VŠB TECHNICKÁ UNIVERZITA OSTRAVA
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Časové řady, cyklické chování a technická analýza pro automatizované obchodování

Time Series, Cyclical Behavior and Technical Analysis for Automated Trading

Bc. Radek Novák

Diplomová práce

Vedoucí práce: Ing. Radoslav Fasuga, Ph.D.

Ostrava, 2023

VŠB TECHNICKÁ UNIVERZITA OSTRAVA | FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Č.j.VSB/22/078952
vsboee22026054

Zadání diplomové práce

Student: **Bc. Radek Novák**

Studijní program: N2647 Informační a komunikační technologie

Studijní obor: 2612T025 Informatika a výpočetní technika

Téma: Časové řady, cyklické chování a technická analýza pro automatizované obchodování
Time Series, Cyclical Behavior and Technical Analysis for Automated Trading

Jazyk vypracování: čeština

Zásady pro vypracování:

Cílem této práce je implementovat statistickou teorii časových řad, trendy, cyklické, sezónní a náhodné složky, klouzavých průměrů a dalších technik, které by pomohly při automatizaci procesu nakupování a prodeje na burzovních a kryptoměnových trzích. Nástroj bude pracovat s dostupnými historickými i průběžně aktualizovanými novými daty o zrealizovaných obchodech. Cílem je minimalizovat ztráty a predikovat budoucí možné vývoje trhu s možností automatizovaného obchodování.
1. Student provede analýzu dostupných nástrojů, pro práci s časovými řadami a jejich reálné využití pro obchody na burze kryptoměn (Coinbase Pro nebo Binance) a definuje požadavky na univerzální systém, který by umožnil automatizovaný nákup a prodej kryptoměn na základě uživatelem definovaných strategií.
2. Student se seznámí s API, které poskytují světové burzy (Binance, Coinbase Pro) a na jejich základě vystaví infrastrukturu pro práci s časovými řadami v rámci rozsáhlé kolekce historických dat zrealizovaných obchodů.
3. Student implementuje různé algoritmy pro hodnocení časových řad, zejména pak jejich cyklické a trendové složky, aby byly jeho výsledky reálně ověřitelné nad dostupnými daty.
4. Na základě vybraných technologií a dostupných API student provede analýzu, návrh a implementaci vlastního řešení, na jehož základě se definují automatizovaná pravidla pro nákup a prodej kryptoměn.
5. Výstupem práce bude metodická příručka zabývající se problematikou použití časových řad k automatizovanému nákupu kryptoměn na světových burzách.
6. Student se bude podílet na společném týmovém projektu analýzy, návrhu a implementace nástroje pro automatizované obchodování na kryptoměnové burze.

Seznam doporučené odborné literatury:

[1] Afzal, A., & Asif, A. (2019). Cryptocurrencies, Blockchain and Regulation: A Review. The Lahore Journal of Economics, 24(1), 103–130.
[2] Flori, A. (2019). Cryptocurrencies In Finance: Review and Applications. International Journal of Theoretical and Applied Finance, 22(5), 1–22.
[3] Duque, J. J. (2020). State Involvement in Cryptocurrencies. A Potential World Money? The Japanese Political Economy, 46(1), 65–82.
[4] Layered Money - From Gold and Dollars to Bitcoin and Central Bank Digital Currencies - Nik Bhatia
[5] Bitcoin and Cryptocurrency Trading & Investing Must Have Wallets, Trading Tools, Exchanges, Trading Bots, Candlestick Patterns and Trading Psychology | 4 Books In 1 - Boris Weiser

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Radoslav Fasuga, Ph.D.**

Datum zadání: 01.09.2022

Datum odevzdání: 30.04.2023

Garant studijního oboru: prof. RNDr. Václav Snášel, CSc.

V IS EDISON zadáno: 07.11.2022 11:59:22

Abstrakt

Tato diplomová práce se zabývá analýzou časových řad a využití jejich výsledků pro automatické obchodování na burze kryptoměn. V práci je popsána teorie časových řad včetně metod a nástrojů pro analýzu časových řad. Práce obsahuje úvod do světa kryptoměn a zásady obchodování na burze. Praktická část se zabývá infrastrukturou pro práci s daty k automatickému obchodování s kryptoměnami. Na ni navazuje analýza časových řad, která poskytuje systému predikce vývoje cen. Systém pro automatické obchodování byl implementován v rámci týmového projektu. Pro implementaci analýzy byl využit primárně programovací jazyk Python.

Klíčová slova

časové řady; kryptoměny; technická analýza; analýza časových řad; predikce časové řady; automatické obchodování

Abstract

This thesis deals with the analysis of time series and the use of their results for automated cryptocurrency trading. The thesis describes time series theory including methods and tools for time series analysis. The thesis includes an introduction to the world of cryptocurrencies and the principles of exchange trading. The practical part deals with the infrastructure for working with data for automated trading, which is followed by time series analysis, which provides a price prediction to the system. The system for automatic trading was implemented as part of a team project. The Python programming language was used to implement the analysis.

Keywords

time series; cryptocurrencies; technical analysis; time series analysis; time series prediction; automated trading

Obsah

Seznam použitých symbolů a zkratek **6**

Seznam obrázků **7**

Seznam tabulek **8**

Seznam výpisů zdrojového kódu **9**

1 Úvod **10**

2 Teorie časových řad **12**
2.1 Úvod do teorie časových řad 12
2.2 Metody analýzy časových řad 13
2.3 Nástroje pro zpracování časových řad 19

3 Kryptoměny a obchodování s kryptoměnami **21**
3.1 Úvod do kryptoměn 21
3.2 Obchodování s kryptoměnami 25

4 Infrastruktura pro automatické obchodování **34**
4.1 Volba infrastruktury 34
4.2 Automatické získávání dat 35
4.3 Uložení historických dat 40

5 Realizace algoritmů pro zpracování časových řad **43**
5.1 Implementace algoritmů 43
5.2 Testování výsledků 64

6 Závěr **72**

Literatura **74**

Seznam použitých zkratek a symbolů

API	–	Application Programming Interface
ARCH	–	Autoregressive Conditional Heteroskedasticity
ARIMA	–	Autoregressive Integrated Moving Average
CBCC	–	Central bank cryptocurrencies
CRUD	–	Create, Read, Update, Delete
CSV	–	Comma-separated values
DPH	–	Daň z přidané hodnoty
DTL	–	Distributed Ledger Technology
GARCH	–	Generalized Autoregressive Conditional Heteroskedasticity
HTTP	–	Hypertext Transfer Protocol
IP	–	Internet Protocol
JSON	–	JavaScript Object Notation
MACD	–	Moving Average Convergence/Divergence
NoSQL	–	Not only structured query language
REST	–	Representational state transfer
RSI	–	Relative Strength Index
SDEU	–	Soudní dvůr Evropské unie
SHA	–	Secure Hash Algorithm
SL	–	Stop loss
STL	–	Seasonal and Trend decomposition using Loess
STOCH	–	Stochastic oscillator
SQL	–	Structured query language
SWIFT	–	The Society for Worldwide Interbank Financial Telecommunication
TP	–	Take profit
URL	–	Uniform Resource Locator
XML	–	Extensible Markup Language

Seznam obrázků

2.1 Dekompozice časové řady se sezonní složkou 15
2.2 Dekompozice časové řady ceny kryptoměny Bitcoin 16
2.3 Klouzavý průměr $q = 15$ a $q = 40$ pro časovou řadu ceny kryptoměny Bitcoin 17
2.4 Částečná autokorelační funkce 18

3.1 Půlení zisku těžby kryptoměny Bitcoin [38] 24
3.2 Ukázka obchodování s kryptoměnou Bitcoin u XTB [41] 27
3.3 Svíčkový graf pohybu ceny kryptoměny Bitcoin u XTB [41] 29
3.4 Open-high-low-close graf pohybu ceny kryptoměny Bitcoin u XTB [41] 29
3.5 Čárový graf pohybu ceny kryptoměny Bitcoin u XTB [41] 30

4.1 ERD využívaných tabulek v databázi 41

5.1 Fourierova transformace 48
5.2 Detekovaná sezónní složka pomocí Fourierovy transformace 49
5.3 Detekce anomálií na náhodné složce časové řady 51
5.4 Zobrazení anomálií na původní časové řadě 51
5.5 Časová řada po odstranění anomálií 51
5.6 Vykreslení částečné autokorelace 53
5.7 Diagram aktivit pro určení podobnosti párů korelačním koeficientem 54
5.8 Predikce pomocí modelu ARIMA 60
5.9 Predikce volatility pomocí modelu ARCH 61
5.10 Predikce pomocí modelu Prophet 62
5.11 Diagram aktivit pro určení obchodních doporučení za pomocí predikce 63
5.12 Provedené obchody s využitím predikce 70
5.13 Provedené obchody s využitím ukazatelů 70
5.14 Provedené obchody s využitím obrácených ukazatelů 70
5.15 Provedené obchody s využitím predikce a obrácených ukazatelů 71

Seznam tabulek

5.1 Výsledky ukazatelů pro detekci sezónní složky 49
5.2 Rozdíl ve výpočtu algoritmů lokálních extrémů 57
5.3 Porovnání algoritmů na výpočet lokálních extrémů 58
5.4 Výstup predikce modelu ARCH 60
5.5 Výsledky algoritmů pro období 8. 12. 2022 - 11. 4. 2023 68
5.6 Výsledky algoritmů pro 365 dní do 1. 4. 2023 69

Seznam výpisů zdrojového kódu

4.1 Příklad jednoduchého volání API s autentifikací [67] 37
4.2 Příklad parametrů při zadávání obchodu do požadavku na API[67] 39
5.1 Připojení k databázi v jazyce Python 44
5.2 Dotaz na denní svíčky v tabulce s minutovými daty 45
5.3 Kontrola sezónnosti na bázi lokálních extrémů 46
5.4 Kontrola na bázi Fourierovy transformace 47
5.5 Kontrola významnosti sezónní složky 48
5.6 Detekce anomálií 50
5.7 Implementace autokorelace a částečné autokorelace 52
5.8 Hledání podobných párů 55
5.9 Hledání lokálních extrémů 56
5.10 Predikce pomocí modelu ARIMA 59
5.11 Predikce volatility pomocí modelu ARCH 61
5.12 Predikce pomocí modelu Prophet 62
5.13 Výpočet finálního doporučení obchodu 64
5.14 Výpočet doporučení obchodu z prediktivních modelů 66

Kapitola 1

Úvod

V dnešní době je automatizované obchodování stále populárnější a mnoho investorů využívá algoritmické obchodní strategie, které se spoléhají na analýzu historických dat a detekci vzorů v časových řadách. Tato diplomová práce se zabývá analýzou časových řad a predikcí vývoje časové řady v blízké budoucnosti. Výsledky analýzy a predikce časových řad budou sloužit k doporučení perspektivních obchodů pro systém, který řeší automatické obchodování s kryptoměnami. Tento systém byl implementován jako týmový projekt, kterého je tato práce součástí.

První pasáž teoretické části práce se zabývá teorií časových řad, kde jsou popsány základní parametry časových řad a je zde uvedeno, jak jsou časové řady propojeny s obchodováním na kryptoměnových burzách. Dále jsou rozebrány metody pro analýzu a predikci časových řad, kde je nejvíce prostoru věnováno dekompozici časových řad, od které se vyvíjí většina ostatních analytických a prediktivních metod. Popsána je zde také metoda klouzavých průměrů, autokorelace, spektrální analýza a Box-Jenkinsova metodologie, která je hlavní metodou sloužící k předpovědi časových řad. Na konci kapitoly jsou shrnuty nejznámější nástroje, které slouží ke zpracování a zobrazení dat časových řad.

Druhá teoretická část se věnuje kryptoměnám a jejich obchodování na burze. Začátek kapitoly uvádí do světa kryptoměn, je zde zahrnuta jejich historie a popsána těžba. Následuje průřez teorií analýzy trhu a jsou zmíněny různé metody a strategie obchodování. Dále se kapitola věnuje technickým ukazatelům, které slouží jako hlavní indikátory pro investory. Tuto část práce doplňuje popis možností zobrazení vývoje cen na burze. Následně je shrnuta potřebná legislativa, která se týká obchodování s kryptoměnami. Na závěr kapitoly jsou uvedeny nejznámější kryptoměnové burzy.

Praktická část diplomové práce je rozdělena na dvě kapitoly. První kapitola popisuje volbu infrastruktury pro systém automatického obchodování na kryptoměnové burze. V kapitole je dále obsažen soupis možností automatického získávání dat a jsou popsány možnosti automatického obchodování. V poslední sekci této kapitoly jsou rozebrány možnosti, jakými lze data uchovávat a je popsán datový model, se kterým se při implementaci pracuje.

Poslední kapitola práce je věnována samotné analýze dat cen kryptoměn na burze ve formě časových řad. Kapitola tvoří metodickou příručku zabývající se problematikou použití časových řad k automatizovanému nákupu kryptoměn na světových burzách. Je zde popsána implementace algoritmů zmíněných v teoretické části práce. V závěru práce jsou otestována výsledná data formou simulace reálné burzy. V této části je také porovnána výkonnost implementovaných algoritmů s jinými obchodními strategiemi.

Kapitola 2

Teorie časových řad

V první kapitole této diplomové práce je stručně popsáno, co jsou to časové řady, jakými způsoby se s časovými řadami pracuje a jaké jsou dostupné nástroje, které se využívají pro jejich zpracování. Tyto teoretické základy jsou nutné pro porozumění výsledné analýzy a implementace.

2.1 Úvod do teorie časových řad

Pojmem časová řada se vyjadřuje chronologicky uspořádaná posloupnost hodnot ukazatele nebo ukazatelů, které jsou měřeny v určitých časových intervalech. Díky naměřeným statistickým ukazatelům lze zkoumat chování a dynamiku jevů v čase. Časové intervaly měření mohou být rovnoměrné, neboli ekvidistantní, a nerovnoměrné, neboli neekvidistantní. Tato diplomová práce se zabývá časovými intervaly ekvidistantními. Časové intervaly jsou měřeny v pravidelných rozestupech a můžeme je zapsat následujícím způsobem:

$$y_1, y_2, ..., y_n \;\; neboli \;\; y_t, t = 1, ..., n \tag{2.1}$$

kde y značí analyzovaný ukazatel, t ukazuje na časovou proměnnou a celkový počet měření je značen písmenem n. Obchodování s kryptoměnami využívá většinou denní, hodinová nebo minutová měření (na rozdíl od burzy s cennými papíry se s kryptoměnami obchoduje i o víkendech, takže se počítá se spojitou ekvidistantní časovou řadou), která využívají následující statistické ukazatele:

1. low - nejnižší hodnota kryptoměny během měřeného časového období
2. high - nejvyšší hodnota kryptoměny během měřeného časového období
3. open - hodnota kryptoměny na počátku měřeného časového období
4. close - hodnota kryptoměny na konci měřeného časového období
5. volume - suma hodnot všech obchodů v měřeném časovém období

6. počet obchodů, které proběhly za měřené časové období

Tyto statistické ukazatele jsou dále využívány v analýze časových řad, kdy každý z těchto ukazatelů vykazuje mírně lišící se výsledky a pro přesnost analýzy je nutno posuzovat hodnoty většiny ukazatelů.

Analýza časových řad se zabývá problematikou konstrukce modelu, který umožní porozumět příčinám a mechanikám, které ovlivňují chování a dynamiku změn ukazatelů v čase. Dobře zkonstruovaný model na základě analyzovaných dat sestrojí také predikci, jakým směrem a s jakou dynamikou se bude hodnota ukazatele vyvíjet v blízké budoucnosti. Neexistuje ovšem žádný model, který by byl natolik přesný, že by byly všechny predikace daného modelu pravdivé. Existuje vždy vysoké riziko, že daná evaluace modelu je nepřesná.

S časovými řadami se pojí téměř veškeré obory, kdy data časových řad jsou využívaná například v následujících odvětvích:

- ekonomie - vývoj celkového stavu ekonomiky, data o nezaměstnanosti populace, hodnoty akciových trhů atd.
- medicína - EKG, epidemická data apod.
- meteorologie - vývoj kvality ovzduší, proudění vzduchu atd.
- gastronomie - trendy ve stravování, návštěvnosti apod.

Díky rozsáhlému využití se problematice časových řad klade velký důraz za účelem dosažení úspěchů skrze veškeré obory. [1, 2, 3, 4]

2.2 Metody analýzy časových řad

Existuje mnoho faktorů, které ovlivňují volbu metod pro analýzu časové řady. Důležitým faktorem je typ časové řady, který se zakládá na datech a způsobu, kterým byla data získávána. Další důležitý faktor je samotný účel analýzy, který napoví i předpokládaný výstup analýzy a čeho by měl statistik, který časovou řadu analyzuje, dosáhnout. Je třeba také zmínit infrastrukturu, která je pro analýzu k dispozici (způsob uložení dat, dostupný software a hardware). Jinak bude vypadat přístup k malému množství tabulkových dat na laptopu a jinak k rozsáhlým databázím, které budou zpracovávány superpočítači jako například modely předpovídající počasí.

Dále budou popořadě rozebrány některé základní metody analýzy časových řad. Mezi tyto metody patří:

- Dekompozice časové řady
- Spektrální analýza
- Autokorelace a částečná autokorelace

- Metoda klouzavých průměrů
- Box-Jenkinsova metodologie

2.2.1 Dekompozice časové řady

Dekompozice časové řady je metoda, při které se časová řada rozloží na trendovou, sezónní, cyklickou a náhodnou složku. Metodu dekompozice časové řady je možné použít pouze v případě, že časovou řadu lze rozložit na systematické složky. Řada ovšem nemusí obsahovat všechny výše uvedené systematické složky. Nyní budou postupně rozebrány jednotlivé složky, bude vysvětlena stacionarita časové řady a budou ukázány příklady dekompozice na dvou příkladech časových řad. [2, 5]

2.2.1.1 Trendová složka

Za trendovou složku se považuje tendence či směr vývoje ukazatelů za delší časové období. Existence trendové složky je závislá na poklesu nebo růstu za měřený časový úsek. V případě neexistence trendové složky nebo v případě existence trendové složky s nulovým trendem je časová řada označována jako časová řada stacionární. Trend není znázorňován pouze lineárně, v případě častějších nesezonních změn je zobrazován často nelineárně. [2, 5]

2.2.1.2 Sezónní složka

Sezónní složka ukazuje odchylku od trendu, která se objevuje v pravidelných periodách o známé frekvenci. Tato frekvence je však menší, než velikost sledovaného období. Typická sezónní odchylka od trendu se objevuje na měsíční, kvartální nebo i denní bázi. Například vytížení ranního autobusu (typická školní nebo pracovní linka) o pracovních dnech a o víkendu, kde o víkendu bude tato vytíženost pravidelně nižší, než přes pracovní/školní dny. [2, 5]

2.2.1.3 Cyklická složka

Cyklická složka vyjadřuje fluktuaci okolo trendu, která se v průběhu času opakuje. Oproti sezónní složce nemá jasnou frekvenci periody. Frekvence cyklické složky se mění v čase v závislosti na externích faktorech a není předem známá a bývá větší, než velikost sledovaného období. Cyklická složka se nejčastěji objevuje v meteorologických řadách, či ekonomii (příkladem je globální ekonomická krize). [2, 5]

2.2.1.4 Náhodná složka

Náhodná složka, známá také jako reziduální, zbytková, nesystematická či stochastická, zbývá po odečtení trendové, sezónní, a cyklické složky časové řady. Jedná se o náhodné fluktuace okolo trendu, které mají nesystematický charakter a nedají se předpovídat. Náhodná složka je často modelována jako bílý šum nebo stochastický proces. [2, 5]

2.2.1.5 Stacionarita

Jak již bylo zmíněno v popise trendové složky, stacionarita vzniká odstraněním právě trendové složky z časové řady. Vznikne tedy časová řada s konstantním průměrem a konstantní variabilitou. Transformace časové řady na řadu stacionární je nutný krok téměř k většině dalších analýz časových řad, jako je například spektrální analýza, autokorelační analýza, nebo modelování pomocí ARIMA či SARIMA modelů. V podstatě se jedná o vlastnost, kdy pravděpodobnostní charakteristiky daného procesu nebo signálu zůstávají stejné v čase, tedy jsou invariantní vzhledem k posunu v čase. V praxi se stacionarita využívá například při analýze finančních dat, v meteorologii, v analýze signálů v elektronice nebo v analýze biologických dat. [3, 4]

2.2.1.6 Zobrazení dekompozice časových řad

Na obrázku 2.1 je nahoře znázorněna originální časová řada, která znázorňuje počet cestujících v letecké dopravě, pod ní je vyobrazena téměř lineární trendová složka. Jejich rozdílem je stacionární časová řada, která se dále využívá k mnohým analýzám a složí jako vstup do analytických modelů. Dále na obrázku vidíme sezónní složku a náhodnou neboli reziduální složku. U této časové řady lze na první pohled vypozorovat pravidelně rostoucí trend s významnými sezónními výkyvy. Náhodná složka této časové řady má malou variabilitu. Téměř lineární trend a silná sezónní složka ukazují, že časová řada cestujících v letecké dopravě je i lehce predikovatelná. V případě, že by časová řada obsahovala i novější data (od roku 2020 dále), bylo by možno pozorovat vysoké výkyvy náhodné složky, které by byly způsobeny výpadky letecké dopravy za celosvětové pandemie covid-19.

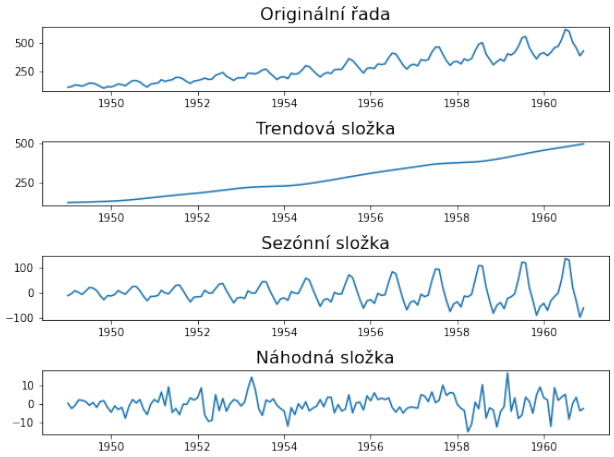

Obrázek 2.1: Dekompozice časové řady se sezonní složkou

Ne všechny časové řady disponují takto ideální dekompozicí a analýza systematických složek není přímočará. Příkladem časové řady, kde je velice obtížné analyzovat systematické složky, jsou finanční data t.j. akciová nebo kryptoměnová burza. Dekompozice obchodovaného páru Bitcoin k euru je zobrazena na obrázku 2.2. Z obrázku je vidět nejasná a nelineární trendová složka, nízká sezónní

složka a náhodná složka s vysokou variabilitou. Tyto parametry znázorňují obtížně predikovatelnou či nepredikovatelnou časovou řadu. Obecně metody analýzy časových řad na časové řadě podobné této nedosahují pozitivních výsledků.

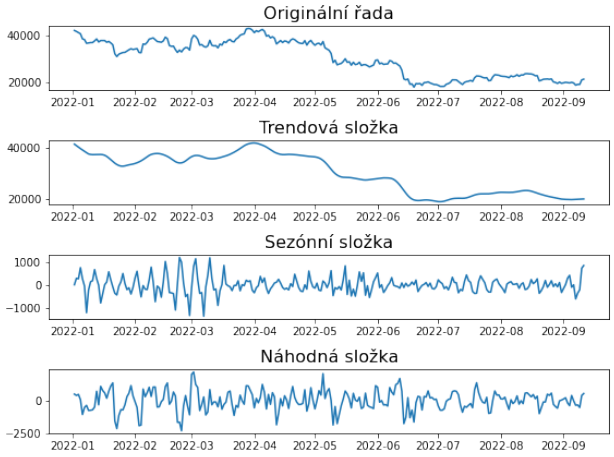

Obrázek 2.2: Dekompozice časové řady ceny kryptoměny Bitcoin

2.2.2 Spektrální analýza

Metoda spektrální analýzy je založena na výstupu sezónní složky časové řady. V případě, že je sezónní složka komplexní, je třeba využít této metody, která pomůže odhalit například více periodických složek v jedné časové řadě. Spektrální analýza časové řady je založena na zkoumání sinusových a kosinusových křivek v rámci časové řady. Pracuje se s různou frekvencí a amplitudou těchto křivek pro vytvoření spektra. Spektrum vyjadřuje, jakým způsobem se signál skládá z jednotlivých frekvencí, které se v něm vyskytují, a umožňuje identifikovat přítomnost a intenzitu různých frekvencí v signálu. [1, 6]

2.2.3 Klouzavý průměr

Velice často využívanou a společností oblíbenou metodou pro analýzu časových řad je metoda klouzavých průměrů. Tato metoda je založena na rozdělení časové řady na kratší časové úseky o délce q, kde se pro všechny hodnoty původní časové řady vypočítá průměr z q hodnot, které jí přímo předcházejí. Výhodou metody klouzavého průměru je, že umožňuje snadno vyhladit šum a získat jen významné informace. Využívá se nejen v ekonomické analýze, ale také v meteorologii, kde se používá k vyhlazení sezónních výkyvů v teplotách, a dokonce i v audio technice, kde se používá k vyhlazení nežádoucího šumu v nahrávkách. Existuje mnoho variant klouzavých průměrů, mezi které patří například vážený klouzavý průměr, exponenciálně vážený klouzavý průměr či také klouzavý medián.

Na obrázku 2.3 je vyobrazena časová řada ceny obchodního páru Bitcoin k Euru. Na této řadě jsou zobrazeny dvě řady klouzavých průměrů a to o délce 15 a 40 hodnot. Podobné zpracování využití klouzavých průměrů je využito v rámci technického indikátoru obchodování Moving Average Convergence Divergence, kde se využívá dvou různých klouzavých průměrů a jejich překřížení značí možný čas na prodej nebo nákup (dle vzestupného nebo klesajícího trendu). Technické indikátory budou dále rozepsány v kapitole 3.2.3. [1, 6, 2]

Obrázek 2.3: Klouzavý průměr $q = 15$ a $q = 40$ pro časovou řadu ceny kryptoměny Bitcoin

2.2.4 Autokorelace

Analýza, která zkoumá relativní míru vzájemné variability dvou subjektů, se nazývá korelační. Při analýze samotné časové řady se využívá korelační analýza sama sebe, neboli autokorelační analýza. Autokorelační analýza zkoumá proměnlivost úseků časové řady posunutých o určitou hodnotu. Relativní míra této proměnlivosti je autokorelační koeficient, který se pohybuje v rozmezí <-1, 1>. Autokorelace slouží k detekci cyklické a sezónní složky a určení její periody. Mimo detekce těchto složek je také autokorelace schopna vyjádřit, zda je časová řada předpověditelná či nikoli.

Autokorelační analýza se zobrazuje pomocí autokorelační funkce jako korelogram, který má na ose x velikost posunu na časové řadě a na ose y hodnoty autokorelačního koeficientu. Autokorelační funkce bývá často rozšířená o intervaly spolehlivosti, kterými se zohledňuje statistická významnost koeficientů. Autokorelační funkce bývá často využívaná ve formě částečné autokorelační funkce, která je vyobrazena na obrázku 2.4 (z časové řady zobrazené na obrázku 2.1). Zde je pěkně znázorněná vysoká významnost koeficientu s posunem 12, což znamená periodu 12 měsíců, neboli roční periodu. [6, 5, 3]

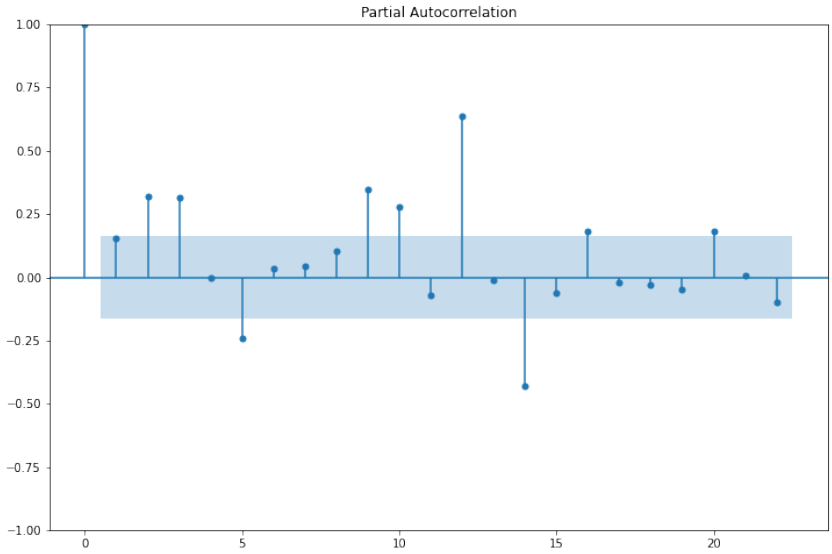

Obrázek 2.4: Částečná autokorelační funkce

2.2.5 Box-Jenkinsova metodologie

Další metoda analýzy časových řad je metoda George Boxe a Gwilyma Jenkinse, která slouží k předpovědi směřování časové řady v budoucnosti a k celkovému porozumění vlastností analyzované časové řady. Při analýze časových řad pomocí Box-Jenkinsovy metodologie je využita primárně náhodná složka časové řady. Časová řada, která je vstupem této metodologie musí být zbavena trendové složky - musí být stacionární. Postup Box-Jenkinsovy metodologie se zakládá na korelační analýze. Výsledný model ARIMA, neboli Autoregressive Integrated Moving Average (Autoregresivní integrovaný klouzavý průměr) se skládá ze tří modelů:

- AR(p) - autoregresivní model vysvětluje část hodnot řady jako lineární kombinaci minulých hodnot, řád p vyjadřuje počet minulých časový intervalů řady
- I(d) - integrační model značí diferenci časové řady a řád d ukazuje, kolikrát se diference aplikuje před autoregresivními modely a modely klouzavých průměrů
- MA(q) - model klouzavých průměrů zobrazuje hodnotu jako průměr q minulých hodnot

Model ARIMA umožňuje predikovat a analyzovat různé typy časových řad. Nezáleží na skutečnosti, zda časová řada obsahuje trend, sezónní složku či jak významnou má náhodnou složku. Díky těmto vlastnostem je často využíván v ekonomické analýze pro predikci budoucích cen na burze. V případě výrazné sezónní složky se využívá model rozšířený o sezónní model SARIMA (Seasonal ARIMA).[1, 5]

2.3 Nástroje pro zpracování časových řad

Poslední část kapitoly Teorie časových řad ukáže na nástroje, které pomáhají data analyzovat, zobrazovat, či predikovat. Na trhu existuje mnoho nástrojů, které těchto funkcionalit dosahují různými způsoby. Tyto nástroje se řadí do dvou hlavních kategorií a těmi jsou:

1. Programovací jazyky a knihovny programovacích jazyků
2. Softwarový produkt zaměřený na vizualizaci a analýzu dat

U první zmíněné kategorie je nejsilnějším hráčem Python[7], který disponuje celou řadou knihoven, které slouží k analýze, zpracování, či zobrazení dat. Pro manipulaci s daty a pro jejich následnou analýzu slouží populární knihovna Pandas[8], která nabízí efektivní datové struktury pro časové řady. Tato knihovna je postavena na další velice oblíbené knihovně NumPy[9], která primárně nabízí velkou podporu pro numerické operace. Python také disponuje několika knihovnami pro zobrazení dat. Této skupině vládnou knihovny Matplotlib[10] a Seaborn[11], na kterých dále staví většina dalších knihoven sloužících k účelu zobrazení dat. Obrovskou škálu metod a modelů na zpracování časových řad nabízí knihovna Statsmodels[12], která bude využita na většinu výpočtů v analýze v praktické části této diplomové práce. Na predikci časových řad založenou na trendové a sezónní složce staví knihovna Prophet[13] od společnosti Meta[14]. Nejsilnější knihovnou pro predikci na bázi strojového učení a neuronových sítí je Tensorflow[15]. Mimo programovací jazyk Python existují také jiné neméně silné jazyky, která dokáží zpracovávat a analyzovat data časových řad. Například jazyk R[16], který se primárně zaměřuje na statistické operace, nebo také MATLAB[17] - programovací jazyk a prostředí, které se běžně používá pro různé matematické výpočty, ale také pro zpracování signálů a analýzu časových řad. Knihovny pro analýzu a zobrazení časových řad nabízí také jazyk JavaScript[18]. JavaScript nabízí velkou škálu knihoven pro implementaci interaktivních grafů s daty časových řad, mezi které patří například Dygraphs[19] a Plotly.js[20] Poskytuje také přístup k metodám analýzy časových řad, kde se na první příčky řadí cloudová služba od společnosti Microsoft[21] známá pod názvem Time Series Insights[22].

Další kategorií jsou již hotové softwarové produkty, které mají naimplementovaný široký výběr metod a modelů dostupných přes uživatelské prostředí. Business intelligence nástroje většinou nabízí svůj vlastní programovací jazyk, který je uživateli k dispozici jak samotný, tak přes uživatelské prostředí. Power BI[23] disponuje jazyky Power Query[24] pro zpracování dat a jazykem DAX[25] pro analýzu a vyobrazení. Power BI dokáže vizualizovat data časových řad pomocí širokého výběru interaktivních analytických grafů, ale také nabízí možnost pro vývoj vlastních zobrazovacích elementů v jazyce R a Python. Power BI má v konkurenci plno podobných softwarových produktů, jako jsou Qlik[26] nebo Tableau[27]. Mimo tyto business intelligence nástroje se dá pracovat s daty časových řad i v jiných velice silných nástrojích. Například statistická softwarová sada SAS[28], která podporuje analýzu a predikci časových řad, nebo také široké veřejnosti známý Excel[29], který nabízí základní funkce pro analýzu, zpracování a vizualizaci časových řad.

Tyto nástroje nabízí různé možnosti a funkce pro zpracování dat časových řad. Přesto výběr nástroje závisí na konkrétních potřebách projektu, použitém programovacím jazyce a prostředí. Nelze jednoduše říci, který nástroj je obecně lepší. Každý nástroj poskytuje silnější podporu jiným způsobem a pro jiné účely. Výběr vhodného nástroje musí být vždy patřičně zvážen.

Kapitola 3

Kryptoměny a obchodování s kryptoměnami

V této kapitole bude nejdříve shrnuto, co to jsou kryptoměny a jak vznikaly. Bude také popsán jejich vývoj a v jaké fázi se kryptoměny nachází dnes. Následovat bude úvod do těžby kryptoměn a bude také popsáno, jak ke kryptoměnám přistupují jednotlivé legislativní a právnické entity ve světě. Dále zde bude zmíněno obchodování s kryptoměnami, jakými způsoby je možno vývoj ceny vizualizovat, či jaká legislativa je spojena s tímto digitálním trhem. Uvedeny budou postupně také rizika, která se s obchodováním digitálních měn spojují.

3.1 Úvod do kryptoměn

V dnešní době se mladší generaci ani nemusí význam kryptoměn vysvětlovat, těm co se pravidelně pohybují na internetu je toto slovo určitě známé. Díky tomu, že se historie kryptoměn objevuje až s rokem 2009 (hlubší pohled do historie kryptoměn je uveden v následující kapitole 3.1.1), tak starším generacím mohou být tyto digitální měny zcela cizí.

Pro pochopení významu zde bude nejprve ve zkratce uvedeno, jak vlastně kryptoměny fungují. Popisovat fungování všech kryptoměn obecně by bylo nesmyslné, proto se tato kapitola zabývá fungováním kryptoměny Bitcoin a jemu podobným kryptoměnám, které tvoří většinu trhu a jsou zpracovány v mnoha publikacích. Kryptoměny poskytují decentralizovaný peer-to-peer platební systém. Peer-to-peer systém zahrnuje mezi dvě strany transakce několik uzlů, mezi kterými se postupně šíří informace o transakci. Tento proces se spouští pravidelně v blocích, které se postupně na sebe řetězí a tvoří takzvaný blockchain. Proces ověřování transakcí na uzlech se nazývá těžba kryptoměn, o které je více informací zahrnuto v kapitole 3.1.2. Aby byla dosažena bezpečnost transakcí, jsou veškerá data převedená do kódu hash metodou SHA-256, která je kvůli detekci změn uplatněna na několika místech. Aby se zabránilo změnám dat u transakcí přepočítáním kódu hash, byl vyvinut

požadavek na proof-of-work, jehož součástí je takzvaný nonce - speciální 32 bitová hodnota, která slouží jako základní ochrana a nachází se v hlavičce každého bloku. [30]

Díky decentralizaci platebního systému vypadávají z řetězce plateb třetí strany, které se starají o ověřování transakcí a zabránění podvodům, ale na druhou stranu jsou to ty složky platebního řetězce, které si na každé platbě berou poplatek 0,58%-1,99% [31]. Mezi třetí strany se u platebních systémů považují banky nebo společnosti, které vydávají platební karty. Na první pohled se může objevit otázka, zda jsou kryptoměny bezpečné, když je neověřuje žádná třetí strana. V minulosti se u digitálních měn objevil problém dvojí útraty, kdy podvodník utratil stejný digitální token u více obchodníků najednou. Tomuto problému zabránily veřejně distribuované účetní záznamy všech transakcí v blockchainu. Veškeré informace a data v digitálním prostoru, mezi které se řadí také kryptoměny, mohou čelit kybernetickým útokům. U kryptoměn jako digitálních peněz se tohoto bezpečnostního rizika také obává mnoho lidí. Tento styl útoku při dnešním tržním kapitálu kryptoměn není reálný, protože by byl možný pouze v případě, kdy útočník vlastní většinu uzlů v síti, čímž získá kontrolu nad většinou výpočetního výkonu sítě a tím i ovládne transakční validaci a další důležité procesy v síti. Tento styl napadení se nazývá 51% útok. Mimo skutečnost, že útoky na sítě kryptoměn jsou téměř nereálné, tak i z pohledu teorie her sama struktura sítě silně odrazuje útočníky. Jakýkoliv povedený útok by nepochybně způsobil výrazný pád měny.

Význam kryptoměn se nedá jednoduše popsat či vysvětlit, i zkušení investoři jej popisují mnoha způsoby. Prvním způsobem je možno pohlížet na kryptoměny jako na decentralizované platební sítě, které byly popsány v předchozím odstavci. Krytoměny jsou ale také softwarový produkt a lze je přirovnat k technologickým akciím, i když produkt samotný není možné ocenit. Digitální měny také slouží jako investice, které nepodléhají inflaci, jako klasické fiat měny. Kryproměny, jako jakékoliv aktivum, jehož zhodnocení ceny předčí míru znehodnocení fiat měny, jsou považovány za formu spoření. Zde ovšem nastává riziko nekontrolovatelného pádu libovolné kryptoměny. Ukázkovým příkladem může být krach obchodní platformy FTX[32] v roce 2022, který výrazně ovlivnil cenu nejpopulárnější kryptoměny Bitcoin. [33, 34, 35]

3.1.1 Historie kryptoměn

Historie digitálních měn sahá do konce 90. let minulého a počátku nového tisíciletí, kdy byl poprvé představen koncept digitálních peněz. Širokou pozornost a popularitu si však digitální měny získaly až po uvedení kryptoměny Bitcoin v roce 2009, která také o několik let později, v roce 2011, stála za samotným názvem kryptoměny. Navzdory své nynější popularitě zůstávají kryptoměny relativně novou a rychle se vyvíjející technologií. Jejich historie a budoucnost se teprve píše a bude zajímavé sledovat, jak budou v následujících letech ovlivňovat svět.

Historie kryptoměn se dá rozdělit do pěti pomyslných etap, které jsou zde sepsány po odstavcích. Jako první budou zmíněny úplné počátky digitálních měn, následně etapa vzniku měny

Bitcoin, kterou následují vzestupy kryptoměn nazývanými jako altcoin. Následuje éra největšího skoku popularity a celá sekce historie bude završena tím, jak kryptoměny vnímáme dnes.

Koncem 90. let minulého a počátkem nového tisíciletí se objevilo několik pokusů o vytvoření digitální měny. Jako první přišel s velkou digitální měnou kryptograf David Chaum, přezdívaný také jako otec anonymní komunikace, se společností Digicash. Tato měna jménem ecash byla ve své době významným vynálezem, ale nepovedlo se mu dostatečně proniknout a tak Digicash následně zkrachovala. Jednou z nejvýznamnějších digitálních měn této doby byl e-gold, který uživatelům umožňoval držet zlato v digitální podobě. Mnoho z těchto raných pokusů však ztroskotalo na problémech, jako je nedostatek důvěry, obavy o bezpečnost a problémy s regulací. [36]

V říjnu roku 2008 osoba nebo skupina osob skrývající se pod pseudonymem "Satoshi Nakamoto"publikovala článek, v němž nastínila novou digitální měnu nazvanou Bitcoin. Samotný Bitcoin byl uveden až v roce 2009. Satoshi Nakamoto se stal následně nedohledatelný a měl v plánu zůstat v anonymitě. I přes tvrdou práci investigativních novinářů se dodnes neví, kdo za tímto pseudonymem stojí. Dohledání tvůrce kryptoměny Bitcoin v konečném důsledku není důležité, nemá totiž nad touto kryptoměnou žádnou moc. [36]

Po úspěchu měny Bitcoin tento trend následovalo několik dalších skupin vývojářů, či firem a začaly vznikat další kryptoměny přezdívané altcoin. Mezi hlavní kryptoměny, které vznikly v této době, se řadí mimo jiné například Litecoin, Ripple a Ethereum. Měny altcoin byly navrženy tak, aby vylepšily nedostatky kryptoměny Bitcoin, jako je rychlost transakcí nebo také škálovatelnost.[30, 36]

S rostoucím počtem kryptoměn rostla také jejich celková popularita ve společnosti. Bitcoin se jako první kryptoměna stal široce využívaným platebním prostředkem a jako platidlo ho začaly přijímat také velké společnosti jako je například Microsoft. Tohoto trendu si všimly také jiné společnosti a tak na trh přišlo velké množství nových burz a peněženek, což usnadnilo lidem obchodování s kryptoměnami. [36]

V dnešní době existuje několik tisíc různých kryptoměn s celkovou tržní kapitalizací v bilionech dolarů. Tyto digitální měny jsou využívány pro různé účely, včetně investic, obchodování nebo jednoduše jako platební prostředky. Blockchain technologie, která stojí za kryptoměnami, má také široké uplatnění v mnoha jiných odvětvích, jako je například zdravotnictví. [36]

3.1.2 Těžba kryptoměn

Těžba kryptoměn je proces ověřování a přidávání nových transakcí do blockchainu, při kterém se dostávají do oběhu nové kryptoměny jako odměna za práci. Jinými slovy jde o proces generování nové kryptoměny řešením extrémně složitých matematických problémů využívajících speciální software. Když je v blockchainu provedena nová transakce, je rozeslána všem uzlům v síti k ověření. Těžaři soutěží mezi sebou o vyřešení tohoto složitého matematického problému a ověření transakce. Těžař, který jako první vyřeší problém a potvrdí transakci, je odměněn předem určeným množstvím

kryptoměny. Obtížnost matematického problému, který musí těžaři vyřešit, je navržena tak, aby se s přibývajícím počtem těžařů v síti zvyšovala, což zajišťuje, že míra tvorby nové kryptoměny zůstává v čase konstantní. Díky tomu je proces těžby v průběhu času také obtížnější a energeticky náročnější. Těžbu kryptoměn může provádět každý, kdo má vhodný hardware a software. Vzhledem k rostoucí obtížnosti těžby a vysokým nákladům na energii s ní spojeným se však mnoho těžařů sdružuje do těžebních poolů, kde kombinují svůj výpočetní výkon, aby zvýšili své šance na vyřešení matematického problému a získání odměny.[37]

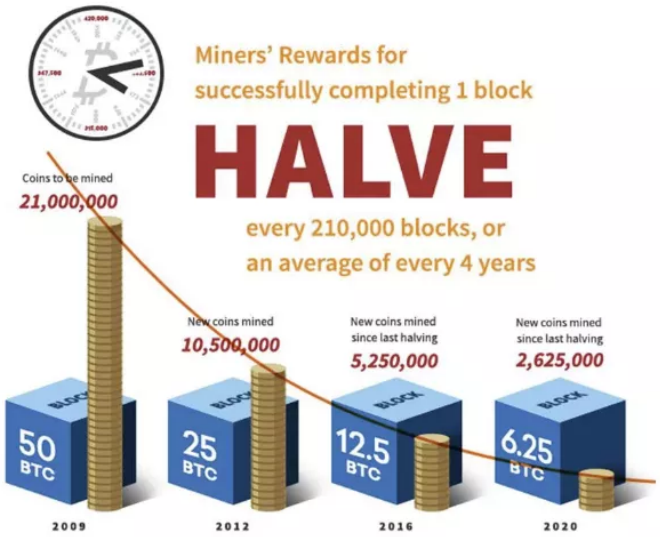

Obrázek 3.1: Půlení zisku těžby kryptoměny Bitcoin [38]

Většina kryptoměn má omezené maximální množství, díky čemuž dochází k postupnému snižování odměny za těžbu a také snižování celkového množství vytěžené měny. Například Bitcoin (jak lze vidět na obrázku 3.1), když byl poprvé spuštěn, odměna za vytěžení bloku činila 50 BTC. V rámci návrhu protokolu se však odměna snižuje přibližně každé čtyři roky na polovinu (každých 210 tisíc bloků). Tento postup se nazývá půlení a je zabudován přímo do zdrojového kódu. K poslednímu půlení došlo v květnu 2020 a odměna za blok byla snížena z 12,5 BTC na 6,25 BTC. Od té doby vznikne přibližně 900 BTC denně, tedy asi 328 500 BTC ročně. Je důležité poznamenat, že maximální množství kryptoměny Bitcoin, které lze vytěžit, nakonec dosáhne maximální hranice 21 milionů.[38]

3.1.3 Kryptoměny ve světě

V dnešním světě, kterému vládne rychle se rozvíjející digitalizace a s ní zvyšující se efektivita a produktivita, musí státní orgány a organizace držet krok s tímto trendem. Důležitou roli musí

držet také regulační orgány, které musí zaujmout aktivní přístup k moderním technologiím, protože technologie vždy předcházely a vždy budou předcházet regulacím.

Od příchodu kryptoměny Bitcoin v roce 2009 začaly kryptoměny vzbuzovat velký zájem států a centrálních bank. Primárně centrální banky a jiné finanční instituce začaly zkoumat možnosti CBCC, neboli kryptoměn centrálních bank (Central bank cryptocurrencies). CBCC by ovšem neměly nahradit klasické měny, ale pouze je doplnit bez větší strukturální změny v systému. Jednou z nejvyspělejších zemí je v tomto ohledu Čína, která již spustila svou CBCC, která využívá blockchain/DTL (technologii distribuované účetní knihy, anglicky distributed ledger technology). Čína s CBCC může být prvním státem na světě, který kryptoměnám dodá společenský zvyk. Spolu s Ruskem také pracuje na blockchainové/DTL alternativě k mezinárodnímu mechanizmu plateb SWIFT. Od začátku ruské invaze na Ukrajinu v únoru roku 2022 je tento krok naléhavější kvůli vyloučení Ruska ze systému SWIFT. Podobně je na tom také Austrálie, která zvažuje zavedení digitálního australského dolaru ze strany Australské rezervní banky. Na zavedení je vyvíjen tlak primárně australským startupem FinTech Australia[39], který navrhuje digitální měnu krytou státní fiat měnou.

Ekonomické problémy mohou také vést státy k alternativním řešením krize a hledají řešení v zavedení kryptoměn jako státní měny. První zemí na světě byl Salvador, který v roce 2021 zavedl Bitcoin jako zákonné platidlo. V podobné části světa s podobnými problémy se nachází také Venezuela, která disponuje hyperinflací a snaží se s krizí bojovat pomocí státní měny The petro, která je podporovaná ropou a ropnými produkty.

Zajímavým úkazem je švýcarské město Zug, právem přezdívané jako "Crypto Valley". Toto malé město žije s představou, že kryptoměny zde budou ještě dlouhou dobu a tak se zde mohou platit daně a účty za komunální služby ve virtuálních měnách.[34, 35]

3.2 Obchodování s kryptoměnami

V následující sekci této diplomové práce jsou vyloženy principy obchodování s kryptoměnami, jejich srovnání s jinými finančními aktivy na trhu, popsány jsou zde také typy grafů a vizualizací, jak je možné vývoje cen kryptoměn vizualizovat. Zmíněna je zde také legislativa obchodování a nakonec existující kryptoměnové burzy.

Obchodování na kryptoměnové burze je v mnoha ohledech podobné jiným finančním aktivům jako jsou například akcie, akciové indexy, dluhopisy či komodity. Hlavním rozdílem je decentralizovanost trhu, která u kryptoměn může vést k větší volatilitě cen a díky tomu i obtížné predikci dalšího vývoje cen. Od zmíněné decentralizace se odvíjí také doba, kdy jsou burzy otevřeny. Zatímco kryptoměny je možno obchodovat v libovolnou dobu, akciový trh je otevřen pouze v pevnou obchodní dobu a převážně jen přes pracovní týden. Obtížnou predikci ovlivňuje také fakt omezené likvidity kryptoměn, kdy se každý větší obchod projeví na ceně dané kryptoměny.

Tato práce se zaměřuje na obchodování s kryptoměnami, a proto následné informace budou založeny na zásady a principy obchodování právě s kryptoměnami, i když se informace mohou prolínat i s principy a zásadami obchodování jiných finančních aktiv.

3.2.1 Analýza trhu

Před obchodováním kryptoměny je důležitý průzkum trhu jako celku a také samostatné kryptoměny, kterou se obchodník chystá nakoupit. U kryptoměn je důležité znát základní princip kryptoměny, její technologii, na které stojí, a převážně historii a její vývoj na trhu včetně událostí, které její vývoj značně ovlivnily.

Průřez existující literaturou uvedl například Andrea Flori ve svém článku Cryptocurrencies in Finance: Review and Applications [40]. Ve svém článku vypisuje studie, které se zaměřily na efektivitu kryptoměn a na jejich investiční a diverzifikační možnosti. Většina studií se týká pouze měny Bitcoin jakožto nejvíce analyzované a zkoumané kryptoměny. Novější studie ovšem začaly zkoumat i ostatní kryptoměny včetně jejich vzájemné závislosti. Většina studií zatím dospívá k podobnému závěru, které shrnul Andrea Flori následně: *"Většina literatury uznává, že tyto kryptotrhy mají obvykle daleko k efektivním systémům, jsou silně charakterizovány obrovskými tržními fluktuacemi a mají sklon vykazovat dlouhodobou paměť a shlukují volatilitu. Celkově mohou tyto aspekty vyvolávat pochybnosti o odhalení správných hnacích sil tvorby ceny a mohou také zpochybnit identifikaci skutečné fundamentální hodnoty altcoinu. Přesto bylo navrženo několik přístupů k testování uskutečnitelnosti investičních strategií, které zahrnují Bitcoin a další kryptoměny společně s běžnými třídami aktiv. Tyto pokusy zkoumají diverzifikaci a investiční příležitosti, které jsou motivovány obrovským rozptylem a mizivou tržní korelací mezi kryptoměnami a ostatními finančními nástroji. Zdá se, že empirická zjištění poukazují na diverzifikační přínosy plynoucí ze začlenění kryptoměny Bitcoin do investičních strategií, ačkoli dlouhodobá udržitelnost a investovatelnost těchto řešení jsou stále předmětem diskusí."* Flori [40]

3.2.2 Obchodní strategie

Díky tomu, že obchodování s kryptoměnami nedisponuje dlouhodobou udržitelností a investovatelností, je důležité si vypracovat obchodní strategii či několik obchodních strategií. Tato strategie by měla určovat míru rizika, které obchodník toleruje, ale také výši peněz, které budou využity k jednotlivým obchodům.

U obchodování s kryptoměnami jsou možnosti na short a long obchodování. Short obchodování znamená sázku na pokles ceny a long obchodování naopak sázku na růst. Toto rozhodnutí, zda obchodovat na short nebo long, je třeba vždy udělat až na základě analýzy a aktuální situace na trhu. Další skutečnost, která se nesmí při obchodování s kryptoměnami opomenout, je "spread", neboli rozdíl mezi nákupní a prodejní cenou. Při obchodování na short se otevře pozice za prodejní cenu, naopak to platí při obchodování na long, kdy se otevírá pozice za kupní cenu. Jakmile je určen

způsob obchodování, nastává okamžik nastavení parametrů obchodu nebo přímé otevření pozice. V případě způsobu obchodování, kterému se říká market, nedochází k nastavování parametrů, ale obchodník hlídá parametry manuálně a v reálném čase určuje další akce, které se budou s pozicemi na burze dít. V opačném případě, kdy obchodník aktivně nehlídá ceny a pozice, může nastavit tyto parametry:

- Limit, který říká, při jaké hodnotě se otevře obchodní pozice, ať už se týká short nebo long obchodování.
- Hodnota "Take profit"(TP), která udává, kdy uzavřít pozici v profitu nebo částečném profitu. Jedná se o horní hranici, které musí kryptoměna na burze dosáhnout, aby byla pozice uzavřena při long obchodování. V případě short obchodování je to minimální hodnota.
- Hodnota "Stop loss"(SL) utváří hranici největší přijatelné ztráty pro obchodníka. V některých případech je také možné tuto hodnotu rozšířit o možnost "Trailing stop", která v případě průběžného zisku posouvá hodnotu SL, aby co nejvíce minimalizovala ztráty.

Obrázek 3.2: Ukázka obchodování s kryptoměnou Bitcoin u XTB [41]

Ukázku, jak takový obchod může vypadat, je možno vidět na obrázku 3.2. Zobrazené jsou zde 4 rovnoběžné přímky, kde vrchní znázorňuje hodnotu TP, druhá hodnotu, za kterou byl obchod proveden, třetí zobrazuje aktuální tržní hodnotu a poslední rovnoběžka hlídá hodnotu SL.

Ve všech případech a libovolné strategii je ovšem důležité sledovat i jiné faktory, které můžou ovlivnit trh. Zásadní faktory v dnešní době jsou média a sociální sítě a na nich primárně účty vlivných lidí. Například kryptoměna Dogecoin se po informaci sdílené Elonem Muskem na sociální síti Twitter [42] během čtyř hodin vyšplhala o více než 300% a následně během několika následujících hodin klesla na téměř polovinu svého maxima.

3.2.3 Techniké ukazatele

Dalším užitečným nástrojem pro identifikaci obchodních příležitostí jsou technické ukazatele. Technické ukazatele jsou často založeny na teorii časových řad, proto v této práci nemohou být opomenuty minimálně ty, které využívají různé matematické nástroje, jako jsou například klouzavé

průměry a oscilátory. Tyto nástroje slouží k možné predikci cen v blízké budoucnosti a odhadují, zda je kryptoměna podhodnocená či nadhodnocena, nebo také zda by mělo docházet ke změně trendu.

Jedním z nejznámějších a nejpoužívanějších ukazatelů je Index relativní síly neboli **RSI** (Relative Strenght Index). RSI měří sílu pohybu ceny v určitém časovém období. Zobrazuje se jako hodnota v rozmezí 0 až 1, kde nízké hodnoty naznačují možný klesající trend a vysoké hodnoty ukazují na podhodnocenost kryptoměny. Existuje mnoho studií, které se zabývají efektivitou toho ukazatele. Dle studie Adriana Moroșana z roku 2011 [43], kde byla testována efektivita RSI, který byl rozšířen implementací objemu obchodů do původního algoritmu. RSI samotný není spolehlivý jako jediný ukazatel při obchodování a vykazuje prokazatelné ztráty. RSI rozšířený o objem obchodů dosahuje sice vyšších zisků při profitu, ale naopak dosahuje také vyšších ztrát. Celkově se dá říct, že navrhuje obchod později, než klasický RSI. Ukázalo se, že RSI neindikuje návrat trendu, ale jeho pokračování, tudíž reverzní hodnota ukazatele poskytuje pozitivnější výsledky, než jeho současná.

Druhý ukazatel, který bude zmíněný v této práci, je také jeden z nejpopulárnějších ukazatelů v technické analýze. Ukazatel konvergence a divergence klouzavých průměrů neboli MACD (Moving Average Convergence/Divergence) byl vytvořený v roce 1979 Geraldem Appelem. MACD se skládá ze tří exponenciálních klouzavých průměrů, které se snaží identifikovat, zda dochází k pokračování trendu nebo k jeho otočení. Odečtením dlouhého klouzavého průměru od krátkého se vytvoří oscilátor hybnosti, který je dále zobrazován se třetím exponenciálním klouzavým průměrem - signální linkou. MACD bývá většinou zobrazován pouze jako histogram s hodnotami rozdílů prvních dvou klouzavých průměrů se signální linkou. [44]

Existuje také mnoho dalších technických indikátorů. Například indikátor Fibonacci retracement, který ukazuje, jaká úroveň návratu může být očekávána po cenovém pohybu. Další využívaný indikátor je Bollinger Bands, který vyjadřuje, jak se cena pohybuje v rámci určitého průměrného rozpětí a umožňuje identifikovat přeprodané a překoupené trhy. V poslední řadě nemohou být vynechány také základní indikátory Moving Averages a Stochastic Oscillator. Tyto indikátory jsou jen malou částí z mnoha, které jsou k dispozici. Je důležité si uvědomit, že každý indikátor má své výhody a nevýhody a že jejich použití by mělo být založeno na konkrétních podmínkách trhu a obchodní strategii.

3.2.4 Vizualizace

Zobrazení vývoje cen a informací o obchodech s kryptoměnami je nedílnou součástí obchodování. Pro investory je to rychlý a srozumitelný nástroj, jak analyzovat a sledovat trhy. Nejčastějším nástrojem pro zobrazení vývoje cen v čase jsou grafy. Nejčastěji je to svíčkový graf, open-high-low-close graf a čárový graf. Tyto grafy budou popsány popořadě níže. Je důležité si uvědomit, že vizualizace vývoje ceny je sice silným a přímočarým nástrojem k zvážení obchodů, měla by sloužit pouze jako doplněk k fundamentální a technické analýze.

3.2.4.1 Svíčkový graf

Obrázek 3.3: Svíčkový graf pohybu ceny kryptoměny Bitcoin u XTB [41]

Svíčkový graf, zobrazený na obrázku 3.3 je jedním z nejpoužívanějších typů grafů ve světě obchodování. Svíčkový graf zobrazuje vývoj ceny kryptoměny v předem určeném pevném časovém období. Tento časový úsek je vždy zobrazen jednou svíčkou a velikost této svíčky je většinou jedna minuta, hodina nebo jeden den. Každá svíčka obsahuje 4 základní informace o obchodech během svého časového období. Cena otevření a cena uzavření je zobrazena tělem svíčky (plný kvádr) a nejnižší a nejvyšší hodnota během časového období je zobrazena formou stínů svíčky. V případě, že je cena při otevření vyšší, než cena uzavření, je svíčka zbarvena červenou barvou a značí pokles ceny za dané časové období. V opačném případě, kdy se cena za dané období zvýšila, je svíčka zabarvena zelenou barvou. Svíčkový graf umožňuje hledat vzory v pohybu ceny, podle kterých se dá předpovědět možný trend vývoje ceny v nejbližší budoucnosti.

3.2.4.2 Open-high-low-close graf

Obrázek 3.4: Open-high-low-close graf pohybu ceny kryptoměny Bitcoin u XTB [41]

Open-high-low-close graf, zobrazený na obrázku 3.4, je další formou vizualizace pohybu cen na burze. Je velice podobný svíčkovému grafu. Místo stínu svíčky se zde nachází vertikální čára, která

zobrazuje nejnižší a nejvyšší cenu během časového období a místo těla svíčky se zde nachází hlavička čáry, která zobrazuje cenu otevření, a patka čáry zobrazuje cenu uzavření.

3.2.4.3 Čárový graf

Čárový graf (vyobrazený na obrázku 3.5) je jedním z nejstarších a nejjednodušších používaných typů grafů v obchodování na burze. Tento graf zobrazuje cenu kryptoměny v podobě spojité čáry. Čárový graf je užitečný pro rychlé určení trendu, vývoj ceny kryptoměny v průběhu času a porovnání několika párů vzájemně.

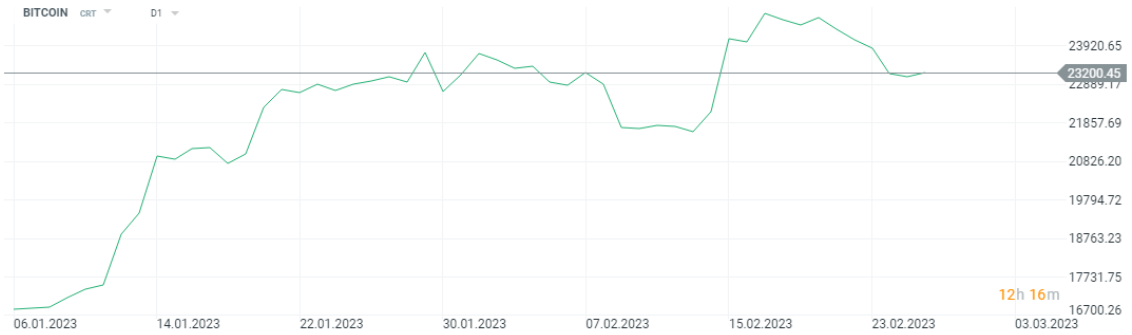

Obrázek 3.5: Čárový graf pohybu ceny kryptoměny Bitcoin u XTB [41]

3.2.5 Legislativa

Legislativa okolo kryptoměn se v posledních letech stává stále důležitější, protože kryptoměny se stávají stále populárnější formou investice a platby. Pro vlády na celém světě se pro rostoucí využívání kryptoměn jako platebních nástrojů staly velkým problémem daňové úniky, pro které byly využívány. Kryptoměny usnadňují také nezákonné transakce kvůli neomezenému počtu peněženek a nedostatku finančních zprostředkovatelů. Národní a nadnárodní úřady pracují na právním rámci pro regulaci kryptoměn a zároveň se snaží zajistit bezpečnost a ochranu spotřebitelů. Na mezinárodní úrovni existují některé dohody a směrnice, které mají regulovat kryptoměny. Například Evropská unie přijala směrnici o digitálních službách, která řeší pravidla pro provozovatele kryptoměnových burz a peněženek. Dalším příkladem jsou mezinárodní organizace jako Financial Action Task Force[45], které vydávají doporučení pro boj proti praní špinavých peněz a proti financování terorismu spojenému s kryptoměnami. USA, Německo a Čína byly mezi prvními zeměmi, které zakročily proti kryptoměnám. V roce 2013 Německo zvažovalo zdanění kryptoměn jako kapitálového aktiva.[34]

V České republice existuje také metodika týkající se kryptoměn. Tato metodika definuje daň z přidané hodnoty (DPH) a také daně z příjmů. Z hlediska daní z příjmů jsou kryptoměny považovány za věc nehmotnou, movitou a zastupitelnou. Oproti tomu z pohledu DPH se považují

kryptoměny za alternativní platební prostředky. Na zisky z obchodování s kryptoměnami se vztahuje patnácti-procentní daň z příjmu, která je vymezena v § 2 zákona o daních z příjmů pro fyzické osoby a v § 17 zákona o daních z příjmů pro osoby právnické. Zahrnuty jsou i zisky ze směny jedné kryptoměny za druhou a směny kryptoměn za zboží. Těžba kryptoměn je zde také započítaná jako nabytí majetku. Platí se také za použití platebních karet, které umožňují platby pomocí virtuálních měn. Výjimka platí pro investory, jejichž celkové příjmy i příjmy z jiných zdrojů nepřesahují 30 000 Kč za rok. Pozor je třeba dát v případě, že příjmy přesahují čtyřiceti-osminásobek průměrné mzdy, kdy se vztahuje dvaceti-tříprocentní daňová sazba. Právnické osoby musí vést účetnictví v korunách a zahrnout do něj i pohyby kryptoměn v hodnotě korun. Pokud firma prodá zboží za kryptoměnu, výnosem je cena toho zboží a kryptoměna se drží v hodnotě tohoto zboží. Rozdíl kurzů se zahrnuje do účetnictví jako výnos nebo ztráta a zahrnuje se do celkového účetnictví. Z pohledu DPH je nezbytné nahlížet na kryptoměny ve smyslu rozsudku SDEU C-264/14 Skatteverket v. David Hedqvist [46]. Těžba kryptoměny není předmětem daně podle § 2 zákona o DPH, neboť neexistuje smluvní vztah mezi osobou a jejím příjemcem. Podobně je na tom také směna kryptoměny za fiat měnu, která je z pohledu DPH brána za směnný obchod, který je osvobozen od DPH.[47, 48]

Legislativa okolo kryptoměn je stále ve vývoji a bude se pravděpodobně vyvíjet společně s rozvojem samotných kryptoměn, operací a akcí, které se v praxi objevují v kryptoměnovém trhu.

3.2.6 Kryptoměnové burzy

V dnešní době existuje již mnoho kryptoměnových burz, které umožňují uživatelům kupovat a prodávat kryptoměny. Burzy se liší v nabídce kryptoměn, obchodních poplatcích, dostupnosti v různých zemích, zprostředkování dat a mnoha dalších faktorech. Některé kryptoburzy nabízí funkce, jako jsou krypto sázky nebo krypto půjčky, které umožňují vydělávat na úrocích z držených kryptoměn. Nejlepší burzy dokonce nabízí vzdělávací kurzy a poskytují informace a nejnovější zprávy ze světa kryptoměn. Při výběru kryptoměnové burzy je důležité zvážit veškeré tyto faktory a vybrat burzu, která vyhovuje potřebám a preferencím konkrétnímu člověku. Níže budou popsány některé z největších a nejznámějších kryptoměnových burz.

3.2.6.1 Binance [49]

Burza Binance, založená v roce 2017 podnikatelem čínsko-kanadského původu jménem Changpeng Zhao, nabízí více než 350 obchodovatelných kryptoměn. Tato skutečnost dává obchodníkům s kryptoměnami a investorům mnoho možností. Platforma nabízí velmi nízké poplatky za zprostředkování obchodů a díky tomu láká velké množství investorů. Binance nabízí několik možností obchodování včetně peer-to-peer obchodování, spotového obchodování a obchodování s marží. Nabízí také spoustu typů příkazů, včetně TP, SL, trailing stop a příkazu, kdy jeden příkaz ruší druhý. Binance nabízí opravdu velkou škálu možností a proto není doporučena pro začátečníky, dokonce i zkušení investoři se mohou cítit zahlceni všemi dostupnými možnostmi. Oproti většině velkých burz na trhu, Binance

nedisponuje digitální peněženkou, ale pouze doporučuje digitální peněženku s velice dobrou pověstí - Trust Wallet, která má po integraci pouze omezené možnosti. Binance se potýkala s několika regulačními a právními problémy v několika zemích. Například ve Spojených státech momentálně funguje pouze v omezené verzi a poskytuje obchodování jen okolo 150 kryptoměn s omezenou funkcionalitou. Hlavní nevýhodou Binance je omezená možnost platby, kdy je podporovaná pouze platba kryptoměnou Bitcoin.[50, 51]

3.2.6.2 Coinbase [52]

Coinbase byla založena v roce 2012 jako kryptoměnová burza, která umožňuje lidem snadný nákup, prodej a ukládání kryptoměny Bitcoin. Dnes je to veřejně obchodovaná kryptoměnová burza, která nabízí uživatelsky přívětivé obchodování přes 200 obchodovatelných kryptoměn, robustní zabezpečení a řadu pokročilých funkcí pro zkušené obchodníky. Coinbase také nabízí možnosti ukládání kryptoměn a pojišťuje digitální prostředky uživatelů. Nicméně poplatky za obchodování mohou být poměrně vysoké a zpětná vazba uživatelů na zákaznickou podporu není vždy pozitivní. Coinbase má velmi jednoduché a intuitivní uživatelské rozhraní a díky tomu působí jako ideální platforma pro investory začátečníky.[50, 53, 54]

3.2.6.3 Kraken [55]

Kraken je jednou z nejuznávanějších a nejspolehlivějších kryptoměnových burz na světě. Byla založena již v roce 2011 a umožňuje investorům nakupovat, prodávat a ukládat více než 185 kryptoměn s konkurenceschopnými nízkými poplatky, které umožňují odstupňovanou strukturu poplatků pro obchodníky s velkým objemem obchodů. Kromě spotového obchodování mohou uživatelé obchodovat s kryptoměnami s využitím marže a obchodovat s krypto deriváty. Kraken nabízí také silně přizpůsobitelné nástroje pro analýzu grafů, podrobný přehled o transakčních knihách a vysokorychlostní provádění transakcí. Tato burza nabízí obchodní platformy Kraken a Kraken Pro. Základní platforma Kraken disponuje pouze omezenou funkcionalitou a také poplatky za transakce jsou zde větší. Burza se také potýkala s celou řadou právních regulací a je omezená v celých Spojených státech.[53, 54]

3.2.6.4 Bitfinex [56]

Bitfinex je pokročilá obchodní platforma, kde lze obchodovat s téměř 200 kryptoměnami s využitím derivátových instrumentů mimo jiné na maržových účtech. Platforma nabízí pokročilé obchodní příkazy, včetně trailing stop a kompletně rozepsané transakční knihy s vizualizací trhu. Založení účtu na této burze vyžaduje pokročilejší ověření ve formě fotky, občanského průkazu a telefonního čísla. Základní funkce platformy jsou velmi intuitivní, což dělá Bitfinex vhodným i pro začínající investory. Nicméně, hack platformy v roce 2016 a nejasnosti ohledně skutečného množství rezerv stablecoinu Tether, na nějž má Bitfinex silnou vazbu, stále kazí jeho pověst.[57]

3.2.6.5 Crypto.com [58]

Crypto.com je kryptoměnová burza, která byla spuštěna v roce 2016. Nabízí více než 250 podporovaných kryptoměn. Svou dobrou pověst si vybudovala na rozsáhlém ekosystému digitálních aktiv, včetně vlastního blockchainu a platební karty Crypto.com Visa. Burza Crypto.com je jedinečná svou mobilní aplikací, která umožňuje mimo jednoduché obchodování také platby přímo kryptoměnami. Uživatelé také mohou využívat token Cronos k placení poplatků na platformě a získávání dalších výhod. Největší negativa této burzy zahrnují vyšší poplatky pro menší investory a také nekvalitní zákaznickou podporu. [53, 54]

Kapitola 4

Infrastruktura pro automatické obchodování

Tato kapitola diplomové práce se zaobírá vybranými možnostmi infrastruktury, na které bude provozován bot pro automatické obchodování na kryptoměnové burze. Budou zde také rozebrány možnosti uložení dat, možnosti automatického získávání dat a možnosti automatického obchodování na burze.

Automatické obchodování je v dnešní době čím dál více populární metodou pro investování do kryptoměn a jiných aktiv. Tento přístup umožňuje obchodovat podle přesně daných podmínek či celých strategií a dokáže rychle reagovat na měnící se trend vývoje ceny. Pro vysokou efektivitu automatického obchodování je důležitá i infrastruktura, na které je bot provozován. Záleží také na struktuře dat, ke které bot přistupuje. Správná infrastruktura by měla zajistit rychlé provádění obchodů, bezpečnost, škálovatelnost a snadnou správu.

4.1 Volba infrastruktury

Pro nasazení automatického obchodování na kryptoměnové burze existuje mnoho variant, jak a na jaké platformě je možno vyvinutý software provozovat.

V dnešní době nejoblíbenější variantou jsou cloudová řešení, která umožňují provozovat bota na vzdáleném virtuálním serveru nebo prostředí, které je ve správě u poskytovatele služby. Cloudové řešení snižuje náklady na hardware, protože zbavuje uživatele povinnosti vlastnit servery a zvyšuje celkovou dostupnost, kterou garantuje zpravidla poskytovatel cloudové infrastruktury. Cloudové služby poskytují škálovatelnou infrastrukturu, která umožňuje přidávat a odebírat výpočetní výkon či úložiště pro ukládání dat dle aktuální potřeby. Mezi nejznámější cloudové poskytovatele dnešní doby patří Google Cloud Platform [59], Amazon Web Service [60] a Microsoft Azure [61].

Vzhledem k aktuální situaci, kdy se ve školním portfoliu nacházel již existující nevyužitý hardware, rozhodlo se zamířit k druhé variantě, kdy je bot provozován na lokálním zařízení. Tento typ

infrastruktury umožňuje plnou kontrolu nad hardwarem, softwarem bota, nebo také nad způsobem uložení dat.

Na lokálním hardwaru existuje také několik možností, jak finální produkt nasadit. Objevují se varianty distribuce řešení v rámci kontejnerů, například za využití služby Docker [62], nebo možnost provozovat vše přímo na hostitelském operačním systému. Kontejnery jsou izolovány od hostitelského operačního systému a mají všechny potřebné informace a závislosti uvnitř kontejneru. To znamená, že je umožněno sestavit a spustit kontejner s botem pro automatické obchodování v jakémkoli prostředí, které podporuje Docker, a není potřeba se starat o instalaci a konfiguraci závislostí v hostitelském systému. Docker také umožňuje snadné nasazení a správu více instancí bota najednou. Toto řešení by umožňovalo izolovat data a obchody jednotlivých párů a mít instanci bota pro každý obchodovaný pár v samostatném kontejneru, což by mohlo být užitečné pro větší rozsah obchodování. Řešení by umožnilo snadnou správu a aktualizaci jednotlivých kontejnerů, aniž by bylo nutné zasahovat do ostatních obchodních párů a umožňovalo by přizpůsobit funkcionalitu nejvíce obchodovaných párů pro lepší efektivitu a profitabilitu. Z hlediska výkonu by toto řešení pomohlo při paralelizaci složitých procedur, které běží sekvenčně pro každý pár. Na druhou stranu by s největší pravděpodobností částečně omezilo celkový výkon serveru, protože by se část výpočetního výkonu musela alokovat virtualizaci. Rizikem by byla také neznalost obchodovaných párů mezi sebou, kde by se těžko řešily například korelace párů a následné reakce na detekované závislosti. S ohledem na zmíněné nevýhody by tento plán nebyl pro provoz našeho bota lukrativní a nebyl by dobře využitelný.

Implementace bota pro automatické obchodování kryptoměn v rámci projektu, kterého je tato práce součástí, byla provedena bez použití kontejnerů. Veškeré procesy běží přímo na hostitelském operačním systému. Toto rozhodnutí bylo učiněno primárně z důvodu algoritmů, které se zabývají několika páry, a bylo by složité toto řešení dělit na jednotlivé páry. Bot momentálně běží na dvou systémech. Dochází k oddělení nejpodrobnějších dat ve formě vteřinových svíček na samostatný server, protože tyto informace obsahují velké množství záznamů a kalkulace, které nad těmito daty běží, vyžadují větší výpočetní výkon. V případě využití jednoho systému by tyto operace mohly zahltit primární systém a omezily by tak celkovou funkčnost bota a mohlo by docházet ke zpomalení odezvy.

4.2 Automatické získávání dat

U automatického obchodování je důležité, aby veškeré procesy mohly být prováděny 24 hodin denně, 7 dní v týdnu. Tento přístup umožňuje investorům využít všechny příležitosti na trzích v reálném čase. V této době, kdy jsou finanční trhy stále více digitalizované, je automatizované obchodování pomocí REST API (Representational State Transfer Application Programming Interface) velmi využívanou formou pro mnoho investorů a obchodníků.

4.2.1 REST API

REST API je jeden z nejvyužívanějších typů webových API. Jedná se o architekturu definující způsob komunikace klienta a serveru pomocí HTTP protokolu. REST API používá standardní HTTP metody GET, POST, PUT, DELETE, které jsou mapovány na standardní CRUD (Create, Read, Update, Delete) operace využívané v databázových systémech. K transferu dat mezi klientem a serverem jsou využity datové formáty JSON a XML. Hlavní cíl REST API je poskytnout uživateli komunikaci se serverem jednoduchým a efektivním způsobem. Klient má možnost manipulovat se zdroji pomocí standardních metod, kdy každý zdroj disponuje vlastním unikátním identifikátorem.

4.2.2 API světových kryptoměnových burz

Většina světových kryptoměnových burz disponuje svými REST API, které poskytují informace o aktuálních tržních cenách, historických datech a dalších informacích relevantních pro obchodování s kryptoměnami. Kromě pouhého získávání dat umožňují také přímo provádět a spravovat obchody.

Následuje popis API dvou světových burz Coinbase a Binance, kdy API burzy Binance bude rozebráno detailněji, vzhledem k tomu, že je nasazeno ve výsledném produkčním systému.

4.2.2.1 Coinbase API [63]

Coinbase API nabízí flexibilní a programovatelné rozhraní, díky čemu může poskytnout spoustu funkcí odlišných od konkurence. API burzy Coinbase umožňuje obchodovat pouze 4 měny a to Bitcoin, Bitcoin cash, Litecoin a Ethereum. Uživatelé mají přístup k informacím o cenách v reálném čase a k historickým údajům. Uživatelé se také mohou připojit k jiným peněženkám, což nabízí možnost vyřizovat transakce s ostatními uživateli. Dále mimo klasické REST API nabízí možnost využít technologie WebSocket pro oznámení o stavu transakcí v reálném čase. Rozhraní API je vyvinuto na platformě Node.js[64] a může být využíváno zdarma do 10 000 požadavků za hodinu. V případě potřeby je možné rozšířit na Coinbase pro, které nabízí více funkcionalit, umožňuje větší počet požadavků a také nabízí vyšší míru zabezpečení. Coinbase API disponuje výbornou dokumentací pro vývojáře, kde se nachází nejen podrobný popis všech funkcí, ale je zde k dispozici také příklad odpovědí serveru pro veškeré možné kódy odpovědí. Dokumentace je jedinečná svou ukázkovou implementací požadavků v 18 programovacích jazycích, která pomáhá vývojářům k rychlejší implementaci celé aplikace. Coinbase poskytuje také sandbox verzi API pro vývojáře. Coinbase API sandbox je bezplatná testovací verze, která umožňuje vývojářům testovat své aplikace bez použití skutečných peněz a skutečných účtů. Tímto způsobem je možno ověřit správnou funkčnost aplikace před jejím nasazením na skutečný účet se skutečnými penězi.[63, 65, 66]

4.2.2.2 Binance API [67]

Binance API nabízí podporu spot obchodování, poskytuje aktuální a historická obchodní data a umožňuje připojení peněženky Binance. Podobně jako Coinbase API, mimo klasické služby poskytované přes REST API, podporuje také streamování živých dat přes WebSocket. Platforma také poskytuje testovací prostředí sandbox.

Mezi výhody Binance API patří primárně samotná burza Binance, díky čemuž má přístup k největším kryptoměnovým trhům a umožňuje obchodovat se stovkami kryptoměn. Dále je velkou výhodou Binance API jeho bezplatné použití a snadná implementace. Poplatky jsou ve srovnání s ostatními platformami skutečně nízké.

Nicméně, Binance API má i některé nevýhody, mezi které se řadí omezení 1 200 požadavků za minutu, které je striktní a není škálovatelné pro uživatele, kteří požadují více, a to i v případě, že by si chtěli za službu doplatit. Překročení tohoto limitu může vést k dočasnému zákazu IP adresy od dvou minut do tří dnů. Zákaznická podpora Binance API není vůbec dobrá a řešení problémů může trvat dlouhou dobu.[67, 68, 66]

Celkově lze říci, že Binance API je dobrá volba pro uživatele nebo společnosti, kteří hledají nízké poplatky za transakce, snadnou implementaci a přístup k největším trhům. Díky těmto výhodám byla zvolena Binance API pro účely projektu, kterého je tato diplomová práce součástí.

Dále budou popsány základní prvky a funkcionality, které Binance API poskytuje. Nejprve bude jednoduše popsáno, jak získat přístup k Binance API a jak vytvořit jednoduchý požadavek. Následně budou popsány možnosti, jakými je možno získávat data o obchodech. Nakonec bude zmíněno, jaké obchodní příkazy je možno za využití API vytvořit.

4.2.2.2.1 Zprovoznění a autentifikace Pro zprovoznění Binance API je prvním krokem generace API klíče, která musí proběhnou manuálně po přihlášení do Binance portálu. Portál uživateli poskytne API key a secret key, které jsou dále využity k autentifikaci při vytváření požadavku na API. Při zakládání požadavku je zapotřebí poskytnout API key a podepsat požadavek pomocí vygenerovaného secret key. [67]

```
1 import requests, hashlib, hmac, time
2
3 # funkce pro vytvoření podpisu
4 def generate_signature(data):
5     signature = hmac.new(API_SECRET.encode('utf-8'), data.encode('utf-8'), hashlib
          .sha256).hexdigest()
6     return signature
7
8 # funkce pro odeslání GET požadavku na API
```

```python
def send_signed_request(endpoint, params):
    params['timestamp'] = int(time.time() * 1000) # timestamp v milisekundách
    param_str = '&'.join([f"{k}={v}" for k, v in params.items()]) # převod
        parametrů na text
    signature = generate_signature(param_str) # vytvoření podpisu
    params['signature'] = signature
    headers = {"X-MBX-APIKEY": API_KEY} # nastavení API klíče v hlavičce
    response = requests.get(f"https://api.binance.com{endpoint}", params=params,
        headers=headers) # odeslání GET požadavku
    return response.json()

endpoint = '/api/v3/ticker/price'
params = {'symbol': 'BTCEUR'}
response = send_signed_request(endpoint, params)
```

Výpis 4.1: Příklad jednoduchého volání API s autentifikací [67]

Jednoduchý příkaz pro získání aktuální ceny obchodovaného páru je znázorněn na výpisu kódu 4.1 psaného v programovacím jazyce Python. Primárně se jedná o ukázku autentifikace, která ukazuje, jak je generován podpis a jak mají vypadat parametry a hlavička požadavku na cílovou Binance API. GET příkazy na obecná obchodní data nepotřebují autentifikaci, regulace požadavků je založena na zdrojové IP adrese uživatele, tím pádem nedojde k nadbytečnému využívaní API neautentifikovaných uživatelů. Odpověď je ve formátu JSON a pro zmíněný příkaz vypadá následovně:

```
{
  "symbol": "BTCEUR",
  "price": "26267.82000000"
}
```

Toto je pouze jednoduchý příklad požadavku Binance API v jazyce Python. Pro pokročilejší příkazy, větší přehlednost kódu a jednodušší implementaci existují knihovny pro obchodovaní na burze a pro získávání dat z burzy. Tyto knihovny existují pro mnoho programovacích jazyků, například v jazyce Python je to knihovna python-binance.[67]

4.2.2.2.2 Kolekce dat Data obchodů lze získat několika způsoby. První způsob je klasický, který nabízí většina burz, a to získávání dat pomocí API. Data lze získat pomocí GET požadavku na určitou adresu API serveru, například posledních 100 hodinových svíček z obchodovaného páru BTC/EUR je možné získat požadavkem na následující adresu:

`https://api.binance.com/api/v3/klines?symbol=BTCUSDT&interval=1h&limit=100`

Data jsou poskytnuta uživateli ve formátu JSON.

Druhý způsob, kterým Binanace vyniká mezi ostatními, je portál Binance Data Collection (také známý jako Binance Data Vision)[69], který nabízí veškerá data o obchodech (včetně agregovaných dat do svíček) na denní a měsíční bázi. Tato data jsou poskytována v CSV souborech vždy za uplynulé období (tj. za předešlý den u denních hodnot a za předchozí měsíc u měsíčních hodnot). Díky přístupu oddělení historických dat od klasického API je Binance API méně vytížená, protože odkloní požadavky přenosu velkého počtu historických dat na jiný server. Mimo možnost stahování CSV souboru přímo pomocí URL je možno stahovat data z tohoto portálu také pomocí poskytované knihovny.

4.2.2.2.3 Obchodování Binance API nabízí uživatelům široké možnosti i co se týče zadávání různých typů obchodních příkazů a vypracování složitých obchodních strategií. Mezi tyto typy obchodů patří například následující obchodní příkazy:

1. Market Order - objednávka se provede okamžitě za aktuální tržní cenu
2. Limit Order - objednávka se provede za stanovenou limitní cenu
3. Stop-Limit Order - rozšiřuje limitní objednávku o stop loss hodnotu
4. Iceberg Order - umožňuje rozdělit velké objednávky na menší části, které se realizují postupně, aby se minimalizovalo ovlivnění trhu

Pro zadání obchodního příkazu přes Binance API je třeba autentifikovat uživatele pomocí podpisu, který byl ukázaný na výpisu kódu 4.1. Zadání obchodního příkazu je velice podobné, využívá se pouze parametrů požadavku a metody POST na následující URL:

`https://api.binance.com/api/v3/order`

Příklad parametrů obchodu typu Stop-Limit Order je uvedený na výpisu kódu 4.2. Požadavek s takto nastavenými parametry zadá příkaz, který otevře obchodní pozici o velikosti 0.1 BTC v momentě, kdy bude cena měny Bitcoin 25000 Euro. Obchodní pozice bude pojištěna hodnotou stop loss v momentě, kdy hodnota klesne na 24000 Euro.

```
1 {
2   'symbol': 'BTCEUR',
3   'side': 'BUY',
4   'type': 'STOP_LOSS_LIMIT',
5   'timeInForce': 'GTC',
6   'quantity': '0.1',
7   'price': '25000',
```

```
    'stopPrice' : '24000',
    'timestamp': timestamp,
    'signature': signature
}
```

Výpis 4.2: Příklad parametrů při zadávání obchodu do požadavku na API[67]

Zadávání obchodních požadavků přes Binance API je velmi rychlé a spolehlivé díky vysokému výkonu platformy. Navíc umožňuje nastavení různých druhů objednávek, což zvyšuje flexibilitu a ochranu při obchodování. S ohledem na možnosti integrace s běžnými programovacími jazyky a rozsáhlou dokumentací je Binance API vhodné pro většinu uživatelů.

4.3 Uložení historických dat

V následující sekci diplomové práce budou popsány možnosti uložení dat obchodů na burze a následně bude popsána implementovaná možnost v rámci projektu.

Existuje mnoho možností, jak ukládat data k automatickému obchodování. Mezi nejznámější možnosti se řadí relační databáze, NoSQL databáze, souborové systémy nebo úložiště typu data lake. Každá možnost má své výhody a nevýhody a záleží na specifických potřebách a požadavcích.

Relační databáze, jako je MySQL[70] nebo PostgreSQL[71], poskytují tradiční způsob ukládání strukturovaných dat a jsou běžně používány pro ukládání dat obchodů na burze. Na druhou stranu NoSQL databáze, jako je MongoDB[72] nebo Cassandra[73], umožňují ukládat nestrukturovaná nebo polostukturovaná data a jsou vhodné pro ukládání dat, která se často mění. Každý projekt pro automatické obchodování na burze může být založen na jiném přístupu k datům, a tím pádem se může hodit jiný způsob uložení dat. Vzhledem ke skutečnosti, že v rámci projektu, kterého je tato práce součástí, se zpracovává velké množství strukturovaných historických dat, bylo nejlepším řešením zvolit relační databázi, konkrétně byla zvolena MySQL databáze.

Po výběru datového úložiště nastává problém, jak rozdělit data, aby přístup k datům nebyl pomalý nebo aby při přístupu k datům nedocházelo k jejich uzamykání. Obecně se doporučuje oddělovat obchodované páry do jednotlivých tabulek v rámci jedné databáze. Toto řešení umožňuje lepší organizaci a snadnější správu dat. Při ukládání všech obchodovaných párů do jedné tabulky by mohlo docházet k problémům s výkonem a efektivitou dotazů na data, zejména v případě velkého objemu dat. Uložením všech dat do jedné tabulky by také vznikala velká šance uzamknutí tabulky, a tím by mohlo dojít k chybám při čtení či zápisu. Na druhou stranu, ukládání každého páru do samostatné databáze by mohlo být náročnější na správu a údržbu databází.

V rámci implementace projektu byla zvolena varianta, kdy každý obchodovaný pár disponuje samostatnou databází. V databázovém systému se nachází navíc ještě jedna databáze, která obsahuje hlavní nastavení a procedury, které dále pracují s obchodovanými páry přes všechny ostatní data-

báze. Veškerá správa dat je tedy situovaná do samostatné databáze. Databázový systém momentálně obsahuje data skoro 1 600 obchodovatelných párů.

4.3.1 Datový model

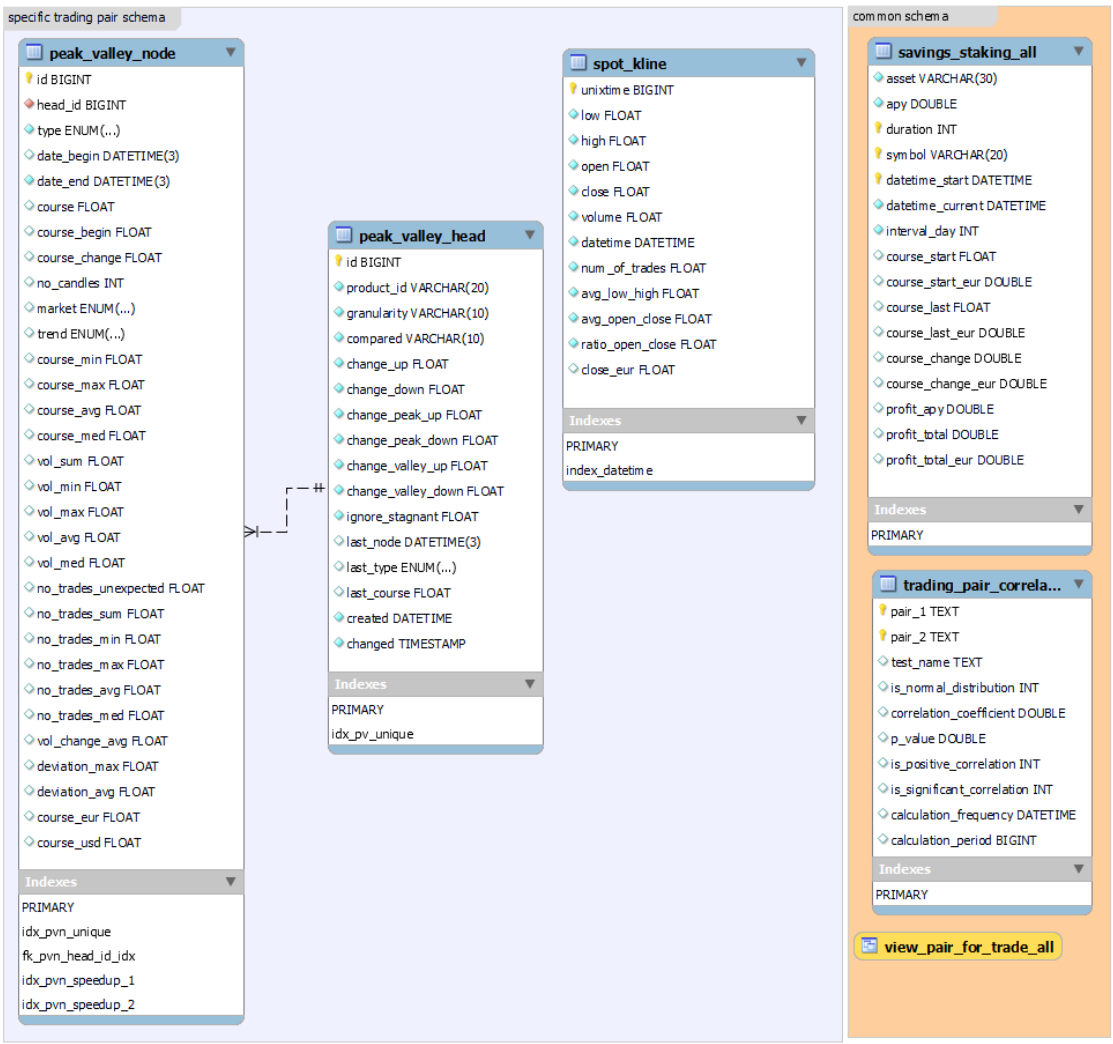

Obrázek 4.1: ERD využívaných tabulek v databázi

Z celé databáze je pro analýzu časových řad zapotřebí jen několik tabulek. Využité tabulky v rámci této práce jsou znázorněny na schématu vyobrazeném na obrázku 4.1.

V pravé části schématu jsou vyobrazeny tabulky společné databáze. Tabulka vlevo nahoře `savings_staking_all` a pohled `view_pair_for_trade_all` jsou dále využity k detekci nejvíce obchodovaných párů. Tyto páry disponují informací o profitu Binance spoření a data jsou využity k porovnání různých strategií spoření. Tabulka `trading_pair_correlation` je využita k ukládání podobných párů.

Levá část diagramu ukazuje využívané tabulky v databázích dedikovaných jednotlivým obchodovaným párům. Tabulky `peak_valley_node` a `peak_valley_head` slouží k ukládání informací o lokálních extrémech. Nejvyužívanější tabulka při analýze časových řad je `spot_kline`, kde jsou uloženy veškeré informace o obchodech daného páru agregovaných do minutových svíček.

4.3.2 Optimalizace databáze

Automatické obchodovaní na kryptoměnové burze vyžaduje velké množství dat. Při implementaci bylo nutné dobře navrhnout strukturu uložení dat a optimalizovat nejčastější dotazy na databázi implementováním indexů.

Při návrhu bylo myšleno na velké množství dat, kdy momentálně jeden obchodovaný pár má více než 1 200 000 záznamů obchodů agregovaných do minutových svíček. Z tohoto důvodu je logické oddělit data do samostatných tabulek nebo databází. Jak bylo již dříve popsáno, data jednotlivých párů jsou v rámci tohoto projektu oddělena do samostatných databází. Toto řešení optimalizuje přístup k datům a také umožňuje pseudoparalelizaci.

Následně byly pro zrychlení operací implementovány indexy pro nejčastější dotazy. Nejvyužívanější index je `index_datetime` na tabulce `spot_kline`, který je založený na sloupci `datetime`. Sloupec `datetime` je alternativou primárního klíče, který je v databázi veden v unixovém formátu a proto index zde dává možnost vysoké optimalizace dotazů. Dalším indexem, který pomáhá optimalizovat činnost procedur využívající lokální extrémy, je `idx_pvn_unique` na tabulce `peak_valley_node`. Tento index je implementovaný na sloupcích `date_end` a `type` a slouží k rychlému vyhledání vybraných lokálních extrémů podle data.

Kapitola 5

Realizace algoritmů pro zpracování časových řad

Tato kapitola se bude zabývat implementací algoritmů pro hodnocení časových řad a definicí pravidel pro automatizovaných nákup a prodej kryptoměn. Využity budou teoretické poznatky a infrastruktura, které byly sepsány v předešlých kapitolách této diplomové práce.

V rámci samotné implementace algoritmů se jako první rozebere dekompozice časové řady a bude zde popsána implementace algoritmu pro detekci sezónní složky v časové řadě. Dále bude rozebrána detekce anomálií a bude demonstrováno, jak anomálie odstranit z analyzované časové řady. Následně bude zobrazen výpočet autokorelace, korelace jednotlivých párů mezi sebou, výpočet lokálních extrémů a predikce vývoje ceny. V rámci predikce vývoje ceny bude zdokumentována implementace konkrétních modelů, a to modelu ARIMA, ARCH modelu a modelu knihovny Prophet. Tyto modely budou použity k predikci budoucího vývoje ceny kryptoměn.

Závěr této kapitoly bude zaměřen na testování výsledků a ověření účinnosti jednotlivých algoritmů v porovnání s jinými způsoby obchodovaní, mezi které budou například zahrnuty obchody za využití technických indikátorů, strategie hodl či stacking hodl a podobné.

5.1 Implementace algoritmů

5.1.1 Práce s daty

Analýza časových řad byla v rámci této diplomové práce vypracována v programovacím jazyce Python. Veškerá data, která jsou dále zpracovávána, jsou získávána ze serveru, na kterém je provozována MySQL databáze obsahující data k analýze z kryptoměnové burzy.

Jak lze vidět na výpisu kódu 5.1, připojení k databázi je řešeno pomocí knihovny SQLAlchemy[74], která umožňuje jednoduché vytvoření spojení s mnoha druhy databázových systémů. V tomto případě se jedná o připojení na MySQL server pomocí potřebných údajů. Data jsou dále

získávána pomocí metody, která je součástí knihovny Pandas. Tato knihovna umožňuje uchovávat a zpracovávat data v interním tabulkovém formátu zvaný DataFrame.

```
1 import sqlalchemy as db
2 import pandas as pd
3
4 connection_string = 'mysql+mysqldb://<user>:<password>@<host IP>:<port>'
5
6 engine = db.create_engine(connection_string)
7 conn = engine.connect()
8
9 df = pd.read_sql('SELECT * FROM binance_pair_ethbtc.spot_kline WHERE datetime >
      DATE_SUB(NOW(), INTERVAL 90 DAY)', conn)
```

Výpis 5.1: Připojení k databázi v jazyce Python

5.1.2 Dekompozice časové řady

Jakmile jsou získána data z databáze a uložena v paměti ve formě DataFrame, je možné je začít analyzovat. Základní forma analýzy časové řady je její dekompozice na jednotlivé složky. Jednotlivé složky ukážou, s jakými složkami se bude v ostatních algoritmech pracovat, případně, které složky před dalším zpracováváním požadavků předzpracovat.

Pro dekompozici časové řady byla využita knihovna statsmodels, konkrétněji podbalík pro analýzu časových řad "tsa". Z tohoto balíku byla z modulu pro sezónní dekompozici časových řad využita funkce STL, neboli Seasonal and Trend decomposition using Loess. Vstupem tohoto algoritmu je spojitá časová řada s předem určenou frekvencí. Data byla upravena tak, ať neobsahují žádné chybějící hodnoty metodou `ffill()`, která v případě chybějících záznamů v databázi doplní hodnotu poslední známou hodnotou v řadě.

Dekompozice dat časových řad obchodních dat kryptoměn ve formě svíček byla provedena na svíčkách minutových, hodinových a denních. Vzhledem ke skutečnosti, že v databázi projektu již nejsou aktualizovaná denní a hodinová data, bylo nutno data seskupit na databázi, čemuž bylo docíleno SQL dotazem, který je znázorněn na výpisu kódu 5.2. Na tomto příkladu je znázorněn výpis denních svíček za posledních 90 dní. Kryptoměnový trh se mění obrovskou rychlostí, protože je ovlivňován širokou škálou náhodných subjektů. Proto je výpočet omezen pouze na posledních 90 dní, aby se zamezilo ovlivnění těmito náhodnými subjekty.

```sql
SELECT
    DATE(datetime) AS date,
    SUBSTRING_INDEX(GROUP_CONCAT(open ORDER BY datetime), ',', 1) AS open,
    SUBSTRING_INDEX(GROUP_CONCAT(close ORDER BY datetime DESC), ',', 1) AS close,
    MIN(low) AS low,
    MAX(high) AS high,
    SUM(volume) AS volume
FROM binance_pair_{symbol}.spot_kline
WHERE datetime > DATE_SUB(NOW(), INTERVAL 90 DAY)
GROUP BY date;
```

Výpis 5.2: Dotaz na denní svíčky v tabulce s minutovými daty

Seskupování dat na databázi je prováděno také pro hodinová data, kde bylo zapotřebí seskupit data podle data a hodiny zároveň. Zde muselo dojít, oproti denním datům, k následné úpravě dat mimo databázi. Hodinová a minutová data byla omezena kratším časovým intervalem, aby nedocházelo ke zmíněnému ovlivňování analýzy historickými náhodnými jevy.

5.1.2.1 Testování sezónní složky

Sezónní složka je významnou složkou časových řad, tudíž pro další analýzy bylo nutné ověřit existenci sezónní složky. Sezónní složka je lehce rozpoznatelná z grafu, který poskytuje hodnoty z již zmíněné funkce STL. Vzhledem k tomu, že automatické obchodování probíhá momentálně na přibližně 1 350 obchodovatelných párech, je nemožné všechny tyto páry kontrolovat ručně. Z tohoto důvodu byl naimplementován skript, který automaticky zjistí, zda daná časová řada obsahuje sezónní složku, či nikoliv. Pro tento test bylo využito několika ukazatelů:

1. Lokální maxima se objevují v pravidelné periodě
2. V nalezených nejčastějších periodách se objevují pravidelně lokální maxima
3. Velikost vrcholů za využitím Fourierovy transformace pro spektrální analýzu
4. Směrodatná odchylka sezónní složky je výrazně větší, než směrodatná odchylka náhodné složky.

Všechny ukazatele byly testovány na několika sezónních časových řadách, díky kterým byly nastaveny parametry pro určení, zda časová řada sezónní složku obsahuje. U sezónních časových řad jsou aktivní minimálně 3 ze zmíněných 4 ukazatelů. Následně bude popsána implementace těchto ukazatelů.

```python
# dekompozice časové řady
stl = STL(day_klines['close'])
result = stl.fit()

df_seasonal = result.seasonal.to_frame()

# posunutí sezónní složky do kladných hodnot pro výpočet rozdílů
df_seasonal['season'] = df_seasonal['season'] + abs(df_seasonal['season'].min())
df_seasonal['diff_ratio'] = df_seasonal['season'] / df_seasonal['season'].shift(1)
    .fillna(0)
df_seasonal['diff_ratio_before'] = df_seasonal['diff_ratio'].shift(-1).fillna(0)

# nalezení lokálních minim a maxim
df_seasonal['peak_valley'] =df_seasonal.apply(lambda x: 'valley' if x['diff_ratio'
    ] < 1 and x['diff_ratio_before'] > 1 else ('peak' if x['diff_ratio'] > 1 and x
    ['diff_ratio_before'] < 1 else None), axis=1)

df_seasonal = df_seasonal.reset_index()

# analýza pouze lokálních maxim - ponechání pouze hodnot, kde se nachází lokální
    maximum
peaks = df_seasonal[df_seasonal['peak_valley'] == 'peak']
peaks['date_diff'] = peaks['datetime'].shift(-1) - peaks['datetime']
peak_values = peaks['date_diff'].value_counts()

if peak_values.shape[0] > 0 and result.seasonal.std()>result.resid.std():
    # kontrola zda, se lokální maxima objevují v pravidelné periodě
    if peak_values.iloc[0] / peak_values.sum() >= .5:
        print('Most peaks in one period', symbol)

    # kontrola, zda se v nalezených nejčastějších periodách objevují pravidelně
        lokální maxima
    df_most_peaks = df_seasonal[df_seasonal['datetime'] >= peaks.iloc[0]['datetime
        ']].iloc[::peak_values.to_frame().index[0].days]
    if peak_values.iloc[0] / df_most_peaks.shape[0] >= 0.75:
        print('Most values in common period', symbol)
    if peak_values.shape[0] > 1:
```

```
32          df_most_peaks = pd.concat([
33              df_seasonal[df_seasonal['datetime'] >= peaks.iloc[0]['datetime']].iloc
                    [::peak_values.to_frame().index[0].days],
34              df_seasonal[df_seasonal['datetime'] >= peaks.iloc[0]['datetime']].iloc
                    [::peak_values.to_frame().index[1].days]
35          ])
36          if (peak_values.iloc[0] + peak_values.iloc[1]) / df_most_peaks.shape[0] >=
                 0.75:
37              print('Most values in common period 2 ', symbol)
```

Výpis 5.3: Kontrola sezónnosti na bázi lokálních extrémů

Ve výpisu zdrojového kódu 5.3 je znázorněna implementace kontroly na bázi lokálních extrémů. Na řádku číslo 2 se vytváří samotná dekompozice časové řady. Na řádcích 8 - 13 probíhá zjednodušený výpočet lokálních extrémů na sezónní složce za pomocí porovnání s předešlou hodnotou. Tento způsob určí, zda v daném okamžiku došlo k otočení trendu. Následně probíhá zpracování lokálních maxim, ale pouze v případě, kdy má sezónní složka větší směrodatnou odchylku, nežli náhodná složka. Tímto se zabrání nechtěným falešně pozitivním výsledkům pro určení sezónnosti, kdy je nalezená sezónnost přebitá náhodnými jevy. Následuje samotná kontrola zmíněných ukazatelů. První ukazatel je kontrolován na řádku 24, kde probíhá výpočet, zda nejčastější perioda lokálních maxim obsahuje alespoň polovinu všech lokálních maxim. Následuje druhá kontrola řádků, kterou zajišťují podmínky na řádcích 29 a 36. Tyto podmínky pracují s nejčastějšími periodami lokálních maxim a hledají, zda se v sezónní složce nachází lokální maximum v těchto periodách alespoň v 75% případů. Tato kontrola probíhá pro jednu a dvě nejčastější periody zvlášť, aby došlo k co nejpřesnější detekci.

```
1  # využití Fourierovy transformace
2  fft_result = np.fft.fft(day_klines['close'])
3
4  # vytvoření amplitud a standardizování výsledků za pomocí průměrné hodnoty časové
       řady
5  amplitudes = (np.abs(fft_result)/day_klines['close'].mean())
6
7  ########### hledání aplitud okolo nulové frekvence
8
9  # odstranění aplitud okolo nulové frekvence
10 amplitudes = amplitudes[ampl_to_ignore:len(amplitudes)-ampl_to_ignore_end]
11 max_amplitude = np.max(amplitudes)
12
```

```
13 # určení významnosti nejvýraznější frekvence
14 if max_amplitude > 10:
15     print('Fourier', symbol, max_amplitude)
```

Výpis 5.4: Kontrola na bázi Fourierovy transformace

Výpis kódu 5.4 znázorňuje část implementace, která využívá spektrální analýzu za pomocí Fourierovy transformace. K výpočtu byla využita knihovna Numpy a následně byl výstup standardizován za pomocí průměrné hodnoty časové řady, aby došlo k sjednocení výsledků mezi všemi obchodovanými páry nezávisle na jejich obchodované ceně. Pro nalezení významné periody byly také odstraněny amplitudy okolo nulové frekvence. Tohoto bylo dosaženo nalezením nejbližších postupně klesajících hodnot nebo hodnot pomalu klesajících, kdy byl rozdíl oproti předešlé hodnotě menší, než 0,5%. Data Fourierovy transformace jsou znázorněna na obrázcích 5.1a a 5.1b, kde je také znázorněno odstranění nerelevantních hodnot. Následně se využívá maximální amplitudy, kdy koeficient pro nalezení významné periody byl nastaven na hodnotu 10 za využití nabytých poznatků z analýzy reálných sezónních dat.

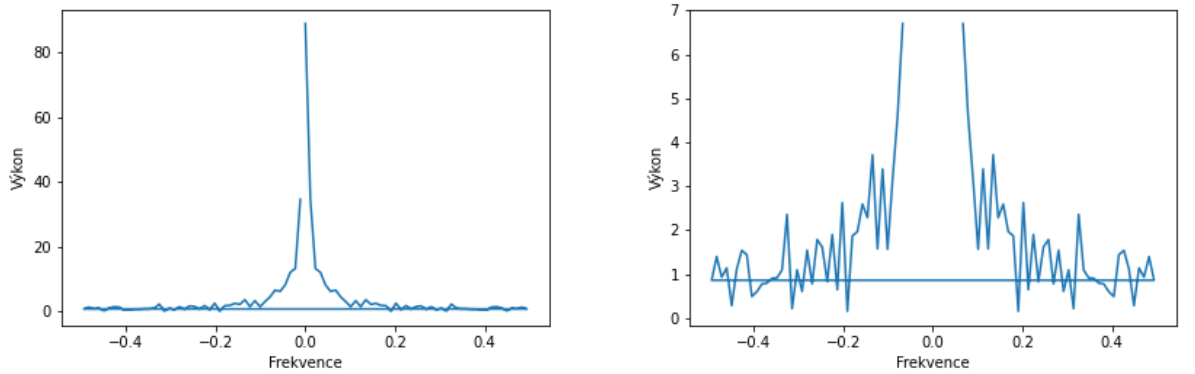

(a) Před odstranění amplitud okolo nulové frekvence (b) Po odstranění amplitud okolo nulové frekvence

Obrázek 5.1: Fourierova transformace

Poslední ukazatel je znázorněný na výpisu kódu 5.5, kde probíhá pouze kontrola směrodatné odchylky. Po testování na reálných sezónních časových řadách byl koeficient kontroly nastaven na hodnotu 1.5, která udává významnost ukazatele v případě, že je směrodatná odchylka sezónní složky minimálně 1.5x vyšší, než směrodatná odchylka náhodné složky.

```
1 # nalezení významné sezónní složky v porovnání s náhodnou složkou
2 if result.seasonal.std()/result.resid.std() > 1.5:
3     print('Seasonal higher than resid', symbol)
```

Výpis 5.5: Kontrola významnosti sezónní složky

Testování ukazatelů bylo provedeno na právě obchodovaných párech, kterých bylo v době analýzy 1 356. Pro všechny tyto páry byly vypočítány zmíněné ukazatele. Výsledky testu jsou znázorněny v tabulce 5.1. Pořadí ukazatelů je stejné, jako v seznamu zmíněném na začátku této sekce. Jediný ukazatel, který se v datech kryptoměn ukazoval aktivní, byl výpočet amplitud za pomocí spektrální analýzy přes Fourierovu transformaci.

Svíčky	ukazatel 1	ukazatel 2	ukazatel 3	ukazatel 4
Minutové	0	0	7	0
Hodinové	0	0	28	0
Denní	0	0	29	0

Tabulka 5.1: Výsledky ukazatelů pro detekci sezónní složky

Následně byly manuálně analyzovány páry, pro které vyšel pozitivní ukazatel sezónnosti, a bylo zjištěno, že se v těchto datech sice objevuje pravidelná sezónní složka, ale je zanedbatelná, nebo zastíněna velkou náhodnou složkou. Z těchto poznatků je možno usuzovat, že data, se kterými tento projekt pracuje, neobsahují sezónní složku nebo ji mají zanedbatelnou. Příklad sezónní složky s uvedenými vlastnostmi je znázorněn na obrázku 5.2. Sezónní složka obsahuje v části řady opakující se vzory, ale i tak je náhodná složka dvojnásobná oproti sezónní a vliv sezónní složky na originální řadu je zanedbatelný.

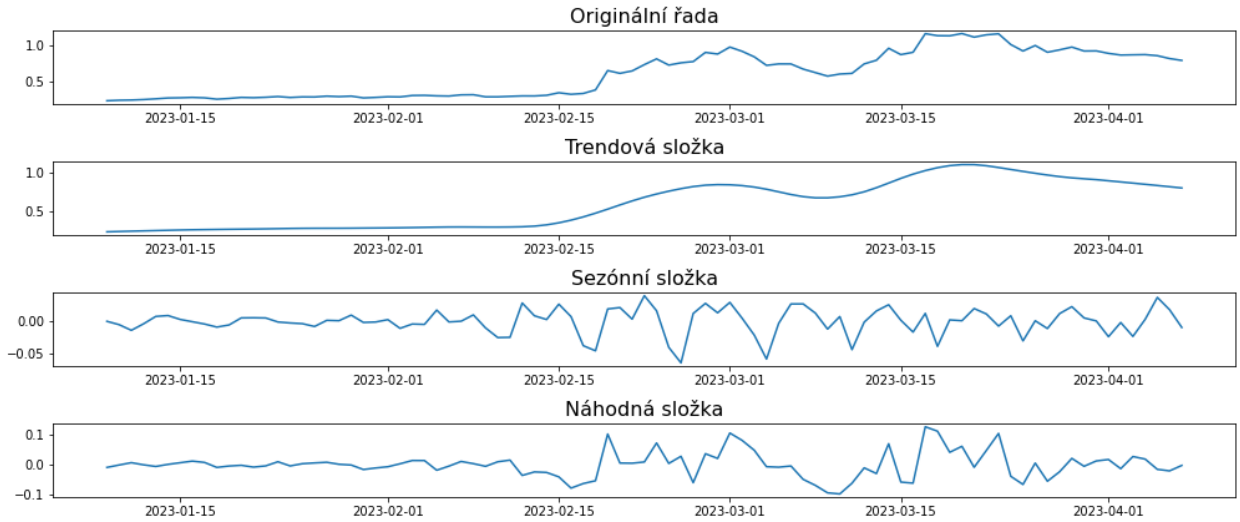

Obrázek 5.2: Detekovaná sezónní složka pomocí Fourierovy transformace

5.1.3 Detekce anomálií a jejich zpracování

Po zjištění skutečnosti, že časové řady s daty cen kryptoměn na burze neobsahují významnou sezónní složku, je možno využít dekompozici časové řady na detekci anomálií a jejich odstranění. Odstranění anomálií zajistí přesnější odhady ceny do budoucna, protože nebudou ovlivněny daty s nadstandardní náhodnou složkou.

Detekce a odstranění anomálií, které bylo implementováno v rámci této diplomové práce, je vyobrazeno na výpisu kódu 5.6. Při detekci je třeba zvolit správnou konfiguraci, aby se za anomálie nepovažovaly náhodné odchylky, které jsou v pravidelně opakující se velikosti. Proto zde bylo využito průměru, od kterého byla hranice stanovena na dvojnásobnou velikost směrodatné odchylky. Průměr se v případě náhodné složky blíží k nule, ale pro větší přesnost výsledků je zde započítán. Ve výpisu kódu je možno pozorovat, že anomálie byly první uloženy jako samostatný DataFrame, který byl následně připojen k původnímu, kde došlo k nahrazení anomálií následujícími hodnotami.

```
1  resid_mu = resid.mean()
2  resid_dev = resid.std()
3
4  lower = resid_mu - 2*resid_dev
5  upper = resid_mu + 2*resid_dev
6
7  anomalies = day_klines[(resid < lower) | (resid > upper)]
8
9  anomalies['Anomaly'] = True
10 day_klines = day_klines.join(anomalies['Anomaly'])
11 day_klines = day_klines.apply(lambda x: x if pd.isna(x['Anomaly']) else [None]*len
       (x), axis =1)
12 day_klines = day_klines.fillna(method='bfill')
```

Výpis 5.6: Detekce anomálií

Detekce anomálií je dále znázorněna na následujících 3 grafech. Na obrázku 5.3 je zobrazena náhodná složka časové řady a zelené pásmo zobrazující hodnoty průměru s přičtením dvojnásobku směrodatné odchylky. Následující obrázek 5.4 zobrazuje časovou řadu, kde jsou červeně zaznačeny detekované anomálie zmíněnou metodou. Poslední obrázek 5.5 zobrazuje stejnou časovou řadu po odstranění anomálií.

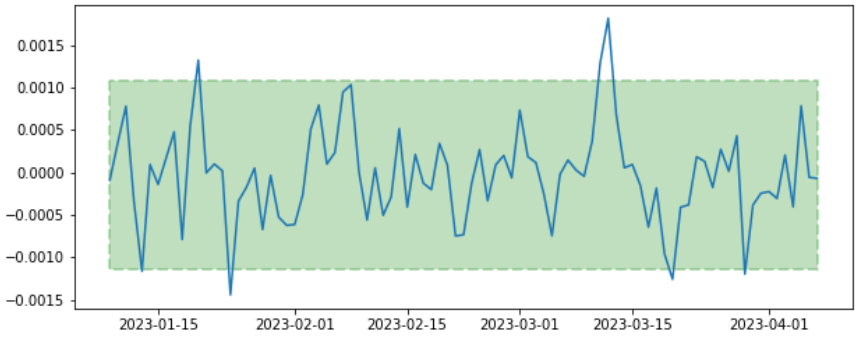

Obrázek 5.3: Detekce anomálií na náhodné složce časové řady

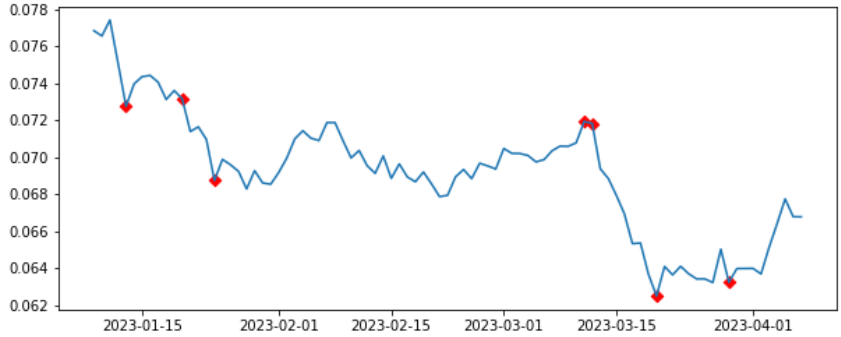

Obrázek 5.4: Zobrazení anomálií na původní časové řadě

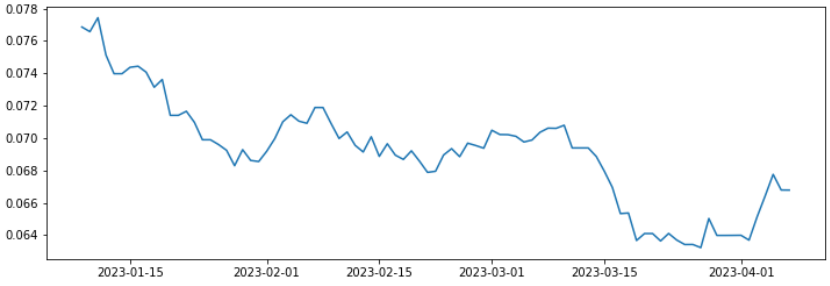

Obrázek 5.5: Časová řada po odstranění anomálií

5.1.4 Autokorelace

Autokorelace časové řady má určitý význam i v případě, že řada nemá významnou sezónní složku a může být užitečná pro některé metody modelování řady. Konkrétně, autokorelace může pomoci určit, zda v časové řadě existuje nějaká závislost na minulých hodnotách a jaký je případně rozsah

této závislosti. Například, pokud má časová řada vysoké hodnoty autokorelace pro několik po sobě jdoucích zpoždění, může to znamenat, že vývoj řady v určitém časovém období je podobný vývoji v minulosti. Dále může autokorelace pomoci při výběru vhodného autoregresivního modelu pro predikci časové řady. Autokorelační funkce může ukázat, které zpoždění jsou statisticky významné a následně se zahrnou do autoregresivních modelů.

V rámci implementace projektu této diplomové práce bylo využito metody částečné autokorelace, která je součástí knihovny Statsmodels a autokorelační funkce naimplementované za pomocí knihovny Numpy, aby došlo k větší diverzitě parametrů. Na výpisu kódu 5.7 je znázorněn postup. Nejdříve proběhl výpočet změny oproti předešlé hodnotě, který je důležitý pro autokorelační analýzu. Následně byla funkce `pacf` využita pro získání parametru q, který bude sloužit jako vstup do modelů predikujících vývoj ceny v budoucnu. Spolu s parametrem q je vypočítán také parametr p za pomocí korelační funkce. Parametry p a q jsou vypočítány vždy jako největší korelační koeficient pro danou funkci od třetí hodnoty (zabránění započítání hodnot, které nejsou adekvátní pro další vstupy). Ve většině případů se dané parametry budou rovnat. Autokorelace je počítána pouze pro 21 hodnot. Toto číslo bylo zvolené pro maximální třítýdenní autokorelaci. Vysoké hodnoty koeficientů výrazně ovlivní výkonnost řešení a není doporučeno je využívat v případě, že není významná sezónní složka.

```
day_klines['change'] = 100*day_klines['close'].pct_change().fillna(0)
max_days_back = 21

pacf_values = pacf(day_klines['change'], nlags=max_days_back)
q = abs(pacf_values[2:]).argmax() + 2

def correlate(data):
    mean=data.mean()
    var=np.var(data)
    data_normalize=data-mean
    corr=np.correlate(data_normalize,data_normalize,'full')
    return corr[len(data)-1:]/var/len(data)

day_klines['correlation_index'] = correlate(day_klines['change'])
pacf_values = day_klines['correlation_index'].head(max_days_back).array
p = abs(pacf_values[2:]).argmax() + 2
```

Výpis 5.7: Implementace autokorelace a částečné autokorelace

Na obrázku 5.6 je znázorněna funkce částečné korelace modře a získané parametry p a q červenou přerušovanou čarou, které se v tomto případě oba rovnají hodnotě 9 a ukazují na nejvýznamnější

autokorelační koeficient. V tomto případě se jedná o zápornou hodnotu koeficientu, která naznačuje, že se pro tento koeficient vyskytuje významná záporná korelace.

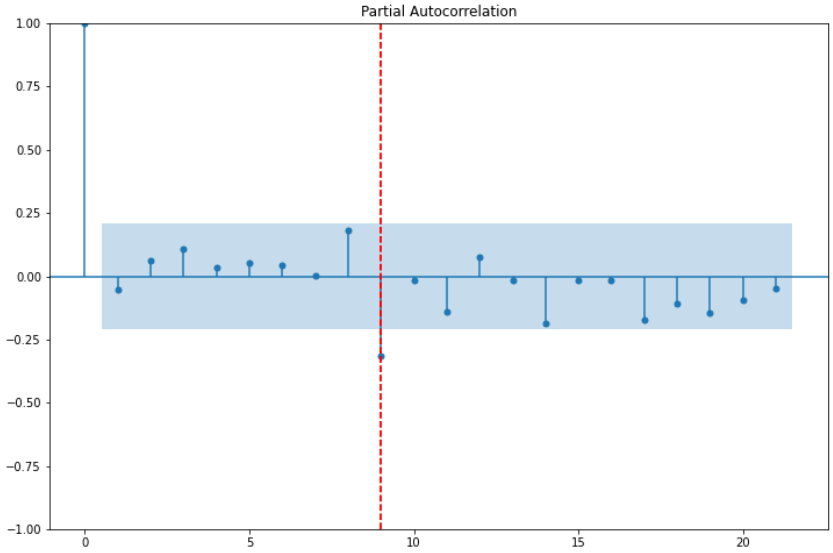

Obrázek 5.6: Vykreslení částečné autokorelace

5.1.5 Korelace párů - podobné páry

Tato podkapitola se zaměřuje na analýzu korelace mezi páry obchodovaných kryptoměn a identifikaci podobných párů. Jsou zde prezentovány metody statistické analýzy, které umožňují měřit míru korelace mezi časovými řadami cenových dat různých finančních instrumentů. Dále je popsáno, jakým způsobem lze na základě těchto analýz identifikovat podobné páry, které vykazují podobné vzory pohybu cen a mohou být využity pro automatizované obchodování.

Na diagramu 5.7 je znázorněn průběh celého skriptu pro výpočet korelace párů. Nejdůležitější částí celého skriptu je aktivita pojmenovaná: Výpočet korelačního koeficientu pro jednotlivé páry. Tato aktivita bude následně přiblížena a bude vypsán zdrojový kód výpočtu.

Pro otestování korelace mezi jednotlivými obchodními páry se využívají korelační testy. Nejběžnější jsou Pearsonův[75] a Spearmanův[76] korelační test, kdy výběr využitého testu závisí na distribuci dat. Data z kryptoměnové burzy mohou mít nenormální rozdělení a mohou obsahovat výrazné odlehlé hodnoty, což může vést k porušení předpokladů pro Pearsonův korelační koeficient. Na druhé straně, Spearmanův korelační koeficient se vypočítává ze samotného pořadí hodnot, což umožňuje jeho použití pro datové sady nesplňující normalitu. Spearmanův korelační koeficient také lépe zachycuje nelineární vztahy mezi proměnnými.

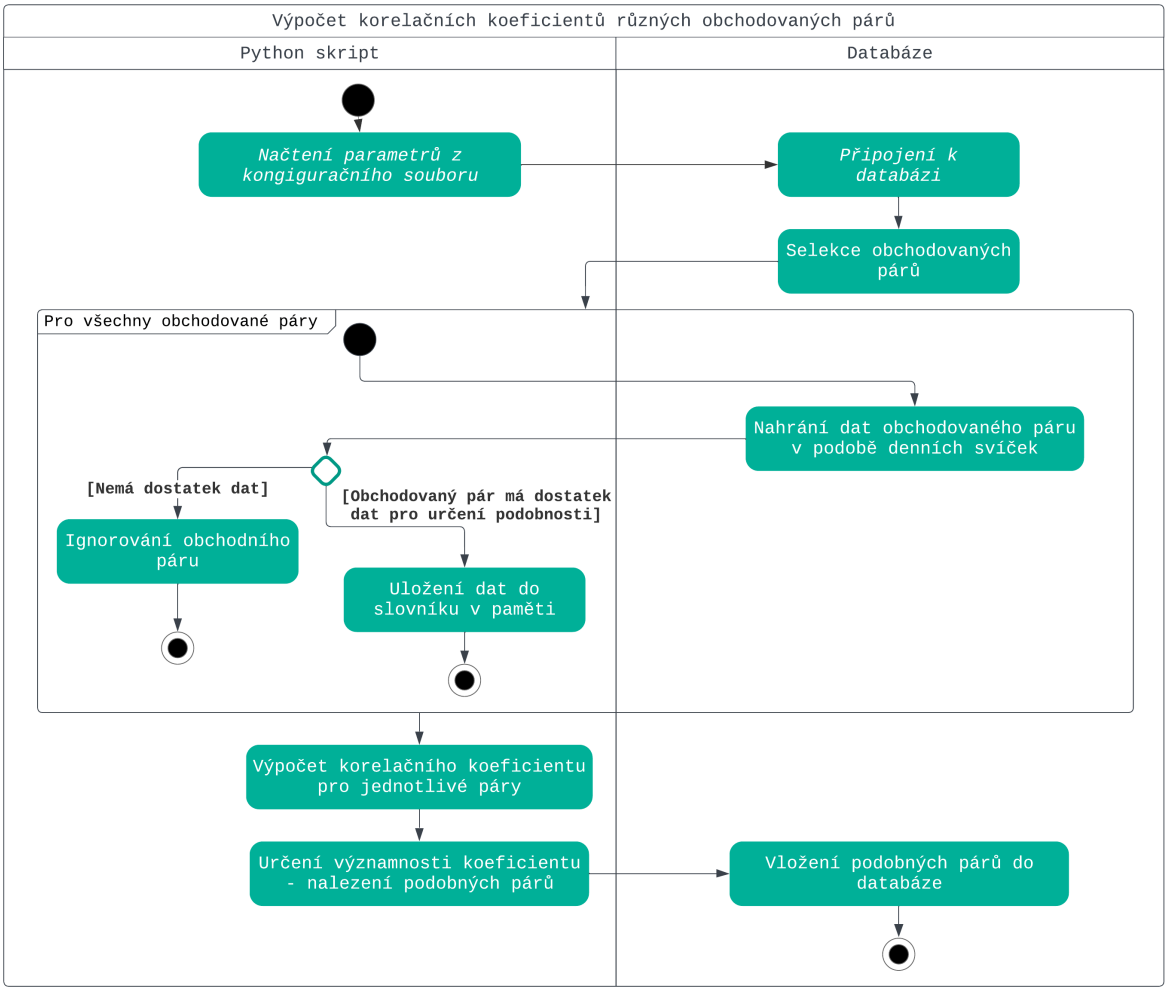

Obrázek 5.7: Diagram aktivit pro určení podobnosti párů korelačním koeficientem

Na výpisu kódu 5.8 je znázorněna samotná implementace korelačních koeficientů. Korelace páru je založena na porovnání párů každý s každým, kdy porovnávané páry musí mít ekvivalentní délku časové řady. Následně byl implementován Shapirův-Wilkův test [77], který ověřuje normalitu dat pomocí testování hypotézy, která předpokládá, že data pocházejí z normálního rozdělení. Dle výsledků Shapirova-Wilkova testu se statistickou významností 95% je využit pro výpočet korelačního koeficientu Pearsonův nebo Spearmanův test. Veškeré testy jsou využity z knihovny SciPy[78].

```
correlation = []

for symbol_1,pair_1 in pairs.items():
  for symbol_2,pair_2 in pairs.items():
    if len(pair_1) != len(pair_2) or symbol_1 == symbol_2:
      continue

    pair_data = {
      'pair_1' : symbol_1,
      'pair_2' : symbol_2,
      'test_name' : 'Spearman',
      'is_normal_distribution' : False,
      'correlation_coefficient' : 0,
      'p_value' : 0
    }

    # ověření normálního rozdělení dat
    if shapiro(pair_1)[1] > 0.05 and shapiro(pair_2)[1] > 0.05:
      pair_data['test_name'] = 'Pearson'
      pair_data['is_normal_distribution'] = True
      pair_data['correlation_coefficient'], pair_data['p_value'] = pearsonr(pair_1
          , pair_2)
    else:
      pair_data['correlation_coefficient'], pair_data['p_value']= spearmanr(pair_1
          , pair_2)

    correlation.append(pair_data)
```

Výpis 5.8: Hledání podobných párů

Pro určení, zda jsou dva obchodované páry podobné, bylo využito hodnoty koeficientu, který se pohybuje v rozmezí od -1 do 1. V případě, že se koeficient blíží k 1, je možno konstatovat, že se jedná o statisticky významnou kladnou korelaci. V opačném případně, kdy se korelační koeficient blíží -1, je možno uvažovat o statisticky významné záporné korelaci. V případě implementace pro tento projekt byla zvolena hranice významnosti 0.8.

Nicméně, i když je korelace statisticky významná, nemusí znamenat, že existuje skutečný vztah mezi časovými řadami. Může to být způsobeno například výraznými odlehlými hodnotami nebo jinými faktory, které ovlivňují data a vytvářejí zdánlivou korelaci.

5.1.6 Lokální extrémy

Analýza lokálních extrémů v časových řadách může být užitečná pro odhalení určitých vlastností časové řady, jako jsou například změna trendu nebo náhodné fluktuace. Lokální extrémy představují body, kde se směr trendu mění. V rámci projektu, který je součástí této diplomové práce, se uvažuje o lokálních extrémech, které se od předešlého liší alespoň o jeden procentní bod. Lokálních extrémů bude menší množství a mohou lépe indikovat změnu celkového trendu, než jen malé odchylky.

Výpočty lokálních extrémů byly již v rámci projektu implementovány jako uložené procedury pro každý obchodovaný pár, jejichž výpočet probíhá každý den. Úkolem bylo ověřit správnost a konzistentnost výpočtů.

Ověření konzistence výpočtů probíhalo zavoláním uložené procedury nad daty pro několik různých časových období. Data byla postupně ukládána do lokálních souborů. Soubory byly následně spojeny v jazyce Python. Výpočty, které provádí uložená procedura, jsou konzistentní, ukázalo se pouze, že se data liší jen v prvním lokálním extrému a dále jsou totožné. Rozdíl dat v prvním výpočtu je logický, neboť každá procedura začala počítat od jiného data.

Ověření správnosti výpočtů probíhalo způsobem implementace nové metody v jazyce Python a srovnání výsledků s vypočítanými hodnotami na straně databáze. Na výpisu kódu 5.9 je znázorněna část cyklu, která je zodpovědná za nalezení extrémů. Jedná se pouze o vybranou část kódu pro popsání logiky, kód samotný není úplný a po spuštění by nevrátil plnohodnotná data.

Funkce má nastavitelné parametry, podle kterých vrátí spočítané lokální extrémy. Jedná se o parametr `column`, který nastavuje, dle kterého sloupce se vypočítají extrémy a parametr `percentage`, který označuje, jak moc velká procentuální změna musí proběhnout od předchozího lokálního extrému, aby bylo možné hodnotit další lokální extrém. V rámci výpočtů bylo počítáno se sloupcem `close` a 1% rozdílem.

V poli `changes` se vytváří dataset o všech významných lokálních extrémech. Základní logika je založena na předchozím směřování trendu. V případě, že byl doposud trend rostoucí a proběhne pokles od maximální hodnoty, v časovém období od minulého lokálního minima, o více než 1%, nejvyšší hodnota se uloží jako lokální maximum, neboli peak a aktuální trend se nastaví na klesající. Na druhou stranu, pokud byl doposud trend klesající a hodnota naroste od minimální hodnoty, v časovém období od minulého lokálního maxima, o více než 1%, hodna se uloží jako lokální minimum, neboli valley a aktuální trend se nastaví na rostoucí. Z výsledného pole je následně vytvořen dataset, který je připojen k analyzovanému původnímu datasetu, aby mohly být zkontrolovány výsledky.

```
1 for i, param in merged.set_index('datetime')[column].items():
2   ratio = (param / changes[changes_index]['course'])-1
3
4   if changes[changes_index]['type'] == 'increasing':
5     if ratio*-1 > percentage:
6       changes[changes_index]['type'] = 'peak'
```

```
7         changes.append({
8           'type' : 'decreasing',
9           'date_begin' : changes[changes_index]['date_end'] + pd.Timedelta(
                time_offset),
10          'date_end' : i,
11          'course': param
12        })
13        changes_index += 1
14
15    elif changes[changes_index]['type'] == 'decreasing':
16      if ratio > percentage:
17        changes[changes_index]['type'] = 'valley'
18        changes.append({
19          'type' : 'increasing',
20          'date_begin' : changes[changes_index]['date_end'] + pd.Timedelta(
                time_offset),
21          'date_end' : i,
22          'course': param
23        })
24        changes_index += 1
```

Výpis 5.9: Hledání lokálních extrémů

Výsledky algoritmu byly následně srovnány s výsledky vypočítanými již dříve implementovanou uloženou procedurou. Ve většině případů algoritmy vrátily totožné hodnoty, ale bylo nalezeno několik nedostatků, které původní procedura nepočítá správně. Příklad srovnání je uveden v tabulce 5.2. V tabulce je znázorněn jeden příklad lišícího lokálního maxima a jeden příklad odlišně vypočítaného lokálního minima. V obou případech se jedná o chybný výpočet na straně uložené procedury. Výpočet nově implementovaným algoritmem ukázal, že v případě lokálního minima nalezne nižší hodnotu a v případě lokálního maxima vrátí vyšší hodnotu. Tato data ukazují, že nový výpočet je přesnější.

čas	typ procedura	kurz procedura	typ python	kurz python
4/26/2022 19:50			maximum	36125.2
4/26/2022 19:52	maximum	36109.9		
4/27/2022 8:50			minimum	36558.9
4/27/2022 11:27	minimum	36561.0		

Tabulka 5.2: Rozdíl ve výpočtu algoritmů lokálních extrémů

Pro srovnání výpočtů na více datech bylo implementováno několik metrik, které ukazují, jak se od sebe algoritmy liší. První metrika se zabývá skutečností, kdy jeden algoritmus určil přesnější lokální extrém - u lokálního minima menší hodnotu a u lokálního maxima vyšší hodnotu. Druhá metrika je založena na nalezení více lokálních extrémů pro stejné nastavení.

symbol	Proc. přesnější	Python přesnější	Proc. chybí	Python chybí	Python celkem
dodobtc	0	557	253	0	8099
bnbaud	0	167	43	0	2969
xlmeur	0	214	66	0	3759
manabtc	0	262	64	0	3517
scrtbtc	0	457	190	0	5456
powrusdt	0	521	94	0	5542
nulsusdt	0	890	304	1	8173
bnbupusdt	0	983	300	0	10218
nexobtc	0	523	188	0	6375
etheur	0	331	49	0	3612
forthbtc	0	690	361	1	8809
funeth	0	107	79	6	3412
kncbusd	0	651	176	0	7972
ltobusd	0	635	456	0	8626
zecbusd	0	333	142	0	6094
santosbtc	0	1317	411	0	10987
betausdt	0	1224	366	0	10440
radbtc	0	683	333	1	8095

Tabulka 5.3: Porovnání algoritmů na výpočet lokálních extrémů

Výpočet byl prováděn na 18 náhodných právě obchodovaných párech a byla využita minutová data za posledních 365 dní. V tabulce 5.3 je jasně vidět, že nově implementovaný algoritmus nabízí mnohem přesnější data a nachází více lokálních extrémů pro stejné nastavení. Z dat vychází, že přibližně 11% výpočtů prováděných na straně databáze ve formě uložené procedury byl nepřesný. Byla nalezena chyba ve výpočtech na straně uložené procedury. Tato chyba byla opravena a výsledky byly znovu zkontrolovány. Nyní procedura nachází totožné lokální extrémy, jako implementovaná funkce v jazyce Python.

5.1.7 Predikce vývoje ceny

Poslední sekce této diplomové práce, před konečným testováním výsledků, se bude věnovat predikci budoucích cen na burze. Pro predikci bude využit nejznámější autoregresivní model ARIMA, který bude doplněný o model ARCH, který pomůže predikovat volatilitu trhu. Pro potvrzení predikce cen bude také implementován model Prophet. V textu práce bude sepsána pouze práce na denních svíčkách, která se při testování ukázala jako nejpřesnější z minutových, hodinových a denních dat.

5.1.7.1 Model ARIMA

Pro implementaci predikce modelu ARIMA bylo využito knihovny Statsmodels, která poskytuje naimplementovaný model. Pro zvýšení přesnosti modelu je důležité zakládat model na stacionární časové řadě. K predikci byla využita změna ceny oproti minulé hodnotě, která má předpoklady být stacionární časovou řadou. Pro ověření stacionarity byl využit Augmented Dickey–Fuller test, který je také součástí knihovny Statsmodels. Test spočívá v testování hypotézy, že časová řada obsahuje trvale rostoucí nebo klesající trend a není stacionární. Pokud nulová hypotéza není zamítnuta, pak se řada považuje za nestacionární. Naopak, pokud nulová hypotéza je zamítnuta, pak se řada považuje za stacionární. V případě časové řady změn ceny v čase vychází p-hodnota testu menší, než 0.05, což značí zamítnutí nulové hypotézy a řada se považuje za stacionární.

Jak je vidět na výpisu kódu 5.10, nejdříve byl určen počet dní, na který má model predikovat vývoj ceny. Dataset byl následně zmenšen o zmíněný počet dní. Toto řešení je pouze pro testování, aby bylo možno vizualizovat predikci s porovnáním s reálnými daty. Vstupem do modelu ARIMA jsou také parametry p a q, které byly získány v rámci autokorelace a částečné autokorelace. Prostřední parametr d zůstává na nule, jelikož byla již dříve prokázána stacionarita časové řady. Od řádku číslo 12 ukazuje kód přepočítání predikované změny v ceně na predikovanou cenu.

```
1  train_end = day_klines.index.max() - pd.Timedelta(days=DATA_PREDICTION_DAYS)
2  train_data = day_klines['change'][:train_end]
3
4  model = ARIMA(train_data, order=(p,0,q), freq='D')
5  model_fit = model.fit()
6
7  # predikce změny
8  forecast = model_fit.forecast(steps=predict_steps)
9
10 # získání predikované ceny
11 last_close = day_klines[day_klines.index == train_end]['close'].iloc[0]
12
13 forecast_close = []
14 for change in list(forecast):
15     last_close += change
16     forecast_close.append(last_close)
17 forecast_df = forecast.to_frame()
18 forecast_df['close_forecast'] = forecast_close
```

Výpis 5.10: Predikce pomocí modelu ARIMA

Výstupem kódu je jak predikovaná změna ceny pro dalších 7 dní, tak samotná predikovaná cena. Na obrázku 5.8 jsou tyto predikce (oranžově) vizualizovány v porovnání s reálnou hodnotou (modře). Pro přehlednost jsou vizualizovaná data jen za 21 dní, model byl založen na datech z 90 dnů. Ve vizualizovaném příkladu model nepredikoval náhlý nárůst ceny a výsledná predikovaná cena je nižší, než reálná výsledná cena. Z důvodu snížení rizika obchodování se model ARIMA doporučuje implementovat s modelem ARCH, který bude popsán v následující sekci.

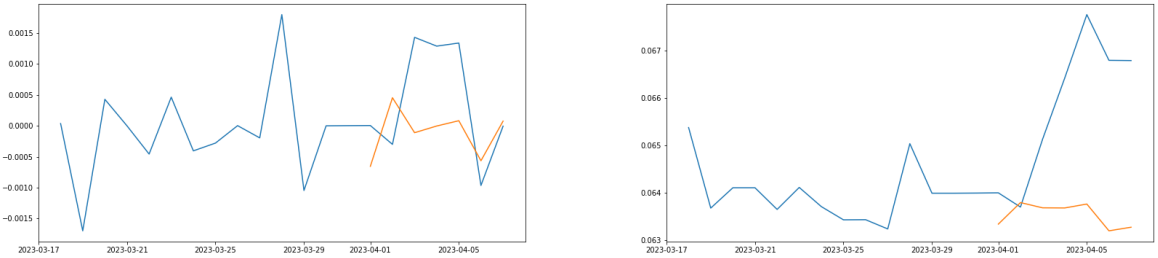

(a) Predikce změny v ceně

(b) Mapování predikce na cenu

Obrázek 5.8: Predikce pomocí modelu ARIMA

5.1.7.2 ARCH model

Použití modelu ARCH (autoregresivní model s heteroskedasticitou) umožňuje analyzovat a predikovat vývoj volatility časových řad, což má velký význam právě v oblasti finanční analýzy. ARCH modely jsou využívány k modelování volatility cen finančních aktiv, mezi které spadají kryptoměny, které jsou součástí této práce. Zvyšující se volatilita může předpovědět jako indikátor budoucího rizika a umožnit tak investorům a obchodníkům adekvátně se přizpůsobit a minimalizovat ztráty.

V práci byl model ARCH implementován na procentuální změně ceny v čase, jak je vidět na výpisu kódu 5.11. Vzhledem k procentuální změně, která je stacionární, byl parametr průměru nastaven na nulu. Využit byl model ARCH a ne model GARCH, který je jeho rozšířenou variantou. GARCH model je vhodný pro situace, kdy volatilita finanční časové řady závisí na vlastní minulé hodnotě řady, ale také na minulé hodnotě volatility, což se u kryptoměnových dat nedá vždy říct. Při testování přesnosti byl přesnější model ARCH. Parametr p je zde využit z výstupu autokorelace.

datetime	h.1	h.2	h.3	h.4	h.5	h.6	h.7
3/31/2023	0.936	0.762	2.037	1.083	2.129	2.036	1.126

Tabulka 5.4: Výstup predikce modelu ARCH

Výstup predikcí volatility modelu ARCH je zobrazen v tabulce 5.4. Sloupec s datem znamená, pro které datum byla data predikována a hodnoty ve sloupcích značí, jakou volatilitu předpovídá model ARCH pro n dní dopředu. V zobrazeném příkladu předpovídá hodnoty pro 7 dní dopředu.

Ve výpisu kódu 5.11 je od řádku číslo 10 ukázána transformace těchto dat do podoby, kdy je možno je dále vizualizovat a zpracovávat ve stejném formátu jako výstupy z ostatních modelů.

```
1 model = arch_model(train_data, mean='ZERO',vol='ARCH', p=int(p))
2 model_fit = model.fit()
3
4 forecast = model_fit.forecast(horizon=DATA_PREDICTION_DAYS)
5
6 last_forecast = forecast.residual_variance.iloc[-1].to_frame().reset_index().melt(
      id_vars='index')
7 last_forecast['index'] = last_forecast['index'].apply(lambda x: x.split('.')[-1])
8 last_forecast['datetime'] = last_forecast.apply(lambda x: pd.to_datetime(x['
      variable']) + pd.Timedelta(days=int(x['index'])), axis=1)
9 last_forecast = last_forecast.set_index('datetime')['value']**(1/2)
```

Výpis 5.11: Predikce volatility pomocí modelu ARCH

Obrázek 5.9 zobrazuje výslednou predikovanou volatilitu (oranžově) mapovanou na reálnou procentuální změnu ceny (modře). Model ARCH oproti modelu ARIMA predikoval následující výkyv v ceně v podobě zvýšené volatility.

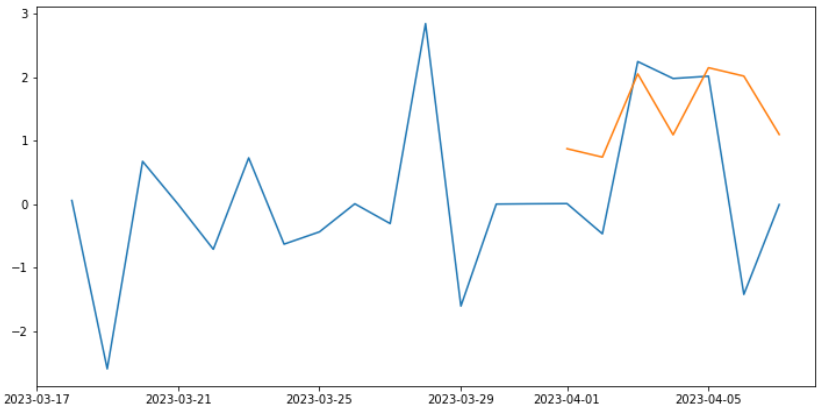

Obrázek 5.9: Predikce volatility pomocí modelu ARCH

5.1.7.3 Knihovna Prophet

Poslední model, který byl v rámci této diplomové práce implementován, byl model od společnosti Meta, dostupný přes známou knihovnu Prophet. Prophet používá přizpůsobitelný lineární model

sestávající z několika komponent, včetně trendu, sezónnosti a regresních předpovědí. Knihovna byla vyvinuta primárně pro aplikace v oblasti digitálního marketingu, ale najde uplatnění i ve finančním odvětví. V projektu byl výstup z toho modelu zamýšlen jako doplňkový výstup k modelu ARIMA.

Implementace predikce s využitím této knihovny je znázorněna na výpisu kódu 5.12. Knihovna vyžaduje předpřipravená data s jednotně pojmenovanými sloupci a její funkčnost je omezena pouze na denní data. Není možné predikci využít pro minutové a hodinové svíčky. Mimo absolutní číslo predikované hodnoty vrátí knihovna také hranice, za které by se následující hodnota neměla dostat. Střední hodnota tohoto rozptylu je vrácena ve sloupci `yhat` a bude dále využita pro testování a výsledky modelu.

```
1 train_data = train_data.reset_index()
2 train_data.columns = ["ds", "y"]
3
4 model = Prophet()
5 model.fit(train_data)
6
7 # Predikce změny pro zvolené období
8 future = model.make_future_dataframe(periods=DATA_PREDICTION_DAYS)
9 forecast = model.predict(future)
```

Výpis 5.12: Predikce pomocí modelu Prophet

Pro vyobrazení predikcí do dat reálných cen měny bylo nutné provést stejnou transformaci, jako bylo popsáno u modelu ARIMA. Jak lze pozorovat na obrázku 5.10, ani predikce za využití modelu Prophet nepredikovala nadcházející nárůst ceny a dosahuje podobných výsledků jako model ARIMA.

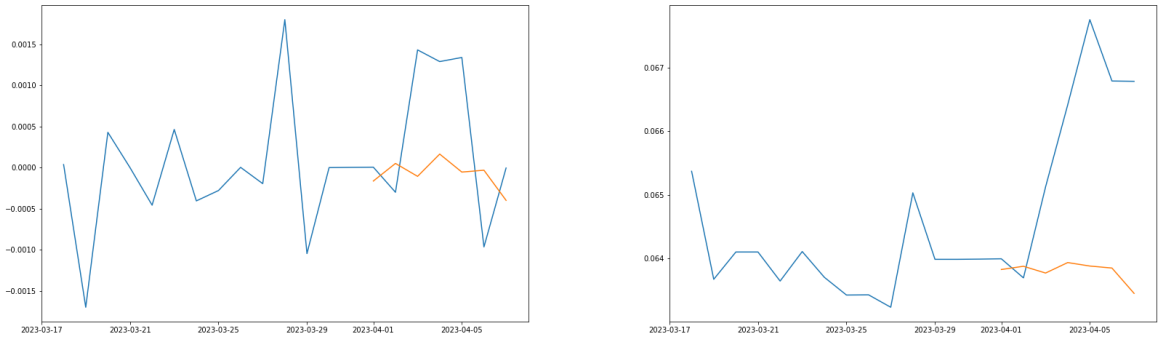

(a) Predikce změny v ceně

(b) Mapování predikce na cenu

Obrázek 5.10: Predikce pomocí modelu Prophet

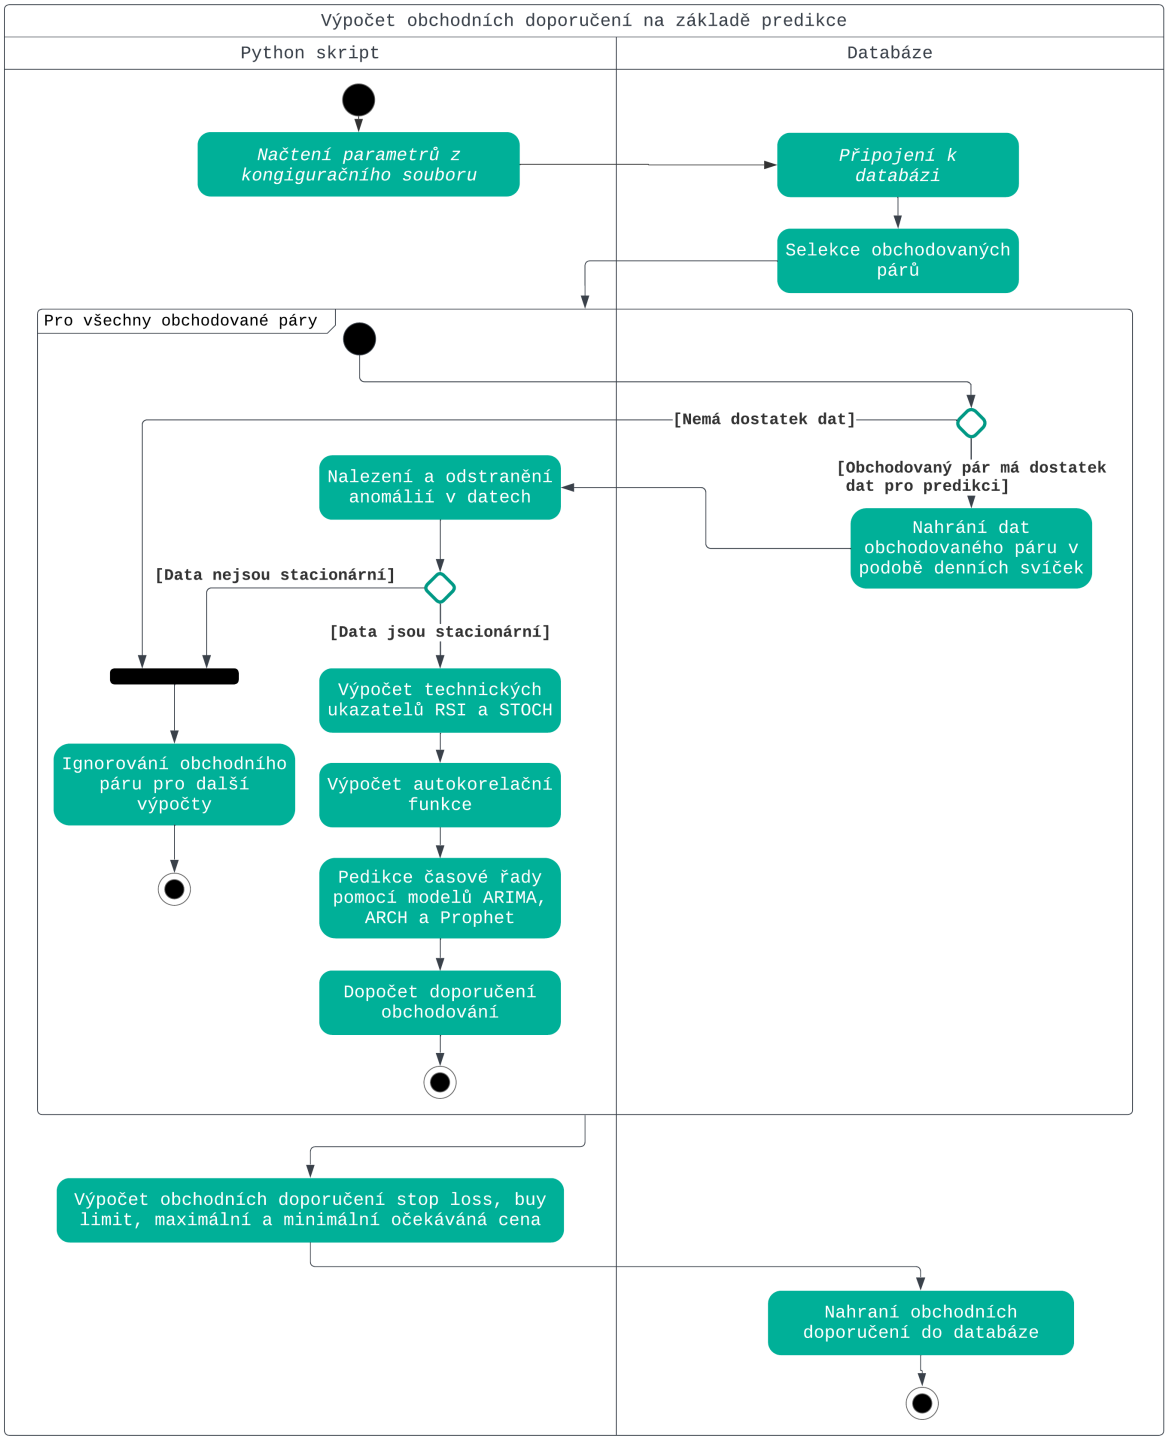

Obrázek 5.11: Diagram aktivit pro určení obchodních doporučení za pomocí predikce

5.1.8 Výsledný algoritmus

Popsané funkce byly následně spojeny do jednoho skriptu, který na denní bázi předpovídá následující vývoj ceny pro obchodované páry. Na diagramu 5.11 je znázorněn průběh aktivit celého skriptu. Dopočet doporučení obchodování bude blíže popsán v kapitole 5.2.1, kde budou také uvedeny části zdrojových kódů, zabývající se uvedenou problematikou.

Výsledné hodnoty jsou ukládány do databáze. Každý den se uloží vypočítané hodnoty pro každý obchodovaný pár, který splnil podmínky pro predikci. Nejdůležitější výsledný atribut je `trade recommendation prediction`, který vyjadřuje samotné doporučení obchodu. Následují atributy `buy limit` a `stop loss`, které určují parametry obchodu. Další parametry ukazují předpovídané hodnoty pro zadané období.

5.2 Testování výsledků

Poslední podkapitola této práce se zaměřuje na testování výsledků automatizovaného obchodování na základě implementovaných algoritmů predikce časových řad. První sekce se zabývá hodnocením prosperity predikčních modelů. Jsou zde prezentovány různé metriky a techniky, které umožňují hodnotit úspěšnost predikcí a zhodnocovat výsledky obchodních strategií na základě těchto predikcí. Druhá sekce se zaměřuje na porovnání výsledků automatizovaného obchodování s využitím predikce časových řad s jinými druhy obchodování, jako je například hodl, americký hodl nebo obchodování s využitím technických ukazatelů. Jsou zde diskutovány výhody a nevýhody využití analýzy časových řad pro automatizované obchodování ve srovnání s jinými metodami. Tato podkapitola nabízí kritické zhodnocení výsledků z hlediska prosperity predikčních modelů a obchodních strategií.

5.2.1 Prosperita predikce

Pro testování prosperity implementovaných algoritmů pro predikci časových řad bylo nutné implementovat několik algoritmů. Prvním potřebným algoritmem byl algoritmus, který z predikovaných hodnot a několika nastavených parametrů určí, zda je momentálně obchodovaný pár vhodný k obchodování. Druhým algoritmem bylo nasimulování obchodování na burze, který pro zadaný počet dnů simuluje obchod za využití predikovaných hodnot a je možno vyhodnotit profit. Posledním algoritmem bylo testování různého nastavení podmínek pro určení významnosti predikcí. Následně budou popsány samotné algoritmy s příklady zdrojových kódů.

```
1 def get_trade_recommendation(forecast, prediction_logic ='or', volatility_next =
    None, volatility_max = None, volatility_mean = None, volatility_logic = 'or',
    arima_price_next = None, arima_price_half = None, arima_price_sum= None,
```

```
    arima_logic = 'or', prophet_price_next = None, prophet_price_half = None,
    prophet_price_sum = None, prophet_logic = 'or'):
2
3   # vypočítání doporučení pro jednotlivé modely
4   arima = prediction_recommendation(forecast['chg_arima'],arima_price_next,
        arima_price_half, arima_price_sum, arima_logic)
5   prophet = prediction_recommendation(forecast['chg_prophet'],prophet_price_next,
        prophet_price_half, prophet_price_sum, prophet_logic)
6
7   # vypočítání volatility trhu - doporučení obchodů pouze při nižší volatilitě
8   if volatility_stable(forecast['volatility_arch'], volatility_next,
        volatility_max, volatility_mean, volatility_logic):
9     if (arima == TRADE_BUY and prophet == TRADE_SELL) or (arima == TRADE_SELL and
          prophet == TRADE_BUY):
10      return TRADE_NO
11    if prediction_logic == 'or':
12      if arima == TRADE_BUY or prophet == TRADE_BUY:
13        return TRADE_BUY
14      if arima == TRADE_SELL or prophet == TRADE_SELL:
15        return TRADE_SELL
16    else:
17      if arima == prophet == TRADE_BUY:
18        return TRADE_BUY
19      if arima == prophet == TRADE_SELL:
20        return TRADE_SELL
21  else:
22    if arima == TRADE_SELL or prophet == TRADE_SELL:
23      return TRADE_UNSTABLE
24
25  return TRADE_NO
```

Výpis 5.13: Výpočet finálního doporučení obchodu

První z algoritmů je znázorněn na výpisech kódu 5.13 a 5.14. Na prvním výpisu 5.13 je znázorněna hlavní funkce, která řídí samotné výsledné doporučení. Vstupem funkce je datová sada, která obsahuje predikované hodnoty a 13 parametrů, které nastavují významnost predikovaných hodnot a určují logiku, kterou budou vypočítány. Jako první jsou ve funkci vypočítány predikce budoucího vývoje ceny za využití modelu ARIMA a Prophet. Tato funkce bude dále popsána na výpisu 5.14. Následně je zhodnocen model ARCH, dle kterého se rozhoduje, zda vůbec zvážit obchodování

(funkce je velice podobná funkci počítající výsledky predikcí). Algoritmus nedoporučí obchodovat v případě, že je dle modelu ARCH predikována vysoká volatilita trhu a pouze upozorní, že je nestabilní trh, pokud alespoň jeden z modelů predikuje klesající trh. V případě nízké volatility je dále uvažováno s výsledky modelů. Algoritmus nedoporučí kupovat ani prodávat měnu v případě, že jeden model predikuje kladné hodnoty a druhý záporné.

Na výpisu 5.14 je znázorněno zpracování parametrů a predikovaných hodnot. Jako první je zohledněno nenastavení některých parametrů, které se v případě nenastavení chovají jako null hodnoty. Funkce počítá s hodnocením predikce pro následující den, pro polovinu období a pro celé období. Následně funkce porovná veškeré nastavené parametry a vrátí doporučení obchodu.

```
1  def prediction_recommendation(change, next, half, sum, logic):
2    chg_next = change.iloc[0] if next != None else 0
3    chg_half = change.iloc[:len(change)//2].sum() if half != None else 0
4    chg_sum = change.sum() if sum != None else 0
5    # přepočítání při výpočtech s null hodnotou
6    next = next if next != None else (1 if logic == 'or' else 0)
7    half = half if half != None else (1 if logic == 'or' else 0)
8    sum = sum if sum != None else (1 if logic == 'or' else 0)
9
10   if logic == 'or':
11     if chg_next >= next or chg_half >= half or chg_sum >= sum:
12       return TRADE_BUY
13     if chg_next <= -next or chg_half <= -half or chg_sum <= -sum:
14       return TRADE_SELL
15     return TRADE_NO
16   # počítání pro logiku and
17   if chg_next >= next and chg_half >= half and chg_sum >= sum:
18     return TRADE_BUY
19   if chg_next <= -next and chg_half <= -half and chg_sum <= -sum:
20     return TRADE_SELL
21   return TRADE_NO
```

Výpis 5.14: Výpočet doporučení obchodu z prediktivních modelů

Algoritmy byly testovány pro 22 momentálně nejperspektivnějších obchodovaných párů. Predikce byla vždy počítána z dat 90 dnů před predikcí a predikovala hodnoty 7 dní dopředu. 90 dní bylo zvoleno jako doba, kdy algoritmus dostane dostatek dat pro predikci a nebude obsahovat příliš náhodných jevů, které se na kryptoměnovém trhnu objevují. Burza byla simulována pro 120 dní obchodování, ze kterých byla určena nejprofitabilnější kombinace vstupních parametrů do zmí-

něné funkce. Celkově bylo otestováno 29 344 kombinací parametrů, kdy nejvýhodnější kombinace je využita ve výsledné predikci a také pro porovnání výsledků následující sekci.

5.2.2 Porovnání s jinými druhy obchodování

V této sekci budou definovány parametry, které byly využity pro výslednou predikci a simulaci obchodů. Následně budou zobrazeny a okomentovány samotné výsledky. Nakonec bude ukázán příklad obchodování pro jeden obchodovaný pár.

V následujícím seznamu jsou uvedeny veškeré metody, se kterými bylo simulováno obchodování na burze. V tabulkách 5.5 a 5.6 budou nadále zobrazeny jen symboly:

- **A1** - Implementované algoritmy predikce časových řad s investováním stejné částky
- **A2** - Implementované algoritmy predikce časových řad se započtením předchozích ztrát/výdělků do dalších obchodů
- **B** - Hodl - nakoupení na začátku období a prodej na konci
- **C** - Americký hodl - nakoupení malého množství měny každý den
- **D1** - Obchodování za využití technických indikátorů s investováním stejné částky
- **D2** - Obchodování za využití technických indikátorů se započtením předchozích ztrát/výdělků
- **E1** - Obchodování za využití reverzních technických indikátorů s investováním stejné částky
- **E2** - Obchodování za využití reverzních technických indikátorů se započtením předchozích ztrát/výdělků
- **F1** - Implementované algoritmy predikce časových řad s využitím technických indikátorů s reverzní strategií s investováním stejné částky
- **F2** - Implementované algoritmy predikce časových řad s využitím technických indikátorů s reverzní strategií se započtením předchozích ztrát/výdělků do dalších
- **G** - Využití Binance spoření

Algoritmus v minulé sekci určil nejlepší možné nastavení parametrů pro rozhodnutí, zda provést obchod na burze na základě modelů pro predikci časových řad. Největší profit algoritmus detekoval s poměrně vysokými hodnotami vstupních parametrů, kdy se uskuteční nákup nebo prodej měny až při predikované změně o 4% následující den a o minimálně 3.5% za další 3 a 7 dní. Nastavení zaručí menší množství obchodů, které celkově profitují více, než větší množství obchodů.

RSI a STOCH byly zvoleny jako technické ukazatele pro porovnání profitu obchodů. Nejlepší výsledky byly detekovány pro RSI detekujících posledních 5 dní a STOCH posledních 8 dní, kdy

se uvažuje s vyrovnáním plovoucím průměrem ukazatele STOCH jen s jednou předchozí hodnotou. Pro vyvolání obchodu jsou využity hranice, kdy RSI je větší než 70 a STOCH větší než 80. Pro uvažování prodeje jsou využity hodnoty, kdy RSI se nachází pod hranicí 30 nebo STOCH se nachází pod hranicí 20. Pro vyhodnocení profitu bylo také využito obrácené logiky pro technické ukazatele, kdy se obchoduje v případě, že RSI je nižší než 30 a STOCH nepřesahuje hodnotu 20. Technické ukazatele byly také využity v kombinaci s predikcí časových řad, kdy pro vyhodnocení obchodu musí existovat signifikantní predikce a také musí být aktivní obrácené technické ukazatele.

SYMBOL	**A1**	**A2**	**B**	**C**	**D1**	**D2**	**E1**	**E2**	**F1**	**F2**	**G**
asrbusd	211	211	251	286	-110	-118	161	153	211	211	16
belbusd	278	281	526	298	-256	-267	386	369	339	354	22
cocosbusd	2799	2593	1906	1145	-292	-287	2602	2739	2799	2593	1
ernbusd	266	266	471	473	23	-14	647	663	266	266	2
fetbusd	3486	3486	3534	836	136	118	1663	1361	3486	3486	5
injbusd	865	865	3657	2233	94	48	1520	2067	1133	1133	5
jasmybusd	113	16	669	377	-280	-280	234	165	197	128	2
juvbusd	0	0	338	505	115	105	544	536	0	0	13
ldobusd	175	167	1435	325	598	695	276	79	267	280	16
leverbusd	-129	-192	-14	59	163	28	-209	-232	-163	-214	3
lunabusd	-363	-349	-254	-164	-63	-114	632	593	-363	-349	2
nearbusd	57	36	206	83	-85	-131	176	119	-60	-73	9
nknbusd	125	93	620	338	86	66	141	105	125	93	36
ogbusd	3242	3242	2383	2972	-89	-132	2841	2900	3242	3242	6
opbusd	1008	865	1311	402	-5	-11	2184	1921	1143	1053	10
qibusd	245	254	317	322	-406	-380	680	775	225	230	2
rndrbusd	2756	2686	2324	1192	-320	-348	3231	3548	2756	2686	1
santosbusd	45	36	-261	64	-566	-527	527	538	97	92	20
solbusd	-24	-40	780	330	-109	-119	1309	1236	-54	-66	3
stxbusd	2932	3394	3166	2001	-180	-184	2417	3226	2932	3394	9
sxpbusd	778	589	1764	1414	1004	907	530	463	855	728	3
xvsbusd	-64	-64	581	355	-28	-56	-25	-60	224	224	10
TOTAL	18804	18435	25709	15845	-567	-999	22467	23262	19657	19491	199
PRŮMĚR	855	838	1169	720	-26	-45	1021	1057	894	886	9
DEN	6.9	6.8	9.4	5.8	-0.2	-0.4	8.2	8.5	7.2	7.1	0.1

Tabulka 5.5: Výsledky algoritmů pro období 8. 12. 2022 - 11. 4. 2023

V tabulce 5.5 jsou uvedeny výsledky simulace obchodů za 124 dní. Bylo uvažováno se simulací 10€ na den na obchodovaný pár a s poplatkem pro provedený příkaz 0.075%. V měřeném období probíhá celkový růst cen kryptoměn na burze a většina algoritmů indikuje značný profit. Z tabulky jasně vyplývá, že při rostoucím trhu je nejvýnosnější strategií hodl (sloupec B). Podobně úspěšné je využití obrácených indikátorů (sloupce E). Dále vysoký profit indikuje také využití implementované predikce časové řady (sloupce A) a tento algoritmus doplněný o hodnoty technických ukazatelů

(sloupce F). Nižšího profitu pochopitelně dosahuje také strategie americký hodl (sloupec C), kdy se každý den investuje 10€ a investice se rozloží přes celou dobu simulace. Velice nízké hodnoty ukazuje Binance spoření (sloupec G), které při rychle stoupajícím trhu dosahuje nejnižšího profitu. Jediný algoritmus, který byl ve ztrátě, bylo využití klasických hodnot ukazatelů (sloupce D).

SYMBOL	A1	A2	B	C	D1	D2	E1	E2	F1	F2
autobusd	-742	-1013	-1922	-551	-1464	-1690	1717	1261	-742	-1013
belbusd	-5863	-3238	-1645	120	-2533	-2318	1669	-261	-5410	-3182
ernbusd	-3949	-2851	-2495	-469	-1096	-1990	-1817	-1641	-3567	-2764
fetbusd	8386	2804	-819	7128	-1351	-1816	3137	667	8643	3296
injbusd	4788	1348	-576	5599	-1249	-1563	948	5	5746	3015
jasmybusd	-3043	-2262	-3065	-853	-3929	-2743	-3327	-2390	-2299	-1907
juvbusd	483	-254	-2200	-1138	-553	-979	-1534	-1470	483	-254
linabusd	-771	-1703	-2208	1108	597	-937	-2365	-2127	-1579	-2047
nearbusd	-4373	-3070	-3148	-1239	-3958	-3001	112	-369	-4342	-3069
qibusd	-260	-895	-3146	-596	-3303	-2792	-733	-1002	718	162
rndrbusd	5280	4227	-1958	3523	-2811	-2338	9321	8616	4701	3115
solbusd	-1397	-2088	-3059	-801	-4429	-2901	581	-385	-2450	-2370
stxbusd	7718	7006	-1368	4585	-2208	-2042	2858	1173	8000	7901
sxpbusd	3388	363	-1975	3645	-1310	-1941	133	-440	3502	540
xvsbusd	25	-337	-2260	-254	-1414	-1778	-2285	-1819	643	368
TOTAL	9670	-1961	-31845	19806	-31011	-30828	8415	-183	12048	1788
PRŮMĚR	645	-131	-2123	1320	-2067	-2055	561	-12	803	119
DEN	1.8	-0.4	-5.8	3.6	-5.7	-5.6	1.5	0.0	2.2	0.3

Tabulka 5.6: Výsledky algoritmů pro 365 dní do 1. 4. 2023

V následující tabulce 5.6 je znázorněna simulace 365 dní obchodování. Kryptoměnový trh na začátku simulovaného období silně spadl, poté přibližně do poloviny období byl stále klesající. Zbytek měřeného období byl kryptoměnový trh na vzestupu. Celkově byl zaznamenán významný pokles. V průměru klesly ceny kryptoměn za simulované roční období o 58% (průměr sloupce B vydělený investovanou částkou 3 650€). I přes celkový významný pokles trhu je možno sledovat profit u implementovaných predikcí časových řad. Využití predikce časových řad s pomocí technických ukazatelů vyšlo s profitem 22%. Pro toto simulované období prokazuje nejvyšší profit americký hodl, pro který měřené časové období prokazovalo nejlepší podmínky trhu. Pro roční měření nebyly k dispozici data pro určení profitu za využití Binance spoření.

Na následujících obrázcích 5.12, 5.13, 5.14 a 5.15 je vyobrazen příklad provedených transakcí pro obchodovaný pár fetbusd. Na obrázcích je jasně vidět malý počet obchodů, které uskuteční algoritmus podle implementované predikce časových řad. Vzhledem k dlouhodobému rostoucímu trhu před měřeným obdobím nebyl predikován významný pokles na začátku tohoto období. Uskutečněný obchod je na obrázcích znázorněn zelenou přerušovanou vertikální čárou a následný prodej je zaznačen červenou přerušovanou čarou.

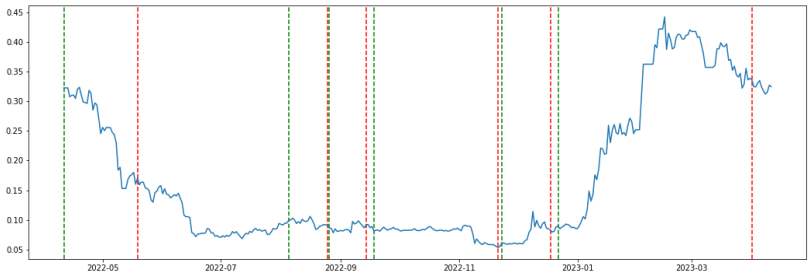

Obrázek 5.12: Provedené obchody s využitím predikce

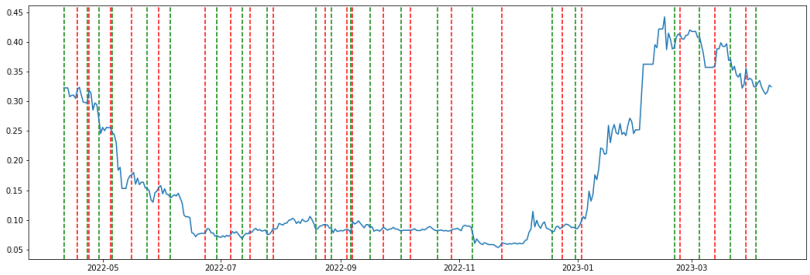

Obrázek 5.13: Provedené obchody s využitím ukazatelů

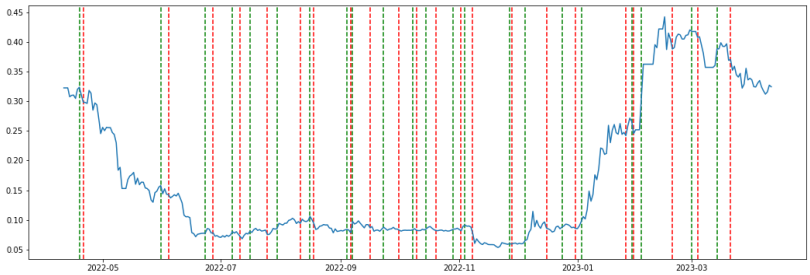

Obrázek 5.14: Provedené obchody s využitím obrácených ukazatelů

Celkově je možno říci, že obchodování na bázi implementovaného algoritmu je profitabilní. Nicméně je třeba mít na paměti, že při klesajícím trhu může dosahovat velkých ztrát. Nejlepší strategií se zdá být americký hodl, který sice dosahuje menšího profitu při stoupajícím trhu, ale dosahuje dobrých výsledků při střídavém pohybu trhu. Strategie ovšem nemusí být vždy profitabilní a v jiném časovém období se její výsledky mohou významně lišit.

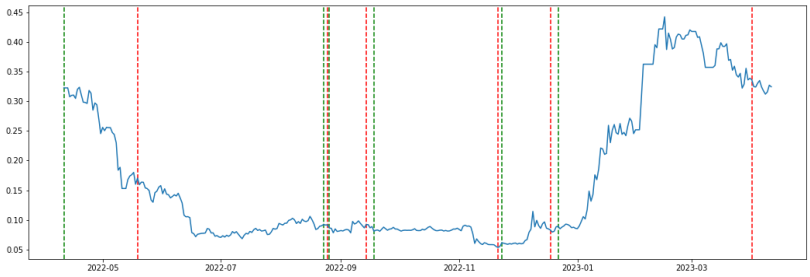

Obrázek 5.15: Provedené obchody s využitím predikce a obrácených ukazatelů

Kapitola 6

Závěr

V rámci této diplomové práce byla implementována statistická teorie časových řad. Časové řady byly rozloženy na jednotlivé složky, které byly následně analyzovány a zpracovány. Dále byly implementovány prediktivní modely, mezi které patří primárně autoregresivní modely využívající metodu klouzavých průměrů. Byly implementovány i jiné techniky, mezi které se řadí například technické ukazatele RSI a STOCH. Tyto modely a techniky pomáhají při automatizaci procesu nakupování a prodeje na burzovních a kryptoměnových trzích. V rámci testování bylo vyzkoušeno téměř třicet tisíc kombinací parametrů pro prediktivní algoritmus, aby došlo k minimalizaci ztrát.

Práce je uvedena teorií časových řad, kde je popsáno, co jsou časové řady a s jakou jejich podobou se pracuje v praktické části této práce. Následně jsou zdokumentovány základní metody analýzy časových řad, mezi které je zahrnuta dekompozice časové řady na jednotlivé složky, spektrální analýza, klouzavý průměr, autokorelační analýza a Box-Jenkinsova metodologie. Na závěr kapitoly (2) jsou sepsány existující nástroje umožňující zpracování časových řad, které jsou rozděleny na knihovny programovacích jazyků a analytický software.

Druhá teoretická kapitola (3) se zabývá kryptoměnovým trhem. Kapitola uvádí do světa kryptoměn, zmiňuje jejich historii, těžbu a nabízí pohled na kryptoměny v zemích po celém světě. V druhé části této kapitoly jsou zmíněny základy obchodování a obchodních strategií, u kterých jsou popsány i technické ukazatele a metody vizualizace tržních hodnot. Následně je zmíněna legislativa a metodiky, bez kterých se obchodování na kryptoměnové burze neobejde. Kapitolu uzavírá stručný popis pěti světových kryptoměnových burz.

První kapitola praktické části (4) řeší volbu a vystavění infrastruktury pro automatické obchodování. Úvodem jsou rozebrány různé druhy virtualizace včetně jejich využití pro automatické obchodování. Následně jsou sepsány možnosti automatického obchodování za využití Coinbase API a Binance API. V poslední části této kapitoly je proveden rozbor různých metod uložení dat, jsou popsány využívané tabulky při analýze časových čas a také jsou zdokumentovány kroky, které vedly k optimalizaci přístupu k datům v databázi.

V poslední kapitole práce (5) je věnován prostor implementaci algoritmů, které zpracovávají a predikují časové řady s obchodními daty z kryptoměnové burzy. Kapitola slouží také jako metodická příručka zabývající se problematikou použití časových řad k automatizovanému nákupu kryptoměn. Úvodem kapitoly je popsáno, jak se zpracovávají data z databáze, aby je bylo možné dále transformovat a využít v knihovně Pandas programovacího jazyka Python. Následně je detailně popsána dekompozice časové řady, ve které je vyvrácena statistická významnost sezónní složky u analyzovaných dat. Významnost sezónní složky je vyvrácena za pomocí několika naimplementovaných ukazatelů, které byly řádně testovány na datech s významnou sezónní složkou. Následně je popsána a vizualizována metodika práce s anomáliemi, na kterou navazuje popis implementace korelační a autokorelační funkce. V následující sekci je ověřena metoda výpočtu lokálních extrémů a jsou navrženy změny pro upřesnění výpočtů na straně databáze. Dále je v kapitole sepsáno využití modelu ARIMA, ARCH a Prophet pro predikci časové řady.

Závěrem práce je zdokumentována metoda pro nalezení optimální kombinace parametrů pro maximalizaci profitu, se kterou byly otestovány implementované algoritmy simulací obchodů za 124 a 365 dní. Výsledky byly porovnány s jinými obchodními strategiemi. Algoritmy obchodující na základě predikce časových řad se zdají být spolehlivé a vykazují pravidelný profit. Problém implementované predikce časových řad je v pozdě odhadnutém poklesu ceny, kterému by se dalo do budoucna zabránit nasazením již implementovaných strategií, které jsou součástí celého projektu. Další možností by mohla být kontrola hodinových či minutových dat, která by mohla lépe detekovat pokles trhu.

Literatura

1. ROBERT H. SHUMWAY, David S. Stoffer. *Time Series Analysis and Its Apliations*. Springer, 2011. ISBN 978-1-4419-7864-6.
2. DOC.ING. JANA HANČLOVÁ CSc., Ing. Lubor Tvrdý. *Úvod do analýzy časových řad*. 2003.
3. GESINE REINERT, prof. *Time Series*. 2010. Dostupné také z: `https://www.stats.ox.ac.uk/~reinert/time/notesht10short.pdf`.
4. DAS, Samarjit. *Time Series Analysis*. Dostupné také z: `https://www.ctanujit.org/uploads/2/5/3/9/25393293/time_series_analysis_sd1final.pdf`.
5. ING. ROMAN DANEL, Ph.D. *Predikce časové řady pomocí autoregresivního modelu*. 2004.
6. PETER J. BROCKWELL, Richard A. Davis. *Introduction to Time Series and Forecasting*. Springer, 2002. ISBN 0-387-95351-5.
7. *Python*. Dostupné také z: `https://www.python.org/`.
8. *Pandas - knihovna jazyka Python*. Dostupné také z: `https://pandas.pydata.org/`.
9. *NumPy - knihovna jazyka Python*. Dostupné také z: `https://numpy.org/`.
10. *Matplotlib - knihovna jazyka Python*. Dostupné také z: `https://matplotlib.org/`.
11. *Seaborn - knihovna jazyka Python*. Dostupné také z: `https://seaborn.pydata.org/`.
12. *Statsmodels - knihovna jazyka Python*. Dostupné také z: `https://www.statsmodels.org/stable/index.html`.
13. *Prophet - knihovna jazyka Python*. Dostupné také z: `https://facebook.github.io/prophet/docs/quick_start.html`.
14. *Společnost Meta*. Dostupné také z: `https://about.meta.com/`.
15. *TensorFlow - knihovna jazyka Python*. Dostupné také z: `https://www.tensorflow.org/`.
16. *Programovací jazyk R*. Dostupné také z: `https://www.r-project.org/`.
17. *MATLAB*. Dostupné také z: `https://www.mathworks.com/products/matlab.html`.
18. *Programovací jazyk JavaScript*. Dostupné také z: `https://www.javascript.com/`.

19. *Dygraphs - knihovna jazyka JavaScript*. Dostupné také z: https://dygraphs.com/.

20. *Plotly.js - knihovna jazyka JavaScript*. Dostupné také z: https://plotly.com/javascript/.

21. *Společnost Microsoft*. Dostupné také z: https://www.microsoft.com/cs-cz/.

22. *Microsoft Time Series Insights*. Dostupné také z: https://azure.microsoft.com/en-au/products/time-series-insights/.

23. *Microsoft Power BI*. Dostupné také z: https://app.powerbi.com/.

24. *Power Query - jazyk využívaný v Power BI*. Dostupné také z: https://powerquery.microsoft.com/en-us/.

25. *DAX - jazyk využívaný v Power BI*. Dostupné také z: https://learn.microsoft.com/en-us/dax/.

26. *Qlik*. Dostupné také z: https://www.qlik.com/us/.

27. *Tableau*. Dostupné také z: https://www.tableau.com/.

28. *SAS*. Dostupné také z: https://www.sas.com/cs_cz/home.html.

29. *Microsoft Excel*. Dostupné také z: https://www.microsoft.com/en-us/microsoft-365/excel.

30. MCDONALD, Oonagh. *Cryptocurrencies: Money, Trust and Regulation*. Agenda, 2021. ISBN 978-1-78821-420-9.

31. LANGEROVÁ, Jana. *Platba kartou na tržnici: Víte, jaké terminály nabízejí nejnižší poplatek?* 2022. Dostupné také z: https://www.podnikatel.cz/clanky/platba-kartou-na-trznici-vite-jake-terminaly-nabizeji-nejnizsi-poplatek/.

32. *FTX Trading Ltd.* Dostupné také z: https://restructuring.ra.kroll.com/FTX/.

33. SANTOS-ALBORNA, Ariel. *Understanding Cryptocurrencies : Bitcoin, Ethereum, and Altcoins As an Asset Class*. Business Expert Press, 2021. ISBN 978-1-63742-100-0.

34. AFZAL A., Asif A. Cryptocurrencies, Blockchain and Regulation: A Review. *The Lahore Journal of Economics*. 2019, roč. 24, č. 1, s. 109–130.

35. DUQUE, Juan J. State involvement in cryptocurrencies. A potential world money? *The Japanese Political Economy*. 2020, roč. 46, č. 1, s. 65–82.

36. STROUKAL DOMINIK, Skalický Jan. *Bitcoin a jiné kryptopeníze budoucnosti*. GRADA Publishing, a.s., 2021. ISBN 978-80-271-1043-8.

37. HONG, Euny. *How Does Bitcoin Mining Work?* 2022. Dostupné také z: https://www.investopedia.com/tech/how-does-bitcoin-mining-work/.

38. HAYES, Adam. *What Happens to Bitcoin After All 21 Million Are Mined?* 2022. Dostupné také z: https://www.investopedia.com/tech/what-happens-bitcoin-after-21-million-mined/.

39. *FinTech Australia*. Dostupné také z: https://www.fintechaustralia.org.au/.

40. FLORI, Andrea. Cryptocurrencies in Finance: Review and Applications. *International Journal of Theoretical and Applied Finance*. 2019, roč. 22, č. 05, s. 1–22.

41. *Aplikace XStoation od XTB - ukázky obchodování*. Dostupné také z: https://xstation5.xtb.com/.

42. *Twitter - Elon Musk tweet o kryptoměně Dogecoin*. 2021. Dostupné také z: https://twitter.com/elonmusk/status/1354924057825837060?s=20.

43. MOROȘAN, Adrian. The relative strength index revisited. *African journal of business management*. 2011-07, roč. 5, s. 5855–5862.

44. BILL HUANG, Yong Soo Kim. *A Test of MACD Trading Strategy*. 2006. Dostupné také z: https://core.ac.uk/download/pdf/56371804.pdf.

45. *Financial Action Task Force*. Dostupné také z: https://www.fatf-gafi.org/en/home.html.

46. *Rozsudek Soudního dvora (pátého senátu)*. 2015. Dostupné také z: https://curia.europa.eu/juris/liste.jsf?num=C-264/14&language=CS.

47. VÁVRA, Jan. *Kryptoměny a daně 2023. Na co všechno berňák dosáhne a jak správně danit*. 2023. Dostupné také z: https://www.e15.cz/kryptomeny-dane?fbclid=IwAR1GmMrF9VL1172pZqEw1ZzahPk
DGbldK7jwMl0F1qbVAUwEfmSHxb0#Obec.

48. ŘEDITELSTVÍ, Generální finanční. *Informace k daňovému posouzení transakcí s kryptoměnami (např. bitcoin)*. 2018. Dostupné také z: https://www.financnisprava.cz/assets/cs/prilohy/d-seznam-dani/Info_kryptomeny_GFR.pdf.

49. *Binance*. Dostupné také z: https://www.binance.com/en.

50. KAMILA LORENZOVÁ, Michaela Černá. *Recenze nejlepších bitcoinových burz 2023*. 2023. Dostupné také z: https://www.arecenze.cz/bitcoinove-burzy/.

51. CLINEBELL, Katie. *Binance Review*. 2023. Dostupné také z: https://www.investopedia.com/binance-review-5209980.

52. *Coinbase*. Dostupné také z: https://www.coinbase.com/.

53. LIELACHER, Alex. *Best Crypto Exchanges*. 2023. Dostupné také z: https://www.investopedia.com/best-crypto-exchanges-5071855.

54. POWELL, Farran. *10 Best Crypto Apps & Exchanges Of 2023*. 2023. Dostupné také z: https://www.forbes.com/advisor/investing/cryptocurrency/best-crypto-exchanges/.

55. *Kraken*. Dostupné také z: https://www.kraken.com/.

56. *Bitfinex*. Dostupné také z: https://www.bitfinex.com/.

57. MARTIN KLASS PH.D., MBA. *Kryptoměnová burza Bitfinex*. Dostupné také z: https://finex.cz/recenze/bitfinex/.

58. *Crypto.com*. Dostupné také z: https://crypto.com/.

59. *Google Cloud Platform*. Dostupné také z: https://cloud.google.com/.

60. *Amazon Web Services*. Dostupné také z: https://aws.amazon.com/.

61. *Microsoft Azure*. Dostupné také z: https://azure.microsoft.com/cs-cz/.

62. *Docker*. Dostupné také z: https://www.docker.com/.

63. *Coinbase API dokumentace*. Dostupné také z: https://docs.cloud.coinbase.com/.

64. *Node.js*. Dostupné také z: https://nodejs.org/en.

65. G, Abhijith. *13 Cryptocurrency APIs for Data Scientists/ Developers*. 2023. Dostupné také z: https://geekflare.com/cryptocurrency-apis/#geekflare-toc-coinbase-api.

66. JAGGER, Emma. *Best Crypto Currency APIs*. 2022. Dostupné také z: https://www.abstractapi.com/guides/best-crypto-currency-apis.

67. *Binance API dokumentace*. Dostupné také z: https://binance-docs.github.io/apidocs/.

68. SRIVASTAVA, Vyom. *13 Cryptocurrency APIs for Data Scientists/ Developers*. 2022. Dostupné také z: https://nordicapis.com/9-apis-for-real-time-cryptocurrency-data/.

69. *Binance Data Vision*. Dostupné také z: https://data.binance.vision/.

70. *MySQL databáze*. Dostupné také z: https://www.mysql.com/.

71. *PostgreSQL databáze*. Dostupné také z: https://www.postgresql.org/.

72. *MongoDB databáze*. Dostupné také z: https://www.mongodb.com/.

73. *Cassandra databáze*. Dostupné také z: https://cassandra.apache.org/_/index.html.

74. *SQLAlchemy - knihovna jazyka Python*. Dostupné také z: https://www.sqlalchemy.org/.

75. *Pearsonův korelační koeficient*. Dostupné také z: https://mathstat.econ.muni.cz/media/12657/pear_cor.pdf.

76. *Spearmanův koeficient pořadové korelace*. Dostupné také z: https://cit.vfu.cz/statpotr/POTR/Teorie/Predn5/nelinear.htm.

77. BUBENÍČEK, Jan. *Shapirův-Wilkův test*. Brno, 2019. Dostupné také z: https://is.muni.cz/th/z4ef9/Shapiro_Wilk_test.pdf. Bakalářská práce. Přírodovědecká fakulta, Masarykova univerzita.

78. *SciPy - knihovna jazyka Python*. Dostupné také z: https://scipy.org/.