Vysoká škola ekonomická v Praze

Fakulta financí a účetnictví

DIPLOMOVÁ PRÁCE

2020 **Marek Koucký**

VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE

Fakulta financí a účetnictví

katedra: Bankovnictví a pojišťovnictví

studijní obor: Bankovnictví a pojišťovnictví

Využití aplikace Google Trends při analýze finančních aktiv

Autor diplomové práce: Bc. Marek Koucký

Vedoucí práce: Ing. Milan Fičura, Ph.D.

Rok obhajoby: 2020

Čestné prohlášení:

Prohlašuji, že jsem diplomovou práci na téma Využití aplikace Google Trends při analýze finančních aktiv vypracoval samostatně a veškerou použitou literaturu a další prameny jsem řádně označil a uvedl v přiloženém seznamu.

V …… dne …….. ..…….……..…

Podpis

Poděkování:

Rád bych tímto poděkoval svému vedoucímu diplomové práce panu Ing. Milanu Fičurovi, Ph.D. za vstřícný přístup i čas, který mi věnoval a především za cenné připomínky k této diplomové práci.

Abstrakt

Hlavním cílem této diplomové práce je ověřit možnost využití dat získaných z aplikace Google Trends při analýze finančních aktiv. Celá práce je rozdělena do tří kapitol. První kapitola je věnována současným metodám analýzy finančních aktiv, především fundamentální a technické analýze. Druhá kapitola je zaměřena na samotnou aplikaci Google Trends. Ukazuje možnosti a způsoby použití, které tato aplikace nabízí. Poslední třetí kapitola se zabývá testováním a analýzou vybraných finančních aktiv pomocí dat získaných z aplikace Google Trends. Součástí této kapitoly je mimo jiné testování modelu GARCH (1,1) a obchodní strategie založené na vlastních technických indikátorech kombinujících informace získané z kurzu aktiva a objemů vyhledávání ve vyhledávači Google.

Klíčová slova: Google Trends, volatilita, GARCH (1,1), technická analýza

Abstract

The goal of this diploma's thesis is to verify the possibility of using data obtained from the Google Trends application in analysis of financial assets. The thesis is divided into three chapters. The first chapter is dedicated to the analysis of financial assets, especially to the fundamental and technical analysis. The second chapter describes the Google Trends application. It shows the possibilities and ways of using this application. The third and last chapter deals with the testing and analysing of financial assets using data obtained from the Google Trends aplication. This chapter also includes testing of the GARCH (1,1) model and optimization and backtesting of the trading system based on the combination of two technical indicators that gather information from asset rates and volumes of searching in Google's search engine.

Key words: Google Trends, volatility, GARCH (1,1), technical analysis

Obsah

Úvod ... 7
1 Současné metody analýzy finančních aktiv ... 9
1.1 Fundamentální analýza ... 9
1.1.1 Globální / makroekonomická / akciová analýza ... 10
1.1.2 Odvětvová analýza ... 10
1.1.3 Analýza jednotlivých tržních subjektů (společností) ... 10
1.2 Technická analýza ... 10
1.2.1 Trend ... 10
1.2.2 Metody technické analýzy ... 11
2 Google Trends ... 14
2.1 Aplikace Google Trends ... 14
2.2 Informace a jejich šíření v internetovém prostředí ... 18
2.3 Velká data – uživatelská data ... 19
2.4 Výzkum – Google Trends ... 19
2.5 Možnosti analýzy finančních aktiv pomocí Google Trends ... 26
2.6 Analýza účelu vyhledávání akcie Apple ... 26
3 Analýza finančních aktiv pomocí Google Trends ... 30
3.1 Základní analýza ... 31
3.1.1 Časová řada přepočtená popularita ... 31
3.1.2 Popularita ... 32
3.1.3 Analýza – zahajovací a uzavírací hodnota kurzu ... 34
3.1.4 Analýza – maximálních a minimálních hodnot kurzu ... 36
3.2 GARCH model ... 38
3.2.1 Postup tvorby modelu ... 38
3.2.2 Příprava časových řad ... 39
3.2.3 Šikmost, špičatost a Jarque-Bera test normality ... 40
3.2.4 Stacionarita - Dickey-Fullerův test ... 41
3.2.5 Tvorba modelů – Akaikeho informační kritérium ... 42
3.2.6 Modely s konstantou ... 43
3.2.7 Modely bez konstanty ... 44
3.2.8 Modely s přepočtenou popularitou ... 45
3.2.9 Modely s impulsy ... 46
3.2.10 Výběr nejlepších modelů ... 47
3.2.11 Testování reziduí nejlépe hodnocených modelů ... 48

3.2.12 Grafická analýza výsledků testování ... 51
3.2.13 Závěry k provedenému sestavení a testování modelů ... 53
3.3 Obchodní strategie ... 54
3.3.1 Indikátor Směru vývoje (MT) ... 54
3.3.2 Indikátor Relativní síly popularity (RSP) ... 54
3.3.3 Metody testování a optimalizace obchodního systému ... 55
3.3.4 Testování, optimalizace a backtesting dle 4. účelové funkce ... 58
3.3.5 Závěry k provedenému testování, optimalizaci a backtestingu ... 62
Závěr ... 67
Seznam použité literatury a pramenů ... 71
Seznam tabulek ... 72
Seznam grafů ... 73
Seznam obrázků ... 73
Seznam příloh ... 74

Úvod

Cílem této diplomové práce je pojednat o možnostech využití aplikace Google Trends při analýze finančních aktiv. Aplikace Google Trends nabízí uživatelům zdarma možnost nahlédnout na informace o popularitě jednotlivých klíčových slov zadávaných uživateli po celém světě do internetového vyhledávače Google.

V posledních letech tvoří významnou část prodejů obchodníků internetový prodej. K jeho neustálému nárůstu přispívá nejen pohodlnost uživatelů při nákupu, ale také personalizovaná reklama. Webové aplikace si data o uživatelích zaznamenávají a na základě jejich zájmů jim přiřazují reklamu. Ta je následně doprovází napříč internetovým prostředím na všech zařízeních. Velkým průkopníkem v internetové reklamě je společnost Google.

V dnešní podobě je systém nastaven tak, že uživatelé využívají většinu služeb společnosti Google zdarma, a na oplátku (někdy i nevědomě) mu poskytují data o svém chování při procházení webových stránek. Tato data následně Google analyzuje a na jejich základě připravuje uživateli obsah. Obsah představují informace a odkazy na odpovídající webové stránky. Obsah se řadí v pořadí dle souvisejících klíčových slov, popularity u ostatních uživatelů, důvěryhodnosti poskytovatele stránek, responzivity prostředí a dalších faktorů. Obecně se Google snaží zobrazit to, co uživatel skutečně hledá a výsledky doplňuje o relevantní reklamu.

Pro získaní odpovídajících výsledků vyhledávání je pro uživatele nejdůležitější správné zadání klíčových slov do vyhledávače. Mimoto, že Google dokáže přiřadit pro hledaný výraz odpovídající výsledky, klíčová slova slouží i jako podklad pro zobrazení reklamy. Stejně jako se dnes Google snaží odhadovat, o jaké zboží má uživatel zájem, mohou se uživatelská data použít pro zjištění zájmu o jednotlivá finanční aktiva. Následně mohou tato data sloužit pro inzerci finančních produktů. Nabízí se však i možnost využití při analýze kurzů finančních aktiv a predikci jejich budoucího vývoje. Právě touto možností se budu ve své diplomové práci podrobněji zabývat.

Cílem této práce je ověřit možnost využití aplikace Google Trends při analýze finančních aktiv. Celá práce je rozdělena do tří kapitol. V první kapitole se zaměřím na teoretickou podstatu zkoumání. Popíši metody zabývající se analýzou informací finančních trhů. Především se zaměřím na fundamentální a technickou analýzu a vliv působení lidského faktoru při provádění těchto analýz.

V druhé části se budu věnovat samotné aplikaci Google Trends a možnostem, které tato aplikace nabízí. Abych lépe ukázal veškeré možnosti, provedu dle informací získaných z aplikace Google Trends srovnání dvou sousedních měst. Následně se již budu zabývat pouze možnostmi využití aplikace Google Trends při analýze finančních aktiv. Analyzuji faktory ovlivňující šíření informací. Podrobněji budu zkoumat účel za jakým lidé mohou ve vyhledávači informace vyhledávat. Graficky znázorním vliv jednotlivých účelů vyhledávání na hodnotu kurzu finančního aktiva. Součástí této kapitoly bude také rešerše studií, které se možností využití objemů vyhledávání při analýze finančních aktiv již zabývaly.

Ve třetí kapitole budu analyzovat a testovat vliv objemu vyhledávání na vývoj hodnoty kurzů čtyř vybraných finančních aktiv. Nejprve vysvětlím pojem popularita a jak je v rámci této práce uvažován. Následně provedu analýzu decilových rozpětí časové řady relativně přepočteného objemu vyhledávání ve vztahu k vývoji hodnoty kurzu vybraných finančních aktiv. Vývoj hodnoty kurzu budu nejprve uvažovat jako vývoj časové řady zahajovacích a uzavíracích kurzů. Následně provedu analýzu i pro časovou řadu minimálních a maximálních hodnot kurzů finančních aktiv. Při analýze se zaměřím i na budoucí vývoj hodnot kurzů obou časových řad. Provedením této analýzy si tak potvrdím, nejen zda existuje vztah mezi vývojem objemů vyhledávání a vývojem kurzů finančních aktiv, ale i zda je možné časovou řadu objemů vyhledávání použit k predikci vývoje hodnoty kurzů finančních aktiv.

Možnost využití dat získaných z aplikace Google Trends při analýze finančních aktiv dále ověřím pomocí použití těchto dat v modelu GARCH, používaném pro modelaci volatility. V této části práce nejprve obecně popíši charakteristiky modelu GARCH a následně sestavím pro každé z vybraných finančních aktiv model. Vyzkouším různé varianty modelu s uplatněním časové řady relativně přepočteného objemu vyhledávání. Pro nejlepší model každého z vybraných aktiv otestuji rezidua modelu a zhodnotím přínos časové řady relativně přepočteného objemu vyhledávání pro model.

V poslední části této kapitoly se budu věnovat testování, optimalizaci a backtestingu obchodní strategie založené na vlastních indikátorech zohledňujících ve své konstrukci vývoj maximálních a minimálních hodnot kurzů a vývoj relativně přepočteného objemu vyhledávání. V rámci obchodní strategie definuji několik scénářů zachycujících určité vzorce chování investorů (vliv pohybu hodnoty kurzu a relativně přepočtených objemů vyhledávání na budoucí vývoj hodnoty kurzu). Testovací období si rozdělím na dvě části, kdy na první části provedu optimalizaci obchodních strategií a druhou část použiji k backtestu optimalizovaných strategií. V závěru vyhodnotím výsledky obchodních strategií při použití nadefinovaných vzorců chování a vyberu nejúspěšnější vzorce chování.

1 Současné metody analýzy finančních aktiv

Ačkoli metody využívající data z aplikace Google Trends spadají spíše do technické analýzy, k pochopení vlivu popularity klíčových slov na vývoj finančních aktiv je důležité porozumět i principům fundamentální analýzy. To především proto, že fundamentální analýza je mezi investory hojně využívána (ovlivňuje investiční rozhodování mnoha investorů). Ale také proto, že v případě významných šoků dochází často k výraznému nadhodnocení či podhodnocení hodnoty aktiva od jeho fundamentální hodnoty.

1.1 Fundamentální analýza

Fundamentální analýzu můžeme považovat za jednu z nejkomplexnějších analýz finančních aktiv, s níž se v běžné investorské praxi setkáváme. Její závěry se využívají při zásadních investičních rozhodnutích. Základním předpokladem fundamentální analýzy je, že se vnitřní hodnota (teoreticky stanovená cena akcie) liší od současných tržních cen (kurzů) akcií kótovaných na veřejných trzích. Výsledné investiční rozhodnutí je pak odvozeno od toho, zda je hodnota akcie nadhodnocená (vnitřní hodnota akcie je nižší než její kurz) nebo podhodnocená (vnitřní hodnota akcie je vyšší než její kurz).

Pro řádné provedení analýzy je nejdůležitější stanovit vnitřní hodnotu akcie. Tu je také možné chápat jako individuální pohled investora na správné ocenění dané akcie. Ke stanovení vnitřní hodnoty akcie využívají analytici/investoři nejrůznějších metod. Analýzy jednotlivých investorů se liší použitými metodami fundamentální analýzy. Avšak i při použití stejných metod mohou dojít k rozdílným výsledkům. To je způsobeno subjektivním přístupem k získávání a doplňování hodnot do vzorců. A také rozlišnostmi v informacích, jimiž disponují. Pro každé aktivum tak v průběhu času existuje mnoho rozdílných ocenění. Tím, že investoři tato ocenění zpracovávají do svých obchodních příkazů, vytváří kurz daného aktiva. Lze tedy tvrdit, že pokud se mění očekávání investorů, mění se hodnoty zadávané do výpočtů a z toho vycházející obchodní příkazy. To v důsledku ovlivňuje i kurzy aktiv.

Pro fundamentální analýzu je tedy důležitá analýza jednotlivých faktorů, které ovlivňují vnitřní hodnotu akcie. Vzhledem k tomu, že firmy (na jejichž hodnotě je velké množství finančních aktiv závislé) působí v reálném ekonomickém prostředí, je potřeba analyzovat nejen informace související s konkrétní firmou, ale i s ní přímo spojený ekonomický systém a globální prostředí. Rozhodující faktory mohou vycházet z kteréhokoli ze zmíněných prostředí. Neopomenutelným faktorem je také sám druh finančního aktiva. Jednotlivé druhy finančních aktiv se svými vlastnostmi mohou lišit a stejně tak práva a povinnosti z nich vycházející nemusí být identická.

Při řešení konkrétních investičních úloh je tak potřeba komplexně analyzovat mnoho rozlišných faktorů pomocí různých metod. Dle jejich charakteru je lze rozdělit do těchto skupin: globální / makroekonomická analýza, odvětvová analýza a analýza jednotlivých tržních subjektů [1, s. 237].

1.1.1 Globální / makroekonomická akciová analýza

Zkoumá ekonomiku jako celek. Soustředí se přitom na globální data a analyzuje vliv makroekonomických agregátů na vývoj kurzů finančních aktiv.

1.1.2 Odvětvová analýza

Pro odvětvovou analýzu je důležité identifikovat faktory ovlivňující vývoj v konkrétním odvětví (oboru) a stanovit jaký vliv mají změny jednotlivých faktorů na budoucí vývoj v odvětví. Zejména se analyzuje citlivost odvětví (oboru) na hospodářské cykly.

1.1.3 Analýza jednotlivých tržních subjektů (společností)

Zabývá se faktory, které přímo souvisí s konkrétní společností (tržním subjektem). Mimo kvantitativní faktory (výnos, růst) se sledují i faktory kvalitativní jako inovace a kvalita managementu.

1.2 Technická analýza

Technická analýza nachází své uplatnění především při analýze jednotlivých finančních aktiv. Cílem technické analýzy je predikce budoucího vývoje kurzu finančního aktiva. Případně může být využita ke sledování tržního vývoje jednotlivých trhů reprezentovaných burzovními indexy. Zdrojem dat technické analýzy jsou veřejně dostupné tržní informace (kurzy finančních aktiv, objemy zrealizovaných obchodů a další veřejně publikované informace).

Základní myšlenka technické analýzy předpokládá, že lidské chování má opakující se tendence. Při vyhodnocování situace na trhu se reakce investorů opakují. Toho lze dle technických analytiků využít k identifikaci trendů, a s jejich pomocí následně predikovat budoucí vývoj kurzů [1, s. 300].

1.2.1 Trend

Trend představuje základní pojem technické analýzy. Jeho identifikace je z pohledu technických analytiků klíčová pro správné určení budoucího vývoje finančních aktiv. Samotná identifikace trendu však není dostatečným vodítkem při vytváření obchodních rozhodnutí. Trend může být velmi proměnlivý a je nutné ho chápat jako celek v jeho jednotlivých podobách.

Identifikovat lze následující čtyři druhy trendů:

Primární trend

Klasifikuje se jako dlouhodobý trend s dobou trvání od jednoho roku do několika let. Tento trend je ovlivňován mnoha faktory a změnu či posílení trendu může způsobit kterýkoli z těchto faktorů. Při analýze trendu se sledují faktory podnikového, odvětvového i globálního charakteru.

Sekundární trend

Je charakterizován jako trend v délce trvání od několika týdnů do několika měsíců. Tento trend je možné pozorovat při zpětných pohybech v rámci primárního trendu (dle Dowovy teorie).

Terciální trend

Tyto trendy působí krátkodobě v řádu několika dnů. Jejich četnost, síla a délka trvání se odvíjí od charakteru konkrétního trhu, neboť představují náchylnost trhu k manipulaci, různé psychologické vlivy a jiné těžko odhadnutelné faktory.

Intradenní trend

Délka tohoto trendu je v rozmezí několika hodin nebo dokonce minut.

Trend lze dále dělit následujícím způsobem dle směru vývoje:

Rostoucí (býčí) trend

Tento trend je charakteristický postupným zvyšováním maxim a minim kurzu finančního aktiva. Kurz v průběhu času roste.

Klesající (medvědí) trend

Medvědí trend odpovídá opačné situaci, kdy má kurz tendenci klesat. Postupem času se maxima i minima kurzu snižují.

Postranní trend

Poslední trend z pohledu směru vývoje trendu představuje postranní trend. Ten je identifikovatelný svým horizontálním vývojem. Hodnota kurzu osciluje kolem určité úrovně.

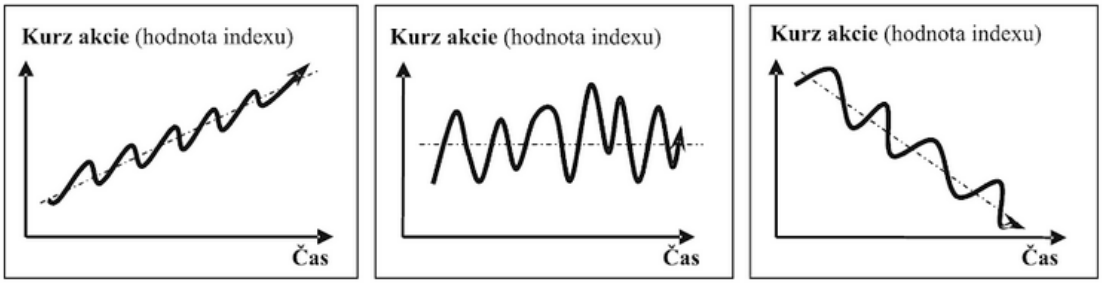

Obrázek 1: Dělení trendu dle směru vývoje (rostoucí, postranní, klesající), [1, s. 314]

1.2.2 Metody technické analýzy

Technická analýza zahrnuje následující druhy metod [2, s. 103]:

Grafická analýza

Nejzákladnější přístup představuje grafická analýza. Tu lze charakterizovat jako tvorbu různých druhů grafů zachycujících kurz (či jiná data související s vybraným aktivem) za účelem identifikace trendu a změn v současném i budoucím vývoji kurzu aktiva.

Trendové indikátory

Jak už název napovídá, trendové indikátory následují aktuální trend. K tomu dochází díky konstrukci indikátorů založené na klouzavých průměrech, jež způsobuje vyhlazené kopírování.

Technickým analytikům podávají trendové indikátory důležitou informaci o tom, jaký trend v současnosti probíhá. Zároveň většinou analytiky informují v případě změny trendu překročením určité hranice, jež je stanovena konstrukcí indikátoru a individuálním nastavením indikátoru analytikem.

Trendové indikátory jsou hojně využívány při vytváření automatických obchodních systémů. Za předpokladu správného nastavení, signalizují analytikovi situaci, kterou z pohledu vývoje trendu vyhledává. Mimo klouzavých průměrů (MA) zahrnuje tato skupina například indikátory Bollingerovy pásy, Parabolic SAR, MACD, TRIX a Vertical Horizontal Filter.

Trendovým indikátorům jsou často vyčítány jejich pomalejší reakce na změny trendu. To je však možné významně ovlivnit nastavením parametrů indikátorů a docílit tak optimálního nastavení z hlediska konkrétního finančního aktiva. Zhoršených výsledků dosahují indikátory také při postranním trendu, kdy generují příliš mnoho signálů.

Oscilátory

Oscilátory představují další velmi populární skupinu indikátorů. Jejich cílem je analyzovat změny v kurzu. Signály těchto indikátorů vychází z překračování předem stanovených pásem. Překročení těchto pásem pak značí překoupený či přeprodaný trh a v kombinaci s návratem do pásma oscilace identifikuje silný signál změny trendu.

Na rozdíl od trendových indikátorů je oscilátory možné použít i při postranním trendu. Naopak tyto indikátory mohou selhávat na býčím nebo medvědím trhu, kde vytváří mnoho falešných signálů, neboť se zde jejich křivka pohybuje okolo linií překoupeného či přeprodaného trhu (v závislosti na aktuálním trendu). Mezi oscilátory řadíme například Momentum, Stochastik, Index relativní síly (RSI) a Average Movement Directional Index (ADX).

Sentiment trhu (behavoriální indikátory)

Cílem sentiment indikátorů je sledovat psychologické aspekty účastníků trhu. Indikátory z této skupiny lze rozdělit do dvou podskupin, na cyklické a anticyklické sentiment indikátory.

Cyklické sentiment indikátory vyhodnocují chování profesionálních investorů. Anticyklické indikátory naopak sledují chování široké investorské veřejnosti. Očekává se, že profesionální investoři reagují na nové informace lépe a rychleji. Technický analytik by tedy měl jednat v souladu s vývojem cyklických sentiment indikátorů a opačně vůči anticyklickým sentiment indikátorům.

Nevýhodou těchto indikátorů je špatná dostupnost dat. V některých případech by se dalo dokonce spekulovat, zda je vhodné dané indikátory považovat za součást technické analýzy. Neboť by mělo platit, že data použitá při technické analýze jsou veřejně dostupná.

Indikátory šíře trhu

Indikátory šíře trhu analyzují trh jako celek, nejrozšířenější jsou při analýze akciových trhů. Data jsou tvořena údaji o jednotlivých akciových titulech. Zohledňují se počty rostoucích a klesajících akcií, kdy převaha rostoucích akcií vede k předpokladu býčího trendu a převaha klesajících akcií k předpokladu medvědího trendu. Pokles počtu rostoucích akcií během býčího trendu nebo pokles počtu klesajících akcií během medvědího trendu, upozorňuje na možnou změnu trendu. Predikce vycházející z indikátorů šíře trhu téměř nelze použít pro určení vývoje konkrétního cenného papíru. Indikátorem šíře trhu je například A/D Line a linie stoupání a klesání.

Objemové indikátory

Objemové indikátory ve své konstrukci pracují s objemem obchodů, a to buď samostatně nebo v kombinaci s kurzem. Hlavní myšlenkou objemových indikátorů je předpoklad, že objemy obchodů potvrzují trend. Tedy s růstem objemu obchodů dochází k pokračování stávajícího trendu a při poklesu objemu obchodů lze očekávat změnu trendu. Mezi objemové indikátory patří například On Balance Volume nebo Money Flow Index.

2 Google Trends

2.1 Aplikace Google Trends

Jedním z nástrojů, který nám umožňuje získat informace o tom, o co se lidé na internetu zajímají, je aplikace Google Trends [I.]. Ta nahradila dříve fungující aplikaci Google Sets, nabízející uživatelům hledání sémanticky příbuzných slov. Nynější Google Trends graficky znázorňuje, kolik lidí se zajímalo o určité klíčové slovo během stanoveného období na definovaném území. V závislosti na délce zvoleného období se data agregují do dnů, týdnů nebo měsíců.

V grafu se na ose y zobrazí relativně přepočítaný objem vyhledávání zvoleného klíčového slova. Přičemž hodnotě 100 odpovídá maximální hodnota za dané období. Ostatní hodnoty se vůči maximální hodnotě relativně přepočítají.

Zájem v průběhu času

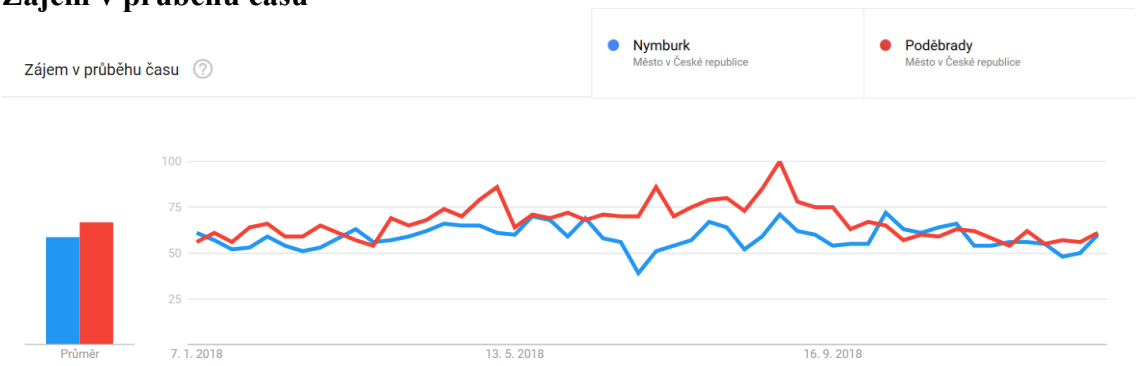

Graf 1: Zájem v průběhu času Nymburk vs Poděbrady, celosvětově, 2018, [I.]

Abych mohl lépe demonstrovat možnosti, které aplikace Google Trends nabízí, rozhodl jsem se pomocí aplikace nejprve analyzovat zájem o dvě sousední města v České republice. Konkrétně jde o města Nymburk a Poděbrady.

V grafu 1 výše můžeme pozorovat, že v průběhu roku 2018 byl o něco větší zájem ve vyhledávání o město Poděbrady. Zájem o města je značně ovlivňován kulturními událostmi, jež se v daném městě konají. Za zvolené období lze za nejsledovanější událost označit Mezinárodní festival filmové hudby a multimédií Soundtrack, který se konal na přelomu srpna a září v Poděbradech. Relativně přepočtený objem vyhledávání zde dosahuje svého maxima. Hodnoty ostatních dnů jsou tedy v relativním vyjádření k tomuto maximu. V tomto období lze pozorovat zvýšený zájem i o město Nymburk. Nicméně ten může být způsoben vyhledáváním města v souvislosti s posvícením, které se tou dobou ve městě každoročně koná.

Porovnání podle regionu

Obrázek 2: Porovnání podle regionu, Nymburk vs Poděbrady, celosvětově, 2018, [I.]

Obrázek 2 výše zobrazuje zájem o města dle jednotlivých regionů. Počet neodpovídá absolutnímu vyjádření, ale relativně přepočtenému zájmu na počet obyvatel daného regionu. Sytost barvy v mapě odpovídá tomu, které z měst bylo v daném regionu vyhledávanější. Regiony, kde byl o města nízký zájem, jsou znázorněny šedou barvou.

Obrázek 3: Zájem dle regionu, Nymburk vs Poděbrady, poměr vyhledávání, Rusko a USA, 2018, [I.]

Lze pozorovat, že Nymburk je vyhledávanější v USA, pravděpodobně i díky výrobním závodům, které jsou v blízkosti města umístěny. Zatímco Poděbrady jsou podstatně vyhledávanější v Ruské federaci, nejspíše kvůli oblibě zdejších lázní ruskými návštěvníky.

Zájem podle oblasti

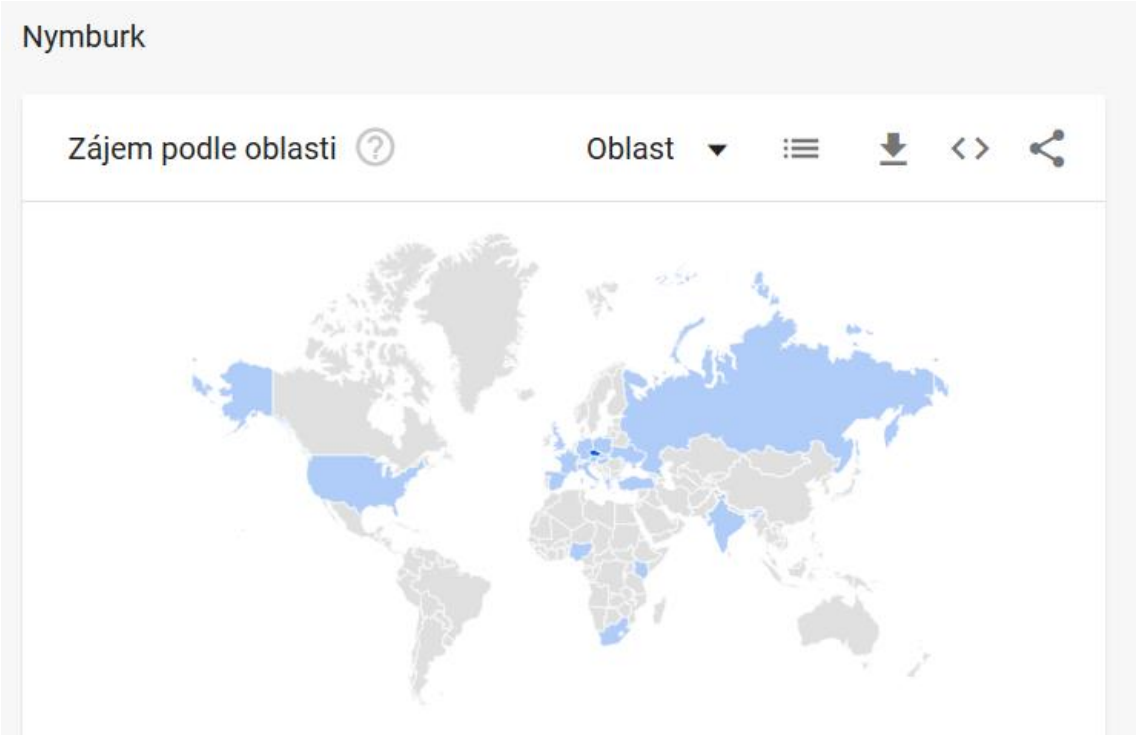

Obrázek 4: Zájem o město Nymburk, celosvětově, 2018, [I.]

Výše na obrázku 4 můžeme pozorovat zájem o město Nymburk. Nejvíce vyhledávání v přepočtu na počet obyvatel na daném území vychází na Českou republiku. V relativním přepočtu následuje Slovensko, kde relativní zájem vůči maximu (ČR) odpovídá 2. V ostatních oblastech je relativně přepočtená hodnota nižší než 1.

Související dotazy

Související dotazy — Na vzestupu

1	urad prace nymburk	Průlom
2	pepco nymburk	Průlom
3	hokej nymburk	Průlom
4	záložna nymburk	Průlom
5	zubní pohotovost nymburk	Průlom

Tabulka 1:Související dotazy pro klíčové slovo Nymburk, celosvětově, 2018, [I.]

Tabulka 1 výše ukazuje nejčastěji vyhledávané související dotazy s městem Nymburk. Nejpopulárnější slovní spojení za rok 2018 bylo „urad prace nymburk“.

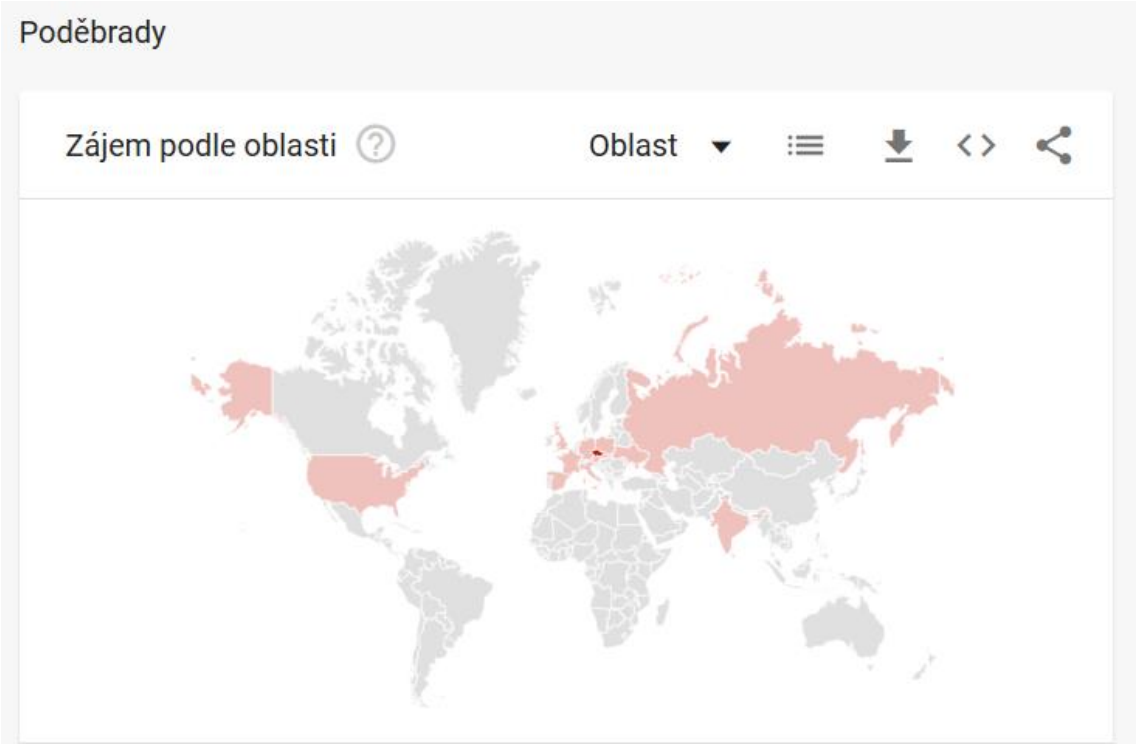

Obrázek 5: Zájem o město Poděbrady, celosvětově, 2018, [I.]

Stejně jako u města Nymburk jsou Poděbrady v relativním přepočtení na počet obyvatel nejčastěji vyhledávány v České republice.

Související dotazy — Na vzestupu

1	jysk podebrady	Průlom
2	opičkov poděbrady	Průlom
3	veřejné bruslení poděbrady	+4 600%
4	hc poděbrady	+300%
5	kemp poděbrady	+180%

Tabulka 2:Související dotazy pro klíčové slovo Poděbrady, celosvětově, 2018, [I.]

V souvislosti s městem Poděbrady vyhledávali uživatelé ve vyhledávači Google nejčastěji informace o nově otevřené prodejně mezinárodního maloobchodního řetězce JYSK. Dále se uživatelé zajímali o zařízení Opičkov, které nabízí propojení kavárny a dětského hřiště.

2.2 Informace a jejich šíření v internetovém prostředí

Data z aplikace Google Trends je možné využít nejen k porovnání popularity dvou sousedních měst, ale i k analýze finančních aktiv. Všechny pohyby cen finančních aktiv vychází z informací. Informace mohou mít různou podobu, ať už zachycují kvalitativní nebo kvantitativní stránku věci. Úvahou jsem dospěl k následujícím faktorům, které je nezbytné při šíření informací vnímat:

Významnost informace
(jak velký šok v hodnotě aktiva může informace způsobit)

Rozšířenost informace
(zda je informace rozšířená mezi profesionálními investory nebo i mezi běžnou investorskou veřejností)

Rychlost šíření informace
(jak rychle se informace šíří a jakými mediálními kanály se šíří)

Výsledný směr, či konkrétní hodnota aktiva
(směr vývoje nebo hodnota aktiva, ke které má informace cílit)

Jako informaci můžeme považovat nejen veškerá investiční doporučení, či události, ale také hodnoty dosazované do indikátorů, ukazatelů a jiných metod analýzy finančních aktiv. Dnes zastává velkou roli při šíření informací internet. Každý uživatel může zadávat libovolné dotazy a získávat požadované informace. Tyto informace následně uživatel využívá při svých investičních rozhodnutích. Podstatná část uživatelů při svých vyhledáváních využívá služeb společnosti Google. Google poskytuje uživatelům informace a na oplátku zaznamenává jejich aktivitu.

Graf 2: Popularita klíčového slova EUR USD, 1. 6. 2016 až 31. 7. 2016, na území USA, [I.]

V grafu 2 výše můžeme pozorovat, jak se vyvíjela vyhledávanost klíčového slova „EUR USD“ v období od června do července 2016. Maxima bylo dosaženo 24. 6. 2016. Ve vývoji lze sledovat určitou sezónnost dat. Kdy ve všední dny je zájem o klíčové slovo vyšší než o víkendu.

Pokud se zaměříme na faktory šíření informací uvedené výše v této části práce zjistíme, že nám Google Trends dokáže částečně odpovědět na otázku významnosti informace. Významnost informace lze vysledovat pomocí výraznějších odchylek ve vývoji objemů vyhledávání klíčového slova. V případě grafu 2 vidíme výrazné vychýlení ve vyhledávání dne 24. 6. 2016, kdy byly zveřejněny výsledky britského referenda o výstupu z EU. Zatímco významnost můžeme posuzovat dle relativně přepočteného objemu vyhledávání, rozšířenost, rychlost šíření informace a ani výsledný směr, či konkrétní hodnotu aktiva

dle samotné informace o vyhledávanosti příliš hodnotit nelze. Rychlost šíření informace by bylo možné posuzovat při delších trendech, avšak je těžké určit, zda vyhledávanost souvisí stále s původní informací nebo je způsobena dalšími informacemi. Rozšířenost by v případě finančních aktiv mohla být posuzována například tak, že bychom měli k dispozici i časovou řadu kurzů příslušného aktiva a předpokládali bychom, že objemy vyhledávání z aplikace Google Trends přísluší pouze investorské veřejnosti, neboť profesionální investoři používají jiné zdroje informací. Následně by se dalo určit, zda změna hodnoty kurzu aktiva byla podpořena zvýšenými objemy vyhledávání souvisejících klíčových slov, a tedy způsobena v důsledku jednání běžné investorské veřejnosti, nebo k žádné změně ve vyhledávání nedošlo a změna nastala v důsledku jednání profesionálních investorů. Směr vývoje by bylo teoreticky možné stanovit na základě určitých vzorců v chování investorů. Například pokud došlo ke změně hodnoty kurzu aktiva a současně k výraznému růstu vyhledávanosti, lze očekávat, že dojde k částečné korekci směrem zpět k původní hodnotě kurzu, neboť zejména na významnější informaci může běžná investorská veřejnost reagovat neúměrně.

2.3 Velká data – uživatelská data

Vznik velkých dat souvisí s náročnými vědeckými výpočty procesů a měření, ale také se zaznamenáváním proměn digitálního obsahu. V posledních letech jde především o využívání webových stránek, aplikací, sociálních sítí, mobilních zařízení a dalších technologií. Dnes většinu těchto dat vytváříme při každodenních běžných činnostech, jako je procházení webových stránek, komunikace na sociálních sítích nebo v diskusních fórech, nákupy v eshopech, platbami platební kartou, při téměř jakémkoliv využívání chytrých telefonů a nebo vytváření a sdílení multimediálního obsahu jako jsou fotky, videa či hudba.

Tato data získávají stále větší hodnotu. Tu představuje nejen stanovení preferencí konkrétního uživatele, ale zároveň vymezení preferencí uživatelů jako celku. Případně analýza preferencí nejrůznějších skupin uživatelů.

2.4 Výzkum – Google Trends

Quantifying Trading Behavior in Financial Markets using Google Trends

Autoři T. Preis, H. S. Moat a H. E. Stanley se ve své práci [II.] zaměřují na využití dat aplikace Google Trends při významných tržních pohybech. Pro účely svého výzkumu definují 98 klíčových slov souvisejících s klíčovým slovem „debt“ pomocí aplikace Google Sets, nástroje pro nalezení sémanticky přidružených slov.

V grafu 3 dále je zobrazena uzavírací cena Dow Jones Industrial Average (DJIA) a relativní změna v objemu vyhledávání definovaných klíčových slov. V grafu lze sledovat provázanost mezi výraznými navýšeními ve vyhledávání a pohyby indexu.

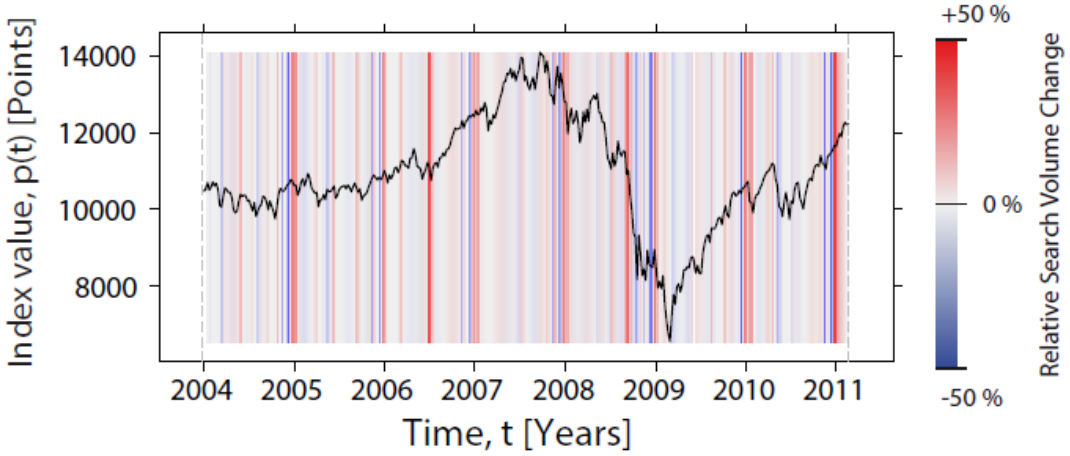

Graf 3: Objemy vyhledávání a pohyby na akciovém trhu, [II.]

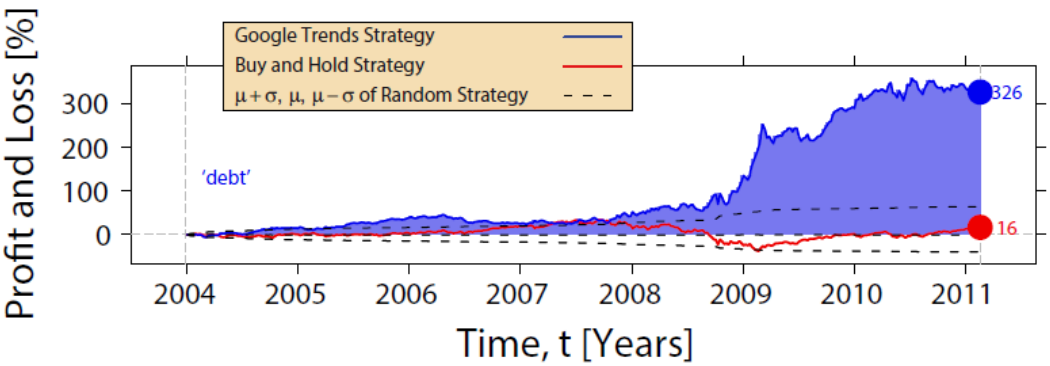

Graf 4: Kumulovaný výsledek obchodování při použití strategie založené na datech z aplikace Google Trends, [II.]

Graf 4 výše ukazuje kumulovaný výsledek obchodování nejlépe hodnocené obchodní strategie založené na klíčovém slově „debt" (modrá linie). Dále je zobrazena strategie „kup a drž", která je založena na náhodných nákupech či prodejích aktiva každý týden (červená linie). Jako poslední je zobrazena standardní odchylka deseti tisíc simulací náhodně provedených investičních strategií (černá přerušovaná linie).

Zajímavým zjištěním je to, že v případě použití dat vyhledávání za území USA bylo dosaženo lepších výsledků než při použití celosvětových dat. Kdy v prvním případě dosáhla strategie „debt" kumulativního výsledku obchodování 2,31 a ve druhém 1,87 (v relativním přepočtu ku standardní chybě deseti tisíc simulací náhodně provedených strategií).

Can we predict the financial markets based on Google's search queries?

Tato práce [III.] se zaměřuje na vztah mezi objemy ve vyhledávání vybraných klíčových slov a vývojem finančních trhů čtyř anglicky mluvících zemí.

Autoři této práce kladou důraz na výběr klíčových slov. Při výběru kritizují metodu založenou na aplikaci Google Sets, která při výběru slov souvisejících s finančním trhem zvolila i slova jako jsou například „garden", „fun", „home" a „environment" (zahrada, zábava, domov a prostředí). Mimo to, že aplikace Google Sets je od září roku 2014 neaktivní, autoři kritizují právě nesouvislost mezi některými vybranými slovy

a finančními trhy. Pro své modely tak vytvářejí databází slov pocházející z portálu Investopedia.com. Tato databáze čítá celkem 14 479 slovních spojení. Výběr nejdůležitějších klíčových slov pak provádí analýzou počtu výskytů jednotlivých slovních spojení ve čtyřech knihách (obrázek 6 níže) z finančního prostředí. Dvě knihy byly vybrány jako akademicky populární a další dvě jako nejprodávanější knihy na amazon.com z investičního prostředí.

(a) Jaffe et al. (2005)

(b) Lynch (2000)

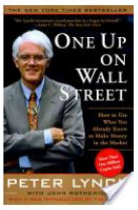

(c) Graham and McGowan (2005)

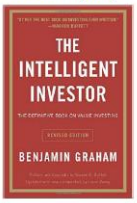

(d) Brealey (2011)

Number	Selected expression	Number of occurrences
1	Finance	2078
2	Cap	1752
3	Capital	1715
4	Corporate Finance	1355
5	Value	1298
6	Par	1077
7	Stock	965
8	Market	871
9	Risk	832
10	Cash	745
11	Dividend	739
12	Journal	718
13	Option	605
14	Year	547
15	Debt	540

Obrázek 6: Knihy použité pro výběr klíčových slov a výsledky četnosti výskytu jednotlivých klíčových slov, [III.]

Tabulka na obrázku 6 výše ukazuje přehled patnácti nejčastěji opakovaných slov. Nejvyšší četnosti výskytů dosahují slova „finance“, „cap“ a „capital“.

	US	GB	AU	CA
Total Return				
Buy & Hold	9,80%	-1,10%	-1,75%	13,20%
Gtrends (*stock*)	21,27%	10,06%	7,38%	18,63%
Arma-Garch	2,00%	-0,10%	-0,32%	13,04%
Risk (volatility)				
Buy & Hold	0,56%	0,52%	0,48%	0,50%
Gtrends (*stock*)	0,56%	0,52%	0,48%	0,50%
Arma-Garch	0,56%	0,52%	0,48%	0,50%
Sharpe Index				
Buy & Hold	0,050	-0,006	-0,010	0,075
Gtrends (*stock*)	0,109	0,056	0,044	0,107
Arma-Garch	0,010	-0,001	-0,002	0,074
% of portfolios with lower sharpe ratios				
Buy & Hold	0.58	0.11	0.46	0.29
Gtrends (*stock*)	0.98	0.79	0.97	0.63
Arma-Garch	0.31	0.14	0.62	0.28

Tabulka 3: Výsledky obchodování pomocí strategie založené na objemech vyhledávání, [III.]

Tabulka 3 výše zachycuje výsledky dosažené pomocí strategie Gtrends (stock). Ta představuje model založený na klíčovém slovu „stock“, které bylo při testování

hodnoceno nejlépe. Výsledky strategie Gtrends (stock) jsou výrazně lepší než strategie „kup a drž“ nebo strategie založené na modelu ARMA(1,1)-GARCH(1,1).

Feeling the Market’s Pulse With Google Trends

Poslední práce [IV.], kterou bych chtěl zmínit se zabývá propojením dat získaných z aplikace Google Trends a nástrojů technické analýzy. Vyhledávání zde reprezentuje SVI (Search Volume Index), ten odpovídá výstupu aplikace Google Trends. Hledanost vybraného klíčového slova je relativně přepočtena (100 odpovídá maximální hodnotě za zvolené období).

ADX a SVI

V prvním případě se v práci uvažuje kombinace indikátoru SVI a ADX (Average Directional Indicator). Autoři zde uvádí dva možné scénáře, které je pomocí této kombinace možné pozorovat:

Graf 5: ADX a SVI, SBUX, klíčové slovo SBUX, 2012 až 2014, [IV.]

1. První scénář odpovídá situaci, kdy je trend řízen neprofesionálními investory. Indikátor ADX roste nad 25 a stejně tak index SVI značí zvýšený zájem

ve vyhledávání. Dle autorů lze v této situaci očekávat brzkou změnu trendu (trend má krátkou životnost). Růst ceny je totiž řízen krátkodobým sentimentem nikoli dlouhodobými změnami ve fundamentu.

2. Druhý scénář uvažuje přítomnost profesionálních investorů. Indikátor ADX roste nad 25, ale index SVI je neutrální nebo klesá. Vzhledem k přítomnosti profesionálních investorů se očekává větší konzistentnost a dlouhodobější setrvání trendu.

Analýza pohybů cen a SVI

Druhý případ analyzuje vliv vyhledávání v podobě indexu SVI na cenu, viz graf 6 níže. Opět jsou uvažovány dva možné scénáře:

1. Dochází k prudkému poklesu v ceně. Pokles však není doprovázen zvýšeným zájmem ze strany retailových investorů (SVI je neutrální nebo klesá). Stejně jako u indikátoru ADX se zde uvažuje, že index SVI představuje zájem retailových investorů. Pohyb v ceně je tedy přisuzován profesionálním investorům a očekává se jeho konzistentnost.
2. Druhý scénář popisuje situaci, kdy jsou přítomni retailoví investoři. Pokles v ceně (pohyb v ceně) je doprovázen zvýšením zájmu ve vyhledávání v podobě růstu SVI. Vzhledem k přítomnosti retailových investorů se opět uvažuje krátká životnost trendu.

Graf 6: Cenové pohyby a SVI, BP, klíčové slovo BP, 2009 až 2011, [IV.]

Oscilátory a SVI

Index SVI je dále možné použít pro potvrzení divergencí vznikajících u vybraných cenových oscilátorů. Konkrétně je uvažován indikátor RSI (Relative Strength Index). Stejně jako v předchozích případech rozhoduje přítomnost profesionálních investorů. V případě, kdy je pohyb v ceně přisuzován retailovým investorům, lze očekávat následnou korekci pohybu (divergence nezpůsobí změnu trendu). Naopak v případě účasti profesionálních investorů SVI svou neutralitou potvrzuje divergenci (změnu trendu), viz graf 7 níže.

Graf 7: Oscilátory a SVI, LYG, klíčové slovo LYG, 2011 až 2012, [IV.]

Bollinger Bands a SVI

Poslední případ zkoumá možnost využití indexu SVI v kombinace s bollingerovými pásy. SVI zde slouží pro potvrzení signálů generovaných překročením pásma. V grafu 8 níže jde o překročení spodní hranice pásma. Očekává se tedy korekce a změna medvědího trendu na býčí. Index SVI opět představuje indikátor přítomnosti profesionálních investorů. Pokud není překročení pásma doprovázeno přítomností profesionálních investorů, je signál považován za falešný. Naopak přítomnost profesionálních investorů signál potvrzuje.

Graf 8: Bollingerovy pásy a SVI, HPQ, klíčové slovo HPQ, 2012 až 2013, [IV.]

2.5 Možnosti analýzy finančních aktiv pomocí Google Trends

Existuje několik možných způsobů vysvětlení vlivu vývoje objemů vyhledávání na vývoj hodnoty kurzu aktiva. Jako základní přístup bych označil snahu o predikci volatility. Kdy by mělo platit, že pokud roste zájem o určité aktivum, roste i volatilita s ním souvisejících instrumentů. To samozřejmě nemusí platit vždy, protože rozhodujícím faktorem je zde především účel, za jakým lidé dané klíčové slovo vyhledávají. Například pokud se zaměříme na klíčové slovo Apple, můžeme očekávat následující účely vyhledávání:

1. Zájem o informace o společnosti Apple
2. Zájem o produkty společnosti Apple
3. Zájem o akcie Apple
4. Zájem o Apple ve smyslu ovoce

2.6 Analýza účelu vyhledávání akcie Apple

Graf 9 níže nám ukazuje, jak se vyvíjela hodnota akcie Apple Computer za období od 1. 4. 2018 do 30. 11. 2018. V grafu jsem zvýraznil body, kdy došlo k nejvýznamnějším pohybům v kurzu akcie. Na zobrazeném úseku vidíme, že kurz akcie postupně roste. Následně na začátku října dochází ke změně trendu a nastupuje celkem rychlý pokles směrem k původní hodnotě, téměř až na úroveň 170 USD za akcii.

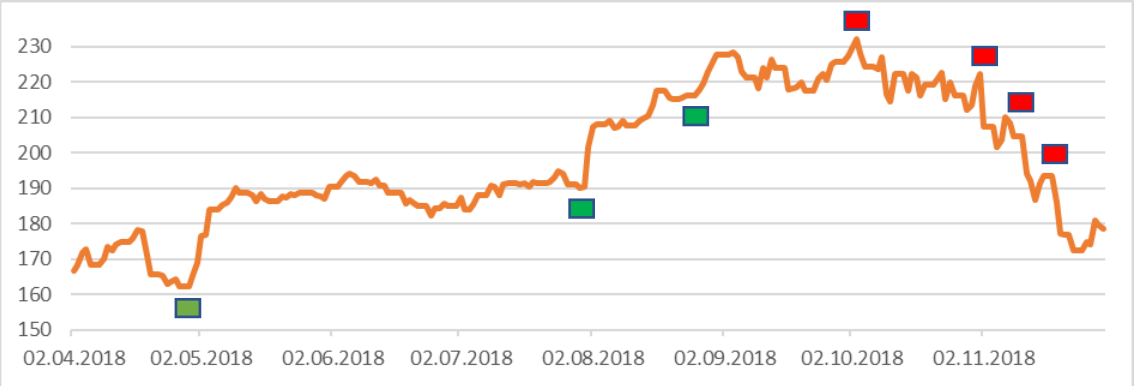

Graf 9: Vývoj akcie Apple (USD), (1.4. až 30. 11. 2018), na území USA, [V.]

Dle výše uvedených příkladů můžeme odhadovat, jaký mají jednotlivá vyhledávaní význam pro vývoj finančního aktiva.

1. V prvním případě uživatel vyhledává informace o společnosti Apple, jeho službách a produktech. Vliv na vývoj akcie by měl být spíše neutrální. Uvažujeme především informativní charakter dotazu. Obdobný příklad může představovat i kurz měnového páru výše (graf 2), kdy většinu uživatelů zajímá pouze hodnota kurzu. Ačkoli i to může mít dopad na vývoj hodnoty kurzu.

   Největší zájem o klíčové slovo „Apple“ ve smyslu společnosti (firmy) byl za zvolené období během září, konkrétně 12. 9. 2018 a následně na konci listopadu 23. 11. 2018 (graf 10). Pokud bychom uvažovali zpoždění v reakci investorů. Dalo by se říci, že změna trendu za zvolené období následovala právě

po zvýšeném zájmu. K potvrzení vlivu vyhledávaní by však byla potřeba hlubší analýza.

Graf 10: Popularita klíčového slova Apple (ve smyslu společnosti), (1.4. až 30. 11. 2018), na území USA, [I.]

2. Ve druhém případě už je situace odlišná. Pokud je zvýšený zájem o produkty společnosti, lze za jistých okolností očekávat i pohyby v kurzu akcie. Zde se však dle mého názoru musí data posuzovat v delším horizontu. Pakliže by platila hypotéza, že zvýšený zájem bude mít za následek zvýšené prodeje oproti očekávání, projeví se to v kurzu akcie společnosti až se zpožděním. Ačkoli lze očekávat, že například ve chvíli, kdy je na trh uveden nový produkt, může kurz reagovat okamžitě.

   V grafu 11 vidíme určitou sezónnost, kdy o víkendech je klíčové slovo „Apple TV " podstatně vyhledávanější než ve všední dny. Výrazný výkyv pozorujeme 23. října 2018. Ten je pravděpodobně způsoben vyhledáváním produktu v rámci akcí „Black Friday". Vývoj kurzu akcie v tomto případě s vyhledáváním nejspíše nesouvisí.

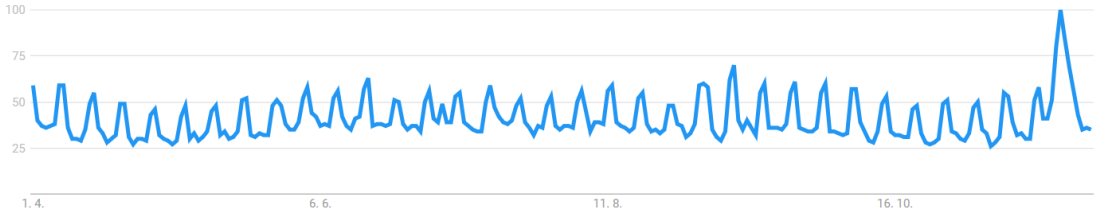

Graf 11: Popularita klíčového slova Apple TV, (1.4. až 30. 11. 2018), na území USA, [I.]

Abychom mohli porovnat zájem o nový produkt a produkt zaběhlý (Apple TV), rozhodl jsem se v rámci tohoto účelu (hledání informací o produktu) zpracovat ještě klíčové slovo iPhone XS. Jde o produkt, který byl představen 12. září 2018. Vidíme (graf 12), že toto klíčové slovo koresponduje s klíčovým slovem Apple (firma) – největší zájem odpovídá 13. 9. 2018. Z proběhlého vývoje lze odhadovat, že informace uvolněné o tomto produktu byly pro investory spíše zklamáním. Vzhledem k následnému prudkému poklesu ceny akcií. Opět jde však pouze o hypotézu a přímý vliv nelze ověřit.

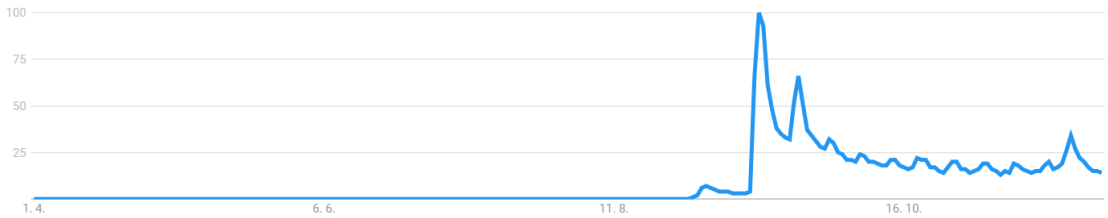

Graf 12: Popularita klíčového slova Apple XS, (1.4. až 30. 11. 2018), na území USA, [I.]

U tohoto účelu hledání je tak především problém ve stanovení, jakého období se konkrétní zvýšení vyhledávání týká. Neboť událostem (informacím), které nabývají platnosti v krátkém období bude pravděpodobně věnována větší pozornost (větší pravděpodobnost pohybu kurzu), než při analýze informací, které se promítnou až se zpožděním.

3. Třetí dotaz má nejspíše největší přímý vliv na vývoj kurzu akcie. Pakliže uživatel vyhledává klíčové slovo „Apple stock", lze očekávat, že se jedná buď o zájemce o akcie nebo vlastníka akcií. Problémem v souvislosti s predikcí vývoje kurzu zde může být zpoždění, kdy vzhledem k tomu, že většina trhů reaguje na informace velmi rychle, nemusí být pro reakci na zájem o klíčové slovo dostatečný časový prostor.

   Pozorovaná sezónnost dat (graf 13) by mohla odpovídat zájmu kvalifikovaných investorů, kteří informace o akciích sledují pravidelně. Zatímco výraznější změny by mohly odpovídat zájmu nekvalifikovaných investorů. Pokud bychom uvažovali jako indikátory pohybu kurzu (zvýšené volatility) úrovně, kde relativní zájem vzrostl nad 50, zjistíme, že body celkem odpovídají bodům, které jsem zvýraznil v grafu 9. Otázkou tak zůstává především to, zda by bylo prakticky možné data o vyhledávání, v podobě v jaké jsou k dispozici na Google Trends, využít k reakcím na vývoj kurzu v reálném čase.

Graf 13: Popularita klíčového slova Apple stock, (1.4. až 30. 11. 2018), na území USA, [I.]

4. Čtvrtý příklad účelu vyhledávání s vývojem hodnoty kurzu akcií společnosti Apple nesouvisí a hodnotu akcií společnosti nejspíše neovlivňuje, ačkoli je klíčové slovo „Apple“ obsaženo v názvu i logu společnosti. Tomu odpovídá i vývoj grafu 14, který je celkem náhodný.

Graf 14: Popularita klíčového slova Apple fruit, (1.4. až 30. 11. 2018), na území USA, [I.]

3 Analýza finančních aktiv pomocí Google Trends

V této části práce provedu hlubší analýzu popularity čtyř vybraných finančních aktiv, respektive čtyř klíčových slov souvisejících s těmito aktivy, a budu zkoumat vliv objemu vyhledávání klíčových slov na hodnotu kurzu těchto aktiv. K analýze jsem vybral aktiva, která jsou populární i mezi neprofesionálními investory. Důvodem je očekávání určitého zpoždění v absorpci informací, jež by mohlo dát prostor pro ex-ante predikci vývoje kurzu či volatility. Pokud bych zvolil aktiva obchodovaná především profesionálními investory, mohl by být trh při absorpci informací efektivnější. Výjimkou ve výběru je měnový pár EUR USD, u kterého lze očekávat vyšší efektivitu trhu.

Vybranými aktivy jsou akcie společnosti Apple, akcie společnosti Facebook, měnový pár EUR USD a kryptoměna Bitcoin. Níže uvádím krátce informace o vybraných finančních aktivech.

Apple Computer (klíčové slovo „Apple stock“)

Společnost Apple navrhuje a vyrábí mobilní a multimediální zařízení, osobní počítače a přenosné přehrávače. Součástí portfolia společnosti je nabídka software, služeb, příslušenství, síťových řešení a aplikací třetích stran. Společnost byla založena v roce 1976 ve městě Cupertin v Kalifornii, v oblasti amerického Silicon Valley. Tato firma se zasloužila o nástup osobních počítačů v 70. letech 20. století.

Mezi produkty a služby firmy v současnosti patří Mac, iPhone, iPad, iPod, Apple Watch, Apple TV, portfolio spotřebitelských a profesionálních softwarových aplikací, úložiště iCloud, Apple Pay a další služby.

Facebook (klíčové slovo „Facebook stock“)

Sociální síť Facebook umožňuje komunikaci mezi uživateli a sdílení multimediálních dat. Facebook byl založen Markem Elliotem Zuckerbergem spolu s jeho kolegy během studií na Harvardské univerzitě.

Mezi produkty společnosti Facebook, Inc, patří mimo jiné i Instagram, Messenger nebo WhatsApp. Facebook je poměrně rychle rostoucí společnost. Na příjmech Facebooku má velký podíl jeho nabídka marketingových služeb, především v podobě cílené reklamy.

EUR USD (klíčové slovo „EUR USD“)

Vztah dvou vyspělých ekonomických celků zachycuje měnový pár EUR USD. Jedná se o nejvýznamnější pár, který má poměrně vysokou volatilitu. Americký dolar je nevíce používaná měna v mezinárodních transakcích. Představuje také jednu z nejdůležitějších determinant ovlivňujících světovou ekonomiku. Vývoj kurzu dolaru vůči ostatním měnám velmi úzce souvisí s vývojem finančních trhů, s monetární politikou zemí celého světa, rozhodováním institucionálních i drobných investorů i s vývojem cen nejdůležitějších světových komodit. Druhou nejvýznamnější měnou v mezinárodním měnovém systému je Euro, které je také společnou měnou zemí eurozóny. Do oběhu bylo zařazeno 1. 1. 2002.

Bitcoin (klíčové slovo „Bitcoin“)

Bitcoin je v současnosti velmi populární kryptoměna, která mimo jiné zahrnuje i open-source P2P platební síť. Bitcoin je plně decentralizován. Je navržen tak, aby autor, nebo jiní jednotlivci či skupiny, nemohl měnu padělat, ovlivňovat nebo způsobovat inflaci. V síti není nikdo, kdo by mohl o síti rozhodovat. Množství bitcoinů je předem dané, uvolňování do oběhu je definováno ve zdrojovém kódu sítě.

3.1 Základní analýza

3.1.1 Časová řada přepočtená popularita

K analýze jsem využil dat získaných z aplikace Google Trends. Data však není možné stáhnout v denní frekvenci za libovolné období. Při výběru delšího období dochází k převodu na týdenní či delší frekvenci.

Proto jsem uložil jednotlivé úseky dat v denní frekvenci a následně relativně přepočetl jejich hodnotu za celé období. Popularita v některých dnech proto mohla přesáhnout úroveň 100. Data jsem uložil tak, aby došlo částečně k jejich prolnutí. Druhé období tedy zahrnuje i část prvního období atd. Sloupce *MaxA* a *MaxB* zachycují maximální hodnotu popularity v průniku období s obdobím předcházejícím. Koeficient je roven podílu *MaxA* a *MaxB* relativně vztaženému k prvnímu období. Převodem všech období jsem tak získal časovou řadu „Přepočtená popularita“ popisující popularitu přibližně v pětiletém úseku pro všechna vybraná finanční aktiva. Tabulka 4 níže ukazuje výstup přepočtu pro akcii společnosti Apple. Pro ostatní aktiva je tabulku možné dohledat v přílohách B1 až B3.

Období	Počáteční datum	Koncové datum	MaxA	MaxB	Koeficient
1	01.11.2013	30.06.2014	x	x	1
2	01.05.2014	31.12.2014	100,00	93,00	1,08
3	01.11.2014	30.06.2015	28,00	42,00	0,72
4	01.05.2015	31.12.2015	41,00	27,00	1,09
5	01.11.2015	30.06.2016	28,00	31,00	0,98
6	01.05.2016	31.12.2016	62,00	85,00	0,72
7	01.11.2016	30.06.2017	62,00	59,00	0,75
8	01.05.2017	31.12.2017	84,00	46,00	1,38
9	01.11.2017	30.06.2018	77,00	100,00	1,06
10	01.05.2018	31.12.2018	80,00	46,00	1,84

Tabulka 4: Přepočtená popularita klíčového slova Apple stock, vlastní tvorba

Data kurzů jsem získal ze serveru patria.cz [V.] a coinmarketcap.com [VI.]. Zatímco Google Trends nabízí data pro každý den včetně víkendů a svátků, hodnoty kurzů mimo obchodní dny k dispozici nejsou. K doplnění dat vyhledávanosti k řadě kurzů jsem použil následující postup: V případě, že některý den v řadě kurzů chyběl, k následujícímu dni (s kurzem) se doplnila vyšší z hodnot vyhledávanosti následujícího nebo současného dne. Každému pondělnímu kurzu tak náležela nejvyšší hodnota popularity dosažená v období sobota až pondělí.

3.1.2 Popularita

Pojem popularita je v rámci práce uvažován jako vyhledávanost (relativně přepočtený objem vyhledávání) určitého klíčového slova v internetovém vyhledávači společnosti Google. Popularita klíčového slova roste a klesá v návaznosti na události a informace objevující se v souvislosti s klíčovým slovem viz část 2.6.

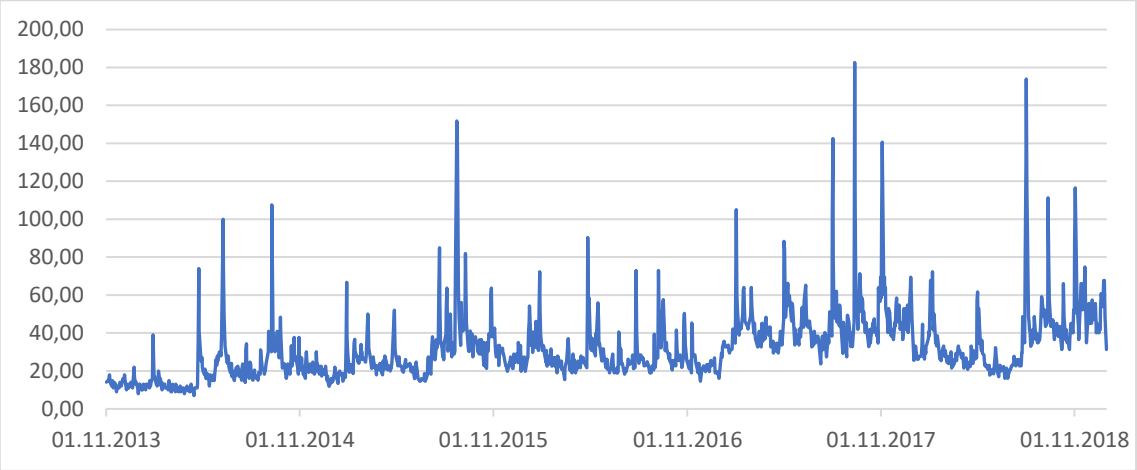

Graf 15: Popularita klíčového slova Apple stock, vlastní tvorba

Graf 15 výše zobrazuje vývoj popularity klíčového slova „Apple stock“ za přibližně pětileté období. Z grafu je patrná volatilita popularity v průběhu celého období. Zájem o klíčové slovo je proměnný a oblasti zájmu dosahují několikanásobku průměrné hodnoty. Nejvyšších hodnot dosahuje popularita při oznamování nových produktů, případně výsledků hospodaření. Maximální hodnoty popularita nabývá 12. září 2017 po představení nového mobilního telefonu iPhone X.

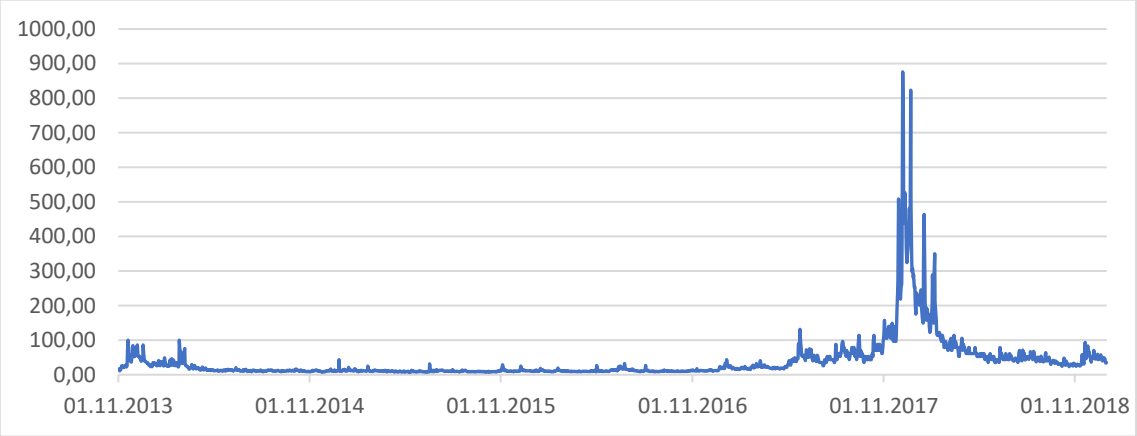

Graf 16: Popularita klíčového slova Bitcoin, vlastní tvorba

Graf 16 výše zachycuje vývoj popularity klíčového slova „Bitcoin“. Popularita Bitcoinu za sledované období průběžně rostla až do prosince roku 2017, kdy 22. prosince dosáhla svého maxima. Popularita v maximu je spojena s prudkým poklesem hodnoty Bitcoinu po krachu korejské burzy kryptoměn.

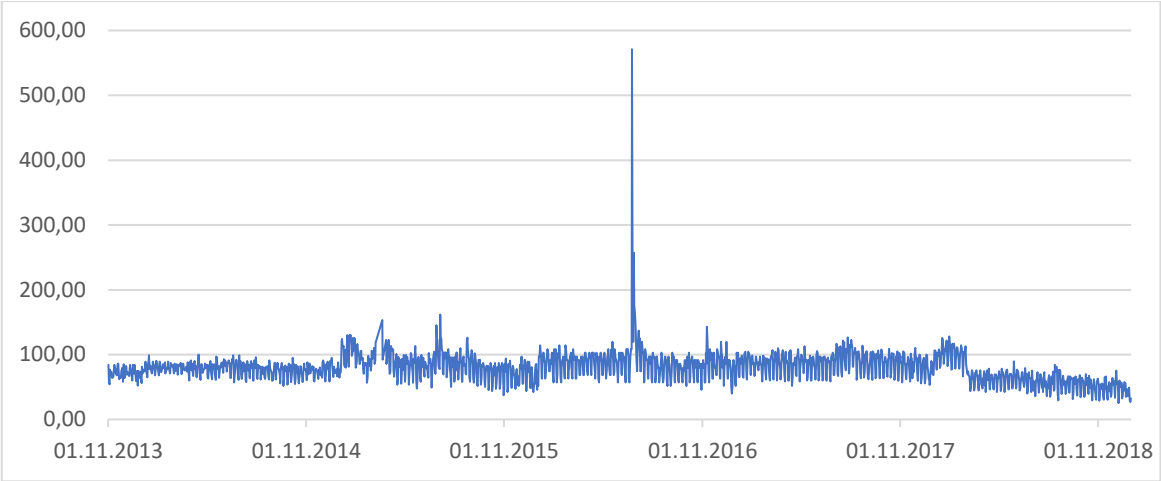

Graf 17: Popularita klíčového slova EUR USD, vlastní tvorba

Graf 17 zobrazuje popularitu klíčového slova „EUR USD“. Popularita je zde celkem stabilní a nedochází k výraznějším odchylkám. Výjimku představuje datum 24. června 2016, kdy byly zveřejněny výsledky referenda o výstupu Velké Británie z EU.

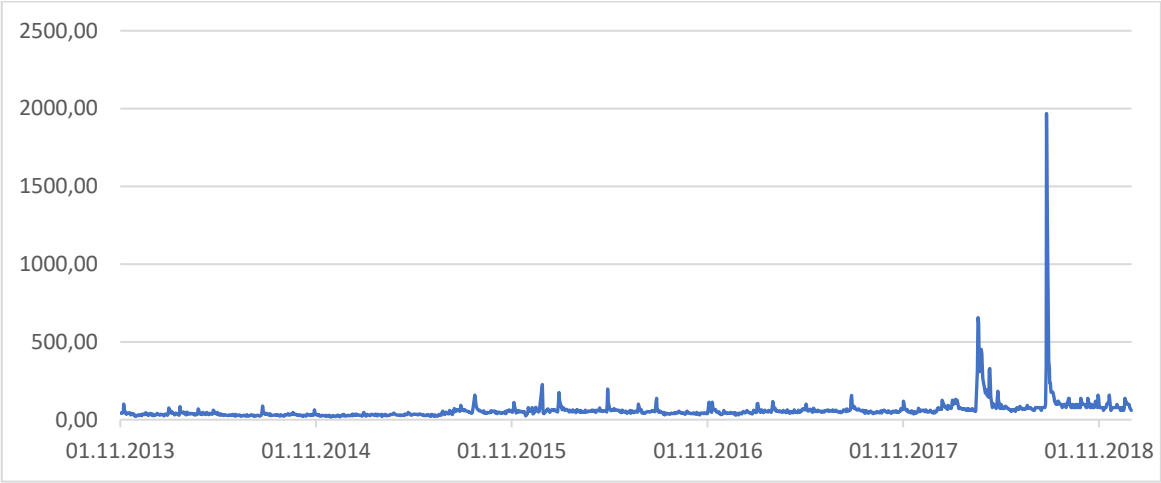

Graf 18: Popularita klíčového slova Facebook stock, vlastní tvorba

Graf 18 ukazuje popularitu klíčového slova „Facebook stock“. Popularita v rámci pětiletého období značně kolísá. Lokální maximum lze pozorovat například 22. března 2018, kdy došlo k oznámení ohledně úniku uživatelských dat. Maxima ve zvoleném období popularita dosahuje 26. července 2018, kdy hodnota akcií náhle klesla o přibližně 19 % v reakci na zveřejnění výsledků hospodaření.

3.1.3 Analýza – zahajovací a uzavírací hodnota kurzu

Abych mohl ověřit, zda mají data z aplikace Google Trends vliv na volatilitu hodnoty kurzu finančních aktiv, rozhodl jsem se analyzovat jednotlivé decily popularity z hlediska absolutní hodnoty změny v hodnotě kurzu za různá časová období.

Decilová rozpětí v tomto případě rozdělují *Popularitu* na přibližně stejně velké úseky dle distribuční funkce. Ve sloupci *Popularita* můžeme dohledat popularitu pro horní hranici příslušného decilového rozpětí. Hodnota *Median_t* odpovídá mediánu absolutní hodnoty změny zahajovací a uzavírací ceny obchodního dne pro odpovídající decilové rozpětí. Sloupce *t+1* až *t+5* udávají medián absolutní hodnoty denní změny uzavíracího kurzu v čase *t+1* až *t+5* (dle zvoleného sloupce) pro příslušné decilové rozpětí.

Decilové rozpětí	Popularita	Median_t	t+1	t+2	t+3	t+4	t+5
Q_0-$Q_{0,1}$	15,87	0,68%	0,80%	0,53%	0,49%	0,41%	0,37%
$Q_{0,1}$-$Q_{0,2}$	20,42	0,63%	0,69%	0,60%	0,50%	0,47%	0,41%
$Q_{0,2}$-$Q_{0,3}$	22,61	0,56%	0,64%	0,55%	0,48%	0,39%	0,39%
$Q_{0,3}$-$Q_{0,4}$	25,00	0,81%	0,70%	0,48%	0,39%	0,38%	0,33%
$Q_{0,4}$-$Q_{0,5}$	28,00	0,49%	0,63%	0,55%	0,54%	0,44%	0,40%
$Q_{0,5}$-$Q_{0,6}$	32,34	0,73%	0,91%	0,56%	0,44%	0,38%	0,38%
$Q_{0,6}$-$Q_{0,7}$	36,78	0,62%	0,70%	0,54%	0,56%	0,43%	0,42%
$Q_{0,7}$-$Q_{0,8}$	42,52	0,59%	0,65%	0,38%	0,39%	0,40%	0,38%
$Q_{0,8}$-$Q_{0,9}$	52,37	0,68%	0,92%	0,72%	0,54%	0,43%	0,41%
$Q_{0,9}$-Q_1	182,61	0,96%	1,00%	0,79%	0,54%	0,57%	0,46%

Tabulka 5: Decilová analýza změny zahajovací a uzavírací hodnoty, klíčové slovo Apple stock, vlastní tvorba

Z tabulky 5, zachycující analýzu klíčového slova „Apple stock“, je patrné, že s rostoucím zpožděním významnost popularity klesá a v čase *t+5* už nemá prakticky žádný vliv. Současně můžeme pozorovat, že pro rozpětí od Q_0 do $Q_{0,9}$ také nemá popularita větší význam. Neboť s rostoucí popularitou se volatilita nezvyšuje. Vliv popularity na změnu hodnoty je pozorovatelný až od decilu $Q_{0,9}$, kdy je absolutní hodnota změny podstatně vyšší než pro ostatní decily. To je pozorovatelné v čase *t, t+1 a t+2*.

Decilové rozpětí	Popularita	Median_t	t+1	t+2	t+3	t+4	t+5
Q_0-$Q_{0,1}$	9,20	0,67%	0,78%	0,64%	0,52%	0,51%	0,45%
$Q_{0,1}$-$Q_{0,2}$	10,18	0,78%	0,74%	0,72%	0,63%	0,57%	0,46%
$Q_{0,2}$-$Q_{0,3}$	10,87	0,96%	1,09%	0,70%	0,73%	0,68%	0,58%
$Q_{0,3}$-$Q_{0,4}$	12,17	1,28%	1,31%	0,94%	0,76%	0,71%	0,60%
$Q_{0,4}$-$Q_{0,5}$	15,23	1,80%	1,68%	1,23%	1,04%	0,87%	0,80%
$Q_{0,5}$-$Q_{0,6}$	24,40	1,68%	1,51%	1,47%	1,26%	1,23%	1,24%
$Q_{0,6}$-$Q_{0,7}$	38,48	1,44%	1,86%	1,16%	0,97%	0,96%	0,85%
$Q_{0,7}$-$Q_{0,8}$	52,55	2,06%	2,21%	1,75%	1,62%	1,49%	1,40%
$Q_{0,8}$-$Q_{0,9}$	78,83	3,35%	2,68%	2,12%	1,42%	1,37%	1,31%
$Q_{0,9}$-Q_1	875,90	4,98%	4,43%	3,11%	2,45%	2,19%	1,91%

Tabulka 6: Decilová analýza zahajovací a uzavírací hodnoty, klíčové slovo Bitcoin, vlastní tvorba

Tabulka 6 ukazuje výsledky analýzy pro klíčové slovo „Bitcoin“. I v tomto případě je volatilita pro decily s vyšší popularitou zvýšená. Přičemž vliv lze sledovat v decilovém rozpětí od $Q_{0,7}$ do Q_1. To je pozorovatelné za všechna období od *t do t+5*. Z výsledků je možné usuzovat, že trh Bitcoinu absorbuje informace pomaleji než trh akcií společnosti Apple, případně informace způsobují větší šoky, které trh není schopný tak rychle absorbovat.

Decilové rozpětí	Popularita	Median_t	t+1	t+2	t+3	t+4	t+5
Q_0-$Q_{0,1}$	55,14	0,04%	0,12%	0,16%	0,13%	0,12%	0,12%
$Q_{0,1}$-$Q_{0,2}$	62,82	0,02%	0,14%	0,15%	0,12%	0,10%	0,12%
$Q_{0,2}$-$Q_{0,3}$	68,53	0,04%	0,13%	0,15%	0,16%	0,14%	0,14%
$Q_{0,3}$-$Q_{0,4}$	75,00	0,10%	0,15%	0,14%	0,13%	0,11%	0,11%
$Q_{0,4}$-$Q_{0,5}$	80,90	0,21%	0,18%	0,13%	0,13%	0,12%	0,10%
$Q_{0,5}$-$Q_{0,6}$	85,66	0,21%	0,17%	0,14%	0,12%	0,11%	0,10%
$Q_{0,6}$-$Q_{0,7}$	91,00	0,30%	0,20%	0,12%	0,12%	0,12%	0,10%
$Q_{0,7}$-$Q_{0,8}$	97,08	0,27%	0,23%	0,17%	0,16%	0,14%	0,12%
$Q_{0,8}$-$Q_{0,9}$	102,79	0,34%	0,30%	0,20%	0,17%	0,13%	0,13%
$Q_{0,9}$-Q_1	571,08	0,45%	0,33%	0,19%	0,15%	0,14%	0,13%

Tabulka 7: Decilová analýza zahajovací a uzavírací hodnoty, klíčové slovo EUR USD, vlastní tvorba

Tabulka 7 zobrazuje analýzu klíčového slova „EUR USD“. Opět lze pozorovat vliv popularity na hodnotu kurzu aktiva. Vliv je pozorovatelný v decilovém rozpětí od $Q_{0,7}$ do Q_1 během období *t* až *t+2*, kdy s rostoucí popularitou volatilita roste. U měnového páru EUR USD jsou oproti předchozím aktivům šoky menší a stejně tak samotná popularita není příliš volatilní.

Decilové rozpětí	Popularita	Median_t	t+1	t+2	t+3	t+4	t+5
Q_0-$Q_{0,1}$	28,31	0,78%	0,95%	0,66%	0,64%	0,51%	0,47%
$Q_{0,1}$-$Q_{0,2}$	33,62	0,85%	1,00%	0,79%	0,57%	0,47%	0,41%
$Q_{0,2}$-$Q_{0,3}$	39,65	0,93%	1,04%	0,76%	0,62%	0,52%	0,44%
$Q_{0,3}$-$Q_{0,4}$	45,36	0,73%	1,01%	0,55%	0,43%	0,41%	0,38%
$Q_{0,4}$-$Q_{0,5}$	50,30	0,74%	0,72%	0,58%	0,53%	0,41%	0,37%
$Q_{0,5}$-$Q_{0,6}$	54,69	0,59%	0,82%	0,51%	0,47%	0,45%	0,38%
$Q_{0,6}$-$Q_{0,7}$	61,24	0,80%	0,71%	0,57%	0,52%	0,37%	0,37%
$Q_{0,7}$-$Q_{0,8}$	72,16	0,63%	0,82%	0,53%	0,58%	0,45%	0,37%
$Q_{0,8}$-$Q_{0,9}$	92,07	0,94%	1,12%	0,77%	0,67%	0,44%	0,50%
$Q_{0,9}$-Q_1	1968,01	1,33%	1,20%	0,90%	0,69%	0,63%	0,57%

Tabulka 8: Decilová analýza zahajovací a uzavírací hodnoty, klíčové slovo Facebook stock, vlastní tvorba

Tabulka 8 zachycuje výsledky pro klíčové slovo „Facebook stock“. I zde je viditelný vliv popularity na volatilitu kurzu. Avšak stejně jako u akcie Apple je vliv výrazněji pozorovatelný až od decilu $Q_{0,9}$ v období *t* až *t+2*.

Analýza zahajovacích a uzavíracích kurzů značí, že při vyšších hodnotách popularity lze očekávat zvýšenou volatilitu kurzu. Přičemž nejvyšší denní změna vychází pro decilové rozpětí $Q_{0,9}$-Q_1 v období *t* až *t+2*.

3.1.4 Analýza – maximálních a minimálních hodnot kurzu

K porovnání jsem dále provedl analýzu spreadu maximálních a minimálních hodnot kurzu za jednotlivá decilová rozpětí. Vzhledem k tomu, že vliv popularity na hodnotu aktiva je možné pozorovat již při analýze zahajovacího a uzavíracího kurzu, můžeme předpokládat, že analýza spreadu maximálních a minimálních hodnot kurzu také ukáže stejné závěry. Sloupec *Median_t_maxmin* udává medián spreadu maximální a minimální hodnoty obchodního dne pro odpovídající decilové rozpětí. Sloupec *Popularita* je horní hranice odpovídajícího decilového rozpětí. Sloupce *t+1* až *t+5* udávají medián spreadu maximálních a minimálních hodnot kurzu v čase *t+1* až *t+5* (dle zvoleného sloupce) pro příslušná decilová rozpětí.

Decilové rozpětí	Popularita	Median_t_maxmin	t+1	t+2	t+3	t+4	t+5
Q_0-$Q_{0,1}$	15,77	1,41%	2,07%	1,34%	1,06%	1,01%	0,86%
$Q_{0,1}$-$Q_{0,2}$	20,07	1,39%	2,23%	1,42%	1,15%	1,02%	0,95%
$Q_{0,2}$-$Q_{0,3}$	22,58	1,42%	2,33%	1,45%	1,16%	0,94%	0,83%
$Q_{0,3}$-$Q_{0,4}$	24,38	1,30%	2,08%	1,31%	1,03%	0,83%	0,80%
$Q_{0,4}$-$Q_{0,5}$	27,00	1,34%	2,00%	1,31%	1,10%	0,94%	0,79%
$Q_{0,5}$-$Q_{0,6}$	30,14	1,41%	2,08%	1,34%	1,09%	0,90%	0,81%
$Q_{0,6}$-$Q_{0,7}$	33,91	1,37%	2,17%	1,40%	1,14%	0,92%	0,83%
$Q_{0,7}$-$Q_{0,8}$	39,44	1,51%	2,46%	1,65%	1,28%	1,13%	0,95%
$Q_{0,8}$-$Q_{0,9}$	47,92	1,91%	3,05%	1,94%	1,45%	1,16%	1,02%
$Q_{0,9}$-Q_1	184,29	2,56%	3,84%	2,47%	1,85%	1,54%	1,28%

Tabulka 9: Decilová analýza maximální a minimální hodnoty, klíčové slovo Apple stock, vlastní tvorba

Tabulka 9 zobrazuje vliv popularity na hodnotu kurzu pro klíčové slovo „Apple stock“. Dle očekávání se vliv popularity při analýze maximálních a minimálních hodnot kurzů ještě více prohloubil. Vyšší volatilitu pozorujeme již od decilového rozpětí $Q_{0,7} – Q_{0,8}$.

Decilové rozpětí	Popularita	Median_t_maxmin	t+1	t+2	t+3	t+4	t+5
Q_0-$Q_{0,1}$	9,20	1,55%	2,74%	1,76%	1,33%	1,14%	1,06%
$Q_{0,1}$-$Q_{0,2}$	10,18	1,78%	2,85%	2,04%	1,55%	1,34%	1,37%
$Q_{0,2}$-$Q_{0,3}$	10,87	2,51%	3,67%	2,31%	1,97%	1,77%	1,62%
$Q_{0,3}$-$Q_{0,4}$	12,17	2,65%	4,21%	2,92%	2,22%	1,89%	1,70%
$Q_{0,4}$-$Q_{0,5}$	15,23	3,78%	5,37%	3,88%	2,80%	2,42%	2,20%
$Q_{0,5}$-$Q_{0,6}$	24,40	3,53%	5,91%	3,72%	3,22%	2,86%	2,54%
$Q_{0,6}$-$Q_{0,7}$	38,48	3,68%	6,09%	4,46%	3,70%	3,27%	2,92%
$Q_{0,7}$-$Q_{0,8}$	52,55	4,64%	7,30%	4,49%	3,56%	3,22%	2,91%
$Q_{0,8}$-$Q_{0,9}$	78,83	6,35%	9,57%	5,83%	4,33%	3,74%	3,40%
$Q_{0,9}$-Q_1	875,90	9,84%	14,98%	9,59%	7,33%	6,02%	5,28%

Tabulka 10: Decilová analýza maximální a minimální hodnoty, klíčové slovo Bitcoin, vlastní tvorba

Tabulka 10 zachycuje výsledky analýzy spreadu maximálních a minimálních hodnot pro klíčové slovo „Bitcoin“. Opět můžeme pozorovat ještě výraznější odchylky změn, a to za celé pozorované období *t* až *t+5*.

Decilové rozpětí	Popularita	Median_t_maxmin	t+1	t+2	t+3	t+4	t+5
Q_0-$Q_{0,1}$	55,14	0,14%	0,54%	0,42%	0,36%	0,31%	0,29%
$Q_{0,1}$-$Q_{0,2}$	62,82	0,11%	0,55%	0,40%	0,34%	0,31%	0,28%
$Q_{0,2}$-$Q_{0,3}$	68,53	0,18%	0,66%	0,44%	0,38%	0,34%	0,30%
$Q_{0,3}$-$Q_{0,4}$	75,00	0,43%	0,66%	0,45%	0,37%	0,32%	0,28%
$Q_{0,4}$-$Q_{0,5}$	80,90	0,56%	0,76%	0,46%	0,37%	0,33%	0,28%
$Q_{0,5}$-$Q_{0,6}$	85,66	0,61%	0,82%	0,51%	0,39%	0,33%	0,28%
$Q_{0,6}$-$Q_{0,7}$	91,00	0,63%	0,91%	0,50%	0,40%	0,33%	0,30%
$Q_{0,7}$-$Q_{0,8}$	97,08	0,69%	0,99%	0,56%	0,44%	0,36%	0,31%
$Q_{0,8}$-$Q_{0,9}$	102,79	0,75%	1,08%	0,62%	0,44%	0,37%	0,32%
$Q_{0,9}$-Q_1	571,08	0,88%	1,16%	0,67%	0,49%	0,39%	0,35%

Tabulka 11: Decilová analýza maximální a minimální hodnoty, klíčové slovo EUR USD, vlastní tvorba

Tabulka 11 ukazuje vliv popularity na volatilitu kurzu pro klíčové slovo „EUR USD“. I zde se potvrzuje, že pro vyšší decilová rozpětí volatilita roste.

Decilové rozpětí	Popularita	Median_t_maxmin	t+1	t+2	t+3	t+4	t+5
Q_0-$Q_{0,1}$	28,31	2,02%	2,98%	1,87%	1,49%	1,32%	1,12%
$Q_{0,1}$-$Q_{0,2}$	33,62	2,09%	3,12%	1,82%	1,41%	1,19%	1,08%
$Q_{0,2}$-$Q_{0,3}$	39,65	2,04%	3,23%	2,04%	1,60%	1,43%	1,27%
$Q_{0,3}$-$Q_{0,4}$	45,36	1,59%	2,34%	1,48%	1,14%	1,05%	0,98%
$Q_{0,4}$-$Q_{0,5}$	50,30	1,59%	2,42%	1,70%	1,30%	1,10%	0,99%
$Q_{0,5}$-$Q_{0,6}$	54,69	1,49%	2,35%	1,48%	1,19%	1,08%	0,91%
$Q_{0,6}$-$Q_{0,7}$	61,24	1,61%	2,52%	1,61%	1,34%	1,13%	1,08%
$Q_{0,7}$-$Q_{0,8}$	72,16	1,73%	2,76%	1,71%	1,41%	1,17%	1,03%
$Q_{0,8}$-$Q_{0,9}$	92,07	2,21%	3,32%	2,12%	1,65%	1,41%	1,26%
$Q_{0,9}$-Q_1	1968,01	2,89%	4,56%	2,63%	2,01%	1,69%	1,53%

Tabulka 12: Decilová analýza maximální a minimální hodnoty, klíčové slovo Facebook stock, vlastní tvorba

Tabulka 12 zobrazuje výsledky pro klíčové slovo „Facebook stock“. Opět pozorujeme zvýšenou volatilitu pro vyšší decilová rozpětí. Neočekávaně zde dosahují poměrně vysokých hodnot i decilová rozpětí Q_0-$Q_{0,1}$, Q_1-$Q_{0,2}$ *a* $Q_{0,2}$-$Q_{0,3}$.

Stejně jako u analýzy zahajovacích a uzavíracích kurzů i analýza spreadu maximálních a minimálních kurzů značí, že při vyšších hodnotách popularity lze očekávat zvýšenou volatilitu kurzu. Přičemž nejvyšší denní změna vychází pro decilové rozpětí $Q_{0,9}$-Q_1 v období *t* až *t+2*. U analýzy maximálních a minimálních kurzů se ještě více projevily odchylky mezi decilovými rozpětími nad decil $Q_{0,8}$ a rozpětími pod decilem $Q_{0,8}$. Kdy denní změna pro vyšší rozpětí byla v některých případech i několikanásobně vyšší.

3.2 GARCH model

Abych ověřil, jaké uplatnění mají data aplikace Google Trends v reálném modelu, rozhodl jsem se pro každou z řad (pro jednotlivá finanční aktiva) vytvořit model GARCH (1,1). Jde o autoregresní model s podmíněnou heteroskedasticitou. Model se nejčastěji využívá při analýze finančních časových řad, které se vyznačují svým v čase proměnlivým rozptylem. To je možné zachytit právě pomocí podmíněné heteroskedasticity. Dále se mohou modely GARCH uplatnit například při sestavování optimálního portfolia, kde slouží k zachycení vztahu očekávaného rizika a výnosu (volatility).

GARCH model (generalized autoregressive conditional heteroskedasticity) představuje zobecněný ARCH model. Model je primárně spojován se jménem Tima Bollersleva, ten do modelu navrhl doplnit zpožděný podmíněný rozptyl.

GARCH modely úspěšně odbourávají některé nedostatky ARCH modelů. Zejména se jedná o výrazné snížení počtu odhadovaných parametrů, nižší řád a zohlednění skutečnosti, že volatilita může být závislá na vlastních zpožděných hodnotách [3, s. 390].

Jak již jsem zmínil v úvodu této části práce, k ověření využiji model typu GARCH (1,1). Tento typ by měl být schopný zachytit pomocí tří parametrů obecné volatilitní struktury. Dle Arltová [4, s. 129] je model dán vztahem:

$$h_t = \omega + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1}, \tag{1}$$

kde h_t je podmíněný rozptyl,

ω, α a β jsou odhadovanými parametry modelu,

ε_{t-1}^2 je zpožděná hodnota čtverce reziduí,

h_{t-1} je zpožděný podmíněný rozptyl.

3.2.1 Postup tvorby modelu

Ke zpracování, vytvoření a testování modelů využiji aplikaci Eviews verze 8. Abych mohl vytvořit model, vytvořím nejdříve časovou řadu výnosů pro všechna vybraná aktiva. Následně provedu u všech řad test normality a stacionarity. Dále budu vytvářet samotné modely, kdy pro každou řadu vytvořím model s konstantou a bez konstanty v rovnici výnosů. Pro lepší z modelů pak připravím i variantu zahrnující popularitu v podobě časové řady přepočtená popularita a jednotkových impulsů v rovnici volatility. Přičemž impulsy jsou generovány v případě, kdy popularita je větší nebo rovna decilu $Q_{0,9}$, dle části 3.1.3 a 3.1.4 této práce. Nakonec modely porovnám a dle Akaikeho kritéria vyberu nejlepší z modelů pro každé finanční aktivum. Zároveň provedu pro nejlépe hodnocené modely testy reziduí.

3.2.2 Příprava časových řad

Abych mohl vytvořit stochastický model, budu muset časovou řadu kurzů upravit tak, aby byla stacionární. K získání stacionární časové řady, nejprve zkusím převést řady kurzů jednotlivých finančních aktiv na řady denních výnosů. Grafy výnosů zobrazují grafy 19 až 22. Vzhledem k tomu, že se jedná o řady denních výnosů, oscilují hodnoty okolo nuly. V dalším kroku řady otestuji na stacionaritu pomocí Dickey-Fullerova testu a normalitu pomocí Jarque-Bera testu.

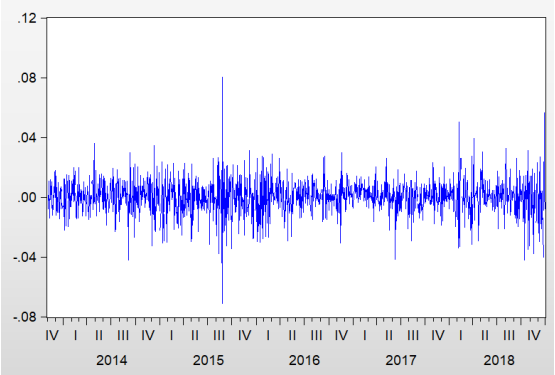

Graf 19: Výnosy akcie Apple, Eviews

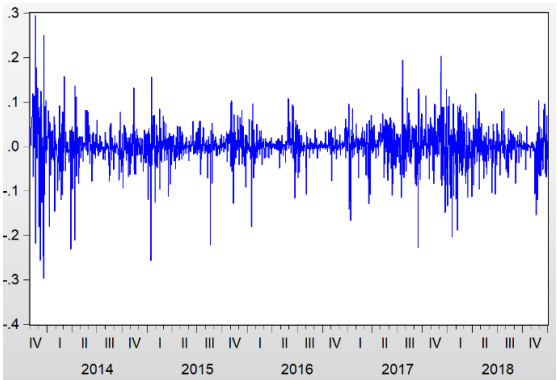

Graf 20: Výnosy Bitcoin, Eviews

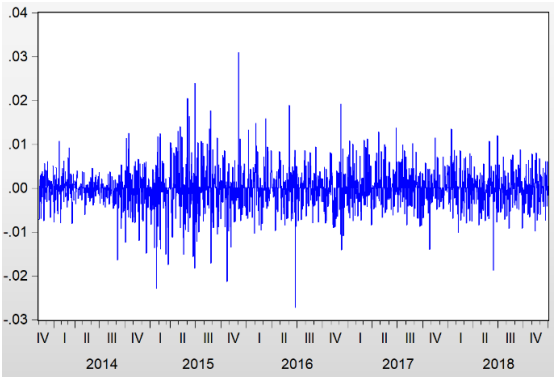

Graf 21: Výnosy akcie Facebook, Eviews

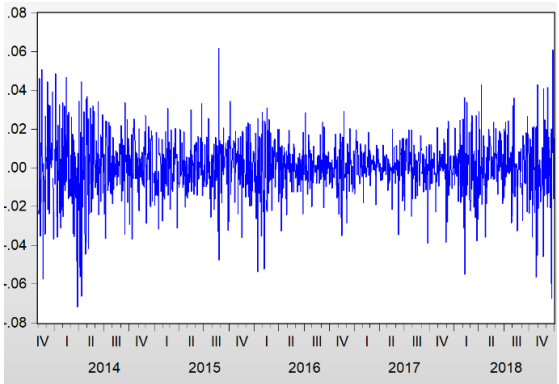

Graf 22: Výnosy EUR USD, Eviews

3.2.3 Šikmost, špičatost a Jarque-Bera test normality

Grafy 23 až 26 níže zachycují výstup testu normality pro vybraná finanční aktiva. Můžeme pozorovat určitou podobnost mezi histogramy akcií a histogramy měn. Hodnoty šikmosti a špičatosti vypovídají o rozdělení pravděpodobnosti. Pokud je rozdělení pravděpodobnosti normální měla by být hodnota šikmosti rovna 0, hodnota špičatosti by měla dosahovat přibližně hodnoty 3.

Dalo by se říci, že hodnoty šikmosti se hodnotě 0 blíží. Šikmost nižší než 0 udává mírné zešikmení doprava. Naopak šikmost větší než nula mírné zešikmení doleva.

Výrazné vychýlení lze pozorovat u špičatosti. Hodnoty špičatosti jsou podstatně vyšší než pro normální rozdělení. Všechny časové řady tak mají vyšší špičku a jsou strmější. Jejich hodnoty jsou soustředěny převážně kolem středu rozdělení.

Dle výše uvedených poznatků tak můžeme očekávat, že časové řady nemají normální, ale leptokurtické rozdělení výnosů, které je charakteristické „užším pasem a těžšími konci“.

Výše popsané skutečnosti potvrzuje i výsledek Jarque-Bera testu normality. Na základě p-hodnoty testu nižší než 5 % můžeme vyvrátit nulovou hypotézu o normálním rozdělení denních výnosů [5, s. 95].

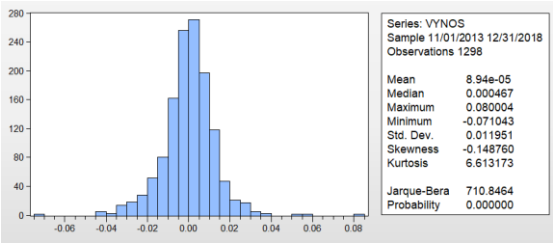

Graf 23: Normalita akcie Apple, Eviews

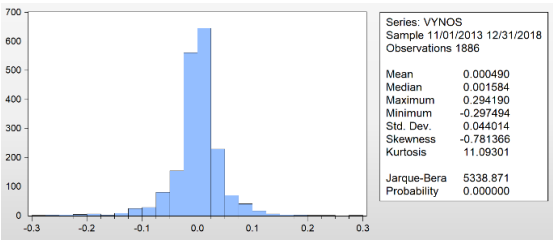

Graf 24: Normalita Bitcoin, Eviews

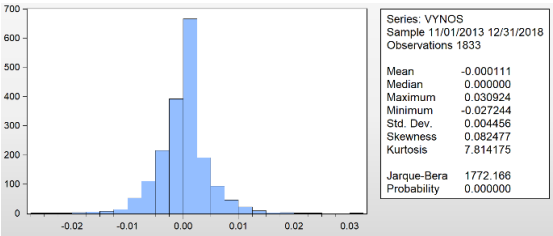

Graf 25: Normalita EUR USD, Eviews

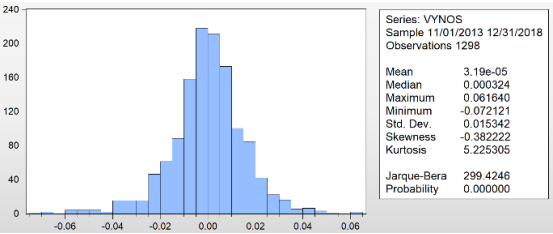

Graf 26: Normalita akcie Facebook, Eviews

3.2.4 Stacionarita - Dickey-Fullerův test

K ověření stacionarity číselných řad denních výnosů použiji rozšířený Dickey-Fullerův test (ADF). Ten slouží k určení optimálního řádu zpoždění. K ověřování hypotéz se v ADF testu zpravidla využívají tři základní druhy testů: bez konstanty, s konstantou, s konstantou a trendem [3.].

Během testování se využívá následujícího vzorce:

$$\Delta y_t = \emptyset y_{t-1} + \sum_{i=1}^{p} a_1 \Delta y_{t-i} + \varepsilon_t, \tag{2}$$

kde y_t je závislá proměnná

p je zpoždění

ε_t je reziduální složka.

Test zkoumá, zda proměnná obsahuje jednotkový kořen. Závěr o stacionaritě plyne z p-hodnoty, kterou porovnáváme s hladinou významnosti (α). Kdy hypotéza H0 značí nestacionární časovou řadu, zatímco hypotéza H1 stacionární časovou řadu [6.].

Vzhledem ke zpoždění vzniklém při převodu z časové řady kurzů na řadu výnosů, můžeme očekávat, že řady budou již stacionární. Nejdříve jsem test provedl s konstantou a trendem. U všech řad vyšla p-hodnota testu nižší než 0,05, nicméně současně se ukázalo, že trend ani konstanta nejsou v testu statisticky významné. Proto jsem test opakoval ještě jednou pouze s konstantou. I v druhém případě se časové řady jevily jako stacionární, avšak konstanta byla opět statisticky nevýznamná. Test jsem tedy provedl pro všechny časové řady potřetí bez trendu a konstanty, kdy všechny testy skončily opět s p-hodnotou nižší než 0,05. Lze tedy vyvrátit nulovou hypotézu o jednotkovosti kořene časových řad na hladině významnosti 1 %, 5 % a 10 %, a můžeme tvrdit, že časové řady jsou stacionární. Výsledky testů pro jednotlivé časové řady zobrazují tabulky 13 až 16 níže.

Null Hypothesis: VYNOS has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=22)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-40.45391	0.0000
Test critical values:	1% level	-3.435180	
	5% level	-2.863561	
	10% level	-2.567895	

*MacKinnon (1996) one-sided p-values.

Tabulka 13: Stacionarita akcie Apple, Eviews

Null Hypothesis: VYNOS has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=25)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-43.08090	0.0000
Test critical values:	1% level	-3.433618	
	5% level	-2.862870	
	10% level	-2.567525	

*MacKinnon (1996) one-sided p-values.

Tabulka 14: Stacionarita Bitcoin, Eviews

Null Hypothesis: VYNOS has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=24)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-44.42152	0.0001
Test critical values:	1% level	-3.433718	
	5% level	-2.862914	
	10% level	-2.567548	

*MacKinnon (1996) one-sided p-values.

Tabulka 15: Stacionarita EUR USD, Eviews

Null Hypothesis: VYNOS has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=22)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-39.71449	0.0000
Test critical values:	1% level	-3.435180	
	5% level	-2.863561	
	10% level	-2.567895	

*MacKinnon (1996) one-sided p-values.

Tabulka 16: Stacionarita akcie Facebook, Eviews

3.2.5 Tvorba modelů – Akaikeho informační kritérium

Vzhledem k zamítnutí nulové hypotézy o jednotkovosti kořene mohu přistoupit k tvorbě modelu. Jak jsem již popsal výše v části 3.2.1, pokusím se pro každou číselnou řadu vytvořit model GARCH (1,1). Přestože lze dle výsledků Dickey-Fullerův testu s konstantou očekávat, že konstanta bude v modelu nevýznamná, nejdříve zkusím sestavit model zahrnující konstantu v rovnici výnosů. V případě, že se konstanta projeví jako statisticky nevýznamná, vytvořím model bez konstanty.

Dále se do modelu (do rovnice volatility) pokusím přidat popularitu, a to v podobě impulsů nebo kompletní číselné řady přepočtená popularita.

Impulsy nabývají hodnot 1 nebo 0, podle toho, zda popularita pro konkrétní den přesáhne předem stanovenou úroveň. Zatímco číselná řada přepočtená popularita zohledňuje všechny hodnoty.

Z důvodu nemožnosti využít k porovnání modelů koeficient determinace, použiji ke srovnání Akaikeho informační kritérium. Akaikeho informační kritérium (AIC) posuzuje schopnost modelů vysvětlit variabilitu v dané číselné řadě. Akaikeho informační kritérium bylo představeno v 70. letech 20. století japonským statistikem Hirotugu Akaikem (1981) a je popisováno následujícím vzorcem [7, s. 138]:

$$AIC = n \cdot ln\left(\frac{RSS}{n}\right) + 2k \tag{3}$$

kde: RSS je reziduální součet čtverců,

k je počet parametrů,

n je počet měření,

RSS/n je reziduální rozptyl.

AIC je statistikou, která zohledňuje věrohodnost modelu a současně jeho složitost. Preferovány jsou modely s nižšími hodnotami AIC.

Po výběru nejlepšího modelu dle Akaikeho kritéria, provedu pro příslušný nejlépe hodnocený model testy reziduí.

3.2.6 Modely s konstantou

Tabulky 17 až 20 zobrazují výstupní údaje modelů s konstantou pro všechna testovaná finanční aktiva. Ve všech případech můžeme pozorovat, že p-hodnota konstanty je vyšší než 0,05, a konstanta je tedy statisticky nevýznamná na zvolené 95% hladině významnosti.

Statisticky významná je konstanta pouze v rovnicích popisujících volatilitu v rámci GARCH (1,1) modelu.

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/09/19 Time: 15:27
Sample: 12/02/2013 12/31/2018
Included observations: 1279
Convergence achieved after 11 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000480	0.000295	1.627686	0.1036
Variance Equation				
C	8.84E-06	1.93E-06	4.570816	0.0000
RESID(-1)^2	0.121843	0.017010	7.163167	0.0000
GARCH(-1)	0.819153	0.026829	30.53283	0.0000

R-squared	-0.001228	Mean dependent var	6.01E-05
Adjusted R-squared	-0.001228	S.D. dependent var	0.011987
S.E. of regression	0.011994	Akaike info criterion	-6.140538
Sum squared resid	0.183861	Schwarz criterion	-6.124419
Log likelihood	3930.874	Hannan-Quinn criter.	-6.134485
Durbin-Watson stat	2.235838		

Tabulka 17: Model s konstantou akcie Apple, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 14:03
Sample: 12/01/2013 12/31/2018
Included observations: 1857
Convergence achieved after 28 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000524	0.000799	0.656374	0.5116
Variance Equation				
C	3.29E-05	2.45E-06	13.40384	0.0000
RESID(-1)^2	0.101881	0.006212	16.40201	0.0000
GARCH(-1)	0.886493	0.004725	187.6007	0.0000

R-squared	-0.000387	Mean dependent var	-0.000314
Adjusted R-squared	-0.000387	S.D. dependent var	0.042603
S.E. of regression	0.042611	Akaike info criterion	-3.782572
Sum squared resid	3.370011	Schwarz criterion	-3.770667
Log likelihood	3516.118	Hannan-Quinn criter.	-3.778185
Durbin-Watson stat	2.008156		

Tabulka 18: Model s konstantou Bitcoin, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 15:33
Sample: 12/01/2013 12/31/2018
Included observations: 1808
Convergence achieved after 12 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	-9.37E-05	9.64E-05	-0.972083	0.3310
Variance Equation				
C	7.28E-08	1.22E-08	5.990109	0.0000
RESID(-1)^2	0.016215	0.001987	8.158735	0.0000
GARCH(-1)	0.980474	0.002178	450.1066	0.0000

R-squared	-0.000021	Mean dependent var	-0.000114
Adjusted R-squared	-0.000021	S.D. dependent var	0.004468
S.E. of regression	0.004468	Akaike info criterion	-8.072352
Sum squared resid	0.036077	Schwarz criterion	-8.060184
Log likelihood	7301.406	Hannan-Quinn criter.	-8.067861
Durbin-Watson stat	2.072498		

Tabulka 19: Model s konstantou EUR USD, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 16:17
Sample: 12/02/2013 12/31/2018
Included observations: 1279
Convergence achieved after 10 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000302	0.000356	0.848841	0.3960
Variance Equation				
C	3.60E-06	1.03E-06	3.494376	0.0005
RESID(-1)^2	0.075270	0.011594	6.492301	0.0000
GARCH(-1)	0.910411	0.014370	63.35686	0.0000

R-squared	-0.000169	Mean dependent var	0.000106
Adjusted R-squared	-0.000169	S.D. dependent var	0.015101
S.E. of regression	0.015102	Akaike info criterion	-5.717388
Sum squared resid	0.291492	Schwarz criterion	-5.701269
Log likelihood	3660.269	Hannan-Quinn criter.	-5.711335
Durbin-Watson stat	2.206130		

Tabulka 20: Model s konstantou akcie Facebook, Eviews

3.2.7 Modely bez konstanty

Tabulky 21 až 24 ukazují výstupní hodnoty testů pro modely bez konstanty. Pro modely všech aktiv zůstaly parametry rovnice volatility statisticky významné.

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/09/19 Time: 15:28
Sample: 12/02/2013 12/31/2018
Included observations: 1279
Convergence achieved after 8 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	8.87E-06	1.97E-06	4.509262	0.0000
RESID(-1)^2	0.120867	0.016572	7.293245	0.0000
GARCH(-1)	0.819818	0.026770	30.62430	0.0000

R-squared	-0.000025	Mean dependent var	6.01E-05
Adjusted R-squared	0.000757	S.D. dependent var	0.011987
S.E. of regression	0.011983	Akaike info criterion	-6.139961
Sum squared resid	0.183640	Schwarz criterion	-6.127872
Log likelihood	3929.505	Hannan-Quinn criter.	-6.135422
Durbin-Watson stat	2.238527		

Tabulka 21: Model bez konstanty akcie Apple, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 14:08
Sample: 12/01/2013 12/31/2018
Included observations: 1857
Convergence achieved after 9 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	3.27E-05	2.44E-06	13.42360	0.0000
RESID(-1)^2	0.101384	0.006172	16.42622	0.0000
GARCH(-1)	0.886850	0.004701	188.6367	0.0000

R-squared	-0.000054	Mean dependent var	-0.000314
Adjusted R-squared	0.000484	S.D. dependent var	0.042603
S.E. of regression	0.042593	Akaike info criterion	-3.783373
Sum squared resid	3.368890	Schwarz criterion	-3.774445
Log likelihood	3515.862	Hannan-Quinn criter.	-3.780083
Durbin-Watson stat	2.008825		

Tabulka 22: Model bez konstanty Bitcoin, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 15:38
Sample: 12/01/2013 12/31/2018
Included observations: 1808
Convergence achieved after 9 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	7.21E-08	1.19E-08	6.040035	0.0000
RESID(-1)^2	0.016239	0.001994	8.145541	0.0000
GARCH(-1)	0.980489	0.002171	451.6466	0.0000

R-squared	-0.000653	Mean dependent var	-0.000114
Adjusted R-squared	-0.000100	S.D. dependent var	0.004468
S.E. of regression	0.004468	Akaike info criterion	-8.072942
Sum squared resid	0.036099	Schwarz criterion	-8.063816
Log likelihood	7300.940	Hannan-Quinn criter.	-8.069574
Durbin-Watson stat	2.071189		

Tabulka 23: Model bez konstanty EUR USD, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 16:39
Sample: 12/02/2013 12/31/2018
Included observations: 1279
Convergence achieved after 9 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	3.58E-06	1.03E-06	3.462649	0.0005
RESID(-1)^2	0.075285	0.011572	6.505933	0.0000
GARCH(-1)	0.910512	0.014364	63.38943	0.0000

R-squared	-0.000049	Mean dependent var	0.000106
Adjusted R-squared	0.000733	S.D. dependent var	0.015101
S.E. of regression	0.015096	Akaike info criterion	-5.718354
Sum squared resid	0.291457	Schwarz criterion	-5.706265
Log likelihood	3659.887	Hannan-Quinn criter.	-5.713815
Durbin-Watson stat	2.206394		

Tabulka 24: Model bez konstanty akcie Facebook, Eviews

3.2.8 Modely s přepočtenou popularitou

Tabulky 25 až 28 zobrazují výstupy pro modely zahrnující přepočtenou popularitu (POPT1). U tří ze čtyř modelů je parametr přepočtené popularity statisticky významný. Jako statisticky nevýznamný se parametr jeví u modelu popisujícího kurz akcie společnosti Facebook.

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 01/18/20 Time: 23:47
Sample: 12/02/2013 12/31/2018
Included observations: 1279
Convergence achieved after 29 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1) + C(4)*POPT1

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	4.99E-06	3.50E-06	1.426268	0.1538
RESID(-1)^2	0.163248	0.024373	6.697866	0.0000
GARCH(-1)	0.685339	0.039547	17.32962	0.0000
POPT1	5.48E-07	1.18E-07	4.647088	0.0000

R-squared	-0.000025	Mean dependent var	6.01E-05
Adjusted R-squared	0.000757	S.D. dependent var	0.011987
S.E. of regression	0.011983	Akaike info criterion	-6.150586
Sum squared resid	0.183640	Schwarz criterion	-6.134468
Log likelihood	3937.300	Hannan-Quinn criter.	-6.144533
Durbin-Watson stat	2.238527		

Tabulka 25: Model s popularitou akcie Apple, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 14:21
Sample: 12/01/2013 12/31/2018
Included observations: 1857
Convergence achieved after 16 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1) + C(4)*POPT1

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	2.97E-05	3.59E-06	8.270048	0.0000
RESID(-1)^2	0.101747	0.008016	12.69270	0.0000
GARCH(-1)	0.849790	0.008670	98.01676	0.0000
POPT1	1.91E-06	2.54E-07	7.515304	0.0000

R-squared	-0.000054	Mean dependent var	-0.000314
Adjusted R-squared	0.000484	S.D. dependent var	0.042603
S.E. of regression	0.042593	Akaike info criterion	-3.802827
Sum squared resid	3.368890	Schwarz criterion	-3.790922
Log likelihood	3534.925	Hannan-Quinn criter.	-3.798439
Durbin-Watson stat	2.008825		

Tabulka 26: Model s popularitou Bitcoin, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 15:40
Sample: 12/01/2013 12/31/2018
Included observations: 1808
Convergence achieved after 23 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1) + C(4)*POPT1

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	-6.32E-06	1.52E-07	-41.55267	0.0000
RESID(-1)^2	0.140872	0.021671	6.500321	0.0000
GARCH(-1)	-0.070928	0.018615	-3.810310	0.0001
POPT1	2.70E-07	6.50E-09	41.50506	0.0000

R-squared	-0.000653	Mean dependent var	-0.000114
Adjusted R-squared	-0.000100	S.D. dependent var	0.004468
S.E. of regression	0.004468	Akaike info criterion	-8.190039
Sum squared resid	0.036099	Schwarz criterion	-8.177870
Log likelihood	7407.795	Hannan-Quinn criter.	-8.185548
Durbin-Watson stat	2.071189		

Tabulka 27: Model s popularitou EUR USD, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 16:41
Sample: 12/02/2013 12/31/2018
Included observations: 1279
Convergence achieved after 17 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1) + C(4)*POPT1

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	2.17E-06	1.48E-06	1.465287	0.1428
RESID(-1)^2	0.077417	0.012087	6.404967	0.0000
GARCH(-1)	0.904434	0.015259	59.27369	0.0000
POPT1	3.63E-08	2.19E-08	1.661640	0.0966

R-squared	-0.000049	Mean dependent var	0.000106
Adjusted R-squared	0.000733	S.D. dependent var	0.015101
S.E. of regression	0.015096	Akaike info criterion	-5.720221
Sum squared resid	0.291457	Schwarz criterion	-5.704103
Log likelihood	3662.081	Hannan-Quinn criter.	-5.714168
Durbin-Watson stat	2.206394		

Tabulka 28: Model s popularitou akcie Facebook, Eviews

3.2.9 Modely s impulsy

Tabulky 29 až 32 zobrazují výstupy modelů zahrnujících v sobě jednotkové impulsy (IMP1). Jako úroveň pro generování impulsu jsem zvolil dosažení hodnoty decilu časové řady přepočtená popularita Q_9 a hodnoty vyšší. Přestože u akcie společnosti Facebook můžeme pozorovat zvýšenou p-hodnotu 0,0288, stále je parametr *IMP1* na zvolené 95% hladině významnosti statisticky významný. Zároveň hodnota Akaikeho informačního kritéria dosahuje nižších hodnot než v modelu neobsahujícím popularitu. Pokud srovnáme hodnoty AIC pro modely s přepočtenou popularitou a jednotkovým impulsem pro Bitcoin a měnový pár EUR USD, zjistíme že je AIC pro modely s přepočtenou popularitou nižší a modely jsou tedy dle zvoleného kritéria vhodnější než modely s impulsy.

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 01/18/20 Time: 23:49
Sample: 12/02/2013 12/31/2018
Included observations: 1279
Convergence achieved after 15 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1) + C(4)*IMP1

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	1.12E-05	2.13E-06	5.253338	0.0000
RESID(-1)^2	0.122283	0.019041	6.422179	0.0000
GARCH(-1)	0.776307	0.030352	25.57707	0.0000
IMP1	3.94E-05	1.02E-05	3.864937	0.0001

R-squared	-0.000025	Mean dependent var	6.01E-05
Adjusted R-squared	0.000757	S.D. dependent var	0.011987
S.E. of regression	0.011983	Akaike info criterion	-6.155677
Sum squared resid	0.183640	Schwarz criterion	-6.139559
Log likelihood	3940.556	Hannan-Quinn criter.	-6.149625
Durbin-Watson stat	2.238527		

Tabulka 29: Model s impulsem akcie Apple, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 14:24
Sample: 12/01/2013 12/31/2018
Included observations: 1857
Convergence achieved after 17 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1) + C(4)*IMP1

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	4.38E-05	3.32E-06	13.20388	0.0000
RESID(-1)^2	0.096706	0.006640	14.56461	0.0000
GARCH(-1)	0.874440	0.005725	152.7338	0.0000
IMP1	0.000240	5.84E-05	4.110743	0.0000

R-squared	-0.000054	Mean dependent var	-0.000314
Adjusted R-squared	0.000484	S.D. dependent var	0.042603
S.E. of regression	0.042593	Akaike info criterion	-3.790147
Sum squared resid	3.368890	Schwarz criterion	-3.778243
Log likelihood	3523.152	Hannan-Quinn criter.	-3.785760
Durbin-Watson stat	2.008825		

Tabulka 30: Model s impulsem Bitcoin, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 15:43
Sample: 12/01/2013 12/31/2018
Included observations: 1808
Convergence achieved after 17 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1) + C(4)*IMP1

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	1.75E-05	4.97E-07	35.12268	0.0000
RESID(-1)^2	0.120946	0.018154	6.662247	0.0000
GARCH(-1)	-0.154551	0.014579	-10.60085	0.0000
IMP1	3.15E-05	3.99E-06	7.883316	0.0000

R-squared	-0.000653	Mean dependent var	-0.000114
Adjusted R-squared	-0.000100	S.D. dependent var	0.004468
S.E. of regression	0.004468	Akaike info criterion	-8.076924
Sum squared resid	0.036099	Schwarz criterion	-8.064756
Log likelihood	7305.539	Hannan-Quinn criter.	-8.072433
Durbin-Watson stat	2.071189		

Tabulka 31: Model s impulsem EUR USD, Eviews

Dependent Variable: VYNOS
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 12/29/19 Time: 16:44
Sample: 12/02/2013 12/31/2018
Included observations: 1279
Convergence achieved after 16 iterations
Presample variance: backcast (parameter = 0.7)
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1) + C(4)*IMP1

Variable	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	4.18E-06	1.18E-06	3.550839	0.0004
RESID(-1)^2	0.076333	0.012408	6.152045	0.0000
GARCH(-1)	0.900757	0.016021	56.22283	0.0000
IMP1	1.27E-05	5.80E-06	2.186680	0.0288

R-squared	-0.000049	Mean dependent var	0.000106
Adjusted R-squared	0.000733	S.D. dependent var	0.015101
S.E. of regression	0.015096	Akaike info criterion	-5.720770
Sum squared resid	0.291457	Schwarz criterion	-5.704651
Log likelihood	3662.432	Hannan-Quinn criter.	-5.714717
Durbin-Watson stat	2.206394		

Tabulka 32: Model s impulsem akcie Facebook, Eviews

3.2.10 Výběr nejlepších modelů

Aktivum	Typ modelu	AIC
akcie Apple	model s konstantou	-6,1405
akcie Apple	model bez konstanty	-6,1400
akcie Apple	model s přepočtenou popularitou	-6,1506
akcie Apple	**model s impulsem**	**-6,1557**
Bitcoin	model s konstantou	-3,7826
Bitcoin	model bez konstanty	-3,7834
Bitcoin	**model s přepočtenou popularitou**	**-3,8028**
Bitcoin	model s impulsem	-3,7901
EUR USD	model s konstantou	-8,0724
EUR USD	model bez konstanty	-8,0729
EUR USD	**model s přepočtenou popularitou**	**-8,1900**
EUR USD	model s impulsem	-8,0769
akcie Facebook	model s konstantou	-5,7174
akcie Facebook	model bez konstanty	-5,7184
akcie Facebook	model s přepočtenou popularitou	-5,7202
akcie Facebook	**model s impulsem**	**-5,7208**

Tabulka 33: Hodnocení modelů dle AIC, vlastní tvorba

Tabulka 33 výše zachycuje výsledky jednotlivých modelů dle Akaikeho informačního kritéria (AIC). Výsledky ukazují, že nejlepšího hodnocení dosáhly u všech aktiv modely obsahující v rovnici volatility časovou řadu relativně přepočtených objemů vyhledávání.

Zatímco pro obě akcie si nejlépe vedly modely, kde byla vyhledávanost použita v rovnici volatility jako jednotkové impulsy, u obou měn dosáhl lepších výsledků model obsahující v rovnici volatility kompletní časovou řadu vyhledávání.

Rozdílnost konstrukce rovnic volatility modelů pro akcie a měny může vycházet z částečně odlišného pravděpodobnostního rozdělení denních výnosů, případně by mohla být zapříčiněna volbou analyzovaných klíčových slov. Kdy pro obě akcie jsem zvolil klíčové slovo zahrnující název akcie a slovo „stock“ a pro obě měny jsem ponechal klíčová slova dle jejich názvu, neboť slovo „stock“ nebylo z povahy aktiv odpovídající.

Důvodem rozdílnosti by mohla být odlišná struktura uživatelů vyhledávajících aktivum ve spojení se slovem „stock“ a uživatelů vyhledávajících pouze samotné aktivum dle jeho názvu. Kdy uživatel, který hledá klíčové slovo obsahující slovo „stock“, by mohl mít větší potenciál k reálnému nákupu či prodeji aktiva, neboť se zajímá o investiční instrument, a nejen o informace související s daným aktivem.

3.2.11 Testování reziduí nejlépe hodnocených modelů

Nezbytným krokem k ověření vhodnosti použití modelů v praxi je testování reziduí odhadnutých modelů. K ověření použiji následující testy: Jarque-Bera test normality, ARCH LM test podmíněné heteroskedasticity a test autokorelace pomocí korelogramu ACF a PACF.

Testování normality reziduí – Jarque-Bera test

Výsledky testů ukazují grafy 27 až 30. Z výsledků je patrné, že velká část reziduí zůstala stále nevysvětlena. Přestože se u téměř všech modelů podařilo šikmost i špičatost přiblížit normálnímu rozdělení, stále nelze na zvolené hladině významnosti tvrdit, že se dle Jarque-Berova testu jedná o normální rozdělení.

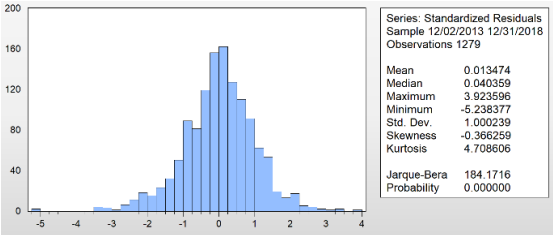

Graf 27: Normalita reziduí, model s impulsem, akcie Apple, Eviews

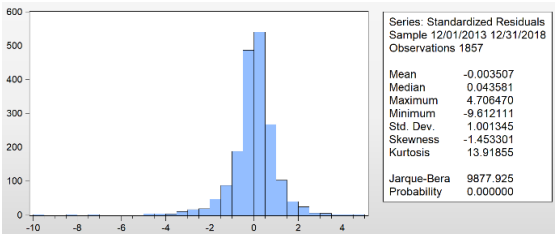

Graf 28: Normalita reziduí, model s popularitou, Bitcoin, Eviews

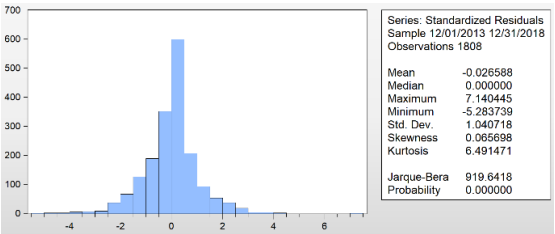

Graf 29: Normalita reziduí, model s popularitou, EUR USD, Eviews

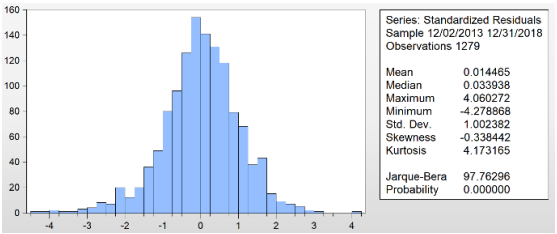

Graf 30: Normalita reziduí, model s impulsem, akcie Facebook, Eviews

Testování podmíněné heteroskedasticity – ARCH LM test

Pro účely testování heteroskedasticity reziduí odhadnutých modelů jednotlivých finančních aktiv byl využit ARCH-LM test. Test by měl ověřit, zda lze modely považovat za homoskedastické a neprojevuje se v nich heteroskedasticita [4, s. 144].

Tabulky 34 až 37 ukazují, že zpožděné čtverce reziduí nejsou statisticky významné u žádného z testovaných modelů. Dle p-hodnoty testu se nulová hypotéza o homoskedasticitě nezamítá a rezidua modelů by měla být homoskedastická.

Heteroskedasticity Test: ARCH

F-statistic	1.695871	Prob. F(1,1276)	0.1931
Obs*R-squared	1.696275	Prob. Chi-Square(1)	0.1928

Test Equation:
Dependent Variable: WGT_RESID^2
Method: Least Squares
Date: 01/18/20 Time: 23:54
Sample (adjusted): 12/03/2013 12/31/2018
Included observations: 1278 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.963292	0.060596	15.89693	0.0000
WGT_RESID^2(-1)	0.036435	0.027978	1.302256	0.1931

R-squared	0.001327	Mean dependent var	0.999748
Adjusted R-squared	0.000545	S.D. dependent var	1.921745
S.E. of regression	1.921221	Akaike info criterion	4.145363
Sum squared resid	4709.833	Schwarz criterion	4.153427
Log likelihood	-2646.887	Hannan-Quinn criter.	4.148391
F-statistic	1.695871	Durbin-Watson stat	1.997378
Prob(F-statistic)	0.193064		

Tabulka 34: ARCH LM test reziduí, model s impulsem, akcie Apple, Eviews

Heteroskedasticity Test: ARCH

F-statistic	0.434155	Prob. F(1,1854)	0.5100
Obs*R-squared	0.434522	Prob. Chi-Square(1)	0.5098

Test Equation:
Dependent Variable: WGT_RESID^2
Method: Least Squares
Date: 12/29/19 Time: 14:43
Sample (adjusted): 12/02/2013 12/31/2018
Included observations: 1856 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.987363	0.086908	11.36102	0.0000
WGT_RESID^2(-1)	0.015301	0.023222	0.658904	0.5100

R-squared	0.000234	Mean dependent var	1.002704
Adjusted R-squared	-0.000305	S.D. dependent var	3.606686
S.E. of regression	3.607236	Akaike info criterion	5.404838
Sum squared resid	24124.53	Schwarz criterion	5.410793
Log likelihood	-5013.690	Hannan-Quinn criter.	5.407033
F-statistic	0.434155	Durbin-Watson stat	1.999185
Prob(F-statistic)	0.510039		

Tabulka 35: ARCH LM test reziduí, model s popularitou, Bitcoin, Eviews

Heteroskedasticity Test: ARCH

F-statistic	0.580211	Prob. F(1,1805)	0.4463
Obs*R-squared	0.580667	Prob. Chi-Square(1)	0.4461

Test Equation:
Dependent Variable: WGT_RESID^2
Method: Least Squares
Date: 12/29/19 Time: 15:56
Sample (adjusted): 12/02/2013 12/31/2018
Included observations: 1807 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.103164	0.064897	16.99876	0.0000
WGT_RESID^2(-1)	-0.017928	0.023536	-0.761716	0.4463

R-squared	0.000321	Mean dependent var	1.083763
Adjusted R-squared	-0.000232	S.D. dependent var	2.537047
S.E. of regression	2.537342	Akaike info criterion	4.701217
Sum squared resid	11620.78	Schwarz criterion	4.707304
Log likelihood	-4245.550	Hannan-Quinn criter.	4.703464
F-statistic	0.580211	Durbin-Watson stat	1.999738
Prob(F-statistic)	0.446329		

Tabulka 36: ARCH LM test reziduí, model s popularitou, EUR USD, Eviews

Heteroskedasticity Test: ARCH

F-statistic	0.004374	Prob. F(1,1276)	0.9473
Obs*R-squared	0.004381	Prob. Chi-Square(1)	0.9472

Test Equation:
Dependent Variable: WGT_RESID^2
Method: Least Squares
Date: 12/29/19 Time: 17:00
Sample (adjusted): 12/03/2013 12/31/2018
Included observations: 1278 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.006759	0.057310	17.56683	0.0000
WGT_RESID^2(-1)	-0.001851	0.027994	-0.066138	0.9473

R-squared	0.000003	Mean dependent var	1.004899
Adjusted R-squared	-0.000780	S.D. dependent var	1.784373
S.E. of regression	1.785069	Akaike info criterion	3.998355
Sum squared resid	4065.937	Schwarz criterion	4.006419
Log likelihood	-2552.949	Hannan-Quinn criter.	4.001383
F-statistic	0.004374	Durbin-Watson stat	1.999944
Prob(F-statistic)	0.947279		

Tabulka 37: ARCH LM test reziduí, model s impulsem, akcie Facebook, Eviews

Testování autokorelace reziduí – korelogram ACF a PACF

Posledním z prováděných testů je test autokorelace. Jde o test sériové závislosti náhodné složky na vlastních zpožděných hodnotách. Test provedu pomocí autokorelačního grafu reziduální složky (ACF) a parciálního autokorelačního grafu reziduální složky (PACF), viz [5.]. Výstup testu zobrazují tabulky 38 až 41. Zobrazeno je prvních 20 časových zpoždění z celkových 36.

Pro tři ze čtyř modelů jsou časové řady reziduí závislé na svých zpožděných hodnotách. Nulová hypotéza o neautokorelovanosti reziduí časových řad je zamítnuta pro časové řady kryptoměny Bitcoin a akcie Apple i Facebook. Časová řada reziduí je tedy autokorelována. Problém by mohl být vyřešen zvolením jiného lineárního nebo nelineárního modelu volatility, nebo odstraněním samotné autokorelace.

Date: 01/18/20 Time: 23:55
Sample: 12/02/2013 12/31/2018
Included observations: 1279

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
		1	-0.056	-0.056	3.9494	0.047
		2	0.006	0.003	4.0013	0.135
		3	-0.009	-0.008	4.0961	0.251
		4	0.003	0.003	4.1116	0.391
		5	0.002	0.003	4.1189	0.532
		6	0.002	0.002	4.1218	0.660
		7	-0.007	-0.006	4.1776	0.759
		8	-0.010	-0.011	4.3039	0.829
		9	-0.017	-0.018	4.6932	0.860
		10	0.054	0.053	8.5268	0.578
		11	-0.035	-0.029	10.126	0.519
		12	-0.016	-0.020	10.455	0.576
		13	0.017	0.016	10.813	0.626
		14	-0.044	-0.043	13.296	0.503
		15	0.009	0.004	13.412	0.571
		16	0.013	0.014	13.627	0.627
		17	0.035	0.036	15.208	0.580
		18	0.029	0.034	16.288	0.572
		19	0.020	0.024	16.797	0.604
		20	-0.008	-0.009	16.877	0.661

Tabulka 38: Test autokorelace reziduí, model s impulsem, akcie Apple, Eviews

Date: 12/29/19 Time: 15:11
Sample: 12/01/2013 12/31/2018
Included observations: 1857

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
		1	0.056	0.056	5.7645	0.016
		2	0.005	0.001	5.8024	0.055
		3	0.031	0.031	7.6118	0.055
		4	0.005	0.001	7.6501	0.105
		5	0.022	0.021	8.5206	0.130
		6	0.094	0.092	25.169	0.000
		7	0.004	-0.006	25.205	0.001
		8	-0.016	-0.017	25.657	0.001
		9	-0.028	-0.032	27.142	0.001
		10	0.071	0.074	36.435	0.000
		11	0.030	0.020	38.122	0.000
		12	0.005	-0.005	38.162	0.000
		13	0.015	0.011	38.581	0.000
		14	0.028	0.030	40.101	0.000
		15	-0.010	-0.009	40.274	0.000
		16	0.041	0.027	43.423	0.000
		17	0.024	0.013	44.467	0.000
		18	0.013	0.013	44.762	0.000
		19	0.015	0.014	45.194	0.001
		20	0.034	0.024	47.374	0.001

Tabulka 39: Test autokorelace reziduí, model s popularitou, Bitcoin, Eviews

Date: 12/29/19 Time: 16:01
Sample: 12/01/2013 12/31/2018
Included observations: 1808

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
		1	-0.034	-0.034	2.0617	0.151
		2	0.015	0.014	2.4627	0.292
		3	-0.020	-0.019	3.1531	0.369
		4	-0.021	-0.023	3.9564	0.412
		5	-0.016	-0.017	4.4227	0.490
		6	0.010	0.009	4.5975	0.596
		7	0.025	0.025	5.7075	0.574
		8	-0.007	-0.007	5.8000	0.670
		9	-0.013	-0.014	6.1026	0.730
		10	-0.027	-0.027	7.4772	0.680
		11	-0.000	-0.000	7.4773	0.759
		12	0.030	0.031	9.1348	0.691
		13	-0.037	-0.038	11.642	0.557
		14	-0.014	-0.020	11.989	0.607
		15	0.034	0.035	14.095	0.518
		16	-0.003	0.001	14.107	0.591
		17	-0.019	-0.020	14.744	0.614
		18	-0.019	-0.023	15.418	0.633
		19	0.005	0.004	15.463	0.693
		20	-0.000	0.003	15.463	0.749

Tabulka 40: Test autokorelace reziduí, model s popularitou, EUR USD, Eviews

Date: 12/29/19 Time: 17:12
Sample: 12/02/2013 12/31/2018
Included observations: 1279

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
		1	-0.082	-0.082	8.5509	0.003
		2	-0.005	-0.012	8.5856	0.014
		3	-0.028	-0.030	9.5985	0.022
		4	-0.024	-0.029	10.308	0.036
		5	-0.027	-0.032	11.213	0.047
		6	-0.013	-0.020	11.436	0.076
		7	0.006	0.001	11.477	0.119
		8	0.014	0.012	11.734	0.163
		9	-0.010	-0.010	11.854	0.222
		10	0.025	0.022	12.667	0.243
		11	-0.022	-0.019	13.310	0.274
		12	-0.019	-0.022	13.785	0.315
		13	0.028	0.027	14.831	0.318
		14	-0.005	-0.001	14.868	0.387
		15	-0.005	-0.006	14.899	0.459
		16	0.000	-0.001	14.899	0.532
		17	0.019	0.018	15.355	0.570
		18	0.028	0.032	16.383	0.566
		19	0.018	0.025	16.791	0.604
		20	0.018	0.023	17.209	0.639

Tabulka 41: ARCH LM test reziduí, model s impulsem, akcie Facebook, Eviews

3.2.12 Grafická analýza výsledků testování

Graf 31 a graf 32 zobrazují použití modelů při modelaci volatility kurzu akcie Apple a kryptoměny Bitcoin přibližně na ročním období. Pro srovnání je modelace provedena pro model s přepočteným objemem vyhledávání (jednotkové impulsy nebo kompletní časová řada popularity) a bez použití přepočtených objemů vyhledávání. V obou případech se křivka modelu používajícího data z aplikace Google Trends blíží křivce, která data z Google Trends nepoužívá. Rozdíly je možné pozorovat pouze v některých úsecích, kdy se křivky používající přepočtené objemy vyhledávání částečně odchýlí. Zatímco v případě akcie Apple je patrné vychýlení přibližně uprostřed sledovaného období v důsledku zvýšeného vyhledávání, u kryptoměny Bitcoin je vychýlení způsobeno spíše nižším objemem vyhledávání, to je možné pozorovat zpočátku sledovaného období.

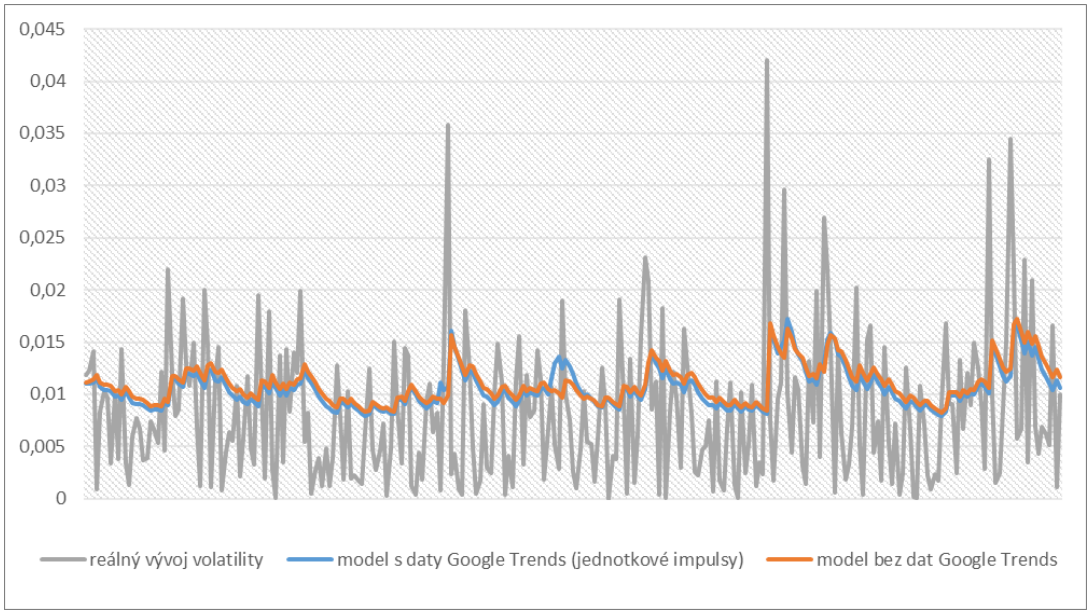

Graf 31: Modelace volatility, akcie Apple, rok 2014, vlastní tvorba

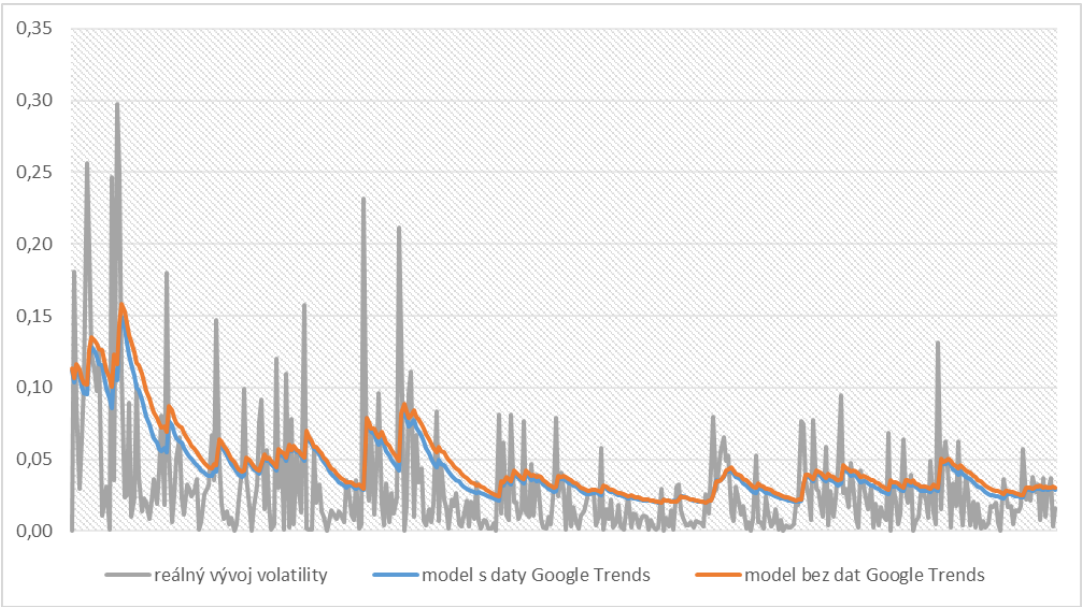

Graf 32: Modelace volatility, Bitcoin, rok 2014, vlastní tvorba

Graf 33 a graf 34 zachycují modelaci volatility pro měnový pár EUR USD a akcii Facebook. Modelace je provedena opět pro přibližně roční období (rok 2014). Modelace v případě měnového páru EUR USD je pro model využívající data z aplikace Google Trends a pro model nevyužívající tato data na sledovaném úseku dat velmi rozdílná. Přičemž modelace v případě modelu využívajícího data z aplikace Google Trends se jeví jako lépe vystihující reálný vývoj volatility. U akcie Facebook je modelace pro oba modely velmi podobná, odlišuje se jen velmi nepatrně při sníženém objemu vyhledávání.

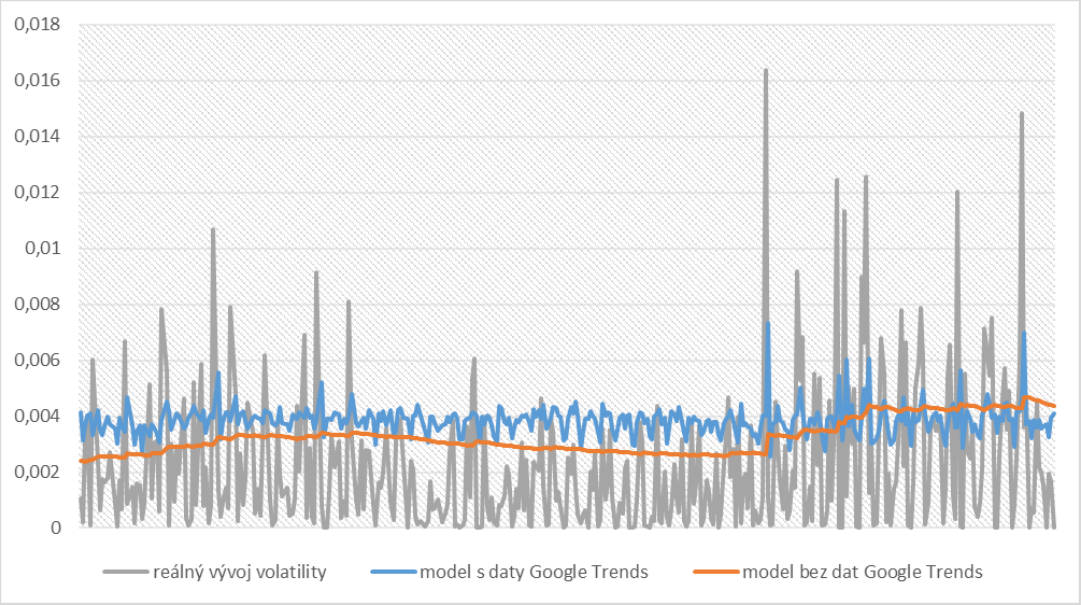

Graf 33: Modelace volatility, měnový pár EUR USD, rok 2014, vlastní tvorba

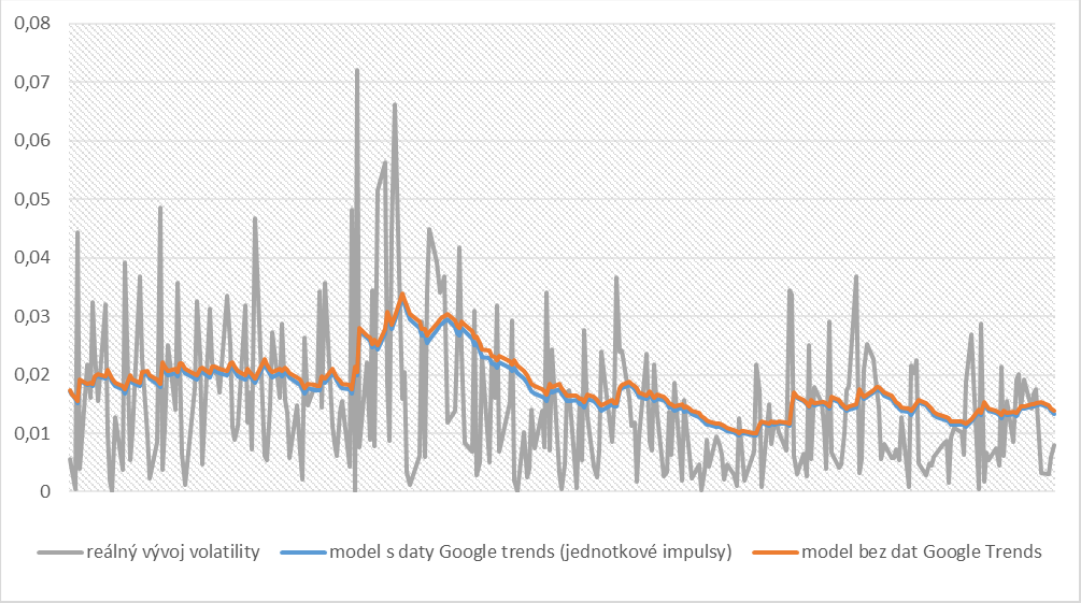

Graf 34: Modelace volatility, akcie Facebook, rok 2014, vlastní tvorba

3.2.13 Závěry k provedenému sestavení a testování modelů

Pro každou z časových řad zachycujících denní výnosy jednotlivých vybraných finančních aktiv jsem sestavil ekonometrický model GARCH (1,1). Jako měřítko k hodnocení modelů jsem si zvolil Akaikeho informační kritérium, které hodnotí samotný model a současně jeho složitost.

Nejdříve jsem časové řady kurzů převedl na časové řady denních výnosů, tím jsem zajistil, že časové řady budou stacionární a vhodné ke stochastickému modelování. Stacionaritu časových řad jsem ověřil na základě Dickey-Fullerova testu. Dále jsem časové řady otestoval na normalitu pravděpodobnostního rozdělení. U všech testovaných řad se projevilo leptokurtické rozdělení. Například špičatost v případě Bitcoinu i několikanásobně přesahovala hodnotu normálního rozdělení.

Následně jsem vytvořil a porovnal několik variant modelů. Přičemž pro kryptoměnu Bitcoin a měnový pár EUR USD se jako nejlepší ukázal model s popularitou v podobě časové řady přepočtená popularita. U akcií společností Apple a Facebook se naproti tomu nejlépe osvědčil model s popularitou v podobě jednotkových impulsů generovaných při překročení předem stanovené úrovně popularity v příslušném období.

Vzhledem k tomu, že si modely s popularitou dle zvoleného Akaikeho kritéria vedly lépe, pokračoval jsem testováním reziduí těchto modelů. Testy reziduí ukázaly na některé nedostatky modelů. Přestože se šikmost i špičatost v některých modelech přiblížila normálnímu rozdělení, výsledky Jarque-Berova testu zamítly hypotézu H0 o normálním rozdělení reziduí. Testováním pomocí ARCH LM testu jsem následně potvrdil nulovou hypotézu o homoskedasticitě a v modelech by se tak heteroskedasticita neměla objevovat. V posledním z prováděných testů na autokorelaci reziduí se však ukázala autokorelace modelů časové řady Bitcoinu, akcie Apple i akcie Facebooku.

Přestože testy reziduí ukazují na možnosti vylepšení modelů, obecně lze konstatovat, že data z aplikace Google Trends jako taková přispěla k vylepšení modelů volatility všech testovaných finančních aktiv. Ať už v podobě časové řady přepočtená popularita nebo jednotkových impulsů. Parametry spojené s popularitou byly na zvolené hladině významnosti statisticky významné, a současně modely zahrnující popularitu byly dle zvoleného kritéria hodnoceny lépe než modely, kde popularita nebyla obsažena v žádné podobě.

3.3 Obchodní strategie

V této kapitole se budu zabývat testováním vlastního obchodního systému. Vytvořený obchodní systém pracuje s časovou řadou kurzů a s časovou řadou přepočtená popularita. Cílem testování je odhalit vzorce v chování investorů z hlediska vztahu vývoje hodnoty kurzu a vývoje objemů vyhledávání uživatelů ve vyhledávači Google. Obchodní systém vyhodnocuje každý první obchodní den v týdnu vývoj kurzu a popularity za předchozí dva týdny.

3.3.1 Indikátor Směru vývoje (MT)

Vývoj kurzu je porovnáván na základě vlastního indikátoru *Směr vývoje MT* (Movement Tendency) porovnávajícího maximální a minimální hodnoty kurzu dle následujícího vzorce:

$$MT = 100 - \left[\frac{100}{1+\frac{Max(kurz)_{t-1}+Min(kurz)_{t-1}}{Max(kurz)_{t-2}+Min(kurz)_{t-2}}}\right], \tag{4}$$

kde $Max(kurz)_{t-1}$ je týdenní maximální hodnota kurzu dosažená předchozí týden,

$Max(kurz)_{t-2}$ je týdenní maximální hodnota kurzu dosažená před dvěma týdny,

$Min(kurz)_{t-1}$ je týdenní minimální hodnota kurzu dosažená předchozí týden,

$Min(kurz)_{t-2}$ je týdenní minimální hodnota kurzu dosažená před dvěma týdny.

Hodnoty indikátoru oscilují v pásmu od 0 do 100. Indikátor je svou konstrukcí podobný indikátoru indexu relativní síly (RSI) [8, s. 65], avšak místo kladných a záporných kurzových změn porovnává vývoj maximálních a minimálních hodnot kurzů předchozích dvou týdnů.

3.3.2 Indikátor Relativní síly popularity (RSP)

Obdobně je konstruován i indikátor relativní síly popularity (RSP). V konstrukci tohoto indikátoru jsou kladné a záporné kurzové změny nahrazeny průměrnými hodnotami popularity předchozích dvou týdnů. Indikátor tedy zachycuje, jak velká byla v předchozím týdnu tendence popularity růst či klesat vůči týdnu předcházejícímu. Konstrukci indikátoru popisuje následující vzorec:

$$RSP = 100 - \left[\frac{100}{1+\frac{prům(popularita)_{t-1}}{prům(popularita)_{t-2}}}\right], \tag{5}$$

kde $prům(popularita)_{t-1}$ je týdenní průměrná hodnota popularity předchozího týdne,

$prům(popularita)_{t-2}$ je týdenní průměrná hodnota popularity dosažená před dvěma týdny.

Pro oba indikátory platí, že hodnoty vyšší než 50 značí tendenci růstu kurzu či popularity a hodnoty nižší než 50 tendenci poklesu.

3.3.3 Metody testování a optimalizace obchodního systému

Testování provedu v programu Excel pomocí nástroje Řešitel. Testováno bude celkem osm možných scénářů. Všechny kombinace růstu a poklesu kurzu a popularity, a současně otevření krátké a dlouhé pozice pro každou z kombinací.

Podmínky a proměnné jednotlivých scénářů zachycuje tabulka 42Tabulka 42 níže.

č. scénáře	RSP	MT	typ pokynu
1	>50	>50	nákup
2	>50	<50	nákup
3	<50	>50	nákup
4	<50	<50	nákup
5	>50	>50	prodej
6	>50	<50	prodej
7	<50	>50	prodej
8	<50	<50	prodej

Tabulka 42: Scénáře testované obchodní strategie, vlastní tvorba

V rámci obchodní strategie je odpovídající typ pokynu proveden v případě splnění následujících podmínek:

1) Hodnota indikátoru RSP spadá do předem stanoveného intervalu hodnot *(RSP-,RSP+)*.
2) Hodnota indikátoru MT spadá do předem stanoveného intervalu hodnot *(MT-,MT+)*.

Například v případě prvního scénáře musí být hodnoty indikátoru RSP v rozmezí od 50 do 100. Přičemž v rámci optimalizace dochází k ještě většímu zúžení tohoto intervalu, a to shora i zdola.

Pro optimalizaci a testování jsem si časové řady rozdělil na dvě období. První období bylo přibližně dvouleté a druhé období přibližně tříleté. Nejprve jsem provedl optimalizaci obchodní strategie v prvním období a následně backtest v druhém období. Optimalizace obchodní strategie spočívá v úpravě intervalů *(RSP-,RSP+)* a *(MT-,MT+)*.

Jak již bylo uvedeno výše, veškeré informace jsou v rámci obchodní strategie vyhodnocovány vždy první pracovní den v týdnu (v případě nákupu / prodeji je většinou uplatněn pondělní zahajovací kurz). Pokyn pro vstup do pozice vychází ze signálů indikátorů RSP a MT. K výstupu z pozice pak dochází automaticky opět v první pracovní den následujícího týdne. Jednotlivé obchody jsou prováděny se stejným objemem kapitálu. V rámci pokynu je uvažován poplatek 0,2 % hodnoty aktiva [9, s. 238].

Optimalizace probíhala na základě evolučního algoritmu v programu Microsoft Excel. Parametry evolučního algoritmu byly následující:

Konvergence: 0,001

Frekvence mutací: 0,075

Velikost základního souboru: 200

Náhodné číslo: 0

Maximální doba bez vylepšení: 60

Při samotné optimalizaci se úspěšnost obchodních strategií posuzovala na základě účelové funkce. Pro optimalizaci jsem vyzkoušel čtyři účelové funkce. Při sestavování účelových funkcí jsem vycházel z poznatků dle [VII, s. 22]. Nejprve jsem otestoval následující funkci:

$$\text{účelová funkce } 1 = \text{celkový výnos } (\%) \cdot \text{počet obchodů} - \text{drawdown } (\%), \tag{6}$$

kde parametr *drawdown* je nejvyšší hodnota propadu kapitálu ve vztahu ke kapitálu vloženému do jednoho obchodu. Tato funkce v průběhu optimalizace ukázala některé nedostatky. Především se jednalo o velké množství provedených obchodních pokynů, které vycházely z konstrukce účelové funkce, jež příliš upřednostňovala počet provedených obchodů.

Při konstrukci druhé účelové funkce jsem se rozhodl místo parametru *drawdown* využít t-test k ověření, zda jsou výnosy obchodů významně odlišné od hodnoty 0 a objem provedených obchodů jsem z funkce vyřadil. Statistickou významnost jsem určil pomocí funkce T.TEST v aplikaci Microsoft Excel. Výstupem funkce T.TEST je p-hodnota t-testu.

$$\text{účelová funkce } 2 = \text{celkový výnos } (\%) \cdot (1 - T.TEST), \tag{7}$$

kde parametr *T.TEST* představuje stejnojmennou funkci aplikace Microsoft Excel. Druhá testovaná funkce podstatně zvýšila počet strategií, které obstály při backtestu. Nicméně se projevilo, že některé strategie byly ziskové jen kvůli nízkému počtu vysoce ziskových obchodů – ve většině případů bylo provedeno pouze několik obchodů za celé období optimalizace i backtestu.

Konstrukce třetí funkce vycházela z konstrukce 2. účelové funkce. Abych zamezil upřednostnění strategií s nízkým počtem vysoce ziskových obchodů, vydělil jsem celkový výnos (%) za sledované období maximálním výnosem (%) dosaženým v rámci jednoho obchodu, viz následující vzorec:

$$\text{účelová funkce } 3 = \frac{\text{celkový výnos } (\%)}{abs(\text{maximální výnos na jeden obchod}(\%))} \cdot (1 - T.TEST) \tag{8}$$

Optimalizace pomocí 3. účelové funkce přinesla podstatně vyšší výnos pro úspěšně hodnocené scénáře. S vyšším výnosem však souviselo i vyšší riziko, kdy kumulovaný výnos za jednotlivé scénáře přesáhl ztrátu 100 % původního kapitálu, viz tabulka 43 níže. Současně je nutné zmínit, že se nepodařilo zvýšit průměrný počet provedených obchodů a odstranit scénáře s nízkým počtem vysoce ziskových obchodů.

Při konstrukci poslední účelové funkce jsem se zaměřil na snížení podstupovaného rizika. Opět jsem vycházel z konstrukce 2. účelové funkce, viz výše. Do konstrukce jsem dále zahrnul podmínku maximalizující intervaly hodnot pro oba použité technické indikátory (RSP a MT). Podmínku zachycuje následující účelová funkce:

$$\text{účelová funkce } 4 = \text{celkový výnos } (\%) \cdot (1 - T.TEST) \cdot \frac{(RSP+)-(RSP-)}{50} \cdot \frac{(MT+)-(MT-)}{50}, \quad (9)$$

kde *RSP+* je horní hranici intervalu indikátoru RSP pro podání obchodního pokynu,

RSP- je dolní hranice intervalu indikátoru RSP pro podání obchodního pokynu,

MT+ je horní hranice intervalu indikátoru MT pro podání obchodního pokynu,

MT- je dolní hranice intervalu indikátoru MT pro podání obchodního pokynu.

Jednotlivé scénáře při optimalizaci pomocí 4. účelové funkce dosáhly dobrého průměrného výnosu za úspěšné strategie (úspěšná strategie má výnos vyšší než 0 za optimalizované i backtestové období). Zároveň se podařilo navýšit průměrný počet obchodů na strategii. Velmi dobrý je také kumulovaný výnos za všechny strategie, kdy se podařilo udržet nezáporný výnos, viz tabulka 43 níže. Negativní je navýšení průměrného drawdown.

číslo účelové funkce	úspěšných v backtestu	geometrický průměr p-hodnot (úspěšné)	geometrický průměr výnosů (úspěšné)	průměr drawdown (úspěšné)	kumul. výnos za všechny strategie	prům. počet obchodů na strategii
1	28%	0,39	6,37%	21,44%	-192,25%	26
2	41%	0,39	6,62%	9,59%	-73,47%	10
3	34%	0,26	9,42%	10,38%	-177,18%	11
4	44%	0,34	7,69%	14,45%	7,28%	15

Tabulka 43: Přehled výsledků za jednotlivé účelové funkce, vlastní tvorba

Tabulka 43 výše ukazuje úspěšnost jednotlivých účelových funkcí při optimalizaci a backtestu. Pro text níže platí, že jako úspěšná byla označena ta strategie, která dosáhla výnosu vyššího než 0 za optimalizované i backtestové období. Sloupec *úspěšných v backtestu* ukazuje procentuální úspěšnost při použití účelové funkce ve smyslu podílu počtu úspěšných strategií a celkového počtu všech testovaných strategií. Sloupec *geometrický průměr p-hodnot (úspěšné)* je geometrickým průměrem p-hodnot t-testů (posuzujících, zda je výnos na obchod statisticky vyšší než 0). Do průměru jsou zahrnuty pouze úspěšné strategie. Sloupec *geometrický průměr výnosů (úspěšné)* je geometrickým průměrem výnosů úspěšných strategií. Sloupec *průměrný drawdown* představuje průměrný nejvyšší propad kapitálu za jednotlivé strategie ve vztahu k počátečnímu kapitálu. Sloupec *kumulovaný výnos za všechny strategie* zachycuje kumulovaných výnos dosažený za všechny testované strategie pro odpovídající účelovou funkci. Sloupec *průměrný počet obchodů na strategii* odpovídá průměrnému počtu provedených obchodů na jednu strategii pro odpovídající účelovou funkci.

Výsledky scénářů se při optimalizaci za použití různých účelových funkcí liší a není možné tvrdit, že některá z funkcí dosáhla podstatně lepších výsledků než funkce ostatní. Za účelem ukázky výsledků jsem se rozhodl podrobněji zkoumat optimalizaci dle 4. účelové funkce. To především proto, že se zaměřuje na nejširší možný interval

hodnot použitelných ve vytvořených indikátorech RSP a MT. Výsledky ostatních funkcí budou zohledněny v závěru kapitoly při hodnocení jednotlivých scénářů.

3.3.4 Testování, optimalizace a backtesting dle 4. účelové funkce

Testování, optimalizace a backtesting – akcie Apple

scénář	RSP+	RSI-	MT+	MT-	účelová funkce	max drawdown	celkový výnos (optimalizace)	počet obchodů	p-value
1	78,65	50,03	51,94	50,37	0,0022	1,95%	13,14%	15	0,06
2	78,65	50,00	49,79	47,90	0,0037	3,66%	19,11%	15	0,09
3	47,12	27,84	51,94	50,54	0,0013	2,31%	14,49%	8	0,16
4	50,00	27,84	49,97	47,90	0,0022	29,57%	22,54%	25	0,47
5	78,65	50,66	50,78	50,02	0,0017	1,88%	21,03%	15	0,03
6	63,37	55,45	50,00	47,91	0,0001	2,82%	3,42%	5	0,57
7	50,00	37,90	51,94	50,62	0,0005	2,82%	9,54%	7	0,24
8	46,04	27,85	49,69	47,90	0,0014	6,45%	18,57%	5	0,40

Tabulka 44: Výsledky optimalizace obchodní strategie, akcie Apple, vlastní tvorba

Tabulka 44 ukazuje výsledky optimalizace obchodní strategie pro akcii Apple za první období. Pro všechny testované scénáře se podařilo nalézt přípustné řešení – tedy řešení splňující omezení parametrů indikátorů. Dle hodnoty účelové funkce si nejlépe vedla strategie scénáře 2. Tento scénář pracuje se vzorcem chování, kdy pokles hodnoty kurzu aktiva a současně růst v objemech vyhledávání dávají signál k provedení nákupního pokynu. Celkem bylo v rámci tohoto scénáře uskutečněno 15 obchodních pokynů. Naopak nejhůře si vedl scénář 6 charakteristický zvýšeným zájmem ve vyhledávání a současným poklesem v hodnotě kurzu aktiva – oproti scénáři 2 odlišný tím, že výsledkem je podání prodejního nikoli nákupního pokynu. Během tohoto scénáře bylo provedeno pět obchodů.

scénář	celkový výnos backtest	počet obchodů (backtest)	max drawdown (backtest)	účelová funkce (backtest)	p-value (back test)
1	21,15%	26	5,69%	0,0035	0,07
2	-2,56%	23	24,87%	- 0,0000	0,92
3	-7,14%	13	11,86%	- 0,0004	0,51
4	-1,86%	34	22,46%	- 0,0000	0,94
5	-37,50%	30	46,83%	- 0,0031	0,05
6	11,07%	9	2,66%	0,0006	0,18
7	10,48%	15	2,70%	0,0005	0,29
8	-8,37%	9	14,39%	- 0,0006	0,42

Tabulka 45: Výsledky backtestingu obchodní strategie, akcie Apple, vlastní tvorba

Tabulka 45 zachycuje výsledky backtestingu provedeného na druhém období. Jednotlivé scénáře si při backtestingu vedly o poznání hůře. Největší propad nastal u strategie dle scénáře 5.

Nejlépe si vedla strategie dle scénáře 1 založená na generování nákupních signálů při růstu hodnoty kurzu aktiva a současném růstu objemů vyhledávání. Bylo dosaženo dobrého výnosu při vysokém počtu provedených obchodů, s nízkým drawdown a p-hodnotě značící téměř 95% statistickou významnost odlišnosti výnosů od hodnoty 0. Dobře si vedly i strategie dle scénáře 6 a 7. Obě strategie dosáhly výnosu přes 10 %

a to při zachování poměrně nízkého propadu kapitálu (drawdown). Scénáře těchto strategií jsou založeny na podávání prodejních signálů. V případě scénáře 6 je signál generován poklesem v hodnotě kurzu a současně růstem v objemech vyhledávání. Scénář 7 odpovídá situaci opačné, tedy růstu v hodnotě kurzu a poklesu objemů vyhledávání.

Testování, optimalizace a backtesting – Bitcoin

scénář	RSP+	RSI-	MT+	MT-	účelová funkce	max drawdown	celkový výnos (optimalizace)	počet obchodů	p-value
1	71,26	52,13	61,42	50,02	0,1452	5,71%	171,61%	12	0,03
2	71,22	50,00	48,52	42,23	0,0522	5,75%	99,21%	13	0,01
3	46,93	32,83	61,42	50,00	0,0135	11,47%	30,82%	9	0,32
4	48,08	33,28	49,30	48,76	0,0003	0,00%	9,78%	2	0,05
5	65,76	51,62	57,52	52,42	0,0007	10,40%	7,89%	4	0,70
6	71,26	50,13	50,00	45,48	0,0260	15,20%	73,87%	20	0,08
7	49,90	32,83	61,42	52,10	0,0182	0,00%	30,47%	4	0,06
8	49,65	32,83	50,00	42,23	0,0596	14,75%	115,94%	30	0,02

Tabulka 46: Výsledky optimalizace obchodní strategie, Bitcoin, vlastní tvorba

Tabulka 46 výše zachycuje výsledky optimalizace obchodní strategie pro kryptoměnu Bitcoin. Dle účelové funkce byl nejlépe hodnocený scénář 1, který zachycuje situaci růstu objemů vyhledávání ve vyhledávači Google a současného růstu hodnoty kurzu aktiva. Při splnění podmínek scénáře dochází k podání nákupního pokynu.

Nejhůře skončil scénář 4. U tohoto scénáře je obchodní signál k nákupu aktiva generován v případě poklesu objemů vyhledávání a poklesu hodnoty kurzu aktiva.

scénář	celkový výnos backtest	počet obchodů (backtest)	max drawdown (backtest)	účelová funkce (backtest)	p-value (back test)
1	146,04%	31	27,90%	0,0578	0,22
2	54,07%	15	31,85%	0,0179	0,38
3	-47,56%	23	66,06%	- 0,0140	0,49
4	-18,04%	5	10,42%	0,0000	0,96
5	0,00%	18	60,41%	- 0,0068	0,47
6	3,19%	23	42,88%	0,0001	0,95
7	-8,79%	6	26,85%	0,0021	0,78
8	-29,89%	38	85,14%	- 0,0047	0,69

Tabulka 47: Výsledky backtestingu obchodní strategie, Bitcoin, vlastní tvorba

Backtest obchodní strategie Bitcoinu ukazuje tabulka 47. Velmi dobré výsledky potvrdila strategie popsaná scénářem 1. Tento scénář zachycuje situaci růstu objemů ve vyhledávání a růstu hodnoty kurzu aktiva. Pokud je obchodní signál generován, dochází k podání nákupního pokynu. Celkem strategie dosáhla výnosu 146,04 %. Horní a dolní hranice indikátorů RSP a MT ukazují, že v rámci scénáře 1 bylo možné generovat nákupní signály na poměrně širokém intervalu hodnot. Celkem bylo provedeno 31 obchodů. Dobrých výsledků dosáhl i scénář 2 popisující strategii založenou na nákupu aktiva v důsledku růstu objemů vyhledávání a poklesu v hodnotě kurzu aktiva.

Testování, optimalizace a backtesting – EUR USD

scénář	RSP+	RSI-	MT+	MT-	účelová funkce	max drawdown	celkový výnos (optimalizace)	počet obchodů	p-value
1	60,27	50,50	50,34	50,19	0,0000199	0,00%	3,77%	2	0,09
2	56,11	52,84	49,94	49,31	0,0000276	0,00%	3,47%	4	0,03
3	48,32	42,55	50,40	50,05	0,0000087	0,23%	1,68%	3	0,35
4	47,15	39,30	49,98	49,20	0,0000455	0,00%	2,11%	3	0,12
5	56,34	50,43	50,22	50,14	0,0000035	0,00%	2,96%	2	0,38
6	66,37	54,59	49,94	49,48	0,0000069	0,85%	1,13%	2	0,72
7	48,16	41,35	50,54	50,01	0,0000053	2,31%	1,34%	6	0,73
8	49,87	43,90	49,77	49,55	0,0000172	1,30%	3,95%	9	0,18

Tabulka 48: Výsledky optimalizace obchodní strategie, EUR USD, vlastní tvorba

Tabulka 48 ukazuje výsledky optimalizace obchodní strategie pro měnový pár EUR USD. Nejlépe v tomto případě dopadla strategie dle scénáře 4. Jde o scénář zachycující situaci poklesu popularity i hodnoty kurzu aktiva. Přičemž generované signály mají podobu nákupních pokynů.

Nejhůře se dle účelové funkce umístil scénář 5. Tento scénář podává prodejní pokyny, pokud roste popularita a současně roste hodnota kurzu aktiva.

scénář	celkový výnos backtest	počet obchodů (backtest)	max drawdown (backtest)	účelová funkce (backtest)	p-value (back test)
1	3,38%	8	0,41%	0,0000188	0,04
2	1,66%	3	0,00%	0,0000098	0,28
3	-1,17%	7	2,39%	- 0,0000044	0,53
4	-0,83%	4	1,28%	- 0,0000085	0,58
5	-2,10%	9	2,75%	- 0,0000026	0,36
6	-1,63%	3	1,79%	- 0,0000273	0,22
7	-0,51%	12	3,55%	- 0,0000010	0,86
8	0,34%	7	1,85%	0,0000002	0,90

Tabulka 49: Výsledky backtestingu obchodní strategie, EUR USD, vlastní tvorba

Tabulka 49 výše udává výsledky backtestu obchodních strategií pro měnový pár EUR USD. Úspěšně backtest obstály pouze tři scénáře. Nejlépe si opět vedl scénář 1, který dosáhl celkem dobrých výsledků už i při optimalizaci. Celkem bylo podáno 8 nákupních signálů. Dle p-hodnoty t-testu lze tvrdit, že výnosy jsou na 95% hladině významnosti odlišné od hodnoty 0.

Testování, optimalizace a backtesting –akcie Facebook

scénář	RSP+	RSI-	MT+	MT-	účelová funkce	max drawdown	celkový výnos (optimalizace)	počet obchodů	p-value
1	86,09	50,62	51,86	50,99	0,0002	7,71%	5,17%	10	0,67
2	91,28	50,02	50,00	46,87	0,0159	9,48%	35,87%	18	0,14
3	49,99	25,76	52,49	50,08	0,0091	10,33%	39,63%	31	0,02
4	47,40	25,75	49,10	46,87	0,0020	0,00%	11,87%	3	0,14
5	91,28	52,20	52,49	50,33	0,0063	2,99%	18,94%	14	0,02
6	91,28	53,48	50,00	46,87	0,0034	0,05%	10,37%	6	0,30
7	45,92	25,75	51,10	50,31	0,0001	0,00%	2,32%	2	0,02
8	47,08	25,75	50,00	46,87	0,0050	7,70%	25,91%	13	0,28

Tabulka 50: Výsledky optimalizace obchodní strategie, akcie Facebook, vlastní tvorba

Jako poslední jsem testoval obchodní systém na akcii Facebooku. Výsledky optimalizace ukazuje tabulka 50. Nejlepšího výsledku dosáhl při optimalizaci scénář 2, který podává nákupní pokyny v případě růstu objemů vyhledávání a poklesu hodnoty kurzu aktiva.

scénář	celkový výnos backtest	počet obchodů (backtest)	max drawdown (backtest)	účelová funkce (backtest)	p-value (back test)
1	2,46%	4	3,30%	0,0001	0,83
2	52,11%	31	21,71%	0,0206	0,24
3	-99,29%	43	136,84%	- 0,0208	0,10
4	3,39%	4	3,22%	0,0002	0,64
5	2,93%	21	37,81%	0,0001	0,93
6	-12,75%	12	34,28%	- 0,0019	0,69
7	16,74%	9	20,28%	0,0004	0,63
8	-41,76%	16	47,31%	- 0,0107	0,04

Tabulka 51: Výsledky backtestingu obchodní strategie, akcie Facebook, vlastní tvorba

Výsledky backtestingu obchodních strategií pro akcii Facebooku zachycuje Tabulka 51. V backtestu se negativně projevil scénář 3, který dosáhl ztráty 99 % kapitálu použitého na jeden obchod. Poprvé dosáhl nejlepších výsledků scénář 2. Nicméně i tentokrát zůstala strategie dle scénáře 1 v rámci backtestu s kladným výnosem. Scénář 2 je založený na podávání nákupních pokynů v případě růstu objemů vyhledávání a poklesu hodnoty kurzu aktiva.

3.3.5 Závěry k provedenému testování, optimalizaci a backtestingu

V rámci testování možnosti využití dat z aplikace Google Trends při analýze finančních aktiv jsem vytvořil obchodní strategii založenou na vlastních indikátorech Směr vývoje (MT) a Relativní síla popularity (RSP). Konstrukce obou indikátorů vychází z konstrukce indikátoru Indexu relativní síly (RSI). Zatímco indikátor RSI ve své konstrukci zohledňuje podíl kladných a záporných změn za zvolenou časovou periodu, indikátor MT porovnává vývoj minimálních a maximálních kurzů za poslední dva týdny. Indikátor RSP pracuje místo s časovou řadou kurzů s časovou řadou přepočtená popularita (viz kapitola 3.1.2) a v konstrukci zohledňuje vývoj relativně přepočteného objemu vyhledávání za poslední dva týdny.

Pro obchodní strategii jsem stanovil celkem 8 možných scénářů (vzorců chování), které byly v této kapitole testovány. Scénáře vycházely z charakteristik indikátorů MT a RSP. Každý scénář tak představuje jinou kombinaci růstu či poklesu hodnoty kurzu aktiva a relativně přepočteného objemu vyhledávání. Pro každou kombinaci jsem navíc otestoval strategii založenou na generování prodejních i nákupních signálů.

Při optimalizaci jsem využil evolučního algoritmu v nástroji Řešitel v programu Excel. Kritérium úspěšnosti bylo stanoveno pomocí celkem čtyř účelových funkcí, které zohledňovaly různé varianty následujících parametrů: celkový výnos (%), počet provedených obchodů, velikost nejvyššího propadu kapitálu (drawdown), statistickou významnost odlišnosti výnosů za jednotlivé obchody od nuly a šíři intervalů směrodatných pro podávání pokynů v rámci obou vytvořených indikátorů. Abych znevýhodnil strategie generující mnoho nákupních či prodejních pokynů, stanovil jsem za každý provedený obchod poplatek ve výši 0,2 % hodnoty aktiva.

Testovací období jsem si rozdělil do dvou částí, kdy na první části (přibližně dvouleté období) jsem provedl optimalizaci strategií a na druhé části (přibližně tříleté období) backtest optimalizovaných parametrů.

scénář	akcie Apple	Bitcoin	EUR USD	akcie Facebook	Celkem	Úspěšnost (%)
1	4	4	3	2	**13**	81%
2	2	4	2	4	**12**	75%
3	-	-	1	-	**1**	6%
4	1	1	-	2	**4**	25%
5	-	1	-	2	**3**	19%
6	3	3	-	-	**6**	38%
7	3	1	1	2	**7**	44%
8	-	-	1	-	**1**	6%

Tabulka 52: Úspěšnost scénářů při backtestingu, vlastní zdroj

Tabulka 52 výše zobrazuje úspěšnost jednotlivých scénářů při backtestingu kompletně za všechny provedená testování všech čtyř účelových funkcí. Jako úspěšná byla označena ta strategie, která dosáhla kladného zůstatku účtu v období optimalizace i backtestu. Nejlépe v testování dopadly obchodní strategie založené na scénáři 1 a 2.

scénář	akcie Apple	Bitcoin	EUR USD	akcie Facebook	Celkem
1	8,39%	80,54%	2,18%	0,63%	**8,28%**
2	2,06%	49,29%	1,47%	46,44%	**15,85%**
3	x	x	0,65%	x	**0,65%**
4	7,39%	30,38%	x	3,37%	**7,10%**
5	x	10,02%	x	4,45%	**5,84%**
6	4,82%	4,88%	x	x	**4,85%**
7	6,79%	2,70%	2,33%	13,05%	**6,16%**
8	x	x	0,34%	x	**0,34%**

Tabulka 53: Výnos dosažený za úspěšné strategie, vlastní tvorba

Tabulka 53 výše uvádí geometrický průměr výnosů za scénáře pro jednotlivá aktiva. Uvažovány jsou pouze úspěšné strategie, viz výše. Nejvyššího průměrného výnosu bylo dosaženo opět v rámci scénářů 1 a 2.

Níže jsem se rozhodl zobrazit vývoj účtů pro strategie založené na scénáři 1 a 2. Ačkoli scénář 2 dosáhl v některých kritériích lepších výsledků, strategie dle scénáře 1 byly méně rizikové a stabilnější. Optimalizace pro níže uvedené strategie probíhala na základě účelové funkce 4, která se taktéž dle výsledků strategií jevila nejvhodnější, viz tabulka 43 výše.

Scénář 1 uvažuje situaci, kdy dojde k nákupu aktiva na základě růstu objemů vyhledávání (popularity) a současného růstu hodnoty kurzu aktiva. Reálně si tuto situaci můžeme představit následovně: V důsledku nové významné pozitivní informace dojde k navýšení hodnoty kurzu aktiva. Retailoví investoři však informaci absorbují pomalu, a vzniká tak prostor pro otevření dlouhé pozice. Následně rostoucí trend pokračuje, dokud retailoví investoři zprávu zcela neabsorbují (ačkoli může být reakce na informaci přehnaná a časem dojít k částečné korekci směrem zpět k původní hodnotě).

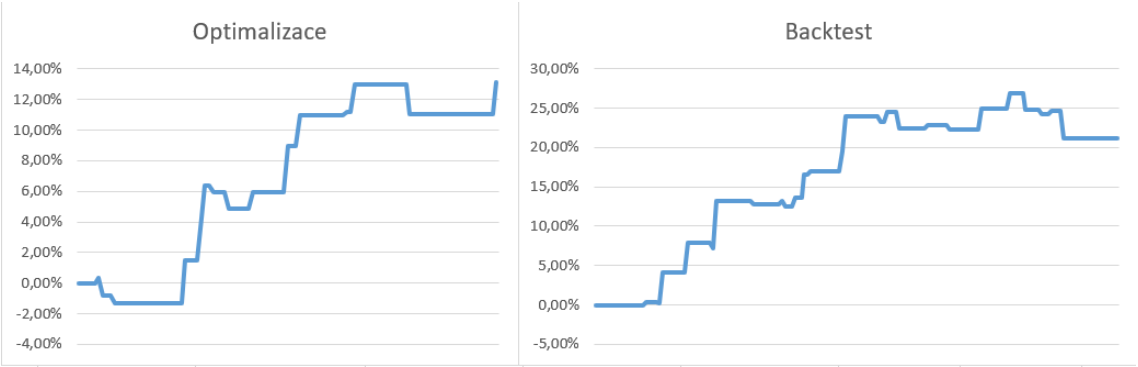

Graf 35: Vývoj účtu strategie dle scénáře 1, akcie Apple, opt. dle účelové funkce 4, vlastní tvorba

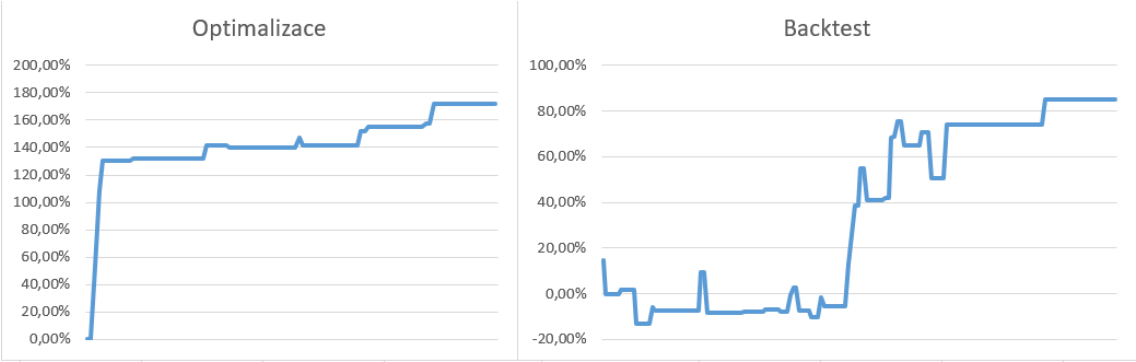

Graf 36: Vývoj účtu strategie dle scénáře 1, Bitcoin, opt. dle účelové funkce 4, vlastní tvorba

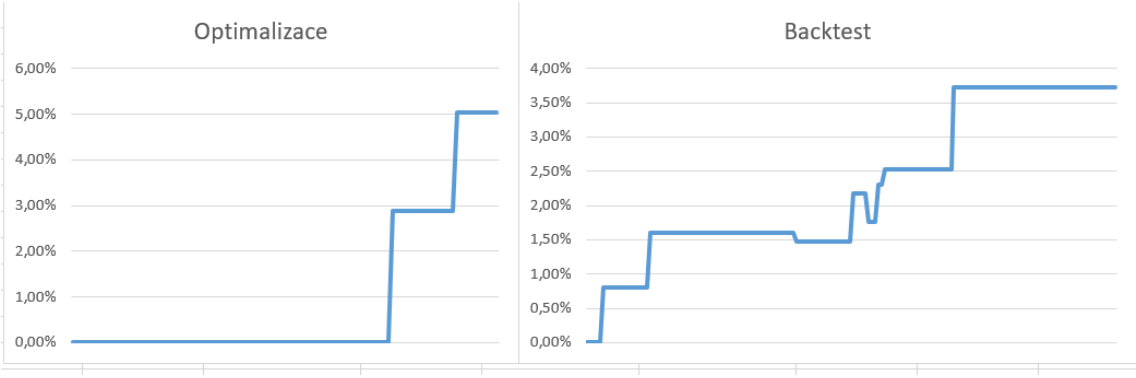

Graf 37: Vývoj účtu strategie dle scénáře 1, EUR USD, opt. dle účelové funkce 4, vlastní tvorba

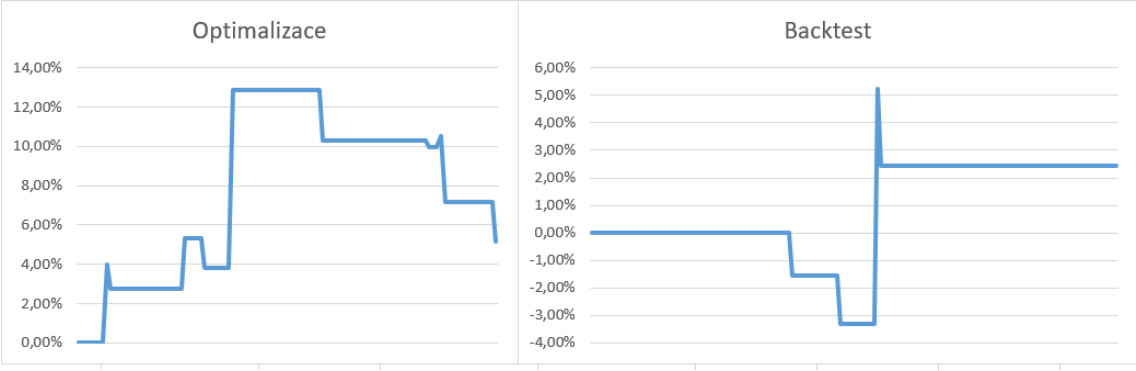

Graf 38: Vývoj účtu strategie dle scénáře 1, akcie Facebook, opt. dle účelové funkce 4, vlastní tvorba

Grafy 35 až 38 zachycují vývoj účtu strategií založených na scénáři 1 a optimalizovaných pomocí účelové funkce 4 pro jednotlivá finanční aktiva. Zatímco pro grafy 35 až 37 pozorujeme celkem stabilní růstový vývoj účtu, v grafu 38 je kladný zůstatek účtu způsoben pouze jediným vysoce ziskovým obchodem. Přesto je možné scénář 1 považovat za úspěšný, neboť více než 80 % strategií založených na tomto scénáři dosáhlo kladného výnosu při optimalizaci i v backtestu. Pro některé strategie bylo dokonce možné stanovit na 95 % hladině významnosti, že výnosy jednotlivých obchodů se statisticky odlišují od 0. Obecně u strategií tohoto scénáře nedocházelo k extrémním propadům kapitálu (drawdown), jehož průměr za všechny strategie byl okolo 11 % kapitálu vkládaného do jednoho obchodu.

Scénář 2 odpovídá vzorci chování, kdy s růstem objemů vyhledávání klíčových slov souvisejících s daným finančním aktivem a poklesem hodnoty kurzu finančního aktiva, můžeme očekávat budoucí růst hodnoty aktiva (provedeme nákup aktiva). Tento scénář by mohl odpovídat například reálné situaci, kdy se na trhu objeví nová negativní informace a neprofesionální investoři reagují přehnaným prodejem daného aktiva. Tato informace (velikost reakce) však nemá fundamentální důvod, čehož si jsou vědomi profesionální investoři, hodnota aktiva tak provede korekci směrem k původní hodnotě.

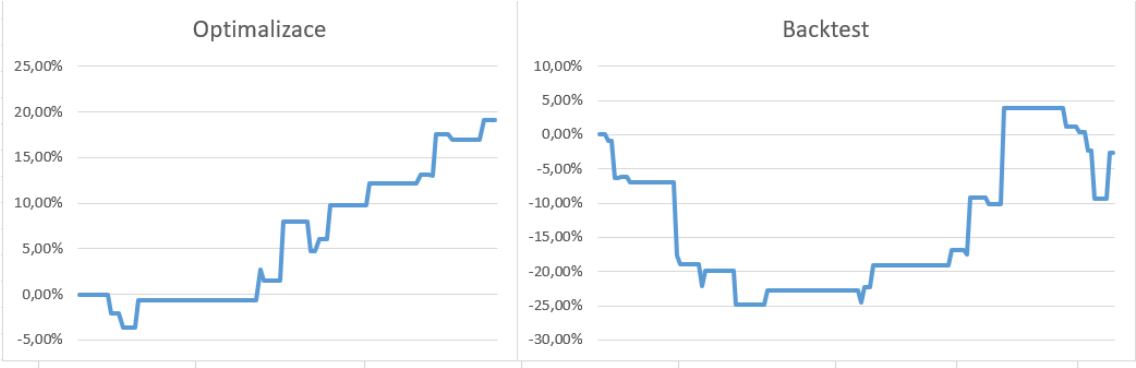

Graf 39: Vývoj účtu strategie dle scénáře 2, akcie Apple, opt. dle účelové funkce 4, vlastní tvorba

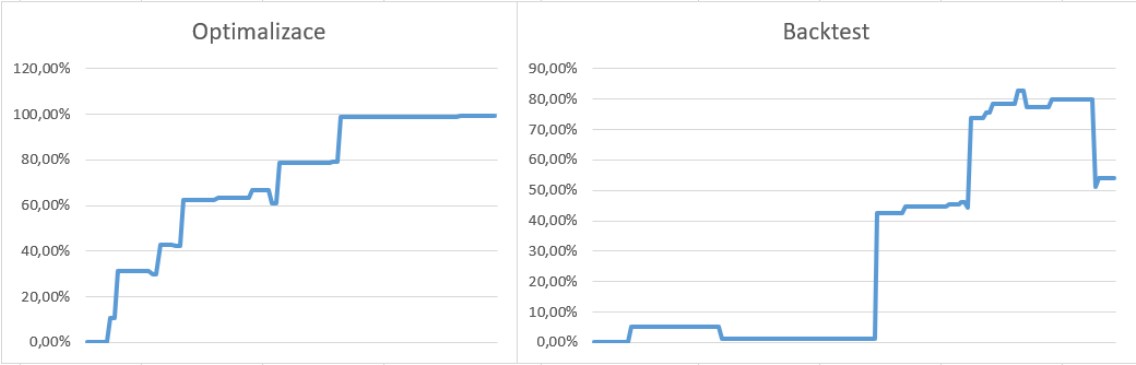

Graf 40: Vývoj účtu strategie dle scénáře 2, Bitcoin, opt. dle účelové funkce 4, vlastní tvorba

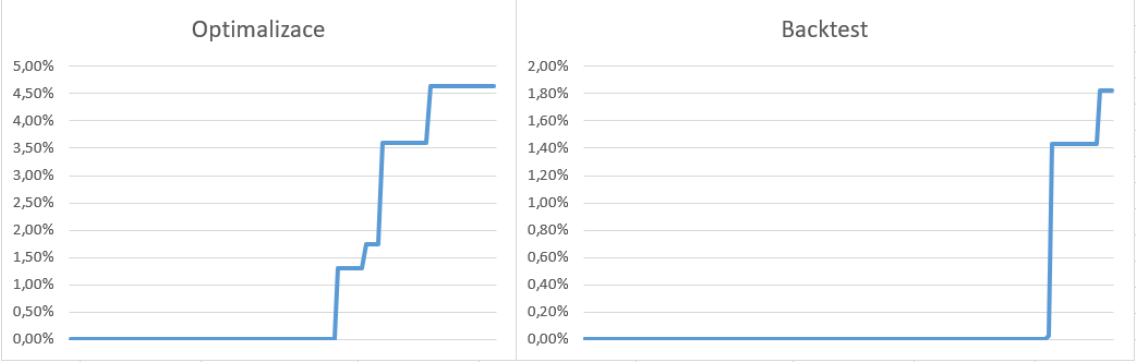

Graf 41: Vývoj účtu strategie dle scénáře 2, EUR USD, opt. dle účelové funkce 4, vlastní tvorba

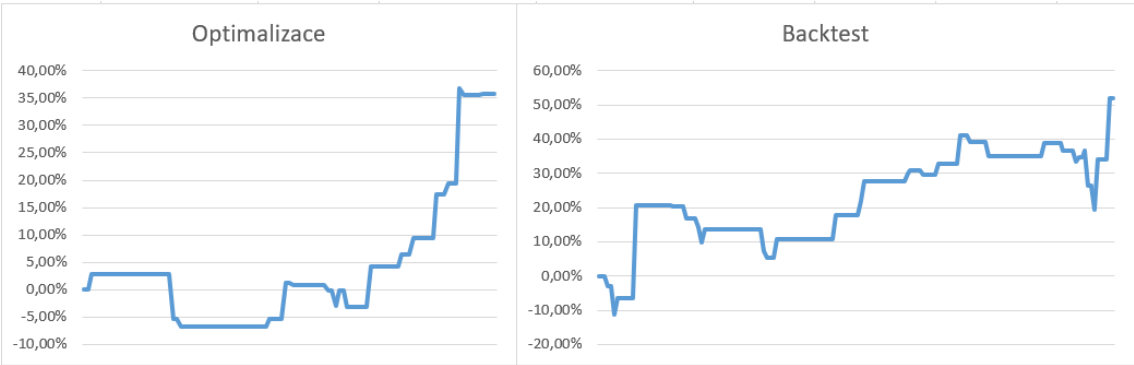

Graf 42: Vývoj účtu strategie dle scénáře 2, akcie Facebook, opt. dle účelové funkce 4, vlastní tvorba

Grafy 39 až 42 zobrazují vývoj účtu strategií založených na scénáři 2 a optimalizovaných pomocí účelové funkce 4 pro jednotlivá finanční aktiva. Vývoj účtu pro akcii Apple dosahuje záporného výsledku. Nicméně pozorujeme jistou tendenci návratu a na okamžik se účet dostává i do kladných hodnot. Pro ostatní aktiva je vývoj účtu postupně rostoucí. Z celkového počtu 16 provedených testů strategií založených na scénáři 2, bylo 12 úspěšných. V průběhu testování se však strategie založené na scénáři 2 projevily jako více rizikové, než strategie založené na scénáři 1 (průměrný drawdown byl téměř dvakrát větší). Nicméně v průměru dosáhly strategie dle scénáře 2 téměř dvojnásobného výnosu oproti strategiím dle scénáře 1.

Závěr

Cílem této práce bylo ověřit možnost využití aplikace Google Trends při analýze finančních aktiv. V první kapitole jsem se zabýval současnými metodami a způsoby analýzy finančních aktiv. Například jsem zkoumal, jakým způsobem informace ovlivňují očekávání investorů ohledně budoucího vývoje aktiv skrze hodnoty zadávané analytiky do vzorců metod fundamentální analýzy.

Ve druhé kapitole jsem krátce ukázal možnosti, které nabízí aplikace Google Trends při porovnání dvou sousedních měst. Například se ukázalo, že město Poděbrady je v internetovém vyhledávači Google podstatně vyhledávanější v Ruské federaci, nejspíše kvůli zdejším lázním. Zatímco město Nymburk bylo vyhledávanější ve Spojených státech amerických.

Dále už jsem se zaměřil výhradně na možnost využití dat aplikace Google Trends při analýze finančních aktiv. Zabýval jsem se tím, jakými faktory lze popsat informace šířící se v internetovém prostředí. Úvahou jsem dospěl k následujícím faktorům: významnost informace (riziko informace, jak velký šok v hodnotě aktiva může informace způsobit), rozšířenost informace (zda je informace rozšířena mezi profesionálními investory nebo i mezi běžnou investorskou veřejností), rychlost šíření informace (jak rychle se informace šíří a jakými mediálními kanály) a výsledný směr či hodnota kurzu aktiva, ke které informace směřuje. Pro jednotlivé faktory jsem pak určil, zda by bylo možné je analyzovat pomocí dat získaných z aplikace Google Trends. Například rozšířenost informace by bylo možné sledovat, pokud bychom předpokládali, že objemy vyhledávání ve vyhledávači Google odpovídají zájmu retailových investorů.

Obsahem této kapitoly byla mimo jiné i rešerše již uskutečněných výzkumů. Na základě těchto výzkumů jsem volil nejvhodnější klíčová slova pro jednotlivá vybraná finanční aktiva. Například jsem tak pro akcii společnosti Apple zvolil klíčové slovo „Apple stock“, které by mělo dle provedených výzkumů nejlépe charakterizovat časovou řadu zachycující vyhledávání uživatelů ohledně vývoje hodnoty kurzu akcie Apple.

Poslední část této kapitoly se věnovala účelu vyhledávání na příkladě klíčového slova Apple. Úvahou jsem dospěl k následujícím účelům vyhledávání: zájem o informace o společnosti Apple, zájem o informace o produktech společnosti Apple, zájem o akcie společnosti Apple, zájem o Apple ve smyslu ovoce (účel nesouvisející s akcií společnosti Apple). Dopad jednotlivých účelů jsem graficky znázornil a zhodnotil. Při grafické analýze se projevila provázanost mezi jednotlivým účely. To bylo možné sledovat například při analýze vyhledávání klíčového slova souvisejícího s uvedením nového produktu na trh, kdy došlo k navýšení vyhledávanosti i dalších klíčových slov.

V rámci práce jsem si zavedl pojem popularita, který představuje časovou řadu relativně přepočteného objemu vyhledávání určitého klíčového slova ve vyhledávači Google. Popularita klíčového slova roste a klesá v návaznosti na události a informace objevující se v souvislosti s daným klíčovým slovem a s ním souvisejícím finančním aktivem.

Ve třetí kapitole jsem vybral čtyři finanční aktiva, respektive čtyři klíčová slova související s vybranými aktivy, a zkoumal jsem vliv popularity na hodnotu kurzu těchto aktiv. K analýze jsem vybral aktiva, která jsou populární i mezi neprofesionálními investory. Důvodem je očekávání určitého zpoždění v absorpci informací, jež by mohlo

dát prostor pro ex-ante predikci vývoje kurzu. Pokud bych zvolil aktiva obchodovaná především profesionálními investory, mohl by být trh při absorpci informací efektivnější. Výjimkou ve výběru byl měnový pár EUR USD, u kterého lze očekávat vyšší efektivitu trhu.

U analýzy absolutní hodnoty denních výnosů zahajovacích a uzavíracích kurzů i analýzy spreadu maximálních a minimálních kurzů se projevilo, že při zvýšeném vyhledávání souvisejících klíčových slov lze očekávat zvýšenou volatilitu kurzu odpovídajícího finančního aktiva. Přičemž nejvyšší denní změna výnosů vychází pro decilové rozpětí $Q_{0,9}$-Q_1 časových řad zachycujících vyhledávání souvisejících klíčových slov v období t až $t+2$. U analýzy maximálních a minimálních kurzů se ještě více projevily odchylky mezi decilovými rozpětími nad decil $Q_{0,8}$ a rozpětími pod decilem $Q_{0,8}$, kdy denní změna pro vyšší rozpětí byla v některých případech i několikanásobně vyšší. U kryptoměny Bitcoin tak například pro decilové rozpětí nacházejících se u dolní hranici hodnot vyhledávání vycházel medián absolutní hodnoty denního výnosu 0,67 %, zatímco pro decilové rozpětí nacházející se u horní hranice byl medián absolutní hodnoty denního výnosu 4,98 %. Tento jev se navíc projevoval i v budoucích hodnotách denních výnosů.

V další části této kapitoly jsem se zabýval tvorbou a testováním modelu GARCH. Pro každou z číselných řad zachycujících denní výnosy jednotlivých vybraných finančních aktiv jsem sestavil ekonometrický model GARCH (1,1). Jako měřítko k hodnocení modelů jsem si zvolil Akaikeho informační kritérium, které hodnotí samotný model a současně jeho složitost.

Nejprve jsem časové řady kurzů převedl na časové řady denních výnosů, tím jsem si zajistil, že budou časové řady stacionární a vhodné ke stochastickému modelování. Stacionaritu časových řad jsem si ověřil pomocí Dickey-Fullerova testu. Dále jsem časové řady otestoval na normalitu pravděpodobnostního rozdělení. U všech testovaných řad se projevilo jejich leptokurtické rozdělení. Například špičatost v případě Bitcoinu i několikanásobně převyšovala hodnotu normálního rozdělení.

Následně jsem vytvořil a porovnal několik variant modelů. Přičemž pro kryptoměnu Bitcoin a měnový pár EUR USD se ukázal jako nejlepší model s popularitou v podobě časové řady přepočtená popularita. U akcií společností Apple a Facebook se naproti tomu nejlépe osvědčil model s popularitou v podobě jednotkových impulsů generovaných při překročení předem stanovené úrovně popularity v příslušném období.

Vzhledem k tomu, že si modely s popularitou dle zvoleného Akaikeho kritéria vedly lépe, pokračoval jsem testováním reziduí těchto modelů. Test reziduí ukázal na některé nedostatky modelů. Přestože se šikmost i špičatost v některých modelech přiblížila normálnímu rozdělení, výsledky Jarque-Berova testu jasně zamítly hypotézu H0 o normálním rozdělení reziduí. Testováním pomocí ARCH LM testu jsem potvrdil nulovou hypotézu o homoskedasticitě a v modelech by se tak heteroskedasticita neměla objevovat. V posledním z prováděných testů na autokorelaci reziduí se však ukázala autokorelace modelů časové řady Bitcoinu a akcie Apple i Facebook.

Ačkoli testy reziduí ukazují na možnosti vylepšení modelů, obecně lze konstatovat, že popularita jako taková přispěla k vylepšení modelů volatility všech testovaných finančních aktiv. Ať už v podobě jednotkových impulsů nebo časové řady přepočtená

popularita. Parametry spojené s popularitou byly na zvolené hladině významnosti statisticky významné, a současně modely zahrnující popularitu byly dle zvoleného kritéria lépe hodnoceny než modely, kde popularita nebyla obsažena v žádné podobě.

Dále jsem v rámci testování možnosti využití dat z aplikace Google Trends při analýze finančních aktiv vytvořil obchodní strategii založenou na vlastních indikátorech Směr vývoje (MT) a Relativní síla popularity (RSP). Konstrukce obou indikátorů vychází z konstrukce indikátoru Indexu relativní síly (RSI). Zatímco indikátor RSI ve své konstrukci zohledňuje podíl kladných a záporných změn za zvolenou periodu, indikátor MT porovnává vývoj minimálních a maximálních kurzů za poslední dva týdny. Indikátor RSP pracuje místo s časovou řadou kurzů s časovou řadou přepočtená popularita a v konstrukci zohledňuje vývoj relativně přepočteného objemu vyhledávání za poslední dva týdny.

Pro obchodní strategii jsem definoval celkem 8 možných scénářů (vzorců chování), které byly v této kapitole testovány. Scénáře vycházely z indikátorů MT a RSP. Každý scénář tak představuje jinou kombinaci růstu či poklesu hodnoty kurzu aktiva a relativně přepočteného objemu vyhledávání. Pro každou kombinací jsem navíc otestoval strategii založenou na generování nákupních i prodejních signálů.

Při optimalizaci jsem využil evolučního algoritmu v nástroji Řešitel v programu Excel. Kritérium úspěšnosti bylo stanoveno pomocí celkem čtyř účelových funkcí, které zohledňovaly různé varianty těchto parametrů: celkový výnos (%), počet provedených obchodů, velikost nejvyššího propadu kapitálu (drawdown), statistickou významnost odlišnosti výnosů za jednotlivé obchody od nuly a šíři intervalů směrodatných pro podávání pokynů v rámci obou vytvořených indikátorů. Abych znevýhodnil strategie generující mnoho nákupních či prodejních pokynů, stanovil jsem za každý provedený obchod poplatek ve výši 0,2 % hodnoty aktiva.

Testovací období jsem si rozdělil do dvou částí, kdy na první části (přibližně dvouleté období) jsem provedl optimalizaci a na druhé části (přibližně tříleté období) backtest optimalizovaných parametrů.

Nejlépe v testování dopadly obchodní strategie založené na scénáři 1 a 2. Strategie založené na těchto scénářích obstály při testování na všech finančních aktivech a lze je tak považovat za celkem robustní.

Scénář 1 uvažuje situaci, kdy dojde k nákupu aktiva na základě minulého růstu objemu vyhledávání (popularity) a současného růstu hodnoty kurzu aktiva. Reálně si tuto situaci můžeme představit následovně: V důsledku nové významné informace dojde k navýšení hodnoty kurzu aktiva. Retailoví investoři však informaci absorbují se zpožděním a vzniká tak prostor pro otevření dlouhé pozice. Následně rostoucí trend pokračuje, dokud retailoví investoři zprávu zcela neabsorbují (ačkoli může být reakce na informaci přehnaná a časem dojít k částečné korekci směrem zpět k původní hodnotě).

Scénář 2 odpovídá vzorci chování, kdy s růstem objemu ve vyhledávání klíčových slov souvisejících s daným finančním aktivem a poklesem hodnoty kurzu daného finančního aktiva, můžeme očekávat budoucí růst hodnoty aktiva (provedeme nákup aktiva). Tento scénář by mohl odpovídat například reálné situaci, kdy se na trhu objeví nová negativní informace a neprofesionální investoři reagují přehnaným prodejem daného aktiva. Tato

informace (velikost reakce) však nemá fundamentální důvod, čehož si jsou vědomi profesionální investoři, kurz aktiva tak provede korekci směrem k původní hodnotě.

Dle provedených analýz a testů lze tvrdit, že data získaná z aplikace Google Trends je možné použít při analýze finančních aktiv. Data naleznou uplatnění nejen při výstavbě ekonometrických modelů, ale mohou být použita i při sestavování automatických obchodních systémů založených na indikátorech technické analýzy či jiných metodách. Uvažovat lze o použití těchto dat především v kratším časovém horizontu, neboť v delším časovém horizontu ztrácí informace význam, jsou trhem absorbovány. Právě proto se data získaná z aplikace Google Trends zdají být vhodná jako doplňková data některých technických indikátorů a obecně metod technické analýzy, která se zaměřuje na analýzu kurzů aktiv v krátkém období.

Seznam použité literatury a pramenů

Knižní zdroje

[1.] REJNUŠ, Oldřich. *Finanční trhy*. 4., aktualiz. a rozš. vyd. Praha: Grada, 2014. Partners. ISBN 978-80-247-3671-6.

[2.] VESELÁ, Jitka a Martin OLIVA. *Technická analýza na akciových, měnových a komoditních trzích*. 1. vydání. Praha: Ekopress, 2015. ISBN 978-80-87865-22-4.

[3.] CIPRA, Tomáš. *Finanční ekonometrie.* Praha: Ekopress, 2008. 538 s. ISBN 978-80-86929-43-9.

[4.] ARLT, Josef a Markéta ARLTOVÁ. *Ekonomické časové řady*. Praha: Professional Publishing, 2009. 290 s. ISBN 978-80-86946-85-6.

[5.] HANČLOVÁ, Jana. *Ekonometrické modelování: klasické přístupy s aplikacemi*. Praha: Professional Publishing, 2012. 214 s. ISBN 978-80-7431-088-1.

[6.] HUŠEK, Roman. *Aplikovaná ekonometrie: teorie a praxe*. Praha: Oeconomica, 2009. Vysokoškolská učebnice (Vysoká škola ekonomická v Praze). ISBN 978-80-245-1623-3.

[7.] LEDDER, Glenn. *Mathematics for the life sciences: calculus, modeling, probability, and dynamical systems*. New York: Springer, [2013]. Springer undergraduate texts in mathematics and technology. ISBN 978-146-1472-759.

[8.] WILDER jr, J. W. *New concepts in technical trading systems*. Greensboro, N.C.: Trend Research, 1978. ISBN 0894590278.

[9.] LO, A W. -- MACKINLAY, A C. A non-random walk down Wall Street. Princeton: Princeton University, 1999. ISBN 0-691-05774-5.

Elektronické zdroje

[I.] Google LLC. *Google Trends* [online]. [cit. 2019-01-19]. Dostupné z: https://trends.google.com

[II.] PREIS, Tobias, Helen Susannah MOAT a H. E. STANLEY. Quantifying Trading Behavior in Financial Markets Using Google Trends. *Scientific Reports (Nature Publisher Group)* [online]. 2013, vol. 3, s. 1684.

[III.] PERLIN, Marcelo S. et al. Can We Predict the Financial Markets Based on Google's Search Queries?. *Journal of Forecasting*. 2017, vol. 36, no. 4, s. 454-467. ISSN 0277-6693.

[IV.] Lim, Shawn & Stridsberg, Douglas. (2014). Feeling the Market's Pulse with Google Trends. International Federation of Technical Analysts' Journal. 8-14.

[V.] Patria.cz. *Databanka* [online]. [cit. 2019-01-20]. Dostupné z: https://www.patria.cz/akcie/vyzkum/databanka.html

[VI.] Bitcoin. *CoinMarketCap* [online]. [cit. 2019-04-27]. Dostupné z: https://coinmarketcap.com/currencies/bitcoin/

[VII.] *Applications of Data Mining in E-Business and Finance*, edited by C. Soares, et al., IOS Press, 2008. ProQuest Ebook Central, https://ebookcentral.proquest.com/lib/vsep/detail.action?docID=363227.

Seznam tabulek

Tabulka 1:Související dotazy pro klíčové slovo Nymburk, celosvětově, 2018, [I.] ... 16
Tabulka 2:Související dotazy pro klíčové slovo Poděbrady, celosvětově, 2018, [I.] ... 17
Tabulka 3: Výsledky obchodování pomocí strategie založené na objemech vyhledávání, [III.] ... 21
Tabulka 4: Přepočtená popularita klíčového slova Apple stock, vlastní tvorba ... 31
Tabulka 5: Decilová analýza změny zahajovací a uzavírací hodnoty, klíčové slovo Apple stock, vlastní tvorba ... 34
Tabulka 6: Decilová analýza zahajovací a uzavírací hodnoty, klíčové slovo Bitcoin, vlastní tvorba ... 34
Tabulka 7: Decilová analýza zahajovací a uzavírací hodnoty, klíčové slovo EUR USD, vlastní tvorba ... 35
Tabulka 8: Decilová analýza zahajovací a uzavírací hodnoty, klíčové slovo Facebook stock, vlastní tvorba ... 35
Tabulka 9: Decilová analýza maximální a minimální hodnoty, klíčové slovo Apple stock, vlastní tvorba ... 36
Tabulka 10: Decilová analýza maximální a minimální hodnoty, klíčové slovo Bitcoin, vlastní tvorba ... 36
Tabulka 11: Decilová analýza maximální a minimální hodnoty, klíčové slovo EUR USD, vlastní tvorba ... 37
Tabulka 12: Decilová analýza maximální a minimální hodnoty, klíčové slovo Facebook stock, vlastní tvorba ... 37
Tabulka 13: Stacionarita akcie Apple, Eviews ... 41
Tabulka 14: Stacionarita Bitcoin, Eviews ... 41
Tabulka 15: Stacionarita EUR USD, Eviews ... 41
Tabulka 16: Stacionarita akcie Facebook, Eviews ... 41
Tabulka 17: Model s konstantou akcie Apple, Eviews ... 43
Tabulka 18: Model s konstantou Bitcoin, Eviews ... 43
Tabulka 19: Model s konstantou EUR USD, Eviews ... 43
Tabulka 20: Model s konstantou akcie Facebook, Eviews ... 43
Tabulka 21: Model bez konstanty akcie Apple, Eviews ... 44
Tabulka 22: Model bez konstanty Bitcoin, Eviews ... 44
Tabulka 23: Model bez konstanty EUR USD, Eviews ... 44
Tabulka 24: Model bez konstanty akcie Facebook, Eviews ... 44
Tabulka 25: Model s popularitou akcie Apple, Eviews ... 45
Tabulka 26: Model s popularitou Bitcoin, Eviews ... 45
Tabulka 27: Model s popularitou EUR USD, Eviews ... 45
Tabulka 28: Model s popularitou akcie Facebook, Eviews ... 45
Tabulka 29: Model s impulsem akcie Apple, Eviews ... 46
Tabulka 30: Model s impulsem Bitcoin, Eviews ... 46
Tabulka 31: Model s impulsem EUR USD, Eviews ... 46
Tabulka 32: Model s impulsem akcie Facebook, Eviews ... 46
Tabulka 33: Hodnocení modelů dle AIC, vlastní tvorba ... 47
Tabulka 34: ARCH LM test reziduí, model s impulsem, akcie Apple, Eviews ... 49
Tabulka 35: ARCH LM test reziduí, model s popularitou, Bitcoin, Eviews ... 49
Tabulka 36: ARCH LM test reziduí, model s popularitou, EUR USD, Eviews ... 49
Tabulka 37: ARCH LM test reziduí, model s impulsem, akcie Facebook, Eviews ... 49
Tabulka 38: Test autokorelace reziduí, model s impulsem, akcie Apple, Eviews ... 50
Tabulka 39: Test autokorelace reziduí, model s popularitou, Bitcoin, Eviews ... 50
Tabulka 40: Test autokorelace reziduí, model s popularitou, EUR USD, Eviews ... 50
Tabulka 41: ARCH LM test reziduí, model s impulsem, akcie Facebook, Eviews ... 50
Tabulka 42: Scénáře testované obchodní strategie, vlastní tvorba ... 55
Tabulka 43: Přehled výsledků za jednotlivé účelové funkce, vlastní tvorba ... 57
Tabulka 44: Výsledky optimalizace obchodní strategie, akcie Apple, vlastní tvorba ... 58
Tabulka 45: Výsledky backtestingu obchodní strategie, akcie Apple, vlastní tvorba ... 58
Tabulka 46: Výsledky optimalizace obchodní strategie, Bitcoin, vlastní tvorba ... 59
Tabulka 47: Výsledky backtestingu obchodní strategie, Bitcoin, vlastní tvorba ... 59
Tabulka 48: Výsledky optimalizace obchodní strategie, EUR USD, vlastní tvorba ... 60
Tabulka 49: Výsledky backtestingu obchodní strategie, EUR USD, vlastní tvorba ... 60
Tabulka 50: Výsledky optimalizace obchodní strategie, akcie Facebook, vlastní tvorba ... 61
Tabulka 51: Výsledky backtestingu obchodní strategie, akcie Facebook, vlastní tvorba ... 61
Tabulka 52: Úspěšnost scénářů při backtestingu, vlastní zdroj ... 62
Tabulka 53: Výnos dosažený za úspěšné strategie, vlastní tvorba ... 63

Seznam grafů

Graf 1: Zájem v průběhu času Nymburk vs Poděbrady, celosvětově, 2018, [I.] ... 14
Graf 2: Popularita klíčového slova EUR USD, 1. 6. 2016 až 31. 7. 2016, na území USA, [I.] ... 18
Graf 3: Objemy vyhledávání a pohyby na akciovém trhu, [II.] ... 20
Graf 4: Kumulovaný výsledek obchodování při použití strategie založené na datech z aplikace Google Trends, [II.] 20
Graf 5: ADX a SVI, SBUX, klíčové slovo SBUX, 2012 až 2014, [IV.] ... 22
Graf 6: Cenové pohyby a SVI, BP, klíčové slovo BP, 2009 až 2011, [IV.] ... 23
Graf 7: Oscilátory a SVI, LYG, klíčové slovo LYG, 2011 až 2012, [IV.] ... 24
Graf 8: Bollingerovy pásy a SVI, HPQ, klíčové slovo HPQ, 2012 až 2013, [IV.] ... 25
Graf 9: Vývoj akcie Apple (USD), (1.4. až 30. 11. 2018), na území USA, [V.] ... 26
Graf 10: Popularita klíčového slova Apple (ve smyslu společnosti), (1.4. až 30. 11. 2018), na území USA, [I.] ... 27
Graf 11: Popularita klíčového slova Apple TV, (1.4. až 30. 11. 2018), na území USA, [I.] ... 27
Graf 12: Popularita klíčového slova Apple XS, (1.4. až 30. 11. 2018), na území USA, [I.] ... 28
Graf 13: Popularita klíčového slova Apple stock, (1.4. až 30. 11. 2018), na území USA, [I.] ... 28
Graf 14: Popularita klíčového slova Apple fruit, (1.4. až 30. 11. 2018), na území USA, [I.] ... 29
Graf 15: Popularita klíčového slova Apple stock, vlastní tvorba ... 32
Graf 16: Popularita klíčového slova Bitcoin, vlastní tvorba ... 32
Graf 17: Popularita klíčového slova EUR USD, vlastní tvorba ... 33
Graf 18: Popularita klíčového slova Facebook stock, vlastní tvorba ... 33
Graf 19: Výnosy akcie Apple, Eviews ... 39
Graf 20: Výnosy Bitcoin, Eviews ... 39
Graf 21: Výnosy akcie Facebook, Eviews ... 39
Graf 22: Výnosy EUR USD, Eviews ... 39
Graf 23: Normalita akcie Apple, Eviews ... 40
Graf 24: Normalita Bitcoin, Eviews ... 40
Graf 25: Normalita EUR USD, Eviews ... 40
Graf 26: Normalita akcie Facebook, Eviews ... 40
Graf 27: Normalita reziduí, model s impulsem, akcie Apple, Eviews ... 48
Graf 28: Normalita reziduí, model s popularitou, Bitcoin, Eviews ... 48
Graf 29: Normalita reziduí, model s popularitou, EUR USD, Eviews ... 48
Graf 30: Normalita reziduí, model s impulsem, akcie Facebook, Eviews ... 48
Graf 31: Modelace volatility, akcie Apple, rok 2014, vlastní tvorba ... 51
Graf 32: Modelace volatility, Bitcoin, rok 2014, vlastní tvorba ... 51
Graf 33: Modelace volatility, měnový pár EUR USD, rok 2014, vlastní tvorba ... 52
Graf 34: Modelace volatility, akcie Facebook, rok 2014, vlastní tvorba ... 52
Graf 35: Vývoj účtu strategie dle scénáře 1, akcie Apple, opt. dle účelové funkce 4, vlastní tvorba ... 63
Graf 36: Vývoj účtu strategie dle scénáře 1, Bitcoin, opt. dle účelové funkce 4, vlastní tvorba ... 64
Graf 37: Vývoj účtu strategie dle scénáře 1, EUR USD, opt. dle účelové funkce 4, vlastní tvorba ... 64
Graf 38: Vývoj účtu strategie dle scénáře 1, akcie Facebook, opt. dle účelové funkce 4, vlastní tvorba ... 64
Graf 39: Vývoj účtu strategie dle scénáře 2, akcie Apple, opt. dle účelové funkce 4, vlastní tvorba ... 65
Graf 40: Vývoj účtu strategie dle scénáře 2, Bitcoin, opt. dle účelové funkce 4, vlastní tvorba ... 65
Graf 41: Vývoj účtu strategie dle scénáře 2, EUR USD, opt. dle účelové funkce 4, vlastní tvorba ... 65
Graf 42: Vývoj účtu strategie dle scénáře 2, akcie Facebook, opt. dle účelové funkce 4, vlastní tvorba ... 66

Seznam obrázků

Obrázek 1: Dělení trendu dle směru vývoje (rostoucí, postranní, klesající), [1, s. 314] ... 11
Obrázek 2: Porovnání podle regionu, Nymburk vs Poděbrady, celosvětově, 2018, [I.] ... 15
Obrázek 3: Zájem dle regionu, Nymburk vs Poděbrady, poměr vyhledávání, Rusko a USA, 2018, [I.] ... 15
Obrázek 4: Zájem o město Nymburk, celosvětově, 2018, [I.] ... 16
Obrázek 5: Zájem o město Poděbrady, celosvětově, 2018, [I.] ... 17
Obrázek 6: Knihy použité pro výběr klíčových slov a výsledky četnosti výskytu jednotlivých klíčových slov, [III.]. 21

Seznam příloh

Příloha A - DVD

Soubor A1_data_google_trends_Apple
Soubor A2_data_google_trends_Bitcoin
Soubor A3_data_google_trends_EURUSD
Soubor A4_data_google_trends_Facebook
Soubor A5_Výsledky_strategie

Přílohy B

Příloha B1: Přepočtená popularita klíčového slova Bitcoin, vlastní tvorba 74
Příloha B2: Přepočtená popularita klíčového slova EUR USD, vlastní tvorba 74
Příloha B3: Přepočtená popularita klíčového slova Facebook stock, vlastní tvorba 75

Období	Počáteční datum	Koncové datum	MaxA	MaxB	Koeficient
1	01.11.2013	30.06.2014	x	x	1
2	01.05.2014	31.12.2014	20,00	46,00	0,43
3	01.11.2014	30.06.2015	100,00	100,00	0,43
4	01.05.2015	31.12.2015	73,00	100,00	0,32
5	01.11.2015	30.06.2016	89,00	86,00	0,33
6	01.05.2016	31.12.2016	100,00	100,00	0,33
7	01.11.2016	30.06.2017	72,00	18,00	1,31
8	01.05.2017	31.12.2017	100,00	15,00	8,76
9	01.11.2017	30.06.2018	100,00	100,00	8,76
10	01.05.2018	31.12.2018	9,00	84,00	0,94

Příloha B1: Přepočtená popularita klíčového slova Bitcoin, vlastní tvorba

Období	Počáteční datum	Koncové datum	MaxA	MaxB	Koeficient
1	01.11.2013	30.06.2014	x	x	1
2	01.05.2014	31.12.2014	99,00	100,00	0,99
3	01.11.2014	30.06.2015	96,00	62,00	1,53
4	01.05.2015	31.12.2015	95,00	90,00	1,62
5	01.11.2015	30.06.2016	60,00	17,00	5,71
6	01.05.2016	31.12.2016	100,00	100,00	5,71
7	01.11.2016	30.06.2017	25,00	100,00	1,43
8	01.05.2017	31.12.2017	79,00	89,00	1,27
9	01.11.2017	30.06.2018	87,00	86,00	1,28
10	01.05.2018	31.12.2018	70,00	100,00	0,90

Příloha B2: Přepočtená popularita klíčového slova EUR USD, vlastní tvorba

Období	Počáteční datum	Koncové datum	MaxA	MaxB	Koeficient
1	01.11.2013	30.06.2014	x	x	1
2	01.05.2014	31.12.2014	46,00	52,00	0,88
3	01.11.2014	30.06.2015	40,00	65,00	0,54
4	01.05.2015	31.12.2015	100,00	24,00	2,27
5	01.11.2015	30.06.2016	100,00	100,00	2,27
6	01.05.2016	31.12.2016	44,00	73,00	1,37
7	01.11.2016	30.06.2017	83,00	97,00	1,17
8	01.05.2017	31.12.2017	85,00	64,00	1,55
9	01.11.2017	30.06.2018	76,00	18,00	6,56
10	01.05.2018	31.12.2018	15,00	5,00	19,68

Příloha B3: Přepočtená popularita klíčového slova Facebook stock, vlastní tvorba