.464	55.337
2016-12-22	2802600	165.749	32.857	45.458
2016-12-23	1701200	165.402	49.463	33.745
2016-12-27	1397500	165.829	60.268	55.077
2016-12-28	1757500	164.886	18.943	26.646
2016-12-29	1663500	165.293	34.855	45.019
2016-12-30	2952800	164.688	30.545	28.877


Tabulka 2: Ukázka hodnot indikátoru RSI 5 pro SMA a EMA na 21 denních periodách
(Zdroj: vlastní zpracování)

Relative Strength Index indikátor je často užíván při vizuální analýze na svíčkových grafech při potvrzování hledané grafické formace (*pattern matching*) a v kombinaci s ostatními indikátory jako generátor obchodních signálů, určení změny nebo potvrzení cenového trendu. (11)

2.2.14. Moving Average Convergence Divergence indikátor (MACD)

Moving Average Convergence Divergence (MACD) je představitelem složeného zpožděného oscilátoru, který sleduje cenový trend aktiva a zachycuje vztah mezi krátkodobým a dlouhodobým exponenciálním klouzavým průměrem. MACD se vypočítá odečtením dlouhodobého EMA od krátkodobého EMA. Pro generování

obchodních signálů je využíváno křížení MACD se signální křivkou reprezentovanou exponenciálním klouzavým průměrem vypočítaným z datových bodů MACD. Obvyklé hodnoty pro kalkulaci MACD jsou 26 pro dlouhodobý EMA, 12 pro krátkodobý EMA a 9 pro EMA signální křivky. Kalkulovaný rozdíl $EMA\ 12 - EMA\ 26$ je do grafu vynášen jako křivka MACD, doplňkový sloupcový histogram jako rozdíl mezi MACD a signální křivkou. Součástí grafu je i pomocná nulová přímka, která je definována stavem $EMA\ 12 = EMA\ 26$. (10)



Obrázek 8: Čárový graf akcie IBM s indikátorem MACD

(Zdroj: StockCharts.com)

Na obrázku 8 je zobrazen čárový graf zachycující cenový vývoj pro akcii FA (Facebook, Inc) v časovém rozmezí 1.1.2016 až 31.12.2016., graf je doplněn o indikátor MACD 12,26,9 (spodní graf). Černá křivka představuje MACD a červená signální křivku EMA 9 počítanou z MACD. Modrý sloupcový histogram zachycuje rozdíl mezi MACD křivkou a signální křivkou. Oba grafy sdílejí stejnou časovou osu.

2.2.15. Vzorec pro výpočet Moving Average Convergence Divergence indikátoru (MACD), signální křivky a sloupcového histogramu:

$$MACD(12,26,9) = EMA 12 - EMA 26$$

$$MACD, \text{ signální křivka} = EMA 9 \text{ počítaný z MACD}$$

$$MACD, \text{ histogram} = MACD - \text{Signální linka}$$

$$MACD, \text{ nulová přímka: } EMA 12 = EMA 26$$

Date	Volume	Close	MACD	EMA 26	EMA 12
2016-12-01	4635700	158.566	0.0	158.566	158.566
2016-12-02	2740900	158.765	0.004	158.669	158.674
2016-12-05	3447100	158.586	0.0	158.639	158.64
2016-12-06	2859000	159.092	0.016	158.766	158.782
2016-12-07	4435100	163.497	0.2	159.863	160.063
2016-12-08	3266400	164.063	0.331	160.704	161.035
2016-12-09	3146900	165.214	0.462	161.506	161.968
2016-12-12	3392300	164.202	0.493	161.941	162.434
2016-12-13	5932300	166.97	0.645	162.686	163.331
2016-12-14	4124200	167.188	0.755	163.307	164.062
2016-12-15	3388600	166.702	0.798	163.748	164.545
2016-12-16	7120600	165.422	0.748	163.953	164.701
2016-12-19	2955900	165.372	0.698	164.12	164.818
2016-12-20	2174600	166.285	0.705	164.363	165.068
2016-12-21	3575700	166.017	0.685	164.542	165.227
2016-12-22	2802600	165.749	0.645	164.668	165.313
2016-12-23	1701200	165.402	0.585	164.743	165.328
2016-12-27	1397500	165.829	0.559	164.85	165.409
2016-12-28	1757500	164.886	0.471	164.853	165.325
2016-12-29	1663500	165.293	0.425	164.895	165.32
2016-12-30	2952800	164.688	0.344	164.876	165.22

Tabulka 3: Ukázka hodnot indikátoru MACD a EMA 12,26 na 21 denních periodách
(Zdroj: vlastní zpracování)

Využití MACD indikátoru je široké. Obchodníci jej využívají pro indikování nákupních a prodejních signálů, překoupenosti a přeprodanosti trhu a pro potvrzování směru a sílu trendu. (11)

2.2.16. Stochastic Oscillator indikátor (SO)

Stochastic Oscillator indikátor (SO) je představitelem dopředného oscilátorů vyvinutého v 50tých letech finančníkem George C. Lane. (10)

Stochastic oscilátor pracuje se vzdáleností aktuální close ceny investičního instrumentu vzhledem cenovému rozsahu *low* a *high* cen za určitý časový rámec. Stochastic Oscilátor počítá rychlost trhu neboli rychlost cenových změn, které interpretuje na škále 0 až 100. Indikátor pod hranici 20 signalizuje přeprodanost trhu a naopak hodnota indikátoru nad hranicí 80 signalizuje překoupený trh. (11)

Stochastic oscillator se skládá se ze dvou křivek. První %K je hlavní křivka a druhá křivka se nazývá %D a vypočítá se jako klouzavý průměr x předchozích bodů křivky %K. Křivka %D slouží jako signální linka. Výchozí nastavení pro Stochastic Oscillator je časový rámec o velikosti 14 a křivka %D je jednoduchý klouzavý průměr 3. (25)

2.2.17. Vzorec pro výpočet Stochastic Oscillator indikátoru (SA)

*Stochastic oscillator , křivka %K = (aktuální close – min . low) / (max . high – min . low) * 100*

Stochastic oscillator , křivka %D = n předchozích %K / n

Nutno podotknout, že existují tři varianty indikátoru: full, slow a fast, které se odlišují v hodnotě SMA a časovém rámci. (11)



Obrázek 9: Čárový graf akcie GOOGL s indikátorem Stochastic oscillator
 (Zdroj: StockCharts.com)

Na obrázku 9 je zobrazen čárový graf zachycující cenový vývoj pro akcii GOOGL (Alphabetic Inc) v časovém rozmezí 1.1.2016 až 31.12.2016., graf je doplněn o indikátor Stochastic Oscillator 14,3,3 varianta full (spodní graf). Černá křivka představuje %K a červená signální křivku %D počítanou jako SMA 3 z %K . Oba grafy sdílejí stejnou časovou osu.

Hlavním přínosem indikátoru je predikce bodu obratu v blízkostí úrovně podpory a rezistence. Pokud indikátor prorazí hodnotu 20, signalizuje tím možná vzestupný trend a úspěšné otestování úrovně podpory a naopak průraz hodnoty 80 znamená nadcházející sestupný trend a úspěšné otestování úrovně rezistence. K signalizaci zvratu dochází, pokud hodnota indikátoru roste z hodnot nižších než 20 (*bull turnover*) nebo klesá z hodnot vyšších než 80 (*bear turnover*). (8)

Stochastic Oscillator, jako všechny technické indikátory, podává nejlepší výsledky ve spolupráci s ostatními technickými indikátory. Volume a průlomy mohou potvrdit nebo vyvrátit obchodní signály generované Stochastic Oscillator indikátorem. (25)

2.2.18. Bollinger Band indikátor (BB)

Indikátor Bollinger band (BB) byl vyvinut finančním matematikem John Bollinger v 80tých letech. Bollinger band indikátor je složen ze dvou pásem vycházejících z Volatility investičního instrumentu. Pásma jsou umístěna pod a nad křivkou jednoduchého klouzavého průměru (nejčastěji SMA 20) počítaného z *close* ceny aktiva. Volatilita odpovídá standardní odchylce *close* ceny a je chápána jako cenové pásmo (aktuální cena +/- standardní odchylka), ve kterém se bude cena aktiva nacházet v nadcházející periodě. Pokud se standardní odchylka zvětší, tak se zvětší i Volatilita a obráceně. Šířka pásem odpovídá násobkům Volatility, nejčastěji 2 nebo 3 násobek a změna Volatility se automaticky proporcionálně propaguje do šířky pásem. (11)

2.2.19. Vzorec pro výpočet Bollinger Band indikátoru (BB)

Bollinger band , střední křivka = SMA 20 z close ceny

Bollinger band , horní pásmo = (SMA 20 z close ceny) + 2 x (standardní odchylka z 20 datových bodů)

Bollinger band , spodní pásmo = (SMA 20 z close ceny) - 2 x (standardní odchylka z 20 datových bodů)

Date	Volume	Close	BB	BB UP	BB DOWN
2016-12-01	4635700	158.566	157.994	165.954	150.034
2016-12-02	2740900	158.765	158.441	165.41	151.472
2016-12-05	3447100	158.586	158.877	164.562	153.192
2016-12-06	2859000	159.092	159.176	164.171	154.181
2016-12-07	4435100	163.497	159.653	164.363	154.944
2016-12-08	3266400	164.063	160.177	164.347	156.006
2016-12-09	3146900	165.214	160.489	165.181	155.797
2016-12-12	3392300	164.202	160.699	165.667	155.731
2016-12-13	5932300	166.97	161.199	166.582	155.816
2016-12-14	4124200	167.188	161.687	167.391	155.984
2016-12-15	3388600	166.702	162.12	167.971	156.269
2016-12-16	7120600	165.422	162.464	168.238	156.689
2016-12-19	2955900	165.372	162.776	168.466	157.086
2016-12-20	2174600	166.285	163.016	168.879	157.152
2016-12-21	3575700	166.017	163.247	169.205	157.288
2016-12-22	2802600	165.749	163.499	169.431	157.566
2016-12-23	1701200	165.402	163.676	169.614	157.738
2016-12-27	1397500	165.829	163.806	169.816	157.795
2016-12-28	1757500	164.886	163.938	169.92	157.956
2016-12-29	1663500	165.293	164.155	169.994	158.316
2016-12-30	2952800	164.688	164.461	169.675	159.248

Tabulka 4: Ukázka hodnot indikátoru Bollinger Band na 21 denních periodách

(Zdroj: vlastní zpracování)



Obrázek 10: Čárový graf akcie XRX s indikátorem Bollinger Band

(Zdroj: StockCharts.com)

Na obrázku 10 je zobrazen čárový graf zachycující cenový vývoj pro akcii XRX (Xerox corp.) v časovém rozmezí 1.1.2016 až 31.12.2016., graf je doplněn o indikátor Bollinger Band. Centrální tečkovaná modrá křivka představuje SMA 20 a plná modrá čára nad a pod tečkovanou čarou vymezuje horní resp. dolní pásmo o vzdálenosti 2 x Volatilita od centrální křivky.

Bollinger Band indikátor reflektuje směr trendu aktiva s 20 periodou a Volatilitou v horních a spodních pásmech. Tyto pásma mohou být použity pro indikaci nadhodnocené nebo podhodnocené ceny a tím pádem i brzké korekce . Podle tvůrce Bollingera může indikátor signalizovat až 80% těchto stavů. Samozřejmě platí, že prodejní signály generované Bollinger Band indikátorem by měly být potvrzovány v kombinaci s ostatními trend indikátory. (10)

2.2.20. On-Balance Volume indikátor (OBV)

On-balance Volume indikátor (OBV) byl na počátku 60tých let vyvinut matematikem Joe Granville a je představitelem dopředného oscilátoru. (11)

On-balance Volume indikátor primárně zkoumá volume aktiva před cenou a snaží se indikovat jeho pozitivní nebo negativní volume *flow* složku. Tvůrce indikátoru

předpokládá, že změna volume předchází změně ceny z důvodu, že institucionální investoři mají lepší informační základu a do pozic vstupují dříve než široká investorská veřejnost. Svými nákupy zvedají objemy uskutečněných obchodů, zvedají cenu aktiva a tím motivují ostatní investory k nákupu, což se posléze odrazí v ceně. (10)

On-balance Volume indikátor rozlišuje 3 typy trendu a to *up*, *down* a *doubtful* neboli rostoucí, klesající a nejasný. Vzestupný trend nastává, když je vrchol a dno aktuálního OBV trendu nad předcházejícím vrcholem a dnem OBV trendu a sestupný trend nastává, když je vrchol a dno aktuálního OBV trendu pod předcházejícím vrcholem. Indikátor tak zohledňuje, zda volume roste z nákupů nebo prodeje aktiva. (11)

Uživatelé technické analýzy On-balance Volume indikátor používají způsobem, kdy sledují konvergenci nebo divergenci indikátoru k cenové křivce a odhadují tak trendový zvrát nebo potvrzení trendu. (25)

2.2.21. Vzorec pro výpočet On-balance Volume indikátoru (OBV)

OBV = minulý OBV + aktuální Volume , pokud je současná cena nad minulou cenou

OBV = minulý OBV – aktuální Volume , pokud je současná cena pod minulou cenou

OBV = minulý OBV , pokud je současná cena shodná s minulou cenou



Obrázek 11: Čárový graf akcie IBM s On-balance Volume indikátorem
(Zdroj: StockCharts.com)

Na obrázku 11 je zobrazen čárový graf zachycující cenový vývoj pro akcii IBM (International Business Machines Co.) v časovém rozmezí 1.1.2016 až 31.12.2016., graf je doplněn o On-balance Volume indikátor (spodní zelený sloupcový graf). Oba grafy sdílejí stejnou časovou osu.

Stejně jako ostatní indikátory, i On-balance Volume je doporučeno používat v kombinaci s ostatními nástroji technické analýzy, například s oscilátory nebo potvrzovači trendu. (10)

Krátce jsme si představili několik nejběžnějších technický indikátoru a některé z nich využijeme v našem řešení jako filtr vhodných akciových titulů z indexu S&P 100, respektive S&P 500 pro další zpracování nebo jako generátor signálů pro vstup do a výstup z pozic.

Při práci s technickými indikátory je třeba mít na mysli, že nejsou 100% spolehlivé a že jejich predikce mohou naprosto selhávat v turbulentních dobách jako byla finanční krize 2007 až 2011. V takových situacích je lepší zvážit uzavření všech pozic a

stáhnout se z trhu. Někdy je výhodnější se vzdát potencionálních menších zisků než utrpět velké ztráty.

Mít dostatečné množství kapitálu na konci krize je velká výhoda. Na trhu stále přetrvává nejistota z minulých let a většina investičních aktiv je k dispozici za podhodnocené ceny. Dodatečný zisk tak lze realizovat nákupem investičních instrumentů za výhodné ceny. (19)

2.3. Strojové učení

Definice: strojové učení je podoblast počítačové vědy, která podle Arthura Samuela dává počítačovým systémům schopnost učit se, aniž by byly explicitně naprogramovány. Strojové učení zkoumá konstrukci algoritmů, které se mohou naučit a předpovídat ze vstupních dat. (31)

V dnešní doba moderních technologií je charakteristická tím, že nás obklopuje velké množství dat, strukturovaných a nestrukturovaných. V druhé polovině 20tých let minulého století se na scéně objevuje strojové učení jako podobor počítačových věd umělé inteligence. Strojové učení se zabývá návrhem a realizací samoučících algoritmů, které dokáží z ohromného množství obecných nestrukturovaných dat (*big data*) vyextrahovat vědomost do formy modelu. (21)

Tento model lze uložit do souboru, znovu načíst a aplikovat na nová data a z nich predikovat požadovanou veličinu. To se děje bez nutnosti explicitní analýzy dat a programování algoritmů člověkem. S aplikacemi strojového učení se již běžně setkáváme v každodenním životě, například v při analýze sentimentu textových dokumentů, v rozpoznávání obrazu, v bankovních aplikacích při hodnocení bonity klienta, při detekci anomálií, ve webových vyhledávačích, v samořiditelných autech, ve zdravotnictví atd. (24)



Obrázek 12: Proces fungování algoritmu strojového učení

(Zdroj: vlastní zpracování)

Na obrázku 12 vidíme proces fungování algoritmů strojového učení. Z obecných dat pomocí algoritmů strojového učení a procesem učení vytvoříme naučený model, tzn. že

model má znalost o datech. Do tohoto modelu vložíme nová neznámá data (obrázek, zvuk, textový dokument, video) a očekáváme ze systému kvalifikovanou odpověď, například rozpoznání objektu na obrázku, třídu vstupních dat vyjádřenou číslem, onálepkování dokumentu atd...

Praktická aplikace algoritmů strojového učení má dvě základní fáze (13):

- **učení** - extrakce vědomostí ze známých dat a vytváření prediktivního modelu na základě algoritmů strojového učení. Vše proběhne bez programování člověkem,
- **predikce** – použití naučeného modelu na neznámá data a získání kvalifikované odpovědi. Odpověď je zatížena určitou mírou chybovosti.



Obrázek 13: Typy algoritmů strojového učení
(Zdroj: vlastní zpracování)

2.3.1. Algoritmy strojového učení

Algoritmy jsou základní esenci investičního modelu ML. Řešitel úlohy musí vybrat vhodný algoritmus a optimálně nastavit jeho konfigurační parametry (*hyperparameters*). (13)

Algoritmy dělíme podle informací o vstupních datech do tříd (21):

- **Učení s učitelem** (*supervised learning*) – algoritmus je instruován správných výstupem, vstupní trénovací data jsou vybavena i požadovanou odpovědí, příkladem je označování spamu, algoritmus dostane na vstupu množství testovacích emailů spolu s vědomostí zda daný email je nebo není spam.
- **Učení bez učitele** (*unsupervised learning*) – vstupní trénovací data jsou algoritmu předložena bez znalosti správného výstupu, algoritmus si musí sám zjistit vazby mezi daty a data správně rozřadit podle neznámého společného znaku. Typickou úlohou je rozčlenění zákazníků do segmentů.
- **Zpětnovazebné učení** (*reinforcement learning*) – algoritmus v dynamickém prostředí provede akci a získá zpětnou (odměnu nebo trest), na základě této vazby provede další krok a znovu získá zpětnou vazbu a tak stále dokola, tím mění své chování na požadované a po každé iteraci se zlepšuje. Využití nalezneme například v samoříditelných autech, samoučících robotech a v hraní her proti lidskému soupeři.

Řešíme typy úloh (24):

- **Klasifikace** (*classification*) - vstupní data jsou dělena do jedné nebo několika tříd, například jsou rozpoznány a označeny objekty na fotce (zvířata, lidé, stroje, květiny, atd..).
- **Regrese** (*regression*) - na základě řady vstupních dat odhadujeme budoucí hodnotu, například predikujeme vývoj kurzu měny v blízké budoucnosti.
- **Shlukování** (*clustering*) - vstupní objekty rozřazujeme do několika předem neznámých tříd, například segmentace zákazníků.

Nejpoužívanější algoritmy strojového učení :

- **lineární regrese** (*linear regression*) - je velmi rychlý algoritmus (má konstantní rychlost), jehož předností je jednoduchost, vhodnost práce s numerickými daty s mnoha atributy a odolnost proti přeučení (*overfitting*). Nehodí se pro modelaci příliš komplexních vazeb a je schopen zpracovat jen lineární vazby. V případě nelineárních vazeb je nutné provést matematickou transformaci na vazby lineární. Jeho podstatou je interpolace naměřených hodnot lineárním výrazem, například v případě dvojrozměrného prostoru je výsledkem funkce přímky. Lineární regrese je typu učení bez učitele. (24)
- **rozhodovací stromy** (*decision trees*) – je rychlý, přesný, multiklasifikační algoritmus, který je odolný proti chybějícím atributům a šumu. Je vhodný pro zachycení nelineárních vazeb s vysokou komplexitou dat a pracuje na principu rozhodovací stromové struktury. Každý uzel stromu vyhodnocuje právě jednu vlastnost (atribut). Kořenový či výše položený uzel musí rozhodovat vlastnost s co největší mírou odlišností než uzly jemu podřízené. Rozhodovací stromy neumí zpracovat spojitá data a proto je nutné použít transformaci na diskrétní hodnoty. Algoritmus je typu učení s učitelem. (24)
- **neuronové sítě** (*neural networks*) – reprezentují rodinu výkonných rozhodovacích algoritmů, které jsou vhodné pro zpracování dat s velmi komplexními vazbami. Princip neuronových sítí je inspirován biologií a je tvořen soustavou propojených rozhodovacích prvků tzv. neuronů. Neurony charakterizuje mnoho vstupů a právě jeden výstup s možnou hodnotou 0 nebo 1. Evaluace neuronu funguje tak, že všechny vstupy jsou sečteny, je vypočítána přenosná funkce a pokud její výsledek přesáhne prahovou hodnotu, tak dojde k aktivaci neuronu a výstup je nastaven na 1. Při učení neuronových sítí vyhledáváme optimální hodnotu váhových koeficientů každému vstupu tak, aby výsledný predikční model fungoval dle očekávaného výsledku naší úlohy. Neuronové sítě jsou odolné proti přeučení a velkou výhodou je, že nepotřebují znát strukturu vstupních dat. Jako nevýhodu můžeme chápat vysokou výpočetní náročnost a nemožnost interpretace vnitřní

konfigurace modelu, tzn. fungují jako *black box*. Neuronové sítě můžeme učit s i bez učitele. (21)

- **podpůrné vektory** (SVM, *support vector machines*) – je metoda strojového učení, která rozděluje vstupní data na dva prostory vektorem tak, aby minimální vzdálenost bodů (reprezentantů dat) od dělícího vektoru byla co největší. Metoda je vhodná pro klasifikaci datových lineárních vazeb a ze své podstaty má binární charakter. Na vstupní data je třeba aplikovat podpůrný výpočet, tzv. jádrovou transformaci, která zajistí řešitelnost pomocí SVM - tedy možnost rozdělit data do dvou prostorů. Výsledný predikční model je přesný, odolný proti šumu, ale náročný na výpočetní kapacitu. Metoda podpůrných vektorů je typu učení bez učitele. (21)
- **metoda k-nejbližších sousedů** (*k-nearest neighbors*) – je jednoduchý a výkonný algoritmus strojového učení, který na základě nastaveného parametru K vyhledá pro zkoumaný bod X nejbližší sousedy o počtu K. Bod X je pak přiřazen do klasifikační skupiny, která je četnější u vyhledaných sousedů. Vstupní data je nutné transformovat do prohledávaného prostoru tak, aby měly střední hodnotu 0 a rozptyl 1. Algoritmus je ze své přirozené podstaty multiklasifikační a není příliš vhodný pro vysoce dimenzionální data. Metoda k-nejbližších sousedů je typu učení s učitelem. (24)

2.3.2. Optimalizace hyperparametrů modelů

U většiny algoritmů strojového učení je nutné nastavit tzv. hyperparametry (*hyperparameters*) – počáteční konfigurační parametry, které ovlivňují chování modelů během procesu učení a při predikci. Optimální hodnota hyperparametrů se liší podle řešené úlohy, dostupnosti vstupních dat a požadovaného chování modelu (například přesnost predikce, rychlost predikce, míru falešných předpovědí atd...). (24) V tabulce 5. vidíme seznam hyperparametrů pro modely včetně nejběžnějších hodnot. Pro účely diplomové práce využijeme některé z volně dostupných optimalizačních aplikací, které dokáží kromě hyperparametrů doporučit i vhodný algoritmus.

Model	Parameters to optimize	Good range of values
Linear Regression	<ul style="list-style-type: none"> • fit_intercept • normalize 	<ul style="list-style-type: none"> • True / False • True / False
Ridge	<ul style="list-style-type: none"> • alpha • Fit_intercept • Normalize 	<ul style="list-style-type: none"> • 0.01, 0.1, 1.0, 10, 100 • True/False • True/False
k-neighbors	<ul style="list-style-type: none"> • N_neighbors • p 	<ul style="list-style-type: none"> • 2, 4, 8, 16 • 2, 3
SVM	<ul style="list-style-type: none"> • C • Gamma • class_weight 	<ul style="list-style-type: none"> • 0.001, 0.01.....10...100...1000 • 'Auto', RS* • 'Balanced' , None
Logistic Regression	<ul style="list-style-type: none"> • Penalty • C 	<ul style="list-style-type: none"> • L1 or l2 • 0.001, 0.01.....10...100
Naive Bayes (all variations)	NONE	NONE
Lasso	<ul style="list-style-type: none"> • Alpha • Normalize 	<ul style="list-style-type: none"> • 0.1, 1.0, 10 • True/False
Random Forest	<ul style="list-style-type: none"> • N_estimators • Max_depth • Min_samples_split • Min_samples_leaf • Max features 	<ul style="list-style-type: none"> • 120, 300, 500, 800, 1200 • 5, 8, 15, 25, 30, None • 1, 2, 5, 10, 15, 100 • 1, 2, 5, 10 • Log2, sqrt, None
Xgboost	<ul style="list-style-type: none"> • Eta • Gamma • Max_depth • Min_child_weight • Subsample • Colsample_bytree • Lambda • alpha 	<ul style="list-style-type: none"> • 0.01,0.015, 0.025, 0.05, 0.1 • 0.05-0.1,0.3,0.5,0.7,0.9,1.0 • 3, 5, 7, 9, 12, 15, 17, 25 • 1, 3, 5, 7 • 0.6, 0.7, 0.8, 0.9, 1.0 • 0.6, 0.7, 0.8, 0.9, 1.0 • 0.01-0.1, 1.0 , RS* • 0, 0.1, 0.5, 1.0 RS*

Tabulka 5: Algoritmy a hyperparametry k optimalizaci

(Zdroj: (24))

2.3.3. Příprava dat

Pro natrénování a predikci modelu jsou vhodně vybraná a upravená vstupní data rozhodující faktor přenosnosti predikce. Vstupní data bez dodatečné úpravy obvykle nejsou vhodná pro přímé učení, protože často obsahují redundance, chybějící nebo chybné atributy, mají nevhodný datový typ, nevhodnou škálu, malý rozsah nebo nejsou

normalizována. Proto musíme data upravit do správného tvaru (*data preprocessing*). (13)

Porozumění a výběr vstupních dat

Z povahy řešeného úlohy bychom měli mít představu, jaká data a v jakém rozsahu potřebujeme. Často setkáme s tím, že jsme zahlceni velkým množstvím nestrukturovaných a špatně popsanych dat. Naším úkolem je data rozřadit, popsat, snížit jejich komplexitu a vybrat jen ta, které mají vztah ke zkoumané úloze.

Správný výběr dat (*data selection*) má zásadní vliv na rychlost a přesnost predikčního modelu a v neposlední řadě šetří výpočetní a úložní kapacitu. (13)

V praxi je běžné, že je využito cca 10 až 20% dodaných dat a že datový specialista stráví až 80% času práce jen na přípravě dat (13).

Klasifikace vstupních dat dle typu (24):

- numerická - 20, 1950, 11.25,...
- kategorická - neřazená - červená, zelená, modrá,...
- řazená (ordinální) – malý, větší, největší, ...
- binární – 0 / 1, pravda / nepravda, ...

Čištění dat (*data cleaning*)

Při čištění dat nahradíme chybějící nebo poškozené hodnoty atributů novou hodnotou (např. klouzavým průměrem, mediánem nebo konstantou) nebo smažeme celý záznam měření (řádek). (24)

Transformace dat (*data transformation*)

Transformace dat je proces, při kterém měníme reprezentaci dat na novou skutečnost, která se hodí pro strojové zpracování. Vhodná transformace dat dokáže zvýšit přesnost predikčního modelu. (24)

Metody transformace dat (13):

- **Normalizace dat** - je přepočítání hodnot numerických atributů na škálu (-1, 0, 1).
- **Standardizace dat** - představuje posunutí rozložení hodnot numerických atributů na škálu tak, aby jejich průměr byl 0 a standardní odchylka 1. Při aplikaci standardizace je vhodné brát v potaz použitý klasifikační algoritmus.
- **Konverze datových typů** - znamená převod nenumernických atributů na numerické, např: hodnoty ANO/NE převedeme na 1/0 .
- **Agregace atributů a snižování dimenzí** – data se snažíme upravit tak, aby neztratila potřebnou informační hodnotu a přitom obsahovala co nejméně atributů (dimenzí). Jedna z možností je vytvoření nového atributu, který nahradí korelující a zároveň kauzálně propojené atributy. Správnost rozhodnutí je nutné ověřit experimentem.

3. ANALÝZA SOUČASNÉHO STAVU

V teoretické části práce jsme si představili důležité koncepty a pojmy, které použijeme jako východisko pro naše vlastní řešení. Popsali jsme si základní princip technické analýzy, často používané technické indikátory: Simple Moving Average, Bollinger Band, On-balance Volume, Stochastic Oscillator, MACD, Relative Strength Index včetně jejich kalkulačních vzorců, ukázkových grafů a způsobu interpretace výsledků.

Algoritmy strojového učení použijeme jako dodatečnou predikci hodnoty časové řady ceny akcie a pro klasifikaci růstu nebo poklesu ceny akcie.

V praktické části budeme realizovat zadání diplomové práce. Navrhne a implementujeme finanční modely TECH a ML pro tvorbu a optimalizaci akciového investičního portfolia, otestujeme je na historických burzovních datech a porovnáme s odborníky uznávaným benchmarkem.

Pro výpočet a optimalizaci modelů použijeme open source softwarové nástroje - programovací jazyk Python, který má bohatý ekosystém pro finančně ekonomické výpočty, má strmou křivku učení a je zdarma. Jádro výpočtu budou mít na starosti knihovny Pandas a Numpy, strojové učení (ML) pak knihovna Scikit-learn, což je vlastně kolekce softwarových nástrojů, kterými jsme schopni kompletně pokrýt celý proces tvorby ML prediktoru - od výběru a přípravy vstupních dat až po výběr a optimalizaci vhodného modelu klasifikátoru. Pro uložení burzovních historických dat a konečných výpočtů zvolíme osvědčenou databázi PostgreSQL, která má dostatečný výkon, je zdarma ke stažení a bezproblémově spolupracuje s jazykem Python. Pro názornou prezentaci výsledků použijeme knihovnu pro tvorbu grafů Matplotlib, která nabízí širokou paletu grafů a grafických vizualizací a je úzce provázána s knihovnou Pandas.

Všechny funkcionality investičních modelů budou vyjádřeny ve formě softwarových tříd a příslušných metod, přes které budou tyto třídy, resp. jejich instance vzájemně interagovat ve smyčce hlavního programu. Náš hlavní program nazveme Automatický obchodní systém (AOS), který vykonává strategii AOS.

Důležitou roli v našem AOS hrají prediktory, které z historických dat předvídají s určitou úrovní jistoty budoucí vývoj trendu datové řady, v našem případě cenového vývoje, na základě kterého budou generovány obchodní signály pro nákup nebo prodej akciového titulu. Prediktory pro srovnání vytvoříme dva, první bude navržen na principu technické analýzy (Predictor TECH) a druhý bude vycházet z prvního, kterého doplní o klasifikátor na bázi algoritmů strojového učení (Predictor ML). Očekává se, že by měl dosahovat lepších výsledků v předpovědi a tím zvýšit profitabilitu a/nebo stabilitu portfolia.

Výkonnost AOS vyhodnotíme metodou backtesting, která je založena na simulovaném obchodování na historických burzovních datech. Princip je následující, automatický obchodní systém prochází burzovní data vybraných akcií od nejstaršího záznamu směrem do budoucna, pro každý obchodní den predikuje cenový vývoj všech zkoumaných akcií a na základě podmínek maximalizujících zisk a stabilitu provede nákup nebo prodej na fiktivní obchodní účet. Pro co nejvíce realistický průběh backtestingu započítáme do nákladů fiktivní poplatky za provedené transakce (*trade fee*) a dodržíme princip dopředného testování (*forward testing*), tzn. že prediktor kalkuluje svůj výpočet z cenových dat, která jsou starší než aktuálně obchodovaný den, bere v potaz časovou souslednost jednotlivých cenových bodů a predikce tak není ovlivněna informacemi z budoucnosti (*bias problem*).

Pro fungování AOS je podmínkou dostupnost konzistentních historických burzovních dat dostupných z rychlého lokálního úložiště. V našem případě využijeme poskytovatelů Yahoo a Quandl, kteří burzovní data vystavují zdarma přes http protokol. Data načteme pomocí knihovny Pandas, provedeme jejich validaci, zbavíme je duplicit a chybějících položek a uložíme do databáze PostgreSQL.

Automatický obchodní systém (AOS) je složen ze 7 základních komponent:

- Databáze PostgreSQL – úložiště historických burzovních OHLC dat,
- Data provider – připravuje OHLC data pro ostatní komponenty systému,
- Strategy – generuje hodnoty indikátorů a obchodní signály,
- Predictor ML – predikuje trend datové řady na základě strojového učení,

- Predictor TECH – predikuje trend datové řady na základě technické analýzy,
- Portfolio – spravuje investovaný kapitál a naši tržní pozici,
- Statistics – generuje statistiku pro backtesting a benchmarking.

Jednotlivé softwarové komponenty včetně vstupních parametrů popíšeme detailněji níže v praktické části.

Prediktory ML a TECH obsahují konfiguračních volby, které je nutné před spuštěním nastavit. Chceme, aby automatický obchodní systém dosahoval nejlepších výsledků, a proto musíme pro konfigurační volby nalézt optimální hodnoty. Toho dosáhneme pomocí optimalizací konfiguračním předvoleb.

Optimalizace přestavuje náročnou úlohu, protože se prohledává obrovský stavový prostor všech možných kombinací konfiguračních předvoleb, se kterými se spustí AOS a vypočítá fitness funkce. Fitness funkce odpovídá maximálnímu zhodnocení vstupního kapitálu (*maximize equity curve with minimal risk*) za přijatelného rizika. Optimalizace hledá její maximum a dodržuje se zásada, že optimalizaci provádíme na jiných burzovních datech, než která nepoužijeme pro backtesting. Tím zvýšíme objektivitu backtestingu, protože AOS bude optimalizovaný pro obecná data a nikoliv speciálně pro vzorek určený pro backtesting.

Samotný backtesting AOS spustíme pro běžné období od 1.1.2006 do 31.12.2016 a období finanční krize od 1.1.2007 do 31.12.2011., na fiktivním obchodním účtě budeme mít 100 000 dolarů. Backtesting provedeme s oběma typy prediktorů, ML a TECH. Jako benchmark nám poslouží fixní investice 100 000 dolarů do akciového indexu S&P 500, respektive S&P100, které necháme zhodnocovat po stejné časové období a bez jakékoliv dodatečné manipulace obchodníkem. Očekáváme, že výsledky našeho AOS překonají fixní investici do akciových indexů ve zhodnocení vstupního kapitálu, ve stabilitě a s menšími kapitálovými propady. Vyhodnocení zobrazíme formou tabulek a grafů.

Výsledkem diplomové práce bude software Automatický obchodní systém, který využije navržené investiční modely realizované pomocí modulů prediktor ML a

prediktor TECH. Software zajistí optimální nastavení všech konfiguračních předvoleb a vyhodnotí výkonnost na historických burzovních datech pomocí metody backtesting.

4. NÁVRH VLASTNÍHO ŘEŠENÍ

V této kapitole bude popsán návrh a realizace cíle diplomové práce - *Návrh investičního modelu*. Na základě teoretických předpokladů v předcházejících kapitolách budou navrženy a otestovány dva investiční modely TECH a ML. Model TECH pro předpověď obchodních signálů využívá poznatků technické analýzy a model ML je podstatě modifikovaný model TECH s přidáním predikční složky na základě algoritmů strojového učení. Míra stability výnosů pro každý akciový titul je hodnocena na historické datové řadě hodnot ukazatelů Sortino ratio, Sharpe ratio a Volatility.

Oba modely budou spuštěny v podpůrném prostředí softwarové aplikace Automatický obchodní systém (AOS), která byla pro tyto účely vytvořena v programovacím jazyku Python.

Aplikace AOS provede následující kroky:

- spustí se komponenta Strategie s optimalizovanými předvolbami. Tato komponenta představuje základ systému AOS a sekvenčně spustí níže uvedené kroky,
- pro každý akciový titul z indexu S&P 500, respektive S&P 100 budou načtena z databáze historická burzovní OHLC data z časového intervalu od 1.1.2001 do 31.12.2016 do datové struktury Pandas Dataframe,
- spustí se komponenta Portfolio, která uchovává otevřené pozice (nakoupené akciové tituly), sleduje profitabilitu uzavřených kontraktů a nakonec vypočítá finální statistiky. Počáteční fixní kapitál bude nastaven na fiktivních 100 000 dolarů a pro zvýšení realističnosti simulace bude započítán poplatek 1 dolar za každý uzavřený kontrakt (nákup nebo prodej),
- vyfiltrují se neperspektivní akciové tituly - vyřadí se ty, jejich průměrný denní volume za poslední dva roky byl méně než 1000 000 kontraktů,

- pro každý akciový titul se vypočítají hodnoty indikátorů SMA, RSI a ukazatelů Volatility , Sortino ratio, Sharpe ratio, které jsou vstupními parametry pro modely TECH a ML,
- investiční model TECH nebo ML, respektive komponenta Prediktor ML nebo TECH spočítá obchodní signály (doporučení pro nákup nebo prodej) pro každou akcii den po dni a uloží je do datové struktury Dataframe,
- spustí se backtesting, na základě vypočítaných obchodních signálů a den po dni (od nejstaršího dne po nejmladší) se zobchodují nákupy a prodeje akcií na fiktivní obchodní účet kalkulovaný přes komponentu Portfolio,
- komponenta Statistics vyhodnotí zobchodované uzavřené kontrakty uložené v komponentě Portfolio, vypočítá konečnou statistiku a porovná s benchmarkem S&P 500 respektive S&P 100. Výsledky se uloží do csv tabulek a zobrazí do grafů.

Výsledná aplikace nemá ambici být plnohodnotnou obchodní platformou, ale má demonstrovat výkonost investičních modelů TECH a ML ve srovnání s benchmarkem. V případě zájmu lze aplikaci upravit tak, aby i základně poučený uživatel byl schopen aplikaci používat a na základě jejich doporučení online obchodovat na burze.

4.1. Použité technologie

4.1.1. Hardware

Pro běh aplikace AOS byl zapůjčen výkonný server Dell 720r o konfiguraci:

- 2 x procesor Xeon, 2,6 GHz, 8 jader, (celkem 16 jader)
- 64 GB ram
- 2 x 2TB SATA disk
- operační systém Linux Centos 7

Vysoký výkon serveru bude využit při optimalizačních úlohách vyhledávající vhodné nastavení investičních modelů TECH a ML nebo při hledání vhodného algoritmu strojového učení.

Pro naprogramování aplikace dostačuje běžný notebook o konfiguraci:

- procesor Core i5, 2,4 GHz, 2 jádra
- 4 GB ram
- 120 SSD disk
- operační systém Windows 10, vývojové prostředí Pycharm

4.1.2. Python

Url programu: <https://www.python.org/>

Python je dynamický interpretovaný skriptovací jazyk navržený v roce 1991 Guido van Rossumem. (22) Python byl vytvořen tak, aby umožňoval tvorbu od jednoduchých skriptů až po plnohodnotné aplikace. Nabízí dynamickou kontrolu datových typů a podporuje objektově orientovaný, procedurální nebo funkcionální programátorský přístup. Python je zdarma (open source projekt) a k dispozici pro všechny běžné platformy (Linux, Unix, Windows, Mac OS). Python má strmou křivku učení a tak průměrně technicky zdatný člověk si základy osvojí v řádech dní. S pohledu výkonosti

je na tom Python ve srovnání s ostatními jazyky velmi dobře, protože výpočetně náročné rutiny jsou napsané v jazyku C a tedy velmi rychlé.

Hlavním důvodem výběru jazyka Python je bohatý ekosystém knihoven a modulů určených pro finančně ekonomické výpočty.

4.1.3. Pandas

Url knihovny: <http://pandas.pydata.org/>

Knihovna Pandas je určena pro analýzu a zpracování dat v tabulkovém formátu a pro práci s časovými řadami. Knihovna je vybavena velkým množstvím funkcí, které jsou navrženy pro finančně ekonomické výpočty. (17)

Dataframes a Series jsou základními objekty knihovny a odpovídají indexované tabulce nebo datové řadě. Knihovna podporuje mimo jiné tyto základní operace (17):

- načtení a uložení dat do csv souborů
- uložení celého objektu na disk pomocí metody *pickle*
- široká podpora datových typů: čísla, řetězce, kategorie, datумы a další
- ošetření chybějících dat, transformace dat mezi typy a formáty
- *reshaping* tvaru tabulky (změna počtu řádků a sloupců, T transformace)
- selekce a poziční, značkový slicing dat
- *up, down resampling* časových řad a aplikace agregačních funkcí (např. *sum, min, max, last, count* atd..)
- provádění výpočtu nad posuvným oknem (*moving windows*)

Knihovna Pandas je pro naši aplikaci AOS klíčová, protože objekt Dataframe představuje základní datovou strukturu, do které se budou nahrávat data a nad kterou se budou spouštět jednotlivé matematické výpočty a datové transformace.

4.1.4. Numpy

Url knihovny: <http://www.numpy.org/>

NumPy obsahuje rozsáhlou knihovnu pokročilých matematických funkcí pro zpracování a analýzu velkých vícerozměrných polí a matic.

4.1.5. Scipy

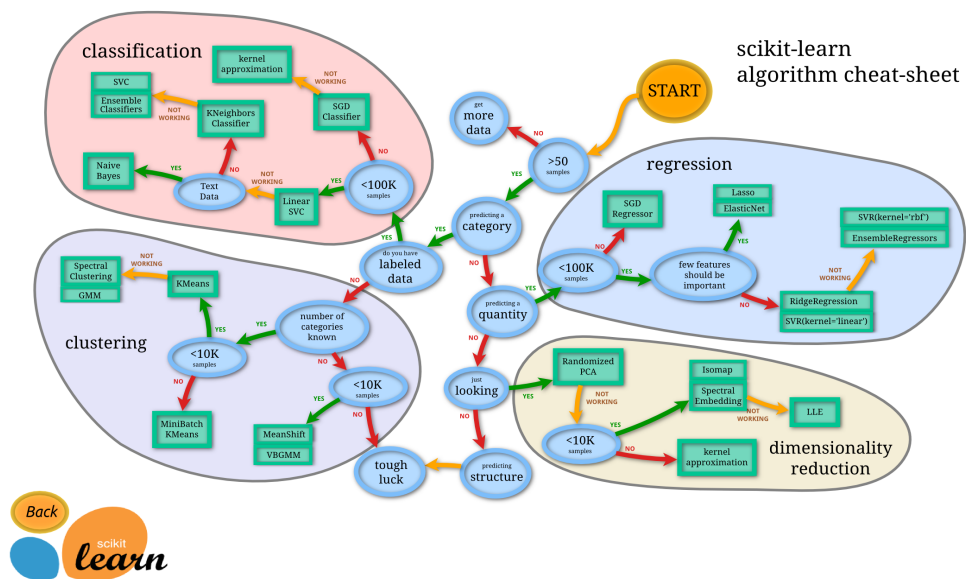
Url knihovny: <https://scipy.org/>

SciPy je knihovna pro vědecké výpočty a analýzu dat obsahujících řadu pokročilých matematických funkcí a metod.

4.1.6. Scikit-learn

Url knihovny: <http://scikit-learn.org/>

Knihovna Scikit-learn byla vytvořena vývojářem David Cournapeau v roce 2007 v rámci iniciativy Google summer code of project a je považována jako základní knihovna pro práci v oblasti strojového učení a je úzce provázána s knihovnami Scipy a Numpy. Knihovna podporuje celou rodinu algoritmů strojového učení, například classification, regression and clustering algorithms including support vector machines, random forests a gradient boosting, k-means. (24)



Obrázek 14: Algoritmy strojového učení podporované knihovnou Scikit-learn

(Zdroj: (32))

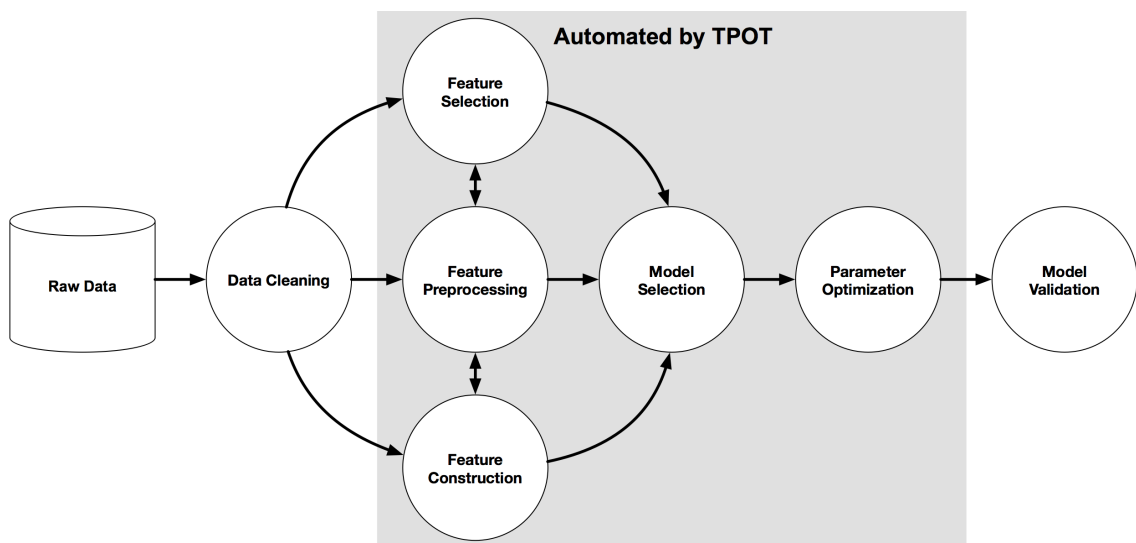
4.1.7. Tpot

Url programu: <http://thiever.github.io/tpot/>

Program Tpot slouží k výběru vhodného algoritmu strojového učení a pro optimalizaci hyper parametrů modelu strojového učení. Prohledání stavového prostoru všech možných kombinací parametrů je zajištěno genetickými algoritmy. (35) Tpot je vydáván pod licencí open source a je tedy zdarma.

Program Tpot funguje následovně:

- pomocí skriptu jsou programu předány vstupní trénovací a testovací data
- provede zarovnání, očištění a transformaci data pokud je to nutné (normalizaci, centrování, škálování)
- postupně vyzkouší všechny algoritmy s různými hodnotami hyperparametrů
- nejlepší kombinaci transformaci dat, algoritmu, hyperparametrů zapíše do výstupního souboru
- soubor obsahuje optimalizovaný kód s rutinami knihovny Scikit-learn



Obrázek 15: Schéma optimalizace algoritmu strojového učení pomocí programu Tpot
(Zdroj: (33))

```

from tpot import TPOTClassifier
from sklearn.datasets import load_iris
from sklearn.model_selection import train_test_split
import numpy as np

iris = load_iris()
X_train, X_test, y_train, y_test = train_test_split(iris.data.astype(np.float64),
    iris.target.astype(np.float64), train_size=0.75, test_size=0.25)

tpot = TPOTClassifier(generations=5, population_size=50, verbosity=2)
tpot.fit(X_train, y_train)
print(tpot.score(X_test, y_test))
tpot.export('tpot_iris_pipeline.py')

```

Obrázek 16: Spouštěcí skript programu Tpot
(Zdroj: vlastní zpracování)

```

import numpy as np

from sklearn.model_selection import train_test_split
from sklearn.naive_bayes import GaussianNB
from sklearn.pipeline import make_pipeline
from sklearn.preprocessing import Normalizer

# NOTE: Make sure that the class is labeled 'class' in the data file
tpot_data = np.recfromcsv('PATH/TO/DATA/FILE', delimiter='COLUMN_SEPARATOR', dtype=np.float64)
features = np.delete(tpot_data.view(np.float64).reshape(tpot_data.size, -1),
    tpot_data.dtype.names.index('class'), axis=1)
training_features, testing_features, training_classes, testing_classes = \
    train_test_split(features, tpot_data['class'], random_state=42)

exported_pipeline = make_pipeline(
    Normalizer(),
    GaussianNB()
)

exported_pipeline.fit(training_features, training_classes)
results = exported_pipeline.predict(testing_features)

```

Obrázek 17: Obsah výstupního souboru programu Tpot
(Zdroj: vlastní zpracování)

Na obrázku 16. a 17. vidíme ukázkový kód optimalizační úlohy pro Tpot. Obrázek 16. ukazuje kód pro optimalizaci klasifikátoru včetně vstupních testovacích a trénovacích dat. Obrázek 17. je výstupní optimalizovaný kód pro knihovnu Scikit-learn. Výsledný kód lze s minimálními úpravami použít ve vlastní aplikaci.

Program Tpot bude použit pro optimalizaci investičního modelu ML, respektive softwarové komponenty Predictor ML.

4.1.8. PostgreSQL

Url programu: <https://www.postgresql.org/>

PostgreSQL je objektově-relační databáze, která je vydávána pod licencí open source a je tedy zdarma. PostgreSQL se vyznačuje výborným výkonem a bezproblémovým přístupem z jazyka Python

Databáze PostgreSQL bude využita v komponentě Data provider jako úložiště historických burzovních dat. Předpokládaných několik milionů záznamů databáze bezproblémově zvládne.

4.2. Implementace indikátorů a ukazatelů v jazyku Python

Pro potřeby Automatického obchodního systému byly implementovány vybrané indikátory a ukazatele do Python funkcí.

4.2.1. Jednoduchý klouzavý průměr (SMA) a exponenciální klouzavý průměr (EMA)

```
def calc_sma(sr_column, window):
    """ Return simple moving average """
    sr_sma = sr_column.rolling(window=window).mean()
    return sr_sma

def calc_ema(sr_column, window):
    """ Return exponential moving average """
    sr_sma = sr_column.ewm(span=window).mean()
    return sr_sma
```

Obrázek 18: Zdrojový kód indikátoru SMA a EMA v jazyku Python

(Zdroj: vlastní zpracování)

Funkce *calc_sma* a *calc_ema* mají dva parametry. Datovou strukturu Pandas Series, obsahující denní close cenu (*sr_column*) a časové okno (*window*) ve dnech, pro které se klouzavý průměr počítá.

Relative Strength index z jednoduchého klouzavého průměru (RSI SMA)

```
def calc_rsi_sma(sr_column, window):
    """ Return RSI SMA """

    delta = sr_column.diff()
    delta = delta[1:]

    up, down = delta.copy(), delta.copy()
    up[up < 0] = 0
    down[down > 0] = 0

    roll_up = up.rolling(window=window).mean()
    roll_down = down.abs().rolling(window=window).mean()

    RS = roll_up / roll_down
    sr_rsi = 100.0 - (100.0 / (1.0 + RS))
    return sr_rsi
```

Obrázek 19: Zdrojový kód indikátoru RSI SMA v jazyku Python
(Zdroj: vlastní zpracování)

Funkce `calc_rsi_sma` má dva parametry. Datovou strukturu Pandas Series, obsahující denní close cenu investičního instrumentu (`sr_column`) a časové okno (`window`) ve dnech, pro které se jednoduchý klouzavý průměr počítá.

4.2.2. Relative Strength index z exponenciálního klouzavého průměru (RSI EMA)

```
def calc_rsi_ema(sr_column, window):  
    """ Return RSI EMA"""  
  
    delta = sr_column  
    delta = delta[1:]  
  
    up, down = delta.copy(), delta.copy()  
    up[up < 0] = 0  
    down[down > 0] = 0  
  
    roll_up = up.ewm(span=window).mean()  
    roll_down = down.abs().ewm(span=window).mean()  
  
    RS = roll_up / roll_down  
    sr_rsi = 100.0 - (100.0 / (1.0 + RS))  
    return sr_rsi
```

Obrázek 20: Zdrojový kód indikátoru RSI EMA v jazyku Python

(Zdroj: vlastní zpracování)

Funkce `calc_rsi_ema` má dva parametry. Datovou strukturu Pandas Series, obsahující denní *close* cenu (*sr_column*) a časové okno (*window*) ve dnech, pro které se exponenciální klouzavý průměr počítá.

4.2.3. Sortino ratio

```
def calc_sortino(sr_returns, days, benchmark=0.0):
    """ Return sortino ratio """

    def sortino(returns, days, benchmark):
        mean = np.mean(returns)
        negative_returns = returns[returns < benchmark]
        downside_risk = np.sqrt(np.mean((negative_returns ** 2)))
        sortino = mean * np.sqrt(days) / downside_risk
        return sortino

    sr_sortino = sr_returns.rolling(window=days).apply(lambda x: sortino(x, days=days, benchmark=benchmark))
    return sr_sortino
```

Obrázek 21: Zdrojový kód ukazatele Sortino ratio v jazyku Python
(Zdroj: vlastní zpracování)

Funkce *calc_sortino* má tři parametry. Datovou strukturu Pandas Series, obsahující změnu *close* ceny na denní bázi v procentech (*sr_returns*), počet dní pro které se Sortino ratio počítá (*days*) a výnosovou míru, se kterou se Sortino ratio srovnává (*benchmark*).

4.2.4. Volatilita

```
def calc_volatility(sr_returns, days):
    """ Return volatility """

    def volatility(returns, days):
        volatility = np.std(returns) * np.sqrt(days)
        return volatility

    sr_volatility = sr_returns.rolling(window=days).apply(lambda x: volatility(x, days=days))
    return sr_volatility
```

Obrázek 22: Zdrojový kód ukazatele Volatility v jazyku Python
(Zdroj: vlastní zpracování)

Funkce *calc_volatility* má dva parametry. Datovou strukturu Pandas Series, obsahující změnu *close* ceny na denní bázi v procentech (*sr_returns*), a počet dní (*days*), pro které se Volatilita počítá.

4.2.5. Maximal Drawdown

```
def calc_max_dd(sr_returns, days):
    """ Return maximal drawdown """

    def max_dd(returns):
        r = pd.Series(returns).add(1).cumprod()
        dd = r.div(r.cummax()).sub(1)
        max_dd = dd.min()
        return max_dd * 100

    sr_max_dd = sr_returns.rolling(window=days).apply(lambda x: max_dd(x))
    return sr_max_dd
```

Obrázek 23: Zdrojový kód ukazatele Maximal Drawdown v jazyku Python
(Zdroj: vlastní zpracování)

Funkce *calc_max_dd* má dva parametry. Datovou strukturu Pandas Series, obsahující změnu *close* ceny na denní bázi v procentech (*sr_returns*), a počet dní (*days*), pro které se Maximal Drawdown počítá.

4.2.6. Sharpe ratio

```
def calc_sharpe(sr_returns, days, benchmark=0.0):
    """ Return sharpe ratio """

    def sharpe(returns, days, benchmark):
        volatility = np.std(returns)
        sharpe = (np.mean(returns) - benchmark) / volatility
        return sharpe

    sr_sharpe = sr_returns.rolling(window=days).apply(lambda x: sharpe(x, days=days, benchmark=benchmark))
    return sr_sharpe
```

Obrázek 24: Zdrojový kód ukazatele Sharpe ratio v jazyku Python
(Zdroj: vlastní zpracování)

Funkce *calc_sortino* má tři parametry. Datovou strukturu Pandas Series, obsahující změnu *close* ceny na denní bázi v procentech (*sr_returns*), počet dní pro které se Sortino ratio počítá (*days*) a výnosovou míru, se kterou se Sharpe ratio srovnává (*benchmark*).

4.3. Investiční modely TECH a ML

4.3.1. Obchodní strategie Larry Connors RSI 2

Oba investiční modely TECH a ML vycházejí z obchodní RSI 2 strategie vyvinutou obchodníkem Larry Connors.⁽³⁴⁾ Strategie je typu *mean-reversion*, což znamená, že se vyhledávají obchodní příležitosti v čase, kdy se cena aktiva provádí korekci a hledá rovnovážný stav - nabídka aktiva odpovídá poptávce. Strategie je poměrně jednoduchá, Connors navrhuje hledat nákupní příležitosti, když se hodnota ukazatele RSI 2 dostane pod 10, což znamená, že je akcie silně přeprodaná a cena bude stoupat. Naopak, příležitosti k prodeji lze hledat, když se hodnota ukazatele RSI 2 dostane nad 90, což znamená, že je akcie silně překoupená a cena bude klesat.

Strategie se aplikuje na close cenu aktiva a postup je následující:

- určí se hlavní trend indikátorem SMA 200 a minoritní trend indikátorem SMA 5
- vstupujeme do dlouhé pozice při vzestupném hlavním trendu, akcii nakupujeme za podmínek:

$close\ cena > SMA\ 200, close\ cena > SMA\ 5, RSI\ 2 < 20$

- vstupujeme do krátké pozice při sestupném hlavním trendu, tzn. akcii „šortujeme“² za podmínek:

$close\ cena < SMA\ 200, close\ cena < SMA\ 5, RSI\ 2 > 80$

- vystupujeme z dlouhé pozice, tzn. akcii prodáváme za podmínek:

$close\ cena > SMA\ 5, RSI > 70$

- vystupujeme z krátké pozice, tzn. akcii „nakupujeme“ za podmínek:

$close\ cena < SMA\ 5, RSI < 30$

² *Short selling*, „šortování“, prodej na krátko – investor spekuluje na poklesu ceny investičního instrumentu. Technicky je řešeno tak, že si investor od svého brokera vypůjčí akcie, které okamžitě prodá na trhu a čeká na pokles ceny, za kterou akcie nakoupí zpět a vrátí brokerovi. Rozdíl ceny prodeje a nákupu je realizovaný zisk v případě klesající ceny nebo ztráta pokud cena akcie roste.



Obrázek 25: Čárový graf akcie AAPL s indikátory SMA 5, SMA 200 a RSI 2
(Zdroj: StockCharts.com)

Na obrázku 25. je zobrazen čárový graf zachycující cenový vývoj pro akcii AAPL v časovém rozmezí 1.1.2016 až 31.12.2016., graf je doplněn o oscilátor SMA 5, SMA 200 a RSI 2 (spodní graf). Oba grafy sdílejí stejnou časovou osu. Ve grafu jsou obsažené všechny potřebné indikátory pro zjištění obchodních signálů dle strategie Larry Connors RSI 2.

Dle tvůrce Larry Connors není doporučeno používat stop-loss, protože strategie je typu kup a drž (*buy and hold*) a stop-loss order přináší pouze zhoršení výkonnosti. *Stop-loss order* najde opodstatnění v případě použití páky, ale to už je na zvážení každého obchodníka. (34)

Strategie kup a drž (*buy and hold*) - je to dlouhodobá strategie v rádech měsíců až let, která je vhodná pro dlouhodobé investory. Obchodník nakoupí investiční instrument většinou bez použití páky a spoléhá na dlouhodobý vzestupný trend celého trhu. Výhodou strategie je vysoká stabilita a „bezpečnost“ výnosu a skutečnost, že obchodník nemusí svému portfoliu věnovat každodenní péči. Nevýhodou je menší výnosnost ve srovnání s krátkodobými strategiemi. (5)

4.3.2. Obchodní strategie AOS

Naše obchodní strategie AOS vychází ze výše zmíněné strategie Larry Connors RSI 2 (34), zjednodušuje podmínky při generování prodejního signálu a rozšiřuje ji o podpůrnou predikci strojovým učením, složku stability vyjádřenou ukazatelem Sortino ratio a podmínkou minimálního průměrného denního objemu obchodů (volume). Pro zvažování míry stability a budoucích výnosů byl vybrán ukazatel Sortino ratio, protože jeho hodnota není ovlivněna negativními výnosy na rozdíl od Sharpe ratio. Podmínka minimálního průměrného denního objemu obchodů (volume) omezuje riziko obchodování s akciovými tituly, jejichž cena je snáze manipulovatelná velkými institucionálními investory. Dlouhodobý nízký denní volume signalizuje investorskou nedůvěru nebo nezájem o akcii a tím pádem její problematickou cenovou predikci a potencionálně vyšší volatilitu.

Strategie AOS je dlouhodobá strategie typu kup a drž (*buy and hold*) a předpokládá obchodování na denní bázi a investiční horizont v řádech měsíců až let. Obchodovány jsou pouze dlouhé pozice (*long positions*). Je povolen nákup pouze jedné akcie v rámci jednoho obchodního dne a maximální počet akcií v portfoliu je omezen na 10.

Strategie nepoužívá *stop-loss order* protože:

- neobchodujeme na krátko („nešortujeme“) a tedy nejsme technicky ani časově limitováni brokerem
- nepoužíváme páku, takže nám nehrozí násilné uzavření pozice brokerem z důvodu nedostatečného *marginu*.
- vycházíme z hypotézy, že z dlouhodobého hlediska akcie rostou

Predikci cenového vývoje konkrétní akcie pro příští obchodní periodu (den + 1) zajišťuje investiční model TECH a ML.

4.3.3. Investiční model TECH

Investiční model TECH je založen na principu technické analýzy a obchodní signály generuje podle pravidel:

Pro **nákupní signál** musí být splněny současně tyto podmínky:

```
1. close cena > SMA 200
2. RSI 2 < 10
3. roční Sortino ratio > 1
4. průměrné roční Volume > 1000 000
```

Obrázek 26: Pseudokód nákupního signálu pro investiční model TECH
(Zdroj: vlastní zpracování)

ad 1) akcie překonává trh

ad 2) akcie je přeprodaná

ad 3 a 4) větší pravděpodobnost, že akcie má stabilnější budoucí výnosy

Pro **prodejní signál** musí být splněna podmínka:

```
1. close cena > SMA 5
```

Obrázek 27: Pseudokód prodejního signálu pro investiční model TECH
(Zdroj: vlastní zpracování)

ad 1) akcie překonává trh a je nad 5 denním maximem, můžeme realizovat zisk

4.3.4. Investiční model ML

Investiční model ML je založen na algoritmech strojového učení a rozšiřuje model TECH o doplňkovou podmínku pro nákupní signál (bod 5).

Model strojového učení je trénován pro každou akcii zvlášť a na vzorku burzovních OHLC dat, která jsou starší než data pro backtesting, vyhneme se tak *bias* problému a *overfittingu*. (25)

Algoritmus pro sestavení modelu strojového učení a nastavení hyperparametrů bude nalezeno optimalizačním programem Tpot.

Pro **nákupní signál** musí být splněny současně tyto podmínky:

```
1. close cena > SMA 200
2. RSI 2 < 10
3. roční Sortino ratio > 1
4. průměrné roční Volume > 1000 000
5. ML model predikuje růst
```

Obrázek 28: Pseudokód nákupního signálu pro investiční model ML
(Zdroj: vlastní zpracování)

ad 1) akcie překonává trh

ad 2) akcie je přeprodaná

ad 3 a 4) větší pravděpodobnost, že akcie má stabilnější budoucí výnosy

ad 5) podle modelu strojového učení má akcie růstový potenciál

Pro **prodejní signál** musí být splněna podmínka:

```
1. close cena > SMA 5
```

Obrázek 29: Pseudokód prodejního signálu pro investiční model ML
(Zdroj: vlastní zpracování)

ad 1) akcie překonává trh a je nad 5 denním maximem, můžeme realizovat zisk

4.3.5. Selektování portfolia

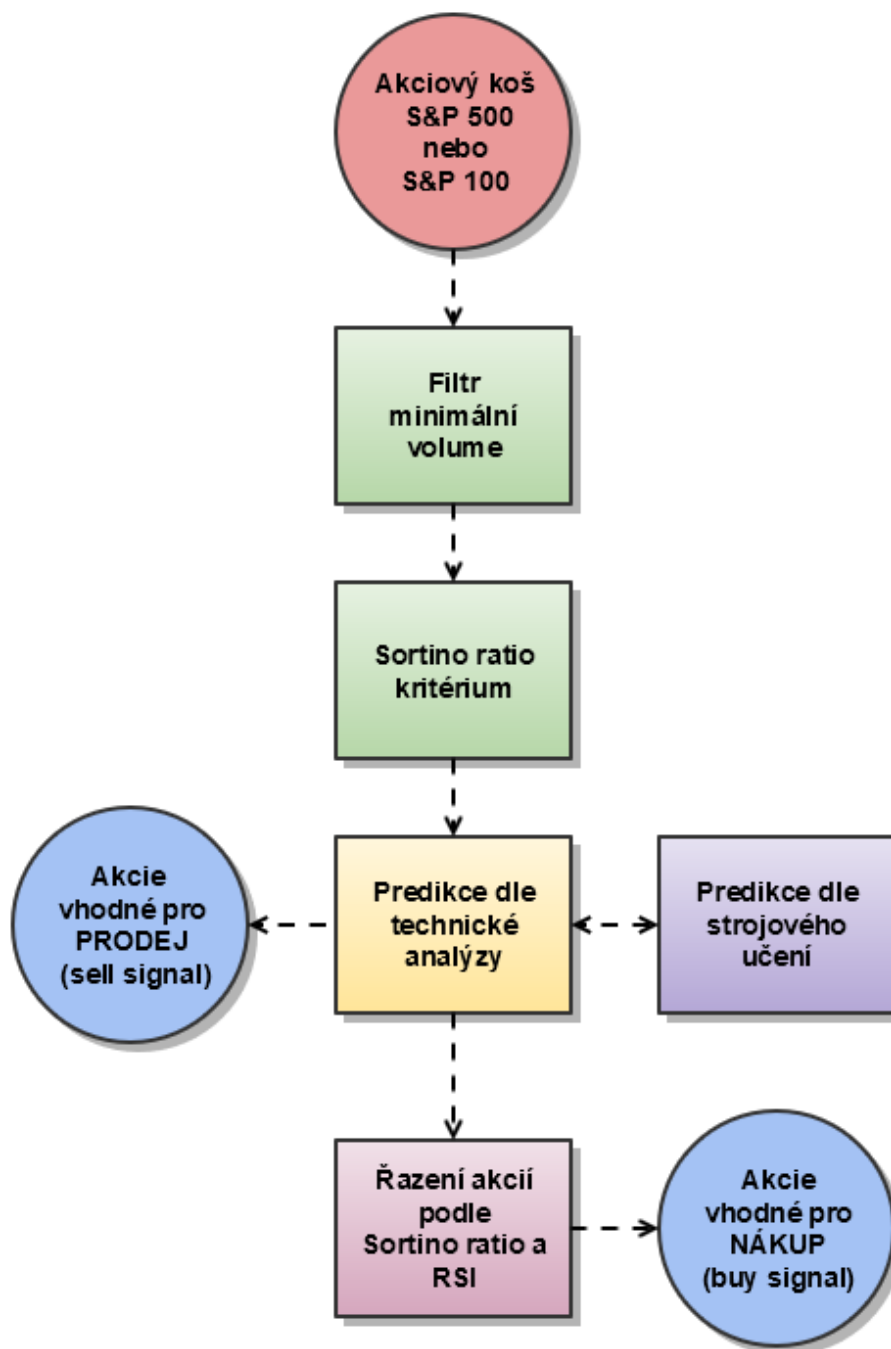
Strategie AOS je spuštěna s parametry:

- obchodovaný seznam akcií nastaven na akciový koš z indexu S&P 100 nebo S&P 500,
- je zvolen investiční model TECH (technická analýza) nebo ML (technická analýza a strojové učení), podle kterého se generují obchodní signály,
- maximální počet akcií v portfoliu nastaven na 10,
- povolen nákup pouze jedné akcie za obchodní den,
- investovaný kapitál nastaven na 100 000 dolarů.

Smyčka selektování portfolia na denní bázi (kroky):

1. je nahrán seznam akcií z indexu S&P 100 nebo S&P 500,
2. pro každou akcii ze seznamu jsou nahrána burzovní OHLC data,
3. vyřazení akcií, které nesplňují podmínku minimálního Volume,
4. vyřazení akcií, které nesplňují podmínku minimálního Sortino ratio ,
5. pro každou akcii jsou modulem Predictor TECH (investiční model TECH) nebo Predictor ML (investiční model ML) vypočítány indikátory SMA, RSI predikován cenový vývoj a při splnění podmínek nastaven obchodní signál **Koupit** nebo **Prodat** (*Buy or Sell*),
6. jsou prodány všechny akcie z portfolia, pro které je nastaven signál **Prodat**,
7. seznam akcií s obchodním signálem **Koupit** je seřazen podle hodnoty indikátoru RSI 2 (nejmenší první) a Sortino ratio (největší první),
8. je nakoupena pouze jedna (první) akcie ze seznamu vytvořeného v bodu 8., pokud byla tato akcie prodána v bodu 7., je přeskočena a nakoupena druhá ze seznamu a tak dále,
9. přechod na následující obchodní den.

Strategie AOS - denní proces selekce portfolia



Obrázek 30: Proces denní selekce portfolia dle strategie AOS

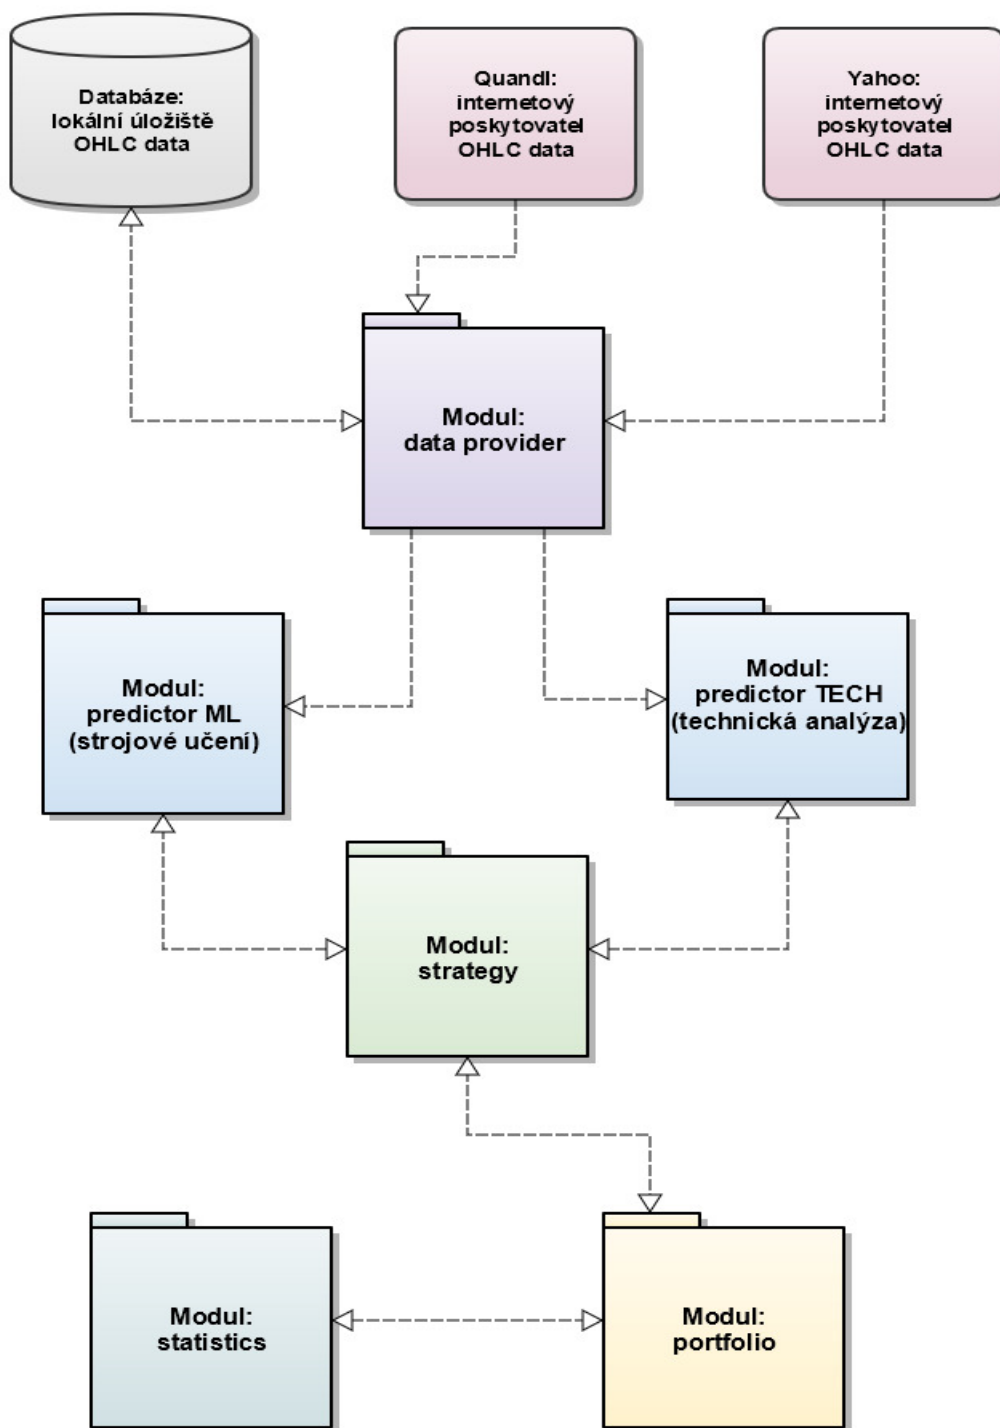
(Zdroj: vlastní zpracování)

4.3.6. Komponenty AOS

Automatický obchodní systém je složen ze 7 základních komponent:

- Databáze PostgreSQL – slouží jako úložiště historických burzovních OHLC dat.
- Data provider – poskytuje OHLC data pro ostatní komponenty formou objektu Dataframe a aktualizuje data z internetových zdrojů. (class *DataProvider* v souboru *core.py*).
- Predictor TECH – pro každou akcii počítá indikátory SMA, RSI a ukazatele Sortio ratio, predikuje cenový vývoj na základě principů technické analýzy a naší obchodní strategie a generuje obchodní signály. (class *PredictorTECH* v souboru *core.py*).
- Predictor ML – rozšiřuje komponentu (třidu) Predictor TECH o predikci vývoje trendu modelu strojového učení. (class *PredictorML* v souboru *core.py*).
- Strategy – je hlavní výkonnou komponentou AOS pro vykonávání backtestingu. Využívá komponent Predictor ML a TECH pro predikci cenového vývoje akcií a generování obchodních signálů. Pro money management a ukládání tržních pozic využívá komponentu Portfolio. (class *Strategy* v souboru *core.py*).
- Portfolio – spravuje investovaný kapitál a tržní pozici (class *Portfolio* v souboru *core.py*).
- Statistics – generuje statistiku backtestingu do textových výstupů, grafů a csv tabulek. (class *Portfolio* v souboru *core.py*).

Automatický obchodní systém



Obrázek 31: Schéma modulů Automatického obchodního systému (AOS)

(Zdroj: vlastní zpracování)

4.3.7. Spuštění a konfigurace systému AOS

AOS se spouští skriptem: *aos.py* a výpočet pro S&P 100 od 2.1. 2001 do 31.12. 2016 s prediktorem TECH na běžném notebooku trvá přibližně 3 minuty. Výsledek je dle nastavení zobrazen v textové tabulce, zobrazen do grafu nebo uložen do csv souboru na disk.

```
[krnavek@dp]# /opt/python3/bin/python3 /aos/aos.py

-----
                                FINAL STATISTICS
-----

Strategy name: AOS TECH vs S&P 100
Trade period: 16 years, (2001-01-02 - 2016-12-30)
Initial equity: 100000

----- TRADES AND FEES -----

Trades: bid/ask/all: 3181/3181/6362
Fee per trade: 1
Total fee expense: 6362.00

----- STABILITY OF EQUITY -----

Max annual drawdown: -11.49(%) (2002)
Mean annual max drawdown: -5.43(%)
Max annual sortino: 4.37 (2013)
Mean annual sortino: 3.20
Max annual sharpe: 0.22 (2013)
Mean annual sharpe: 0.17
Max annual volatility: 0.11 (2002)
Mean annual volatility: 0.08

----- EQUITY RETURN -----

Mean annual return: 11.14(%)
Max annual return: 28.12(%) (2001)
Min annual return: 1.62(%) (2016)
Total equity: 534.37(%)
Total equity: 534374.00
```

Obrázek 32: Spuštění strategie AOS na operačním systému Linux Centos 7
(Zdroj: vlastní zpracování)

Výstupní statistika AOS obsahuje ukazatele:

- počet uskutečněných transakcí (nákupů a prodejů akcií),
- výši poplatku za jednu transakci (*fee*) a celkovou výše poplatků,
- maximální a průměrný roční Drawdown (procentní propad celkového kapitálu),
- maximální a průměrný roční Sortino ratio (indikuje míru stability),

- maximální a průměrný roční Sharpe ratio (indikuje míru stability),
- maximální a průměrná roční Volatilita (indikuje míru stability),
- maximální, průměrnou a minimální roční výnosovou míru v procentech,
- celkový výnos absolutní hodnotě a v procentech.

Konfigurace jednotlivých komponent AOS se nastavuje ve spustitelném skriptu *aos.py* formou nastavení proměnných.

Klíčové proměnné nastavení AOS:

- `ML_START_DATE` - datum začátku tréningu modelu strojové učení,
- `ML_END_DATE` - datum ukončení tréningu modelu strojové učení,
- `TRADE_START_DATE` – datum začátku backtestingu,
- `TRADE_END_DATE` - datum ukončení backtestingu,
- `STOCK_INDEX` - akciový koš (akciový index), ze kterého je portfolio selektováno, S&P 100 nebo S&P 500,
- `PREDICTOR` - typ prediktoru použitého během backtestingu, Predictor TECH nebo Predictor ML.

```

# time period of training machine learning model
# -----
ML_START_DATE = arrow.get(2001, 1, 1).datetime
ML_END_DATE = arrow.get(2005, 1, 1).datetime

# time period of backtesting
# -----
TRADE_START_DATE = arrow.get(2005, 1, 1).datetime
TRADE_END_DATE = arrow.get(2016, 12, 31).datetime

# selecting portfolio from stock index
# -----
STOCK_INDEX_TICKER = TICKER_SP100
STOCK_INDEX = STOCK_INDEX_CHOICE_SP100

# set type of predictor
# -----
PREDICTOR = PREDICTOR_ML

# setting for predictor
# -----
window_sma_long = 200
window_sma_short = 6
windows_rsi = 2
rsi_limit = 10
min_volume = 1000_000
windows_sortino = 252
sortino_limit = 1

# setting for money management
# -----
initial_money = 100_000
count_money_parts = 10
fee_per_trade = 1
max_trades_per_day = 1
max_positions_per_ticker = 4
max_positions_total = 10
money_reinvest = True

# output settings
# -----
generate_cvs = False
show_graph = False
save_dfs = False
console = False

```

Obrázek 33: Konfigurace strategie AOS v souboru *aos.py*
(Zdroj: vlastní zpracování)

4.3.8. Historická burzovní data

Historická burzovní data na denní bázi lze bezplatně stáhnout z internetu například od společnosti Yahoo nebo Quandl. V AOS použijeme pro zvýšení spolehlivosti oba zdroje, protože data z jednoho zdroje nemusí být vždy 100% kvalitní a mohou obsahovat chyby nebo chybějící položky. Křížovou kontrolou, průměrováním a doplněním chybějících položek z jiného zdroje vyřešíme většinu datových chyb.

Data pro aktuální obchodní den jsou k dispozici až po uzavření burzy a s určitým zpožděním, tedy po 22:00 středoevropského času. V případě potřeby lze realtime data získat formou placené služby. Pro účely backtestingu nám plně dostačují neplacená data.

Denní burzovní OHLC³ data pro každý akciový titul obsahují 7 položek.

1. *trade date* – datum obchodního dne,
2. *volume* – objem uzavřených obchodů, součet nákupů a prodejů,
3. *open* - otevírací denní cenu,
4. *high* – nejvyšší denní cenu,
5. *low* – nejnižší denní cenu,
6. *close* - uzavírací denní cenu,
7. *adj_close* - uzavírací denní cenu očištěnou o dividendy a akciový split.

3 Podle názvů položek 4 až 6 se data nazývají zkráceně OHLC data

Trade date	Volume	Open	High	Low	Close	Adj_close
2016-12-01	4635700	161.949997	162.199997	158.300003	159.820007	158.566241
2016-12-02	2740900	159.0	160.289993	158.410004	160.020004	158.764669
2016-12-05	3447100	160.850006	161.149994	159.589996	159.839996	158.586073
2016-12-06	2859000	160.130005	160.789993	158.929993	160.350006	159.092082
2016-12-07	4435100	160.600006	165.179993	160.389999	164.789993	163.497238
2016-12-08	3266400	164.869995	166.0	164.220001	165.360001	164.062774
2016-12-09	3146900	165.179993	166.720001	164.600006	166.520004	165.213677
2016-12-12	3392300	166.720001	166.789993	165.070007	165.5	164.201675
2016-12-13	5932300	165.679993	169.949997	165.679993	168.289993	166.969781
2016-12-14	4124200	168.369995	169.889999	167.449997	168.509995	167.188056
2016-12-15	3388600	168.009995	169.850006	167.779999	168.020004	166.70191
2016-12-16	7120600	168.970001	169.110001	166.059998	166.729996	165.422021
2016-12-19	2955900	166.830002	167.259995	166.0	166.679993	165.372411
2016-12-20	2174600	167.490005	168.25	166.449997	167.600006	166.285207
2016-12-21	3575700	166.25	167.940002	165.25	167.330002	166.017321
2016-12-22	2802600	167.360001	168.229996	166.580002	167.059998	165.749434
2016-12-23	1701200	167.0	167.490005	166.449997	166.710007	165.402189
2016-12-27	1397500	166.979996	167.979996	166.850006	167.139999	165.828809
2016-12-28	1757500	167.289993	167.740005	166.0	166.190002	164.886264
2016-12-29	1663500	166.020004	166.990005	166.0	166.600006	165.293051
2016-12-30	2952800	166.440002	166.699997	165.5	165.990005	164.687836

Tabulka 6: Burzovní OHLC data pro akcii IBM ze zdroje Yahoo

(Zdroj: vlastní zpracování)

V tabulce 6 vidíme ukázkou denních dat pro akcii IBM za měsíc prosinec 2016

Burzovní OHLC data stáhneme kódem (obrázek 34) a uložíme do databázové struktury (obrázek 35) pro další zpracování.

```
def get_ticker(ticker, provider, start_date, end_date):
    """ get OHLC data for ticker in Dataframe """

    if provider == PROVIDER_CHOICE_YAHOO:
        df = data.DataReader(ticker, 'yahoo', start_date, end_date)

    if provider == PROVIDER_CHOICE_QUANDL:
        df = quandl.get(f'WIKI/{ticker}', start_date, end_date)

    return df
```

Obrázek 34: Zdrojový kód pro stažení burzovních dat OHLC ze zdroje Yahoo a Quandl

(Zdroj: vlastní zpracování)


```

class StockIndex(AbstractModel):
    """ relation ticker - index """

    STOCK_INDEX_CHOICE_SP100 = 'sp100'
    STOCK_INDEX_CHOICE_SP500 = 'sp500'
    STOCK_INDEX_CHOICE_WORLD_INDICES = 'indices'

    STOCK_INDEX_CHOICES = (
        (STOCK_INDEX_CHOICE_SP100, 'S&P100'),
        (STOCK_INDEX_CHOICE_SP500, 'S&P500'),
        (STOCK_INDEX_CHOICE_WORLD_INDICES, 'Indices')
    )

    name = models.CharField(choices=STOCK_INDEX_CHOICES, max_length=10)
    ticker = models.CharField(max_length=10)

class Stock(AbstractModel):
    """ stock metadata """

    ticker = models.CharField(max_length=10, unique=True)
    company = models.CharField(max_length=128, blank=True, null=True)
    sector = models.CharField(max_length=128, blank=True, null=True)
    industry = models.CharField(max_length=128, blank=True, null=True)
    listing_day = models.DateTimeField(null=True, blank=True)
    listing_day_txt = models.CharField(max_length=128, blank=True)
    delisting_day = models.DateTimeField(null=True, blank=True)

class OHLC(AbstractModel):
    """ OHLC data for stock """

    PROVIDER_CHOICE_YAHOO = "yahoo"
    PROVIDER_CHOICE_QUANDL = "quandl"

    PROVIDER_CHOICES = (
        (PROVIDER_CHOICE_YAHOO, "Yahoo"),
        (PROVIDER_CHOICE_QUANDL, "Quandl"),
    )

    stock = models.ForeignKey(Stock, on_delete=models.CASCADE)
    provider = models.CharField(choices=PROVIDER_CHOICES, max_length=10)
    day = models.DateTimeField()
    open = models.FloatField()
    high = models.FloatField()
    low = models.FloatField()
    close = models.FloatField()
    adj_close = models.FloatField()
    volume = models.IntegerField()

```

Obrázek 35: Zdrojový kód databázové struktury pro uchování burzovních OHLC dat
(Zdroj: vlastní zpracování)

4.4. Optimalizace investičních modelů

Strategie AOS se musí být spuštěna se správnými parametry, aby podávala dobré výsledky. Proces hledání optimálních parametrů se nazývá optimalizace investičního modelu. V případě investičního modelu TECH budeme hledat hodnoty pro parametry *window_sma_long*, *window_sma_short*, *windows_rsi*, *rsi_limit*, *windows_sortino* a *sortino_limit* a pro investiční model ML hledáme vhodný algoritmus strojového učení. Aby výsledky následného backtestingu nebyly poznamenány *bias* problémem, tak rozdělíme data na tréninková a testovací dle metody dopředné optimalizace a testování.

4.4.1. Metoda dopředné optimalizace a testování

Burzovní OHLC data 2001 - 2016	
2001 - 2005	2005 - 2016
	BACK TESTING
TRÉNINKOVÁ DATA PRO STROJOVÉ UČENÍ	
OPTIMALIZACE PARAMETRŮ AOS	

Obrázek 36: Vizualizace metody dopředné optimalizace a testování

(Zdroj: vlastní zpracování)

Při optimalizaci parametrů AOS a hledání optimálního algoritmu strojového učení použijeme princip metody dopředné optimalizace a testování (*forward performance optimization and testing*). Aplikací metody zabráníme nežádoucímu jevu tzv. „optimalizace na míru“ (*bias problem*), který je důsledkem optimalizací prováděnou na celém rozsahu dat, protože výstup optimalizace je příliš specializován pro konkrétní vzorek dat. Následný backtesting je pak zkreslen a nerealisticky dosahuje lepších výsledků. (26)

Optimalizaci investičních modelů budeme provádět podle kroků:

- burzovní data rozdělíme na dva díly- trénovací díl o velikosti $\frac{1}{4}$ a testovací díl o velikosti $\frac{3}{4}$,
- trénovací díl musí být časově starší než díl pro backtesting, protože chceme zachovat časovou kauzalitu a posloupnost v burzovních datech,
- na trénovacích datech provedeme optimalizaci parametrů AOS a optimalizaci algoritmus strojového učení,
- investiční modely TECH a ML nastavíme dle optimalizací a provedeme backtesting na testovacím dílu dat.

4.4.2. Genetické algoritmy

Při hledání optimálního algoritmu strojového učení použijeme genetické algoritmy. Genetické algoritmy využívají heuristické postupy, které se snaží aplikací principů evoluční biologie nalézt řešení složitých problémů. Princip fungování je takový, že je vypočítána generace jedinců, kdy každý jedinec představuje jedno konkrétní řešení problému. Hodnotu řešení reprezentuje každý jedinec výsledkem tzv. fitness funkce. Populace jedinců postupně přechází mezi generacemi, její jedinci jsou ovlivňováni evolučními procesy (křížení, mutace, selekce,...) a generují nové výsledky fitness funkcí. Celý proces je iterován do doby, kdy je řešení nejlepšího jedince pro nás uspokojivé nebo když dojde čas určený pro výpočet. Genetické algoritmy najdou uplatnění při řešení optimalizačních úloh a jsou využívány programem Tpot. ()

4.4.3. Optimalizace investičního modelu TECH

Při optimalizaci investičního modelu TECH hledáme vhodné parametry pro strategie AOS pomocí softwarové smyčky, která prochází všechny kombinace námi definovaného prohledávaného prostoru parametrů (v našem případě 18900 kombinací) a vyhodnocuje výsledky metody *fitness()*.

Výstupem metody `fitness()` je:

- průměrná roční procentní výnosová míra (*mean annual percentage return*),
- průměrná roční hodnota Volatility (*mean annual volatility*),
- maximální roční hodnota Volatility (*max annual volatility*),
- průměrná roční hodnota Sortino ratio (*mean annual sortino ratio*),
- maximální roční hodnota Sortino ratio (*max annual sortino ratio*),
- průměrná roční hodnota Max Drawdown (*mean annual max drawdown*),
- maximální roční hodnota Max Drawdown (*max annual drawdown*).

```
space_of_params = {
    'window_sma_long': [195, 197, 200, 203, 205],
    'window_sma_short': [4, 5, 6],
    'windows_rsi': [2, 3, 4],
    'rsi_limit': [8, 9, 10, 11],
    'windows_sortino': [64, 88, 168, 210, 252],
    'sortino_limit': np.linspace(0.0, 3.0, 21)
}
```

Obrázek 37: Prohledávaný prostor parametrů strategie AOS

(Zdroj: vlastní zpracování)

Na obrázku 37 vidíme prohledávaný prostor parametrů, jehož velikost byla zvolena tak, aby byla spočítatelná v rozumném čase a obsahovala pás krajních hodnot výchozích parametrů.

Konfigurace a spuštění optimalizace:

Prostor parametrů nastavíme v souboru `/aos/optimize_aos_parameters.py` a stejným souborem pak optimalizaci spustíme.

MEAN ANNUAL RETURN P	1 ▾	MEAN ANNUAL VOLATILITY	2 ▲	MEAN ANNUAL DD	MEAN ANNUAL SORTINO	MAX ANNUAL SORTINO	MAX ANNUAL DD	MAX ANNUAL VOLATILITY
40,2152		0,0635		-3,988	3,3493	3,7771	-4,3098	0,0689
39,9032		0,0635		-3,9871	3,3266	3,701	-4,3086	0,0689
39,7855		0,0631		-3,9875	3,3651	3,919	-4,3093	0,0684
39,5662		0,0759		-7,2237	3,769	4,908	-8,4169	0,0859
39,5447		0,0758		-7,2248	3,7693	4,9082	-8,4185	0,0859
39,5045		0,0761		-7,2249	3,6861	4,7626	-8,4181	0,0859
39,4905		0,0631		-3,987	3,3482	3,8577	-4,3089	0,0684
39,4758		0,0761		-7,2254	3,6853	4,762	-8,4187	0,0859
39,2378		0,0631		-3,9875	3,2874	3,7113	-4,3098	0,0685
38,9542		0,0632		-3,9878	3,2613	3,6189	-4,3099	0,0685
38,9108		0,071		-3,8611	3,4717	4,0315	-4,5096	0,0774
38,762		0,0776		-7,2267	3,7628	4,9059	-8,4214	0,0884
38,7267		0,0649		-4,2327	3,2494	3,867	-4,6768	0,0698
38,72		0,0711		-3,858	3,4117	3,9309	-4,506	0,0774
38,7032		0,0778		-7,2267	3,6792	4,7616	-8,4204	0,0884
38,6305		0,0762		-7,2256	3,7701	4,908	-8,4203	0,0858
38,6305		0,0762		-7,2256	3,7701	4,908	-8,4203	0,0858
38,5918		0,0715		-3,8602	3,4104	4,022	-4,5086	0,0777

Obrázek 38: Seznam nejlepších měření metody *fitness()*

(Zdroj: vlastní zpracování)

Na obrázku 38 vidíme seznam nejlepších výsledků *fitness()* metody z 18900 provedených měření. Optimalizované parametry použijeme logicky z nejlepšího výsledku (*mean annual return* je 40,2152%) za podmínky, že ostatní ukazatele představující míru stability (Sortino ratio, Max Drawdown, Volatility) nevybočují o více než dvojnásobek směrodatné odchylky v negativním směru ukazatele oproti průměrům z 95% percentilu nejlepších měření daného ukazatele - chceme minimalizovat nestabilitu výnosů. Pokud by tato podmínka nebyla splněna, použijeme druhý nejlepší výsledek a případně iterujeme dále.

Total return:	260861,0	Total return p:	260,861	Mean annual return p:	40,2152
Mean annual volatility:	0,0635	Max annual volatility:	0,0689		
Mean annual dd:	-3,988	Max annual dd:	-4,3098		
Mean annual sortino:	3,3493	Max annual sortino:	3,7771		
Mean annual sharpe:	0,1806	Max annual sharpe:	0,1977		

Params:

```

Test params:
window_sma_long: 203
window_sma_short: 6
windows_rsi: 3
rsi_limit: 11
windows_sortino: 64
sortino_limit: 0.3
-----
money_reinvest: True
sortino_limit: 0.3
windows_sortino: 64
min_volume: 1000000
rsi_limit: 11
windows_rsi: 3
window_sma_short: 6
window_sma_long: 203
max_positions_total: 10
max_positions_per_ticker: 1
max_trades_per_day: 1
fee_per_trade: 1
count_money_parts: 10
initial_money: 100000

```

Obrázek 39: Optimalizované parametry z nejlepšího měření
(Zdroj: vlastní zpracování)

Výchozí parametry pro strategii AOS:

- window_sma_long: 200
- window_sma_short: 5
- windows_rsi: 2
- rsi_limit: 10
- windows_sortino: 252
- sortino_limit: 1

Optimalizované parametry pro strategii AOS:

- window_sma_long: 203
- window_sma_short: 6
- windows_rsi: 3
- rsi_limit: 11
- windows_sortino: 64
- sortino_limit: 0.3

Pro ověření výsledku optimalizace provedeme backtesting s výchozími parametry a optimalizovanými parametry pro běžné období od 1.3.2005 do 30.12.2016 pro akciový koš z indexu S&P 100 a porovnáme klíčové ukazatele Equity, Sortino ratio a Maximal Drawdown.

FINAL STATISTICS	
Strategy name: AOS TECH vs S&P 100	
Trade period: 12 years, (2005-01-03 - 2016-12-30)	
Initial equity: 100000	
TRADES AND FEES	
Trades: bid/ask/all: 2441/2441/4882	
Fee per trade: 1	
Total fee expense: 4882.00	
STABILITY OF EQUITY	
Max annual drawdown: -7.12% (2008)	
Mean annual max drawdown: -4.79%	
Max annual sortino: 3.41 (2013)	
Mean annual sortino: 2.50	
Max annual sharpe: 0.17 (2013)	
Mean annual sharpe: 0.13	
Max annual volatility: 0.09 (2008)	
Mean annual volatility: 0.07	
EQUITY RETURN	
Mean annual return: 7.97%	
Max annual return: 16.18% (2005)	
Min annual return: 2.11% (2016)	
Total equity: 250.65%	
Total equity: 250650.00	

Obrázek 40: Výstup strategie AOS TECH s neoptimalizovanými parametry
(Zdroj: vlastní zpracování)

FINAL STATISTICS	
Strategy name: AOS TECH vs S&P 100	
Trade period: 12 years, (2005-01-03 - 2016-12-30)	
Initial equity: 100000	
TRADES AND FEES	
Trades: bid/ask/all: 2360/2360/4720	
Fee per trade: 1	
Total fee expense: 4720.00	
STABILITY OF EQUITY	
Max annual drawdown: -6.56% (2008)	
Mean annual max drawdown: -4.77%	
Max annual sortino: 4.35 (2013)	
Mean annual sortino: 3.10	
Max annual sharpe: 0.22 (2013)	
Mean annual sharpe: 0.16	
Max annual volatility: 0.10 (2008)	
Mean annual volatility: 0.08	
EQUITY RETURN	
Mean annual return: 10.23%	
Max annual return: 17.92% (2009)	
Min annual return: 1.56% (2016)	
Total equity: 320.56%	
Total equity: 320564.00	

Obrázek 41: Výstup strategie AOS TECH s optimalizovanými parametry
(Zdroj: vlastní zpracování)

Optimalizované parametry zlepšily výkonnost strategie AOS TECH následovně:

- investovaný kapitál se zhodnotil o 28 %, z 250260 dolarů na 320564 dolarů,
- 24% nárůst průměrné roční Sortino ratio, z 2,50 na 3,10,
- průměrný Maximal Drawdown se snížil z - 4,79% na - 4,77 %,
- maximální Maximal Drawdown se snížil z - 7,12% na -6,56%,
- snížil se počet transakcí o 162, z 4882 na 4720 obchodů.

4.4.4. Optimalizace investičního modelu ML

Úspěšnost predikce investičního modelu ML stojí na použití vhodného algoritmu strojového učení a na správné konfiguraci hyperparametrů. Pro jejich nalezení použijeme program Tpot.

Klíčové parametry programu Tpot:

- ML_START_DATE - datum začátku burzovních dat pro optimalizaci - 1.1.2001,
- ML_END_DATE - datum ukončení burzovních dat pro optimalizaci - 1.1.2005,
- POPULATION_SIZE - počet jedinců hledajících optimální řešení - 600,
- NUMBER_GENERATION - počet generací, respektive kolikrát dojde k mutaci nebo křížení jedinců - 10,
- klasifikační softwarovou třídu použijeme *TPOTClassifier*; protože predikujeme třídu - vzestupný nebo sestupný trend.

Konfigurace Tpot a spuštění optimalizace:

Počáteční konfiguraci programu Tpot nastavíme v souboru

/aos/optimize_machine_learning.py a stejným souborem pak spustíme hledání algoritmu a hyperparametrů.

```
[krnavek@dp]# /opt/python3/bin/python3 /aos/optimize_machine_learning.py

Generation 1 - Current best internal CV score: 0.5135485416223122
Generation 2 - Current best internal CV score: 0.5135485416223122
Generation 3 - Current best internal CV score: 0.5293400929671421
Generation 4 - Current best internal CV score: 0.5293400929671421
Generation 5 - Current best internal CV score: 0.5293400929671421
Generation 6 - Current best internal CV score: 0.5293400929671421
Generation 7 - Current best internal CV score: 0.5293400929671421
Generation 8 - Current best internal CV score: 0.5329146263572493
Generation 9 - Current best internal CV score: 0.5329146263572493
Generation 10 - Current best internal CV score: 0.5329146263572493

# Selected model
#-----

Best pipeline:
DecisionTreeClassifier(
  RBFSampler(input_matrix,
  RBFSampler__gamma=0.35),
  DecisionTreeClassifier__criterion=gini,
  DecisionTreeClassifier__max_depth=6,
  DecisionTreeClassifier__min_samples_leaf=3,
  DecisionTreeClassifier__min_samples_split=15
)

# Classification report
#-----

```

	precision	recall	f1-score	support
0	0.52	0.32	0.40	247
1	0.52	0.71	0.60	257
avg / total	0.52	0.52	0.50	504

Obrázek 42: Výběr modelu strojového učení a optimalizace hyperparametrů
(Zdroj: vlastní zpracování)

Programem Tpot byl nalezen algoritmus *DecisionTree*. Dle klasifikačního reportu (obrázek 42) je úspěšností predikce 52 %, což není na první pohled mnoho. Algoritmus strojového učení je však pouze doplňková složka predikce, takže jeho přítomnost bude zlepšovat výslednou predikci. Investiční model ML tak bude mít stabilnější výnosy a pravděpodobně zobchoduje méně transakcí než model TECH za stejný časový horizont.

4.5. Vyhodnocení výkonnosti investičních modelů

4.5.1. Metodika metody backtesting

Výkonnost a stabilitu finančních modelů TECH a ML ověříme programem AOS. Pro každý model provedeme backtesting pro běžné období od 2005 do 2016 a pro období finanční krize od 2007 do 2011 a selektovat portfolio budeme z akciového indexu S&P 100 a S&P 500.

Výsledky backtestingu pro období od 2005 do 2016 ukáží charakteristiku výnosů a míry stability, kterou můžeme očekávat od investičních modelů v běžném, klidovém období na finančních trzích. Naopak backtesting pro období krize od 2007 do 2011 napoví, jak si modely povedou v nestandardním, turbulentním období, kdy většina investorů preferuje větší míru stability před maximalizací výnosů.

Backtesting na akciovém koši S&P 100 nebo S&P 500 ukáže, jak si daný investiční model povede při selektování portfolio z koše akcii technologického sektoru (S&P 100) nebo koše obecných akcii (S&P 500).

Jeden z výstupů backtestingu je graf porovnávající kapitálové křivky portfolio AOS (*equity curve*) a kapitálové křivky fiktivní investice do indexu S&P 100, respektive S&P 500, které považujeme jako benchmark.

Backtesting pro období 2005 - 2016			
2001 - 2005	2005 - 2007	2007- 2011 Hospodářská krize	2011 - 2016
Treninková data pro strojové učení (predictor ML)	Backtesting S&P 100		
	Backtesting S&P 500		
	Backtesting S&P 100		
	Backtesting S&P 500		

Obrázek 43: Plán backtestingu pro finanční model TECH a ML

(Zdroj: vlastní zpracování)

Výsledky každého backtestingu obsahují:

textový výstup programu AOS s ukazateli Equity a Sortino ratio, Sharpe ratio, Maximal Drawdown a Volatility

- graf kapitálové křivky AOS a kapitálové křivky benchmarku (fiktivní investice do akciového indexu S&P 100 nebo S&P 500)
- příložený csv soubor se statistikou ukazatelů Equity, Equity diff a Sortino ratio, Sharpe ratio, Maximal Drawdown a Volatility pro kapitálovou křivku AOS a kapitálovou křivku benchmarku na roční bázi
- příložený csv soubor se seznamem všech provedených obchodů (akciových transakcí) a stavu portfolia na denní bázi


4.5.2. Investiční model TECH selektuje portfolio z S&P 100 v období 2005 - 2016

Pro běžné období od 1.3.2005 do 30.12.2016 bylo investičním modelem TECH selektováno portfolio z akciového koše S&P 100.

FINAL STATISTICS	
Strategy name: AOS TECH vs S&P 100	
Trade period: 12 years, (2005-01-03 - 2016-12-30)	
Initial equity: 100000	
----- TRADES AND FEES -----	
Trades: bid/ask/all: 2360/2360/4720	
Fee per trade: 1	
Total fee expense: 4720.00	
----- STABILITY OF EQUITY -----	
Max annual drawdown: -6.56% (2008)	
Mean annual max drawdown: -4.77%	
Max annual sortino: 4.35 (2013)	
Mean annual sortino: 3.10	
Max annual sharpe: 0.22 (2013)	
Mean annual sharpe: 0.16	
Max annual volatility: 0.10 (2008)	
Mean annual volatility: 0.08	
----- EQUITY RETURN -----	
Mean annual return: 10.23%	
Max annual return: 17.92% (2009)	
Min annual return: 1.56% (2016)	
Total equity: 320.56%	
Total equity: 320564.00	

Obrázek 44: Výstup AOS z backtestingu investičního modelu TECH pro S&P 100 v období 2005 - 2016

(Zdroj: vlastní zpracování)



Graf 1: AOS z backtestingu investičního modelu TECH
pro S&P 100 v období 2005 - 2016
(Zdroj: vlastní zpracování)

Roční statistika ukazatelů Equity, Equity diff a Sortino ratio, Sharpe ratio, Volatility je k dispozici v souboru *vysledky_AOS_TECH_SP100_2005-2016.csv*.

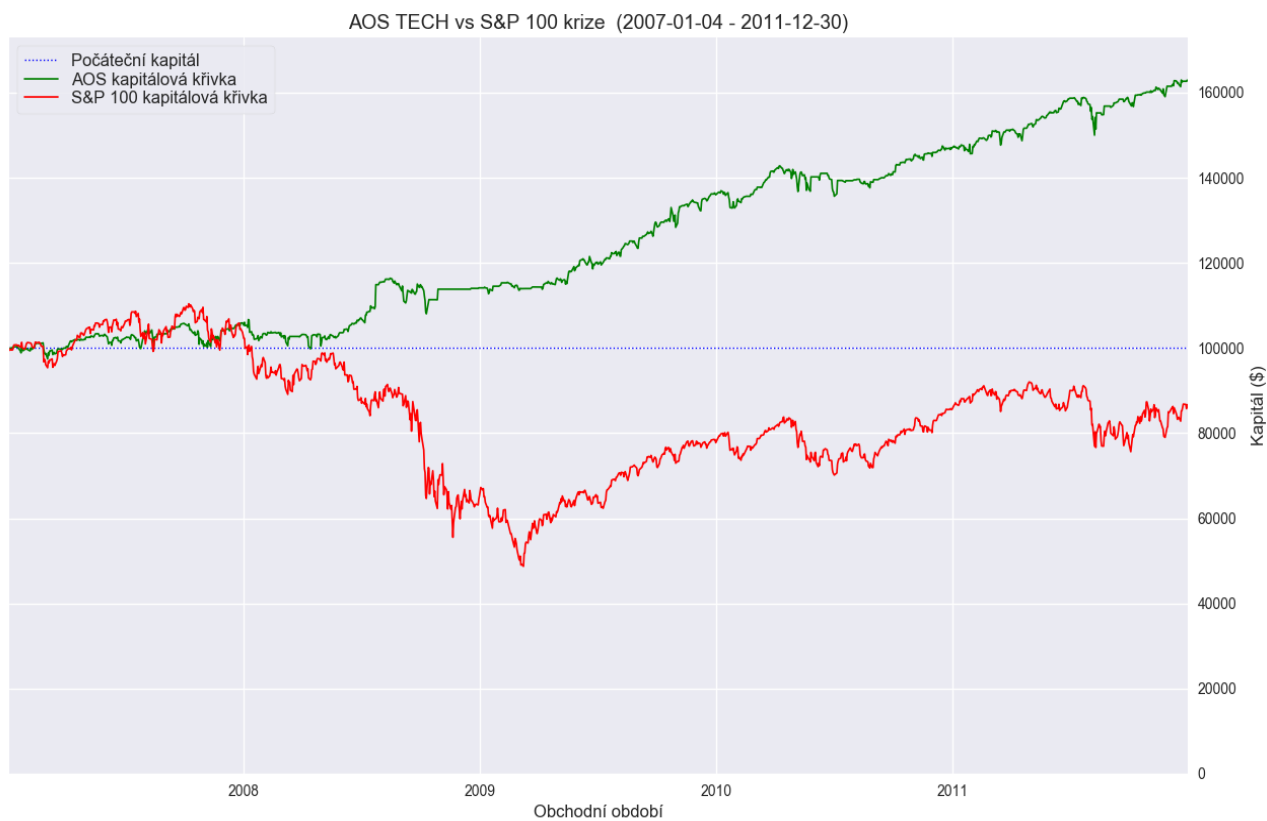
Seznam všech provedených obchodů (akciových transakcí) a stavu portfolia na denní bázi je k dispozici v souboru *backtesting_AOS_TECH_SP100_2005-2016.csv*.

4.5.3. Investiční model TECH selektuje portfolio z S&P 100 v období krize 2007 – 2011

Pro období finanční krize od 1.4.2007 do 30.12.2011 bylo investičním modelem TECH selektováno portfolio z akciového koše S&P 100.

FINAL STATISTICS	
Strategy name: AOS TECH vs S&P 100 krize	
Trade period: 5 years, (2007-01-04 - 2011-12-30)	
Initial equity: 100000	
----- TRADES AND FEES -----	
Trades: bid/ask/all: 891/891/1782	
Fee per trade: 1	
Total fee expense: 1782.00	
----- STABILITY OF EQUITY -----	
Max annual drawdown: -7.17(%) (2009)	
Mean annual max drawdown: -6.23(%)	
Max annual sortino: 3.32 (2011)	
Mean annual sortino: 2.81	
Max annual sharpe: 0.18 (2011)	
Mean annual sharpe: 0.15	
Max annual volatility: 0.12 (2008)	
Mean annual volatility: 0.10	
----- EQUITY RETURN -----	
Mean annual return: 10.30(%)	
Max annual return: 19.16(%) (2009)	
Min annual return: 5.91(%) (2007)	
Total equity: 162.85(%)	
Total equity: 162852.00	

Obrázek 45: Výstup AOS z backtestingu investičního modelu TECH pro S&P 100 v období krize 2007 - 2011 (Zdroj: vlastní zpracování)



Graf 2: AOS z backtestingu investičního modelu TECH
pro S&P 100 v období krize 2007 - 2011
(Zdroj: vlastní zpracování)

Roční statistika ukazatelů Equity, Equity diff a Sortino ratio, Sharpe ratio, Volatility je k dispozici v souboru *vysledky_AOS_TECH_SP100_krize_2007-2011.csv*.


Seznam všech provedených obchodů (akciových transakcí) a stavu portfolia na denní bázi je k dispozici v souboru *backtesting_AOS_TECH_SP100_krize_2007-2011.csv*.

4.5.4. Investiční model TECH selektuje portfolio z S&P 500 v období 2005 – 2016

Pro běžné období od 1.3.2005 do 30.12.2016 bylo investičním modelem TECH selektováno portfolio z akciového koše S&P 500.

FINAL STATISTICS	
Strategy name: AOS TECH vs S&P 500	
Trade period: 12 years, (2005-01-03 - 2016-12-30)	
Initial equity: 100000	
----- TRADES AND FEES -----	
Trades: bid/ask/all: 2801/2801/5602	
Fee per trade: 1	
Total fee expense: 5602.00	
----- STABILITY OF EQUITY -----	
Max annual drawdown: -10.82(%) (2009)	
Mean annual max drawdown: -7.13(%)	
Max annual sortino: 5.14 (2006)	
Mean annual sortino: 2.83	
Max annual sharpe: 0.22 (2014)	
Mean annual sharpe: 0.14	
Max annual volatility: 0.16 (2009)	
Mean annual volatility: 0.10	
----- EQUITY RETURN -----	
Mean annual return: 9.79(%)	
Max annual return: 22.10(%) (2005)	
Min annual return: 1.65(%) (2009)	
Total equity: 309.77(%)	
Total equity: 309775.00	

Obrázek 46: Výstup AOS z backtestingu investičního modelu TECH
pro S&P 500 v období 2005 - 2016
(Zdroj: vlastní zpracování)



**Graf 3: AOS z backtestingu investičního modelu TECH
pro S&P 500 v období 2005 - 2016
(Zdroj: vlastní zpracování)**

Roční statistika ukazatelů Equity, Equity diff a Sortino ratio, Sharpe ratio, Volatility je k dispozici v souboru *vysledky_AOS_TECH_SP500_2005-2016.csv*.


Seznam všech provedených obchodů (akciových transakcí) a stavu portfolia na denní bázi je k dispozici v souboru *backtesting_AOS_TECH_SP500_2005-2016.csv*.

4.5.5. Investiční model TECH selektuje portfolio z S&P 500 v období krize 2007 – 2011

Pro období finanční krize od 1.4.2007 do 30.12.2011 bylo investičním modelem TECH selektováno portfolio z akciového koše S&P 500.

FINAL STATISTICS	
Strategy name: AOS TECH vs S&P 500 krize	
Trade period: 5 years, (2007-01-04 - 2011-12-30)	
Initial equity: 100000	
----- TRADES AND FEES -----	
Trades: bid/ask/all: 1107/1107/2214	
Fee per trade: 1	
Total fee expense: 2214.00	
----- STABILITY OF EQUITY -----	
Max annual drawdown: -16.76(%) (2009)	
Mean annual max drawdown: -13.22(%)	
Max annual sortino: 4.05 (2011)	
Mean annual sortino: 2.25	
Max annual sharpe: 0.18 (2011)	
Mean annual sharpe: 0.12	
Max annual volatility: 0.18 (2009)	
Mean annual volatility: 0.14	
----- EQUITY RETURN -----	
Mean annual return: 7.88(%)	
Max annual return: 16.17(%) (2010)	
Min annual return: -1.59(%) (2009)	
Total equity: 147.21(%)	
Total equity: 147211.00	

Obrázek 47: Výstup AOS z backtestingu investičního modelu TECH pro S&P 500 v období krize 2007 - 2011 (Zdroj: vlastní zpracování)



Graf 4: AOS z backtestingu investičního modelu TECH
pro S&P 500 v období krize 2007 - 2011
(Zdroj: vlastní zpracování)

Roční statistika ukazatelů Equity, Equity diff a Sortino ratio, Sharpe ratio, Volatility je k dispozici v souboru *vysledky_AOS_TECH_SP500_krize_2007-2011.csv*.

Seznam všech provedených obchodů (akciových transakcí) a stavu portfolia na denní bázi je k dispozici v souboru *backtesting_AOS_TECH_SP500_krize_2007-2011.csv*.

4.5.6. Investiční model ML selektuje portfolio z S&P 100 v období 2005 – 2016

Pro běžné období od 1.3.2005 do 30.12.2016 bylo investičním modelem ML selektováno portfolio z akciového koše S&P 100.

FINAL STATISTICS	
Strategy name: AOS ML vs S&P 100	
Trade period: 12 years, (2005-01-03 - 2016-12-30)	
Initial equity: 100000	
TRADES AND FEES	
Trades: bid/ask/all: 2075/2075/4150	
Fee per trade: 1	
Total fee expense: 4150.00	
STABILITY OF EQUITY	
Max annual drawdown: -5.95(%) (2008)	
Mean annual max drawdown: -4.41(%)	
Max annual sortino: 4.94 (2013)	
Mean annual sortino: 2.84	
Max annual sharpe: 0.23 (2011)	
Mean annual sharpe: 0.15	
Max annual volatility: 0.09 (2008)	
Mean annual volatility: 0.07	
EQUITY RETURN	
Mean annual return: 8.52(%)	
Max annual return: 16.94(%) (2009)	
Min annual return: 1.46(%) (2016)	
Total equity: 266.48(%)	

Obrázek 48: Výstup AOS z backtestingu investičního modelu ML
pro S&P 100 v období 2005 - 2016
(Zdroj: vlastní zpracování)



**Graf 5: AOS z backtestingu investičního modelu ML
pro S&P 100 v období 2005 - 2016
(Zdroj: vlastní zpracování)**

Roční statistika ukazatelů Equity, Equity diff a Sortino ratio, Sharpe ratio, Volatility je k dispozici v souboru *vysledky_AOS_ML_SP100_2005-2016.csv*.

Seznam všech provedených obchodů (akciových transakcí) a stavu portfolia na denní bázi je k dispozici v souboru *backtesting_AOS_ML_SP100_2005-2016.csv*.

4.5.7. Investiční model ML selektuje portfolio z S&P 100 v období krize 2007 – 2011

Pro období finanční krize od 1.4.2007 do 30.12.2011 bylo investičním modelem ML selektováno portfolio z akciového koše S&P 100.

FINAL STATISTICS	
Strategy name: AOS ML vs S&P 100 krize	
Trade period: 5 years, (2007-01-04 - 2011-12-30)	
Initial equity: 100000	
TRADES AND FEES	
Trades: bid/ask/all: 755/755/1510	
Fee per trade: 1	
Total fee expense: 1510.00	
STABILITY OF EQUITY	
Max annual drawdown: -7.62% (2008)	
Mean annual max drawdown: -6.22%	
Max annual sortino: 3.58 (2011)	
Mean annual sortino: 2.55	
Max annual sharpe: 0.19 (2011)	
Mean annual sharpe: 0.14	
Max annual volatility: 0.10 (2008)	
Mean annual volatility: 0.09	
EQUITY RETURN	
Mean annual return: 7.15%	
Max annual return: 14.89% (2009)	
Min annual return: 2.54% (2007)	
Total equity: 141.16%	
Total equity: 141160.00	

Obrázek 49: Výstup AOS z backtestingu investičního modelu ML pro S&P 100 v období krize 2007 - 2011

(Zdroj: vlastní zpracování)



**Graf 6: AOS z backtestingu investičního modelu ML
pro S&P 100 v období krize 2007 - 2011
(Zdroj: vlastní zpracování)**

Roční statistika ukazatelů Equity, Equity diff a Sortino ratio, Sharpe ratio, Volatility je k dispozici v souboru *vysledky_AOS_ML_SP100_krize_2007-2011.csv*.


Seznam všech provedených obchodů (akciových transakcí) a stavu portfolia na denní bázi je k dispozici v souboru *backtesting_AOS_ML_SP100_krize_2007-2011.csv*.

4.5.8. Investiční model ML selektuje portfolio z S&P 500 v období 2005 – 2016

Pro běžné období od 1.3.2005 do 30.12.2016 bylo investičním modelem ML selektováno portfolio z akciového koše S&P 500.

FINAL STATISTICS	
Strategy name: AOS ML vs S&P 500	
Trade period: 12 years, (2005-01-03 - 2016-12-30)	
Initial equity: 100000	
TRADES AND FEES	
Trades: bid/ask/all: 2666/2666/5332	
Fee per trade: 1	
Total fee expense: 5332.00	
STABILITY OF EQUITY	
Max annual drawdown: -12.08% (2009)	
Mean annual max drawdown: -6.92%	
Max annual sortino: 6.09 (2014)	
Mean annual sortino: 3.02	
Max annual sharpe: 0.28 (2014)	
Mean annual sharpe: 0.16	
Max annual volatility: 0.14 (2009)	
Mean annual volatility: 0.09	
EQUITY RETURN	
Mean annual return: 9.88%	
Max annual return: 20.15% (2013)	
Min annual return: 3.12% (2012)	
Total equity: 314.22%	
Total equity: 314220.00	

Obrázek 50: Výstup AOS z backtestingu investičního modelu ML pro S&P 500 v období 2005 - 2016 (Zdroj: vlastní zpracování)



Graf 7: AOS z backtestingu investičního modelu ML
 pro S&P 500 v období 2005 - 2016
 (Zdroj: vlastní zpracování)

Roční statistika ukazatelů Equity, Equity diff a Sortino ratio, Sharpe ratio, Volatility je k dispozici v souboru *vysledky_AOS_ML_SP500_2005-2016.csv*.

Seznam všech provedených obchodů (akciových transakcí) a stavu portfolia na denní bázi je k dispozici v souboru *backtesting_AOS_ML_SP500_2005-2016.csv*.

4.5.9. Investiční model ML selektuje portfolio z S&P 500 v období krize 2007 – 2011

Pro období finanční krize od 1.4.2007 do 30.12.2011 bylo investičním modelem ML selektováno portfolio z akciového koše S&P 500.

FINAL STATISTICS	
Strategy name: AOS ML vs S&P 500 krize	
Trade period: 5 years, (2007-01-04 - 2011-12-30)	
Initial equity: 100000	
TRADES AND FEES	
Trades: bid/ask/all: 1032/1032/2064	
Fee per trade: 1	
Total fee expense: 2064.00	
STABILITY OF EQUITY	
Max annual drawdown: -11.41(%) (2009)	
Mean annual max drawdown: -10.03(%)	
Max annual sortino: 5.13 (2011)	
Mean annual sortino: 2.92	
Max annual sharpe: 0.21 (2011)	
Mean annual sharpe: 0.15	
Max annual volatility: 0.15 (2009)	
Mean annual volatility: 0.13	
EQUITY RETURN	
Mean annual return: 10.75(%)	
Max annual return: 22.05(%) (2010)	
Min annual return: 5.26(%) (2011)	
Total equity: 166.81(%)	
Total equity: 166811.00	

Obrázek 51: Výstup AOS z backtestingu investičního modelu ML
pro S&P 500 v období krize 2007 – 2011
(Zdroj: vlastní zpracování)



Graf 8: AOS z backtestingu investičního modelu ML
pro S&P 500 v období krize 2007 - 2011
(Zdroj: vlastní zpracování)

Roční statistika ukazatelů Equity, Equity diff a Sortino ratio, Sharpe ratio, Volatility je k dispozici v souboru *vysledky_AOS_ML_SP500_krize_2007-2011.csv*.

Seznam všech provedených obchodů (akciových transakcí) a stavu portfolia na denní bázi je k dispozici v souboru *backtesting_AOS_ML_SP500_krize_2007-2011.csv*

4.5.10. Vyhodnocení

Strategie AOS v běžném období (3.1.2005 – 30.12.2016)	Počet obchodů	Počáteční kapitál	Konečný kapitál	Celkové zhodnocení (%)	Průměrný roční výnos (%)	Průměrné roční Sortino ratio	Průměrný roční maximální propad (%)	Maximální propad (%)
AOS TECH na S&P 100	4720	100000	320564	320,56	10,23	3,1	-4,77	-6,56
AOS ML na S&P 100	4150	100000	266477	266,47	8,52	2,84	-4,41	-5,95
AOS TECH na S&P 500	5602	100000	309775	309,77	9,79	2,83	-7,13	-10,82
AOS ML na S&P 500	5332	100000	314220	314,22	9,88	3,02	-6,92	-12,08

Tabulka 7: Souhrnné výsledky backtestingu pro běžné období 2005 - 2016

(Zdroj: vlastní zpracování)

Strategie AOS v době finanční krize (4.1.2007 – 30.12.2011)	Počet obchodů	Počáteční kapitál	Konečný kapitál	Celkové zhodnocení (%)	Průměrný roční výnos (%)	Průměrné roční Sortino ratio	Průměrný roční maximální propad (%)	Maximální propad (%)
AOS TECH na S&P 100	1782	100000	162852	162,85	10,3	2,81	-6,23	-7,17
AOS ML na S&P 100	1510	100000	141160	141,16	7,15	2,55	-6,22	-7,62
AOS TECH na S&P 500	2214	100000	147211	147,21	7,88	2,25	-13,22	-16,76
AOS ML na S&P 500	2064	100000	166811	166,81	10,75	2,92	-10,03	-11,41

Tabulka 8: Souhrnné výsledky backtestingu pro období krize 2007 – 2011

(Zdroj: vlastní zpracování)

Z výsledků backtestingu, grafů a přiložených statistik v csv souborech *vysledky** vyplývá, že investiční modely TECH a ML překonávají benchmark (tzn. fiktivní investici do investičního instrumentu kopírujícího index S&P 100, respektive S&P 500) více než 1,8 krát.

Například pokud bychom na začátku roku 2005 investovali 100 000 dolarů do strategie AOS TECH S&P 100 na dobu 12 let, tak se investovaný kapitál zhodnotí o 320,5 % na 320 564 dolarů při průměrné roční výnosnosti 10,23 % a při maximálním kapitálovém propadu 6,56 %. Kapitálová křivka se během celého investičního horizontu nepropadla pod hladinu počátečního kapitálu (graf 1) a benchmark se zhodnotil jen o 170,3% na 173 227 dolarů při průměrném roční výnosnosti 8,69 %. Strategie tak překonala benchmark 1,85 krát o 147 337 dolarů. Při hodnocení průměrném roční výnosnosti bereme v potaz faktor reinvestice kapitálu.

V době finanční krize mezi lety 2007 – 2011 dosáhl AOS ML S&P 100 nejhoršího výsledku ze všech backtestingů. Investovaný kapitál byl zhodnocen za dobu 5 let jen o 141,16% na 141 160 dolarů při průměrné roční výnosnosti 8,52 % a při maximálním kapitálovém propadu 5,95 %. Kapitálová křivka sice v druhé části roku 2008 klesla pod kapitálovou křivku benchmarku a první třetině roku 2009 dokonce i pod hladinu počátečního kapitálu (graf 6), ale i tak překonala benchmark 1,63 krát o 54 808 dolarů.

Zjištěné skutečnosti z benchmarků:

- Investiční model ML dosahuje stabilnějších výsledků v době finanční krize než investiční model TECH .
- Investiční model ML uzavírá za stejné období při podobné výnosnosti méně akciových transakcí než model TECH, což může hrát roli skutečnosti vysokých poplatků za transakci .
- Investiční model ML podává lepší výsledky na akciovém koši indexu S&P 500 a investiční model TECH funguje lépe na akciovém koši indexu S&P 100.
- Investiční model ML oproti modelu TECH má nižší průměrné maximální roční propady, což může být s psychologického hlediska pro investora výhodnější.
- V době krize, kdy obchodník preferuje větší míru stability před výnosem, je výhodnější investiční modely TECH a ML obchodovat na akciovém koši indexu S&P 100 spíše než na S&P 500.
- Největšího kladný rozdíl ve zhodnocení kapitálu oproti benchmarku zaznamenal investiční model ML v době krize na akciovém koši indexu S&P 500. Kapitál byl modelem zhodnocen o 89 % lépe než investice do benchmarku.
- Největší maximální roční propad kapitálu zaznamenal v době finanční krize investiční model TECH na akciovém koši S&P 500 a to 16,76 % v roce 2009.
- Největší meziroční zhodnocení kapitálu zaznamenal v běžné, klidné době investiční model TECH na akciovém koši S&P 500 a to 22,10 % v roce 2005.
- Výpočet investičního modelu ML trvá zhruba 3 krát déle než pro investiční model TECH.

Přínos investičních modelů TECH, ML pro investora do strategie AOS :

- Oba investiční modely porázejí ve výnosnosti trh v klidovém období i době krize v průměru o 66% , což je nezanedbatelná konkurenční výhoda i proti bankovním investičním produktům.
- V době finanční krize 2007 až 2011 drtivá většina pasivních investičních instrumentů a akciových titulů zaznamenala cenové propady až v desítkách procent a strategie AOS pode backtestingu (graf 2) až na několik měsíců v roce 2009 dotázala udržet kapitálovou křivku nad počáteční investicí a investiční horizont skončit s kladným výnosem.
- Strategie AOS nepoužívá k obchodování páku ani *stop-loss order*, takže v případě globálních pádů akciových trhů nedojde k násilnému uzavření otevřených pozic, prodeji akcií za nízké ceny a tím pádem ke ztrátě kapitálu. Investorovi zůstanou akcie, které sice mohou dočasně ztratit na hodnotě, ale na základě historických zkušeností a hypotézy růsti akcií [5] se opět ve většině případů do 1 roku po krizi dostanou na své původní cenové pozice a často je i překonají. Investor z krize vyjde s nekráceným kapitálem, který může následně reinvestovat do nákupů ostatních investičních instrumentů, které jsou po krizi podhodnocené.
- Strategie AOS s investičními modely TECH a ML je uživatelsky přívětivá, protože je obchodována na denní bázi a nevyžaduje průběžnou celodenní kontrolu obchodníkem. Vygenerované obchodní příkazy lze zadat až po uzavření US burz, tedy po 22:00 středoevropského času (americká burza NYSE má běžné otevírací hodiny 15:30 – 22:00 středoevropského času).
- Ve všech uskutečněných měřeních kapitálový výnos na konci investičního horizontu skončil v kladných číslech.
- Strategie AOS by v reálném obchodování dosahovala ještě lepších výsledků, protože do celkového výnosu nebyly započítány dividendové výnosy jednotlivých akciových titulů.

ZÁVĚR

Za základě principů technické analýzy a algoritmů strojového učení byly vytvořeny investiční modely TECH a ML. Pro otestování výnosnosti obou modelů byla v jazyku Python naprogramována aplikace Automatický obchodní systém (AOS), která sloužila ke dvou primárním účelům. K optimalizaci parametrů investičních modelů a k provedení série měření metodou backtesting na historických burzovních datech.

Metodou dopředné optimalizace na historických burzovních datech od 1.1.2001 do 30.12.2016 a pomocí softwarové smyčky byl prohledán stavový prostor potenciálně vhodných parametrů a nalezeno optimální řešení pro klíčové parametry *window_sma_long*, *window_sma_short*, *windows_rsi*, *rsi_limit*, *windows_sortino* a *sortino_limit*. Pro vyhledání vhodného algoritmu strojového učení pro investiční model ML byl použit volně dostupný program Tpot, který s využitím genetických algoritmů doporučil algoritmus *DecisionTree* včetně vhodné kombinace hyperparametrů.

Metodou backtesting byla provedena série 8 měření, které prověřili investiční modely TECH a ML v podmínkách klidné tržní situace v období od 3.1.2005 do 30.12.2016 a v období finanční krize od 4.1.2007 do 30.12.2011. Pro objektivitu porovnání byly výsledky srovnány s benchmarkem - fiktivní nespravovanou investicí do investičního instrumentu kopírujícího akciový index S&P 100, respektive S&P 500 a používanou odborníky ve finančním průmyslu.

Výstup každého měření byl hodnocen ze dvou hledisek, s pohledu výnosnosti a stability. Výnosnost byla hodnocena celkovým zhodnocení investovaného kapitálu a průměrnou roční výnosovou mírou. Faktor stability byl měřen ukazatelem *Sortino ratio*, *Maximal Drawdown* a *Volatility*. Pro vizuální hodnocení byly pomocí softwarového modulu *Matplotlib* vygenerovány grafy kapitálových křivek pro celkové obchodní období, kde je možné průběžně porovnávat stav investice v čase (strategie AOS) a benchmarku.

Z výsledku měření je patrné, že se investiční modely TECH a ML osvědčily a v průměru o 66% překonávaly investici do benchmarku a všech měření skončily kladným zhodnocením kapitálu. Pozitivně je hodnocena skutečnost, že se kapitálová křivka až na

pár měsíců v době hospodářské krize nedostala pod hranici počátečního investovaného kapitálu. Investiční model ML, používající algoritmy strojového učení jako doplňkový faktor predikce, ve srovnání s modelem TECH dosahuje nepatrně horších výsledků ve výnosnosti, ale o to stabilnějších výnosů. To může být některými konzervativními investory chápáno jako výhoda.

Realizace strategie AOS na standardním hardware, za použití běžně dostupných softwarových nástrojů a internetu dokazuje, že i jedinec je schopen vytvořit solidní základy pro investiční produkt, který je schopen konkurovat produktům velkých investičních institucí. Oba investiční modely mají značný potenciál vylepšení. Investiční model ML lze vylepšit za použití vhodnější formy a skladby vstupních tréninových dat a investiční model TECH je možné optimalizovat více matematickými metodami.

Strategii AOS lze za rozumného úsilí upravit tak, aby i poučený uživatel, znalý ekonomických skutečností a burzovních termínů, byl schopen program obsluhovat a manuálně on line obchodovat na burze. Autor diplomové práce si díky praktické části osvojil základy obchodování na burze a naučil se aplikovat softwarová řešení na některé finančně ekonomické problémy za pomoci analytických knihoven Pandas, Numpy a Scikit-learn. Případný zájemce o problematiku algoritmického obchodování může z této práce získat užitečné poznatky nebo využít seznam použité literatury jako zdroj kvalitních informací.

SEZNAM POUŽITÉ LITERATURY

- (1) KURKA, R., PAŘÍKOVÁ, A. *Subjekty finančního trhu: vybrané aspekty likvidace a insolvence*. Vyd. 1., C. H. Beck, 2014, 188 s. ISBN 978-80-7400-277-9.
- (2) BURZA CENNÝCH PAPÍRŮ PRAHA, *Index PX*. [Online; cit. 10-April-2017]. 2017. URL: <https://www.pse.cz/>.
- (3) INVESTOPEDIA, *Financial markets*. [Online; cit. 10-April-2017]. 2017. URL: <http://www.investopedia.com/walkthrough/corporate-finance/>.
- (4) ROSE, P. S. *Money and Capital Markets: Financial Institutions and Instruments in a Global Marketplace*. Chicago, 1997. ISBN 978-02-5615-239-5
- (5) GRAHAM, B. *Inteligentní investor*. Praha: Grada, 2007. 504 s. ISBN 978-80-247-1792-0.
- (6) REJNUŠ, O. *Finanční trhy*. 4. vyd. Praha: Grada, a.s., 2014, 760 s. ISBN 978-80-247-3671-6.
- (7) INTERACTIVE BROKERS, *Interactive brokers documentation*. [Online; cit. 10-April-2017]. 2017. URL: <https://www.interactivebrokers.com> .
- (8) INVESTOPEDIA, *Active Trading Tutorial*. [Online; cit. 10-April-2017]. 2017. URL: <http://www.investopedia.com/university/all/trading/> .
- (9) WILLIAMS, L. *Long-Term Secrets to Short-Term Trading*. USA: Wiley-Interscience, 1999. 255 p. ISBN 0-471-29722-4.
- (10) INVESTOPEDIA, *Technical Analysis*. [Online; cit. 2-April-2017]. 2017. URL: <http://www.investopedia.com/university/technical/techanalysis1.asp> .
- (11) VESELÁ, J., OLIVA, M. *Technická analýza na akciových, měnových a komoditních trzích*. 2015. 246 s. ISBN 978-80-87865-22-4.
- (12) COELHO L. P., RICHERT W. *Building Machine Learning Systems with Python. 2nd Ed.* 2015. 301 p. ISBN 978-1-78439-277-2.

- (13) GÉRON, A. *Hands-On Machine Learning with Scikit-Learn and TensorFlow*. 2017. 566 p. ISBN: 978-1-4919-6229-9.
- (14) CHAN, E. *Algorithmic Trading: Winning Strategies and Their Rationale*. 2013. 224 p. ISBN: 978-1118460146.
- (15) HORCHER, K. A. *Essentials of financial risk management*. Sv. 32. 2011. ISBN: 0470635282.
- (16) ALDRIDGE, I. *High-frequency trading: a practical guide to algorithmic strategies and trading systems*. 2013. ISBN : 978-1-118-34350-0.
- (17) HAUCK, T. *Instant Data Intensive Apps with pandas*. 2013. 38 p. ISBN 978-1-78216-558-3.
- (18) KUMAR, A. *Learning Predictive Analytics with Python*. 2016. 326 p. ISBN 978-1-78398-326-1.
- (19) GLADIŠ, D. *Naučte se investovat*. 2. vyd. 2005 179 s. ISBN 978-80-247-1205-5 .
- (20) MCNEIL, A. J., FREY, R., EMBRECHTS, P. *Quantitative risk management: concepts, techniques, and tools*. Princeton university press, 2010. ISBN: 9780691122557.
- (21) GOLLAPUDI, S. *Practical Machine Learning*. 2016. 433 p. ISBN 978-1-78439-968-9.
- (22) IDRIS, I. *Python Data Analysis*. 2014. 329 p. ISBN 978-1-78355-335-8.
- (23) BOSCHETTI, A., MASSARON, A. *Python Data Science Essentials*. 2015. 236 p. ISBN 978-1-78528-042-9.
- (24) RASCHKA, S. *Python Machine Learning*. 2015. 425 p. ISBN 978-1-78355-513-0.
- (25) HALLS-MORE, M. L. *Successful Algorithmic Trading*. 2015. 199 p.
URL: <https://www.quantstart.com/successful-algorithmic-trading-ebook/> .
- (26) HALLS-MORE, M. L. *Advanced Algorithmic Trading*. 2017. 499 p.
URL: <https://www.quantstart.com/advanced-algorithmic-trading-ebook/> .

- (27) DAVEY, K. J. *Building Winning Algorithmic Trading Systems*. 2014. 269 p. ISBN 978-1-118-77891-3.
- (28) KAUFMAN, J. P. *Trading Systems and Methods. 5th Ed.* 2013. 1211 p. ISBN 978-1-118-04356-1.
- (29) TOMASINI, E. & JAEKLE, U. *Trading Systems*. 2009. 240 p. ISBN 978-1-905641-79-6.
- (30) MARKOWITZ, H. M. *Portfolio selection: efficient diversification of investments*. Sv. 16. Yale university press, 1968. ISBN: 978-0-300-01372-6.
- (31) WIKIPEDIA. *Machine learning*. [Online; cit. 15-April-2017]. 2017. URL: https://en.wikipedia.org/wiki/Machine_learning .
- (32) SCIKIT-LEARN.ORG. *Scikit-learn algorithm cheat sheet*. [Online; cit. 11-April-2017]. 2017. URL: http://scikit-learn.org/stable/tutorial/machine_learning_map .
- (33) GITHUB.COM. *An example Machine Learning pipeline*. [Online; cit. 11-April-2017]. 2017. URL: <https://github.com/rhiever/tpot> .
- (34) CONNORS, L. *The 2-Period RSI Pullback Trading Strategy (Connors Research Trading Strategy Series)*, Kindle Edition, 2012. 59 p. ISBN 978-09853072-6-4.
- (35) TPOT. *Tpot documentation*. [Online; cit. 11-April-2017]. 2017. URL: <http://rhiever.github.io/tpot/> .

SEZNAM TABULEK

Tabulka 1: Ukázka hodnot indikátoru SMA 5 a EMA 5 na 21 denních periodách.....	29
Tabulka 2: Ukázka hodnot indikátoru RSI 5 pro SMA a EMA na 21 denních periodách	32
Tabulka 3: Ukázka hodnot indikátoru MACD a EMA 12,26 na 21 denních periodách.....	34
Tabulka 4: Ukázka hodnot indikátoru Bollinger Band na 21 denních periodách.....	37
Tabulka 5: Algoritmy a hyperparametry k optimalizaci.....	47
Tabulka 6: Burzovní OHLC data pro akcii IBM ze zdroje Yahoo.....	80
Tabulka 7: Souhrnné výsledky backtestingu pro běžné období 2005 –2016.....	109
Tabulka 8: Souhrnné výsledky backtestingu pro období krize 2007 – 2011.....	109

SEZNAM OBRÁZKŮ

Obrázek 1: Svíčkový graf indexu S&P 500.....	18
Obrázek 2: Ukázka trendu vzestupného, sestupného a do boku.....	21
Obrázek 3: Prohození cenových úrovní z rezistence na podporu.....	23
Obrázek 4: Čárový graf akcie firmy Apple s aplikací indikátoru SMA 100.....	24
Obrázek 5: Čárový graf akcie IBM doplněný o indikátor Volume.....	25
Obrázek 6: Čárový graf akcie GE a indikátorů SMA20, SMA200.....	29
Obrázek 7: Čárový graf akcie IBM s indikátorem RSI.....	30
Obrázek 8: Čárový graf akcie IBM s indikátorem MACD.....	33
Obrázek 9: Čárový graf akcie GOOGL s indikátorem Stochastic oscillator.....	36
Obrázek 10: Čárový graf akcie XRX s indikátorem Bollinger Band.....	38
Obrázek 11: Čárový graf akcie IBM s On-balance Volume indikátorem.....	40
Obrázek 12: Proces fungování algoritmu strojového učení.....	42
Obrázek 13: Typy algoritmů strojového učení.....	43
Obrázek 14: Algoritmy strojového učení podporované knihovnou Scikit-learn.....	58
Obrázek 15: Schéma hledání a optimalizace algoritmu strojového učení pomocí programu Tpot.....	59
Obrázek 16: Spouštěcí skript programu Tpot.....	60
Obrázek 17: Obsah výstupního souboru programu Tpot.....	60
Obrázek 18: Zdrojový kód indikátoru SMA a EMA v jazyku Python.....	62
Obrázek 19: Zdrojový kód indikátoru RSI SMA v jazyku Python.....	63
Obrázek 20: Zdrojový kód indikátoru RSI EMA v jazyku Python.....	64
Obrázek 21: Zdrojový kód ukazatele Sortino ratio v jazyku Python.....	65

Obrázek 22: Zdrojový kód ukazatele Volatility v jazyku Python.....	65
Obrázek 23: Zdrojový kód ukazatele Maximal Drawdown v jazyku Python.....	66
Obrázek 24: Zdrojový kód ukazatele Sharpe ratio v jazyku Python.....	66
Obrázek 25: Čárový graf akcie AAPL s indikátory SMA5, SMA200 a RSI 2.....	68
Obrázek 26: Pseudokód nákupního signálu pro investiční model TECH.....	70
Obrázek 27: Pseudokód prodejního signálu pro investiční model TECH.....	70
Obrázek 28: Pseudokód nákupního signálu pro investiční model ML.....	71
Obrázek 29: Pseudokód prodejního signálu pro investiční model ML.....	71
Obrázek 30: Proces denní selekce portfolia dle strategie AOS.....	73
Obrázek 31: Schéma modulů automatického obchodního systému (AOS).....	75
Obrázek 32: Spuštění strategie AOS na operačním systému Linux Centos 7.....	76
Obrázek 33: Konfigurace strategie AOS v souboru <i>aos.py</i>	78
Obrázek 34: Zdrojový kód pro stažení burzovních dat OHLC ze zdroje Yahoo a Quandl.....	80
Obrázek 35: Zdrojový kód databázové struktury pro uchování burzovních OHLC dat.....	81
Obrázek 36: Vizualizace metody dopředné optimalizace a testování.....	82
Obrázek 37: Prohledávaný prostor parametrů strategie AOS.....	84
Obrázek 38: Seznam nejlepších měření metody <i>fitness()</i>	85
Obrázek 39: Optimalizované parametry z nejlepšího měření.....	86
Obrázek 40: Výstup strategie AOS TECH s neoptimalizovanými parametry.....	88
Obrázek 41: Výstup strategie AOS TECH s optimalizovanými parametry.....	88
Obrázek 42: Výběr modelu strojového učení a optimalizace hyperparametrů.....	90
Obrázek 43: Plán backtestingu pro finanční model TECH a ML.....	91

Obrázek 44: Výstup AOS z backtestingu investičního modelu TECH pro S&P 100 v období 2005 – 2016.....	93
Obrázek 45: Výstup AOS z backtestingu investičního modelu TECH pro S&P 100 v období krize 2007 – 2011.....	95
Obrázek 46: Výstup AOS z backtestingu investičního modelu TECH pro S&P 500 v období 2005 – 2016.....	97
Obrázek 47: Výstup AOS z backtestingu investičního modelu TECH pro S&P 500 v období krize 2007 – 2011.....	99
Obrázek 48: Výstup AOS z backtestingu investičního modelu ML pro S&P 100 v období 2005 – 2016.....	101
Obrázek 49: Výstup AOS z backtestingu investičního modelu ML pro S&P 100 v období krize 2007 – 2011.....	103
Obrázek 50: Výstup AOS z backtestingu investičního modelu ML pro S&P 500 v období 2005 – 2016.....	105
Obrázek 51: Výstup AOS z backtestingu investičního modelu ML pro S&P 500 v období krize 2007 – 2011.....	107

SEZNAM GRAFŮ

Graf 1: AOS z backtestingu investičního modelu TECH pro S&P 100 v období 2005 – 2016.....	94
Graf 2: AOS z backtestingu investičního modelu TECH pro S&P 100 v období krize 2007 – 2011.....	96
Graf 3: Graf AOS z backtestingu investičního modelu TECH pro S&P 500 v období 2005 – 2016.....	98
Graf 4: Graf AOS z backtestingu investičního modelu TECH pro S&P 500 v období krize 2007 – 2011.....	100
Graf 5: Graf AOS z backtestingu investičního modelu ML pro S&P 100 v období 2005 – 2016.....	102
Graf 6: Graf AOS z backtestingu investičního modelu ML pro S&P 100 v období krize 2007 – 2011.....	104
Graf 7: Graf AOS z backtestingu investičního modelu ML pro S&P 500 v období 2005 – 2016.....	106
Graf 8: Graf AOS z backtestingu investičního modelu ML pro S&P 500 v období krize 2007 – 2011.....	108

DODATEK A – CD ROM

- zdrojový kód programu Automatický obchodní systém (AOS),
- výsledky 8 měření backtesting,
- ukázkové data indikátorů,
- popisný soubor readme.txt.