

UNIVERZITA PARDUBICE
FAKULTA EKONOMICKO-SPRÁVNÍ

DIPLOMOVÁ PRÁCE

2011

Bc. Kateřina Hronová

Univerzita Pardubice
Fakulta ekonomicko-správní

Analýza a predikce vybraných finančních časových řad

Bc. Kateřina Hronová

Diplomová práce

2011

Univerzita Pardubice
Fakulta ekonomicko-správní
Akademický rok: 2010/2011

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Kateřina HRONOVÁ**
Osobní číslo: **E09708**
Studijní program: **N6202 Hospodářská politika a správa**
Studijní obor: **Ekonomika veřejného sektoru**
Název tématu: **Analýza a predikce vybraných finančních časových řad**
Zadávající katedra: **Ústav matematiky**

Z á s a d y p r o v y p r a c o v á n í :

Cílem práce je analýza finančních časových řad, jejich srovnání a predikce.

Diplomová práce bude obsahovat:

- vymezení základních statistických a matematických pojmů
 - analýza finančních časových řad pomocí modelů
 - predikce v časových řadách.
-

Rozsah grafických prací: —
Rozsah pracovní zprávy: cca 50 stran
Forma zpracování diplomové práce: tištěná/elektronická

Seznam odborné literatury:

ARLT, J. Finační časové řady. Praha: Grada, 2003. 220 str. ISBN 80-247-0330-0

ARLT, J. Moderní metody modelování ekonomických časových řad. Praha: Grada, 1999. 307 str. ISBN 80-7169-539-4

HUŠEK, R. Aplikovaná ekonometrie-teorie a praxe. Praha: Professional Publishing, 2003. 263 str. ISBN 80-86419-29-0

RUBLÍKOVÁ, E. Analýza časových radov. Bratislava: Iura Edition, 2007. 207 str. ISBN 978-80-8078-139-2

MILLS, T. The Econometric Modelling of Financial Time Series. New York: Cambridge University Press, 2008. 446 p. ISBN 978-0-521-71009-1

TAYLOR, S. Modelling financial time series. New Jersey: World Scientific, 2008. 268 p. ISBN 981-277-084-4

TSAY, R. Analysis of Financial Time Series. New York: Wiley, 2002. 704 p. ISBN 0-471-41544-8

www.cnb.cz - Česká národní banka

www.epp.eurostat.ec.europa.eu - Eurostat

www.czso.cz - Český statistický úřad

Vedoucí diplomové práce: doc. PaedDr. Jana Kubanová, CSc.
Ústav matematiky

Datum zadání diplomové práce: 30. června 2010

Termín odevzdání diplomové práce: 6. května 2011

doc. Ing. Renáta Myšková, Ph.D.

děkanka

L.S.

doc. Ing. Jolana Volejníková, Ph.D.

vedoucí ústavu

V Pardubicích dne 11. srpna 2010

Prohlašuji:

Tuto práci jsem vypracovala samostatně. Veškeré literární prameny a informace, které jsem v práci využila, jsou uvedeny v seznamu použité literatury.

Byla jsem seznámena s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorský zákon, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Souhlasím s prezenčním zpřístupněním své práce v Univerzitní knihovně.

V Pardubicích dne 28. 6. 2011

Bc. Kateřina Hronová

Poděkování

Na tomto místě bych ráda poděkovala doc. PaedDr. Janě Kubanové, CSc. za cenné připomínky a odborné rady, kterými přispěla k vypracování této diplomové práce.

ANOTACE

Diplomová práce je zaměřena na analýzu vybraných časových řad a jejich predikci. Jsou zde vysvětleny časové řady, jejich předpoklady a charakteristiky. V další části jsou objasněny termíny jako modelování časových řad a Boxova-Jenkinsova metodologie. Závěr této práce je věnován praktické části, kde je analyzován kurz CAD/CZK pomocí procesů ARIMA, AR a MA. Cílem této práce je poukázat na možnou analýzu a především vhodnou predikci dané finanční časové řady.

KLÍČOVÁ SLOVA

finanční časové řady, trend, sezónní složka, metodologie Box-Jenkins, ARIMA, AR, MA, predikce, analýza

TITLE

Analysis and Prediction of Selected Financial Time Series

ANNOTATION

The thesis is focused on analysis of selected time series and their prediction. There are explained time series, their assumptions and characteristics. The next section clarifies terms as modeling of time series and Box-Jenkins methodology. The conclusion of this work is devoted to the practical part, where the course of CAD / CZK is analyzed by processes of ARIMA, AR and MA. The aim of this work is to point to a possible analysis and especially suitable prediction financial time series.

KEYWORDS

financial time series, trend, seasonal component, Box-Jenkins methodology, ARIMA, AR, MA, prediction, analysis

OBSAH

ÚVOD	11
1. FINANČNÍ TRH	13
1.1 ČASOVÉ ŘADY	14
1.1.1 Pojem časové řady	14
1.1.2 Rozdělení časových řad	15
1.2 EKONOMICKÉ ČASOVÉ ŘADY	16
1.3 CHARAKTERISTICKÉ VLASTNOSTI FINANČNÍCH ČASOVÝCH ŘAD	16
1.4 PŘEDPOKLADY FINANČNÍCH ČASOVÝCH ŘAD	17
1.4.1 Předpoklad normality	17
1.4.2 Předpoklad nelinearity	17
1.4.3 Předpoklad podmíněné heteroskedasticity	18
1.4.4 Předpoklad autokorelace	19
1.4.5 Předpoklad volatility (variability)	20
1.5 ZÁKLADNÍ CHARAKTERISTIKY ČASOVÝCH ŘAD	20
1.5.1 Popisné charakteristiky	21
1.5.2 Míry dynamiky	21
2. MODELOVÁNÍ ČASOVÝCH ŘAD	23
2.1 KLASICKÝ (FORMÁLNÍ) MODEL	23
2.1.1 Cyklická složka	24
2.1.2 Náhodná složka (rezidua, bílý šum)	25
2.2 MODELOVÁNÍ TRENDU	25
2.2.1 Trend	25
2.2.2 Analýza trendu	26
2.2.3 Metoda klouzavých průměrů	26
2.2.4 Exponenciální vyrovnaní	27
2.3 MODELOVÁNÍ SEZÓNŇNÍ SLOŽKY	27
2.3.1 Sezónní složka	27
2.3.2 Analýza sezónní složky	28
2.3.3 Sezónnost	28

2.4	PREDIKCE ČASOVÉ ŘADY	29
3.	BOXOVA-JENKINSOVA METODOLOGIE	30
3.1	STACIONARITA.....	30
3.2	AUTOREGRESNÍ PŘEDPOVĚDNÍ MODELY	31
3.3	STACIONÁRNÍ PROCESY.....	31
3.3.1	<i>Procesy ARIMA.....</i>	<i>31</i>
3.3.2	<i>Procesy AR(1).....</i>	<i>32</i>
3.3.3	<i>Procesy MA(1).....</i>	<i>32</i>
3.3.4	<i>Procesy AR(2).....</i>	<i>33</i>
3.3.5	<i>Procesy AR(1) MA(1).....</i>	<i>33</i>
4.	ANALÝZA FINAČNÍCH ČASOVÝCH ŘAD	34
4.1	PŘEDPOKLADY FINANČNÍCH ČASOVÝCH ŘAD	38
4.1.1	<i>Předpoklad normality</i>	<i>38</i>
4.1.2	<i>Předpoklad nelinearity.....</i>	<i>41</i>
4.1.3	<i>Předpoklad podmíněné heteroskedasticity</i>	<i>41</i>
4.1.4	<i>Předpoklad autokorelace.....</i>	<i>42</i>
4.1.5	<i>Testování předpokladu volatility</i>	<i>43</i>
4.2	ZÁKLADNÍ CHARAKTERISTIKY ČASOVÝCH ŘAD	45
4.2.1	<i>Popisné charakteristiky.....</i>	<i>45</i>
4.2.2	<i>Míry dynamiky</i>	<i>45</i>
4.3	MODELOVÁNÍ TRENDU A SEZÓNŇNÍ SLOŽKY	48
4.3.1	<i>Dekompozice časové řady</i>	<i>48</i>
4.3.2	<i>Základní metody modelování trendové složky</i>	<i>49</i>
4.3.3	<i>Metoda klouzavých průměrů.....</i>	<i>51</i>
4.3.4	<i>Exponenciální vyrovnání</i>	<i>55</i>
4.3.5	<i>Základní metody modelování sezónní složky.....</i>	<i>58</i>
4.4	BOXOVA-JENKINSOVA METODOLOGIE	62
4.4.1	<i>Stochastický proces, stacionarita a autokorelační struktura</i>	<i>62</i>
5.	PREDIKCE FINANČNÍCH ČASOVÝCH ŘAD	67
5.1	PŘEDPOVÍDÁNÍ ČASOVÝCH ŘAD PO SEZÓNŇNÍ DEKOMPOZICI	67

5.1.1	<i>Stacionární procesy</i>	69
5.1.1.1	Procesy ARIMA.....	69
5.1.1.2	Procesy AR(1).....	70
5.1.1.3	Procesy MA(1).....	71
5.1.1.4	Procesy AR (2).....	71
5.1.1.5	Procesy AR(1) MA(1).....	72
5.1.1.6	Procesy ARIMA rezidua.....	73
5.2	PŘEDPOVÍDÁNÍ ČASOVÝCH ŘAD POMOCÍ MODELŮ.....	77
ZÁVĚR	84
POUŽITÁ LITERATURA	86

SEZNAM TABULEK

TABULKA 1: POPISNÉ STATISTIKY LOGARITMY VÝNOSŮ KURZU CAD/CZK.....	40
TABULKA 2: SPEARMANŮV TEST KORELACE	41
TABULKA 3: VÝSLEDKY REGRESE	49
TABULKA 4: VÝSTUPNÍ TABULKA MODELU ARIMA (1,0,0)	69
TABULKA 5: VÝSTUPNÍ TABULKA MODELU ARIMA (0,0,1)	69
TABULKA 6: VÝSTUPNÍ TABULKA MODELU ARIMA (2,0,0)	69
TABULKA 7: VÝSTUPNÍ TABULKA MODELU ARIMA (1,0,1)	70

SEZNAM GRAFŮ

GRAF 1: SPOJICOVÝ GRAF ZNÁZORŇUJÍCÍ KURZ CAD/CZK.....	35
GRAF 2: LOGARITMY VÝNOSU DENNÍHO KURZU CAD/CZK	36
GRAF 3: ABSOLUTNÍ PŘÍRŮSTEK.....	46
GRAF 4: KOEFICIENT RŮSTU.....	47
GRAF 5: RELATIVNÍ PŘÍRŮSTKY	48
GRAF 6: KURZ CAD/CZK	62

SEZNAM OBRÁZKŮ

OBRÁZEK 1: KRABICOVÝ GRAF ZNÁZORŇUJÍCÍ KURZ CAD/CZK	37
OBRÁZEK 2: NORMÁLNÍ ROZDĚLENÍ LOGARITMY VÝNOSŮ	38
OBRÁZEK 3: HISTOGRAM PROLOŽENÝ HUSTOTOU NORMÁLNÍHO ROZDĚLENÍ.....	39
OBRÁZEK 4: STACIONARIZOVANÁ ČASOVÁ ŘADA - PRVNÍ DIFERENCE	43
OBRÁZEK 5: BODOVÝ GRAF S INTERVALEM SPOLEHLIVOSTI.....	44
OBRÁZEK 6: PŘEDPOVĚĎ TRENDOVÉ FUNKCE	50
OBRÁZEK 7: BÍLÝ ŠUM KURZ CAD/CZK	51
OBRÁZEK 8: KLOUZAVÉ PRŮMĚRY DÉLKY 5	52
OBRÁZEK 9: KLOUZAVÉ PRŮMĚRY DÉLKY 30	53
OBRÁZEK 10: KURZ CAD/CZK A KLOUZAVÉ PRŮMĚRY	54
OBRÁZEK 11: JEDNODUCHÉ EXPONENCIÁLNÍ VYROVNÁNÍ	55
OBRÁZEK 12: KURZ CAD/CZK A JEDNODUCHÉ EXPONENCIÁLNÍ VYROVNÁNÍ.....	56
OBRÁZEK 13: DVOJITÉ EXPONENCIÁLNÍ VYROVNÁNÍ	57
OBRÁZEK 14: PERIODOGRAM	58
OBRÁZEK 15: SEZÓNŇNÍ DEKOMPOZICE.....	59
OBRÁZEK 16: SEZÓNŇNÍ INDEXY.....	60
OBRÁZEK 17: KURZ CAD/CZK A SEZÓNŇNĚ OČIŠTĚNÁ DATA	61

OBRÁZEK 18: AUTOKORELAČNÍ FUNKCE (ACF) KURZU CAD/CZK.....	63
OBRÁZEK 19: STACIONARIZOVANÁ ČASOVÁ ŘADA - PRVNÍ DIFERENCE	64
OBRÁZEK 20: AUTOKORELAČNÍ FUNKCE (ACF) - PRVNÍ DIFERENCE.....	65
OBRÁZEK 21: PARCIÁLNÍ AUTOKORELAČNÍ FUNKCE (PACF) - PRVNÍ DIFERENCE	66
OBRÁZEK 22: SEZÓNĚ OČIŠTĚNÁ ČASOVÁ ŘADA S EXPONENCIÁLNÍM VYROVNÁNÍM	68
OBRÁZEK 23: VÝSTUPNÍ DATA PROCES AR (1)	70
OBRÁZEK 24: VÝSTUPNÍ DATA PROCES MA (1)	71
OBRÁZEK 25: VÝSTUPNÍ DATA PROCES AR (2)	71
OBRÁZEK 26: VÝSTUPNÍ DATA PROCES AR (1) A MA (1)	72
OBRÁZEK 27: AUTOKORELAČNÍ FUNKCE PROCESU ARIMA (1,0,0) REZIDUA.....	73
OBRÁZEK 28: AUTOKORELAČNÍ FUNKCE PROCESU ARIMA (0,0,1) REZIDUA.....	74
OBRÁZEK 29: AUTOKORELAČNÍ FUNKCE PROCESU ARIMA (2,0,0) REZIDUA.....	75
OBRÁZEK 30: AUTOKORELAČNÍ FUNKCE PROCESU ARIMA (1,0,1) REZIDUA.....	76
OBRÁZEK 31: PŘEDPOVĚĎ NA 5 LET MODELU ARIMA (1,0,0) S DIFERENCOVÁNÍM1	77
OBRÁZEK 32: PŘEDPOVĚĎ NA 5 LET MODELU ARIMA (2,0,0) S DIFERENCOVÁNÍM1	78
OBRÁZEK 33: PŘEDPOVĚĎ PŮVODNÍ ČASOVÉ ŘADY NA 5 LET, MODEL AR (1)	79
OBRÁZEK 34: PŘEDPOVĚĎ PŮVODNÍ ČASOVÉ ŘADY NA 5 LET, MODEL MA (1)	80
OBRÁZEK 35: PŘEDPOVĚĎ PŮVODNÍ ČASOVÉ ŘADY NA 5 LET, MODEL AR (2)	81
OBRÁZEK 36: PŘEDPOVĚĎ PŮVODNÍ ČASOVÉ ŘADY NA 5 LET, MODEL AR (1) MA (1).....	82
OBRÁZEK 37: PŘEDPOVĚDI MODELŮ KURZU CAD/CZK	83

SEZNAM ZKRATEK

AR – Autoregresní modely

ARIMA – Autoregresní integrované modely klouzavých průměrů

CAD – Kanadský dolar

CZK – Česká koruna

MA – Procesy klouzavých průměrů

ÚVOD

V této práci budou popsány časové řady, které se vyskytují běžně kolem nás. Konkrétně se budeme zabývat ekonomickými a především finančními časovými řadami, kde se používají makroekonomické ukazatele. Práce popisuje dané problematiku jak teoreticky, tak prakticky.

V současné době se nacházíme v období, kdy bohužel není možné provádět důležitá ekonomická rozhodnutí bez propracované a důkladné analýzy základních ekonomických ukazatelů a jejich vztahů.

V posledních letech vzniklo v oblasti analýzy jak ekonomických, tak finančních časových řad mnoho nových metod a přístupů. Také podmínky pro jejich praktickou aplikaci se v posledních několika letech výrazně zlepšily, což je především způsobeno jednak relativně snadnou dostupností poměrně širokého spektra různých druhů kvalitního softwaru a jednak rostoucí délkou analyzovaných časových řad.

Tématem diplomové práce je analýza a predikce finanční časové řady, konkrétně denního kurzu CAD/CZK za rok 2000-2010, pomocí statistických metod. Práce je rozdělena do 5 hlavních částí.

V první kapitole je charakterizován finanční trh především jeho předpoklady a charakteristiky.

Druhá část této práce se zabývá modelováním časových řad a modelování trendu a sezónní složky. Jsou zde vysvětleny základní pojmy jako trend, sezónní složka, cyklická složka a náhodná složka.

Ve třetím bodě je vysvětlena Boxova-Jenkinsova metodologie, do které patří stacionarita a stacionární procesy jako ARIMA, AR a MA.

Pátá a šestá část práce poukazuje na aplikovanou teorii. Jsou zde prakticky analyzovány předpoklady a charakteristiky finančních časových řad, modelování trendu a sezónní složky a metodologie Boxova-Jenkinsova. V poslední části je následně uvedena a zpracována predikce finanční časové řady pomocí procesů ARIMA, AR a MA.

Cílem analýzy časových řad je konstrukce vhodného modelu. Sestrojení daného modelu umožňuje porozumět mechanismu časové řady a pochopit podmínky a vazby, které jsou mezi těmito hodnotami. Na základě těchto modelů, podmínek a předpokladů lze simulovat vliv působící změny ve vývoji finanční časové řady.

Druhým cílem je pak využití těchto získaných poznatků při predikci budoucího chování finanční časové řady. Použité postupy mohou být založeny na principu opakování se minulosti. Tento předpoklad je v praxi plněn s různými přesnostmi, a proto je úkolem práce zjistit vhodné postupy při předpovědi časové řady. O spolehlivosti této predikce můžeme diskutovat, jelikož hodnota ukazatele závisí na ukazatelích, faktorech a podmínkách.

Cílem diplomové práce je provést analýzu vybrané finanční časové řady, konkrétně tedy měnového kurzu CAD/CZK a jeho predikci do budoucna. Dále ukázat hlavní metody, postupy a konstrukce této analýzy. Součástí je také předpověď měnového kurzu CAD/CZK.

1. FINANČNÍ TRH

Základní a první hypotéza o chování finančního trhu byla hypotéza efektivního trhu. Můžeme ji formulovat takto: *Za předpokladu, že ceny plně zahrnují očekávání a informace všech účastníků trhu, jsou jejich změny nepredikovatelné.*¹

Kvantitativní informace o finančním trhu jsou ve většině případů poskytovány ve formě **finančních časových řad**. Tyto časové řady mají svá specifika ve srovnání s ostatními časovými řadami. Viditelným rozdílem je sledování hodnot např. v denní či hodinové frekvenci.

Finanční trh je součástí tržního systému, představuje nabídku a poptávku peněz a kapitálu. Rozlišujeme tři druhy finančních trhů:²

- *dluhopisové trhy,*
- *akciové trhy,*
- *devizové trhy.*

Na finančních trzích se obchoduje s dluhovými cennými papíry, akciemi a peněžními prostředky v různých měnách. Základní informací finančních trhů je:³

- *cena akcie,*
- *cena měny,*
- *cena dluhopisu.*

Ceny jsou sledovány v určité časové frekvenci a tvoří tak časové řady. Tyto časové řady, jakož i řady vycházející z cen nebo charakterizující ceny a jejich vývoj, se označují jako **finanční časové řady**.

¹ Její první formulace se objevily v první polovině 20. století (Bachelier (1900), Cowles (1933)).

V pozdějších pracích z druhé poloviny 20. století (Farma (1970), Malkiel (1992)) byla tato hypotéza dále upřesňována.

² ARLT, J.: *Finanční časové řady*. vyd. 1. Praha: Grada Publishing a.s., 2003. 12 s.

³ ARLT, J.: *Finanční časové řady*. vyd. 1. Praha: Grada Publishing a.s., 2003. 12 s.

1.1 Časové řady

Pokud stojíme před problémem analýzy určitého ekonomického jevu, určitě se setkáme s pojmem časové řady.

1.1.1 Pojem časové řady

Definic týkajících se časových řad je mnoho. Pro řešení naší problematiky postačí tato základní definice časové řady:

- *Časovou řadou budeme chápat jako posloupnost věcně a prostorově srovnatelných pozorování (dat), která jsou jednoznačně uspořádána z hlediska času ve směru od minulosti k přítomnosti.⁴*

Chronologicky uspořádaná data se vyskytují v časových řadách, se kterými se běžně setkáváme v životě. S těmito daty pracuje fyzika, biologie, seismologie, meteorologie, medicína a velký význam mají i v ekonomii atd.

Časové řady jsou charakteristické:⁵

- *trendem,*
- *sezonností,*
- *podmíněnou heteroskedasticitou,*
- *nelinearitou,*
- *společnými vlastnostmi více časových řad.*

Tyto vyjmenované vlastnosti se u časových řad neobjevují zpravidla najednou. Jejich vzájemná přítomnost závisí na typu časové řady (např. sezónnost se objevuje u krátkodobých časových řad, podmíněná heteroskedasticita u vysokofrekvenčních časových řad).

⁴ RUBLÍKOVÁ, E.: *Analýza časových řadov.* vyd.1. Bratislava: Iura Edition, 2007. 11 s.

⁵ ARLT, J.; ARLTOVÁ M.: *Ekonomické časové řady.* vyd. 1. Praha: Grada Publishing a.s., 2007. 14 s.

Charakteristiky, které jsou uvedeny výše, jsou důležité především při provádění analýzy časových řad za účelem konstrukce předpovědí. U finančních časových řad se výrazně projevuje **složka trendová** a **cyklická**, **sezónní složka** není tak zřetelná, i když ji není možné vyloučit.⁶

1.1.2 Rozdělení časových řad

Časové řady můžeme rozlišovat z několika hledisek.

Dle rozhodného časového hlediska:⁷

- *intervalové* – hodnoty ukazatelů závisí na délce časového intervalu sledování,
- *okamžikové* – hodnoty ukazatelů se vztahují k časovým okamžikům, nezávisí na délce časového intervalu sledování.

Podle délky intervalu sledování hodnot:⁸

- *dlouhodobé časové řady* – mají hodnoty sledované v ročních či delších časových úsecích,
- *krátkodobé časové řady* – hodnoty se sledují v úsecích kratších, než je jeden rok,
- *vysokofrekvenční časové řady* – mají hodnoty sledované v úsecích kratších, než je jeden týden.

Dle druhu sledovaných ukazatelů:

- *primární (prvotní)* – ukazatele jsou zjišťované přímo,
- *sekundárních (odvozených)* – vznikají jako funkce primárních ukazatelů, pomocí této řady lze vypočítat časovou řadu kumulativní nebo klouzavých úhrnu.

⁶ ARLT, J.: *Finanční časové řady*. vyd. 1. Praha: Grada Publishing a.s., 2003. 12 s.

⁷ HINDLS, R.; HRONOVÁ, S.; SEGER J.: *Statistika pro ekonomy*. vyd. 7. Praha: Professional Publishing, 2006. 247 s.

⁸ ARLT, J.; ARLTOVÁ M.: *Ekonomické časové řady*. vyd. 1. Praha: Grada Publishing a.s., 2007. 14 s.

A poslední podle způsobu vyjádření údajů:

- *naturální* (hodnoty ukazatele jsou vyjadřovány v naturálních jednotkách),
- *peněžní*.

S těmito základními členěními souvisí především tvar ekonomických časových řad (např. čím je interval sledování delší, tím jsou časové řady vyhlazenější). Důležitou částí je i pořadí u časových řad, způsob jakým na sebe jednotlivé hodnoty v časových řadách navazují. Pořadí určuje jejich tvar a charakteristické vlastnosti.

1.2 Ekonomické časové řady

Ekonomickou časovou řadu můžeme chápat jako řadu hodnot ekonomického ukazatele, která je uspořádána v čase od minulosti do přítomnosti. Základní druhy a charakteristické vlastnosti ekonomických časových řad jsou vysvětleny v kapitole 1.1.

V empirických analýzách se můžeme setkat s tím, že se ekonomické časové řady logaritmičky transformují. Důvodem je, že některé ekonomické časové řady jsou charakteristické exponenciálně se vyvíjejícím trendem a logaritmičká transformace znamená jeho linearizaci. Tímto se časová řada stabilizuje z hlediska variability.

1.3 Charakteristické vlastnosti finančních časových řad

Finanční časové řady si můžeme představit jako např. speciální rysy vývoje úrokových měr, směnných kurzů a finančních indexů. Jde o časové řady, které se vyznačují tím, že mají **vysokofrekvenční data** s nepravidelným záznamem při nesynchronním obchodování, **cenové shlukování**, **podmíněnou heteroskedasticitu**, **leptokurtické rozdělení**⁹, výskyt segmentů s nízkou a naopak vysokou **volatilitou**, **nekorelovanost** mezi hodnotami řady a zároveň

⁹ leptokurtické rozdělení = na rozdíl od normálního rozdělení má „těžší konce“ a „užší pás“.

silnou korelovanost mezi čtverci hodnot řady v různých časech, odlišné reakce volatility na velké kladné či naopak záporné předchozí hodnoty.¹⁰

Finanční časové řady jsou charakterizovány jako časové řady odvozené z cen nebo charakterizující ceny. V případě finančních časových řad se vychází z předpokladu, že cena nemůže být záporné číslo, předpokládá se tedy, že by hodnoty těchto časových řad mohly být generovány **logaritmicko-normálním rozdělením**.

1.4 Předpoklady finančních časových řad

Níže uvedené předpoklady jsou důležité při analýze časových řad. A jednotlivé předpoklady se dají otestovat statistickými testy.

1.4.1 Předpoklad normality

Jedním ze základních předpokladů je, že **logaritmy výnosů**¹¹ mají normální rozdělení s konstantní střední hodnotou μ a konstantním rozptylem σ_r^2 . Toto rozdělení je charakteristické tím, že je symetrické, takže jeho šikmost je rovna nule a jeho špičatost je rovna číslu 3. Ze skutečnosti vyplývá, že časové řady logaritmů výnosů mají rozdělení špičatější s „tlustšími“ konci než je normální rozdělení.

1.4.2 Předpoklad nonlinearity

V analýzách finančních časových řad se předpokládá, že logaritmy výnosů jsou nekorelované a nezávislé. Většina ekonomických časových řad jsou charakteristické strukturálními zlomy, změnami průběhu a variability.

¹⁰ CIPRA, T.: *Finanční a pojistné vzorce*. vyd. 1. Praha: Grada Publishing a.s., 2006. 336 s.

¹¹ Výnosem se rozumí souhrn veškerých budoucích příjmů a důchodů, které lze z dané investice získat. Můžeme do něj zahrnout jak rozdíl mezi kupní a prodejní cenou aktiva, tak i úroky, dividendy, nájemné, kurzovní rozdíly atd. Jeho výši ovlivňuje celá řada faktorů.

V souvislosti s touto problematikou se může v čase měnit i jejich autokorelační struktura. Tento způsob chování ekonomických časových řad nemůže být zachycen klasickými lineárními modely.

Nelinearita se může projevit odlišnými průměrnými diferencemi nebo průměrnými koeficienty růstu v různých obdobích.¹²

1.4.3 Předpoklad podmíněné heteroskedasticity

Tento pojem vymezuje vlastnost, že logaritmus výnosu má normální rozdělení s rozptylem, který se mění v závislosti na čase. Podmíněnou heteroskedasticitu charakterizuje následující model:

$$(\ln X_t - \ln X_{t-1})^2 = \alpha + \rho(\ln X_{t-1} - \ln X_{t-2})^2 + u_t.$$

Proměnné X_t, X_{t-1} vyjadřují hodnoty v časové řadě při změně času t o jednotku. Parametr α se vypočítá pomocí metodou nejmenších čtverců. Poslední proměnná u_t je náhodná složka. Je-li parametr ρ roven nule, podmíněná heteroskedasticita v časové řadě není.

Základní předpoklad, který se uplatňuje jak v teoretických, tak i v empirických analýzách zabývajících se finančními časovými řadami, často vychází z toho, že **logaritmy**, tzv. **výnosů**, tj. **logaritmy koeficientů růstu**, mají normální rozdělení s konstantní střední hodnotou a konstantním rozptylem v čase. Důvod tohoto je, že ceny nemohou být záporné, takže se předpokládá jejich logaritmicko-normální rozdělení. Tato vlastnost se více týká finančních časových řad.¹³

Časové řady logaritmů výnosů mají rozdělení špičatější ve srovnání s rozdělením normálním. Podmíněná heteroskedasticita může být způsobena charakteristickým rysem jejich chování.

¹² TSAY, S., RUEY: *Analysis of financial time series*. 2nd ed. Hoboken, N.J.: Wiley Interscience, 2005. 175 p.

¹³ TSAY, S., RUEY: *Analysis of financial time series*. 2nd ed. Hoboken, N.J.: Wiley Interscience, 2005. 109 p.

Jednoduchým a nejvíce používaným testem heteroskedasticity je **Spearmanův test korelace pořadí**. Vzorec pro daný test:

$$r_{ex} = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)}, i = 1, 2, \dots, n,$$

kde d_i jsou difference v pořadí odpovídajících dvojic pořadových hodnot $|e_i|$ a X_i . Hodnoty blízké jedné svědčí o existenci heteroskedasticity.¹⁴

1.4.4 Předpoklad autokorelace

Předpoklad výskytu autokorelace můžeme testovat pomocí **Durbin-Watsonovy statistiky**.

Testovací statistika:

$$d = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2}.$$

Hodnotu d porovnáme s kritickou oblastí a na základě pozice d vyhodnotíme autokorelaci.¹⁵ Kritické hodnoty d_D a d_H představují dolní mez a horní mez d .

Jednotlivé intervaly:

- interval $\langle 0; d_D \rangle$ značí pozitivní autokorelaci,
- v intervalu $\langle d_D; d_H \rangle$ nemůžeme rozhodnout, zda se jedná o korelaci, či nikoliv,
- interval $\langle d_H; 2 \rangle$ poukazuje na statisticky nevýznamnou pozitivní autokorelaci,
- interval $\langle 2; 4 - d_H \rangle$ poukazuje na statisticky nevýznamnou negativní autokorelaci,
- v intervalu $\langle 4 - d_H; 4 - d_D \rangle$ nemůžeme rozhodnout, zda se jedná o korelaci, či nikoliv,
- interval $\langle 4 - d_D; 4 \rangle$ poukazuje na statisticky významnou negativní autokorelaci.

¹⁴ HUŠEK, R.: *Ekonomická analýza*. vyd.1. Praha: Oeconomica, 2007. 74-78 s.

¹⁵ HUŠEK, R.: *Ekonomická analýza*. vyd.1. Praha: Oeconomica, 2007. 83-89 s.

1.4.5 Předpoklad volatility (variability)

Tato problematika také zahrnuje pojem **variabilita** neboli **volatilita**. Problém změn variability je především spojen s nejistotou na trhu. Volatilita znamená míru kolísání hodnoty aktiva nebo jeho výnosové míry.

Někdy se variabilita může měnit ve velmi krátkých úsecích časové řady a některé výnosy lze tak dokonce považovat za extrémní hodnoty (odlehlá pozorování), jindy zůstává variabilita po určitý čas na podobné úrovni a potom se tato úroveň mění, variabilita se mění ve shlcích.¹⁶

Můžeme říci, že volatilita určité úrovně se udržuje po jistý čas, volatilita v čase t tak závisí na volatilitě v čase $t - 1$. Variabilita se měří směrodatnou odchylkou. V případě časové řady se ale směrodatná odchylka nepočítá z původních pozorování, ale z relativních přírůstků.

Vztah pro výpočet **směrodatné odchylky**:

$$s_x = \sqrt{s_x^2} = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}$$

1.5 Základní charakteristiky časových řad

Obvykle prvním úkolem při analýze časové řady je získat rychlou a orientační představu o charakteru procesu, který tato řada reprezentuje.

Vizuální analýza:

- *grafy*,
- *elementární charakteristiky* (diference různého řádu, tempa a průměrná tempa růstu, průměr časové řady aj.).

¹⁶ Tato zjištění nejsou nová, upozornil na ně již Mandelbrot (1963).

1.5.1 Popisné charakteristiky

Chronologický průměr

Okamžikové časové řady se vypočítávají pomocí speciálního průměru tzv. **chronologický průměr**, kde se rozlišuje, zda je délka mezi jednotlivými časovými okamžiky stejná. Pokud je stejná, použije se prostý chronologický průměr:

$$\bar{y} = \frac{\frac{y_1 + y_2}{2} + \frac{y_2 + y_3}{2} + \dots + \frac{y_{k-1} + y_k}{2}}{k - 1}.$$

Nebude-li délka stejná, použije se vzorec pro vážený chronologický průměr:

$$\bar{y} = \frac{\frac{y_1 + y_2}{2} \cdot d_1 + \frac{y_2 + y_3}{2} \cdot d_2 + \dots + \frac{y_{k-1} + y_k}{2} \cdot d_{k-1}}{d_1 + d_2 + \dots + d_{k-1}},$$

kde y_n hodnoty okamžikových ukazatelů k jsou časové okamžiky a d_k jsou jednotlivé délky intervalů.

1.5.2 Míry dynamiky

Dynamiku časové řady v obdobích lze kvantifikovat pomocí tzv. měr dynamiky, kam můžeme zařadit:

- absolutní přírůstek,
 - průměrný absolutní přírůstek,
 - koeficient růstu,
 - relativní přírůstky.
- *Absolutní přírůstek (první diference)* – vyjadřuje, jak se změní hodnota v časové řadě v čase t ve srovnání s hodnotou v čase $t - 1$.

$$\Delta y_t = y_t - y_{t-1}, t = 2, 3, \dots, T.$$

- *Průměrný absolutní přírůstek (průměrná diference)* – počítá se za celou časovou řadu (aritmetický průměr absolutních přírůstků).

$$\bar{\Delta} = \frac{\sum_{t=2}^T \Delta y_t}{T-1} = \frac{y_T - y_1}{T-1}, t = 2, 3, \dots, T.$$

- *Koeficient růstu (řetězový index)* – po vynásobení stem udává, na kolik % hodnoty v čase $t-1$ se změnila hodnota v čase t (průměrná hodnota relativních přírůstků).

$$k_t = \frac{y_t}{y_{t-1}}, t = 2, 3, \dots, T.$$

- *Průměrný koeficient růstu* – vyjadřuje, kolikrát v průměru vzrostla hodnota proměnné y v časové řadě za jedno období (geometrický průměr koeficientů růstu).

$$\bar{k}_t = \sqrt[t-1]{k_1 \cdot k_2 \cdot \dots \cdot k_T} = \sqrt[t-1]{\frac{y_2}{y_1} \cdot \frac{y_3}{y_2} \cdot \dots \cdot \frac{y_T}{y_{T-1}}} = \sqrt[t-1]{\frac{y_T}{y_1}}, t = 2, 3, \dots, T.$$

- *Relativní přírůstek (koeficient přírůstku)* – vyjadřuje přírůstek hodnoty časové řady v t období proti $t-1$ období jako jejich podíl (podíl mezi dvěma sousedními pozorováními minus jedna).

$$k_{\Delta t} = \frac{\Delta y_t}{y_{t-1}} = \frac{y_t - y_{t-1}}{y_{t-1}} = k_t - 1, t = 2, 3, \dots, T.$$

2. MODELOVÁNÍ ČASOVÝCH ŘAD

Při modelování časových řad se obvykle vychází z tradičního principu a tím je **jednorozměrný model**:

$$y_t = f(t, \varepsilon_t),$$

kde y_t je hodnota modelovaného ukazatele v čase t , $t = 1, 2, \dots, n$, ε_t je hodnota náhodné složky (poruchy) v čase t .

Jednorozměrný model je v zásadě popsán trojím možným způsobem, který je nadále charakterizován.

Vedle jednorozměrných modelů se můžeme setkat i s modely založenými na předpokladu, že vývoj analyzovaného ukazatele není ovlivňován pouze časovým faktorem, ale i řadou jiných ukazatelů. Tyto ukazatele můžeme nazvat příčinné nebo faktorové. Tento typ se nazývá **vícerozměrný model**. Lze ho napsat ve formě:

$$y_t = f(t, x_1, x_2, \dots, x_n, \varepsilon_t),$$

kde x_1, x_2, \dots, x_n jsou ukazatele ovlivňující analyzovaný ukazatel y .

2.1 Klasický (formální) model

Tento model pouze popisuje formy pohybu a nezabývá se příčinami dynamiky časové řady. Model vychází z **dekompozice časové řady** na čtyři složky časového pohybu, které se mohou vyskytnout u vybrané časové řady. Pozornost je zde věnována především konstrukci systematické složky, kde se předpokládá, že jednotlivá pozorování jsou vzájemně nekorelovaná. Tyto složky tvoří systematickou část průběhu časové řady a úkolem je nalezení nástrojů, které vysvětlí chování této časové řady. Všechny čtyři formy se nevyskytují společně, není to podmínka.

Časovou řadu tedy můžeme dekomponovat na tyto 4 základní složky:

- trendová složka T_t ,
- sezonní složka S_t ,
- cyklická složka C_t ,
- náhodná složka ε_t .

Nejčastěji se při analýze časové řady předpokládá **aditivní model** popisu chování řady. Předpokládá se, že jednotlivé složky vývoje se sčítají, takže platí:

$$y_t = T_t + S_t + C_t + \varepsilon_t,$$

kde na pravé straně po řadě vystupují složky trendová, sezónní, cyklická a náhodná.¹⁷

Další model, který se používá, je **multiplikativní model**, který má předpoklad, že se jednotlivé složky vyjadřují součinem.

$$y_t = T_t \cdot S_t \cdot C_t \cdot \varepsilon_t.$$

Při dekompozici časové řady se obvykle postupuje tak, že se nejprve provede určení sezónní složky, která je následně z časové řady odstraněna (sezónní očištění). Následně se u dat očištěných o sezónnost identifikuje trendová složka

Nyní se budeme zabývat charakteristikou jednotlivých složek, přičemž trend a sezónnost je definována podrobně v kapitole 2.2 a 2.3.

2.1.1 Cyklická složka

Můžeme říci, že cyklická složka definuje složku, která kolísá okolo trendu v důsledku dlouhodobého cyklického vývoje. Jedná se např. o cyklus demografický, inovační apod. Občas se vyskytne, že je cyklická složka zahrnována pod složku trendovou jako její část.

¹⁷ CIPRA, T.: *Finanční a pojistné vzorce*. vyd.1. Praha: Grada Publishing a.s., 2006. 323-324 s.

2.1.2 Náhodná složka (rezidua, bílý šum)

Náhodná složka je považována za veličinu, kterou nelze popsat žádnou funkcí času. Je to ta část, která zbývá po vyloučení trendu, sezonní a cyklické složky. Jejím zdrojem jsou nepostižitelné příčiny, které jsou vzájemně nezávislé. Práce s touto složkou je velmi citlivým místem analýzy časových řad, její vlastnosti se prověřují prostřednictvím některých testů.

2.2 Modelování trendu

Analýza trendové složky je zřejmě nejdůležitější částí analýzy časových řad. V průběhu let se potvrdilo, že při výběru trendových funkcí se většinou vystačíme s úzkou nabídkou funkcí, jako jsou např. lineární, exponenciální, logistický a polynomický trend.

2.2.1 Trend

Trend představuje dlouhodobé změny v chování časové řady, resp. obecnou tendenci vývoje zkoumaného jevu za dlouhé období. Můžeme ho chápat jako výsledek faktorů, které dlouhodobě působí ve stejném směru (např. technologie výroby, demografické podmínky či podmínky trhu). Trend může mít různou podobu, může být buď rostoucí nebo klesající, strmý či mírný, v průběhu času se může měnit, lze ho pokládat za cyklus. Může být i hladší nebo variabilnější.

Jednou z možností jak lze trend vyjádřit, je model:

$$X_t = \alpha + \beta t + u_t,$$

kde $t = 1, 2, \dots, T$, který se označuje jako model lineárního deterministického trendu. Parametr β charakterizuje přírůstek řady X_t při změně času t . Odhady parametrů lineární trendové funkce se určují pomocí metody nejmenších čtverců. Odhady parametru β představují dynamiku časové řady. Složka u_t vykazuje korelaci v čase (tzv. autokorelaci).

2.2.2 Analýza trendu

Určení trendu po očištění od periodického a nahodilého kolísání se provádí dvěma způsoby:

- *mechanické* - klouzavými průměry,
- *analytické* - trendovou funkcí (regrese).

Oblíbenější jsou různé druhy klouzavých ukazatelů, které jsou schopny částečně eliminovat vliv náhodných vlivů na sledovaný ukazatel a tím časovou řadu "vyhladit".

Používají se jak **klouzavé mediány**, tak **klouzavé průměry**. Vždy se postupuje tak, že údaj časové řady nahradíme zvoleným ukazatelem z okolních časově předcházejících a následujících údajů.¹⁸

2.2.3 Metoda klouzavých průměrů

Klouzavé průměry patří k mechanickým metodám vyrovnání. Podstata vyrovnání pomocí klouzavých průměrů spočívá v tom, že posloupnost empirických pozorování nahradíme řadou průměrů vypočítaných z těchto pozorování.

Název **klouzavý průměr** vznikl z toho, že při postupném výpočtu průměrů postupujeme (kloužeme) vždy o jedno pozorování kupředu, přičemž zároveň nejstarší (tj. první) pozorování z té skupiny, z níž je průměr počítán, vypouštíme. Velmi důležitou otázkou, kterou je nutné při tomto způsobu vyrovnání řešit, je stanovení počtu pozorování, z nichž jsou jednotlivé klouzavé průměry počítány. Klouzavé průměry pak můžeme rozdělit dle jejich specifikace na **prosté klouzavé průměry**, **vážené klouzavé průměry** a **centrované klouzavé průměry**.¹⁹

¹⁸ KOZÁK, J., HINDLS R.: *Úvod do analýzy ekonomických časových řad*. vyd. 1. Praha: Vysoká škola ekonomická v Praze, 1994. 61 s.

¹⁹ CIPRA, T.: *Finanční ekonometrie*. vyd. 1. Praha: Ekopress s.r.o., 2008. 274 s.

2.2.4 Exponenciální vyrovnání

Exponenciální vyrovnávání je relativně snadno použitelná technika, u které se každý následující člen v zásadě předpovídá jako vážený průměr členů předchozích. Rozlišují se dva typy. Jedním je **jednoduché exponenciální vyrovnání**, je to jednodušší forma a druhá je **dvojitě exponenciální vyrovnání**, tato metoda je složitější pro výpočet parametrů.

Metoda exponenciálního vyrovnání vychází z principu, že starší a novější hodnoty v časové řadě nemají pro stanovení trendu stejnou informační hodnotu.

Výsledkem jednoduchého exponenciálního vyrovnání je exponenciálně vážený aritmetický průměr z hodnot časové řady. Dvojitě neboli Holtovo exponenciální stanovuje nejdříve parametry lineární trendové funkce s použitím vážené metody nejmenších čtverců.

2.3 Modelování sezónní složky

Sezónní dekompozice je relativně jednoduchá procedura, umožňující rozložit časovou řadu na součet nebo součin dvou časových řad, **sezónního faktoru** a **trendu** a dvou s nimi souvisejících složek.

2.3.1 Sezónní složka

Tento termín představuje pravidelně se opakující odchylku od trendové složky. K příčinám sezónního kolísání dochází v důsledku vlivu změn jednotlivých ročních období, vlivu různé délky měsíčního či pracovního cyklu nebo též vlivu různých společenských zvyklostí.

2.3.2 Analýza sezónní složky

Analýza sezónní složky se často provádí až po očištění dat od trendové složky. V podstatě při ní jde o určení časového úseku, po jehož uplynutí mají data zase stejnou hodnotu, příp. ovlivněnou trendovou a náhodnou složkou.

Pro studium sezónní složky se používá několika typů modelů. V ekonomických modelech bývá zpravidla zřejmá velikost periody (čtvrtletí, měsíc), v jiných případech je nutno i tuto délku odhadovat (v hydrogeologii např. u výšky hladiny spodních vod).²⁰

Při sezónním očišťování se používají tzv. **sezónní indexy**. Tyto index vyjadřují srovnání průměrné výše příslušné proměnné a za jednotlivá období vůči průměru za celou časovou řadu.

2.3.3 Sezónnost

Sezónností můžeme rozumět periodické kolísání v časové řadě, které má systematický charakter. Toto kolísání se odehrává během jednoho kalendářního roku a každý rok se ve stejném nebo modifikované podobě opakuje. Tyto periodické změny jsou způsobeny především střídáním ročních období a různými lidskými zvyky.²¹

Sezónnost se vyskytuje u krátkodobých a u vysokofrekvenčních časových řad (např. onačí-li se počet sezon jako S , potom v případě denní časové řady $S = 5$, čtvrtletí $S = 4$ a měsíční $S = 12$ atd.) U většiny časových řad je sezónnost patrná z grafického vyjádření na první pohled. Sezónnost v časové řadě může mít také nepravidelný charakter. Parametry charakterizující sezónnost se nazývají **sezónní faktory**. Sezónní faktory, jejichž součet je roven nule.²²

²⁰ KOZÁK, J., HINDLS R.: *Úvod do analýzy ekonomických časových řad*. vyd.1. Praha: Vysoká škola ekonomická v Praze, 1994. 125 s.

²¹ ARLT, J., ARTLOVÁ M.: *Ekonomické časové řady*. vyd.1. Praha: Grada Publishing, a.s., 2007. 17 s.

²² ARLT, J.; ARTLOVÁ M.: *Ekonomické časové řady*. vyd. 1. Praha: Grada Publishing a.s., 2007. 18 s.

2.4 Predikce časové řady

Konstrukce předpovědi (jinak také predikce či prognóza) je jedním z nejdůležitějších úkolů analýzy časových řad. Výběr příslušné předpovědní techniky, závisí na dané situaci a řadě dalších okolností.

Před každou analýzou časové řady, zejména při predikci, si je třeba uvědomit, že v čase mohou nastat zhruba tyto tři případy:

1. Charakter řady se nemění, následující člen nelze sice předvídat přesně, celkový trend se však zachovává a to umožňuje učinit spolehlivý statistický odhad o budoucím průběhu, konkrétně například určit interval, ve kterém lze příští člen očekávat s 99% pravděpodobností.
2. V čase t dojde k jednorázové poruše, která znemožní předpověď budoucího členu, nezmění však celkový charakter řady. Porucha na nějakou dobu rozhází chování řady, po odeznění přechodových jevů však bude stejná jako dříve nebo na jiné analogické úrovni, v každém případě, ale nemusíme upouštět od dosavadního modelu.
3. V čase t dojde k poruše, která zcela naruší chování řady, že nejen není možné vyslovit rozumnou předpověď ze znalosti minulých členů, ale je nutné opustit dosavadní model chování řady a pokusit se najít nový.

Jinými slovy, kvalifikované předpovědi můžeme poskytnout jen v prvním případě, smysluplné jen v případě, že vyloučíme třetí možnost.

3. BOXOVA-JENKINSOVA METODOLOGIE

Tato metoda považuje za základní prvek konstrukce modelu časové řady náhodnou složku, která může být tvořena korelovanými náhodnými veličinami. U tohoto je těžištěm postupu, na který se klade důraz, korelační analýza více či méně závislých pozorování uspořádaných do tvaru časové řady. Pro příklad můžeme uvést situaci, kdy všechna pozorování jsou vzájemně nezávislá s výjimkou vždy bezprostředně sousedící dvojice empirických údajů. Tvar takového procesu může vypadat následovně:

$$y_t = \varepsilon_t + \varepsilon_{t-1},$$

kde y_t , $t = 1, 2, \dots, n$, představuje napozorované údaje časové řady a ε_t jsou nekorelované náhodné veličiny s nulovou střední hodnotou a s konstantním rozptylem (v čase). Poté můžeme říci, že řada ε_t , $t = 1, 2, \dots, n$, tvoří tzv. bílý šum. Tento uvedený tvar procesu y_t se nazývá **model klouzavých součtů** a označuje se $MA(1)$, tj. v konkrétním případě jde o model klouzavých součtů 1. řádu.

Další kategorií modelu jsou **autoregresní modely** označované AR , které později využijeme v analýze finančních časových řad. Mají především numerickou podobu jako např.

$$y_t = y_{t-1} + \varepsilon_t.$$

Tento tvar se nazývá autoregresním modelem 1. řádu a označuje se $AR(1)$. Kombinací těchto uvedených modelů MA a AR vznikají tzv. smíšené modely $ARMA$.

3.1 Stacionarita

Hodnoty finančních časových řad jsou charakteristické tím, že nemají zřetelnou tendenci vracet se k nějaké konstantě. Tato zmíněná vlastnost se označuje jako **nestacionarita**. Pro analýzu časových řad je potřeba mít tuto řadu stacionární. Stacionaritu získáme pomocí tzv. **diferencí**. Stacionarita se vyskytuje u makroekonomických časových řad, jako např. hrubý domácí produkt, peněžní zásoba, úrokové sazby a měnové kurzy.

Tento typ je zvláštním případem časové řady s konstantní sezónností, v které v dlouhodobém měřítku není pozorovatelná tendence k růstu nebo poklesu.²³

3.2 Autoregresní předpovědní modely

Tento typ modelů můžeme také chápat jako vstupní krok pro aplikace Box-Jenkinsovy metodologie analýzy časových řad. Při analýzách finančních časových řad často narážíme na skutečnost, že zde existuje korelační vztah mezi po sobě jdoucími hodnotami. Potom můžeme říci, že se jedná o autokorelované časové řady. Možná konstrukce předpovědi těchto řad se pak provádí pomocí **autoregresních modelů**. Pokud je popis regrese založen na vztahu bezprostředně sousedících hodnot, mluvíme o autoregresním modelu 1. řádu a pokud je základem vztah s posunem o 2 období, půjde o autoregresní model 2. řádu.

3.3 Stacionární procesy

Následně vyjmenované jednotlivé procesy či modely se používají při analýze a především při predikci stacionárních finančních časových řad. Každý model je něčím specifickým.

3.3.1 Procesy ARIMA

Používá se ke krátkodobé predikci a to v situaci, kdy nejsou k dispozici adekvátní data vysvětlujících proměnných, resp. když při odhadu a verifikaci dospějeme k závěru, že odhadnuté parametry jsou z hlediska ekonomických, statistických i ekonometrických kritérií nepoužitelné, nebo má-li model špatné prognostické vlastnosti.²⁴

²³ MILLS, C., TERENCE: *The Econometric Modelling of Financial Time Series*. 3rd ed. New York: Cambridge University Press, 2008. 10-12 p.

²⁴ ANDERSEN, T., G.; DAVIS, R., A.: *Handbook of Financial Time Series*. 1st ed. Berlin: Springer, 2009. 711 p.

3.3.2 Procesy AR(1)

Procesy $AR(1)$ poskytují jiný přístup k modelování časové struktury stacionárních časových řad. Y_t je vyjádřeno jako funkce několika předcházejících pozorování. Model $AR(1)$ představuje autoregresní model prvního řádu.

Autoregresní model 1. řádu můžeme zapsat takto:

$$Y_t = b_1 \cdot y_{t-1} + \varepsilon_t,$$

kde $b_1 < 1$ a parametr stanovíme tradiční cestou metodou nejmenších čtverců. Střední hodnota stacionárního procesu je nulová.²⁵

3.3.3 Procesy MA(1)

Model MA se nazývá proces klouzavých součtů a $MA(1)$ je **proces klouzavých součtů řádu 1**. Proces MA má tvar, ve kterém se vyskytuje bílý šum a parametry, kde střední hodnota je nulová.

Proces $MA(1)$ má tvar:

$$Y_t = \varepsilon_t + \theta_1 \cdot \varepsilon_{t-1},$$

kde $\theta < 1$.

Jedna z možností modelování dynamiky stacionárních časových řad. Např. analýza vývoje změn cen akcií, kdy tato posloupnost změn cen s nulovým průměrem a konstantním rozptylem lze zapsat:

$$Y_t = u_t$$

u_t jsou identicky rozdělené náhodné složky, sériově nezkorelované. Odrážejí působení neočekávaných vlivů na cenu akcií např. informace o finanční situaci podniku.²⁶

²⁵ HAMILTON, DOUGLAS, JAMES: *Time Series Analysis*. 1st ed. Princeton: Princeton University Press, 1994. 53-56 p.

²⁶ HAMILTON, DOUGLAS, JAMES: *Time Series Analysis*. 1st ed. Princeton: Princeton University Press, 1994. 64-67 p.

3.3.4 Procesy AR(2)

Model $AR(2)$ představuje **autoregresní model druhého řádu**. Autoregresní model 2. řádu bude mít tři neznámé parametry:

$$Y_t = b_1 \cdot y_{t-1} + b_2 \cdot y_{t-2} + \varepsilon_1.$$

Vysvětlení jednotlivých proměnných, které se vyskytují ve zmíněných modelech. Parametry b_1 a b_2 získáme pomocí metody nejmenších čtverců a y_{t-1} a y_{t-2} jsou hodnoty v časové řadě v čase t . Proměnná ε_1 vyjadřuje náhodnou složku.

3.3.5 Procesy AR(1) MA(1)

V praxi při modelování časových řad se setkáváme s případy, kdy stacionární náhodný proces, generující jejich jednotlivá pozorování, nevyhovují zcela předpokladům MA , resp. AR , modelů. V této situaci je adekvátní taková specifikace modelu časové řady, jejíž služby vycházejí z principu kombinace AR a MA procesů. **Smišený model** časových řad, se nazývá $ARMA(p, q)$ model, přičemž p výrazů je autoregresního typu a q reprezentuje zpožděné klouzavé průměry.

4. ANALÝZA FINAČNÍCH ČASOVÝCH ŘAD

V této kapitole bude rozpracována analýza finančních časových řad podle výše vysvětlené teorie. Analýza se provede podle daných metod, vzorců a postupů. Z provedené analýzy pak určíme predikci zvolené časové řady.


Data, která byla použita k analýze finančních časových řad, byla čerpána z České národní banky. Konkrétně tedy kurz **CAD/CZK** (CAD – Kanadský dolar), jehož data jsou hodnocena jako nejlepší pro tuto analýzu. Data jsou sledována v denním intervalu očištěná o víkendy od roku 2000 do roku 2010.

Pro tuto analýzu byl použit softwarový produkt společnosti StatSoft s názvem **STATISTICA** a program **MS Office Excel**.

Důležitým prvním bodem, s kterým byla započata analýza, bylo grafické zobrazení dané finanční časové řady, tedy kurz **CAD/CZK**. Tento základní prostředek prezentace časové řady zobrazuje především jejich charakteristické vlastnosti a rysy. Časová řada byla znázorněna jak pomocí *spojnicového grafu*, tak i *krabičkovým grafem*. Krabičkový graf byl zvolen i proto, že s jeho pomocí je možné provést detailnější pohled na časovou řadu.


Jednotlivé hodnoty časové řady jsou u spojnicového grafu vyznačeny pomocí os. Na ose horizontální jsou vyznačeny jednotlivé denní hodnoty zobrazeny v letech a na ose vertikální potom jednotlivý denní kurz CAD/CZK. Z vyjádřeného grafu lze pozorovat mírně klesající trend kurzu CAD/CZK. Od konce prvního čtvrtletí roku 2000 do začátku druhého čtvrtletí roku 2006 spíše hodnota kurzu stagnovala, později začala klesat (viz graf č. 1.).

Graf 1: Spojnicový graf znázorňující kurz CAD/CZK



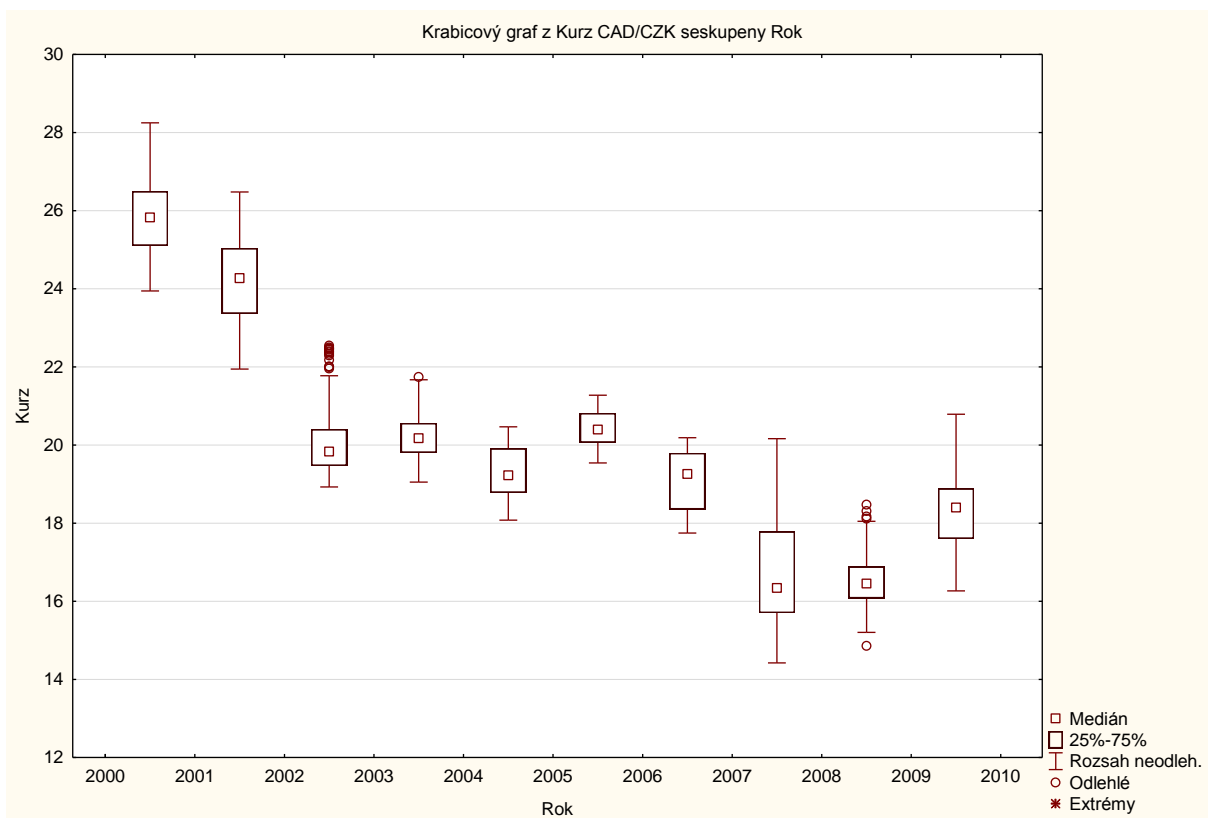
Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Graf 2: Logaritmy výnosu denního kurzu CAD/CZK



Zdroj: vlastní zpracování

Jeden ze základních předpokladů v analýzách finančních časových řad je stacionarita. Ta se ověřuje z **logaritmů tzv. výnosů (koeficienty růstu)** neboli logaritmování, které se provádí z toho důvodu, že ceny nesmí být záporné. Proto byl graf č. 2 znázorněn pro další analýzu.



Obrázek 1: Krabicový graf znázorňující kurz CAD/CZK

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázek č. 1 zobrazuje **krabicové grafy** pro jednotlivé roky 2000-2010. Základním prvkem je *krabička*, jejíž dolní a horní hrana je tvořena 25% a 75% kvantilem, uvnitř je vyznačen medián a aritmetický průměr. Na koncích svislých čar pak leží hodnoty minima a maxima. Jsou zde i hodnoty přesahující tyto hranice označující jako odlehlé, viz obrázek č. 1.²⁷

Z krabicových grafů se dají vyčíst i různé kvantily pravděpodobnostního rozdělení, ale převážně zde figurují data z normálního rozložení, je to dáno polohou mediánu, která leží takřka v prostředku obdélníku. Z obrázku je patrné, že se v datech objevují odlehlé hodnoty.

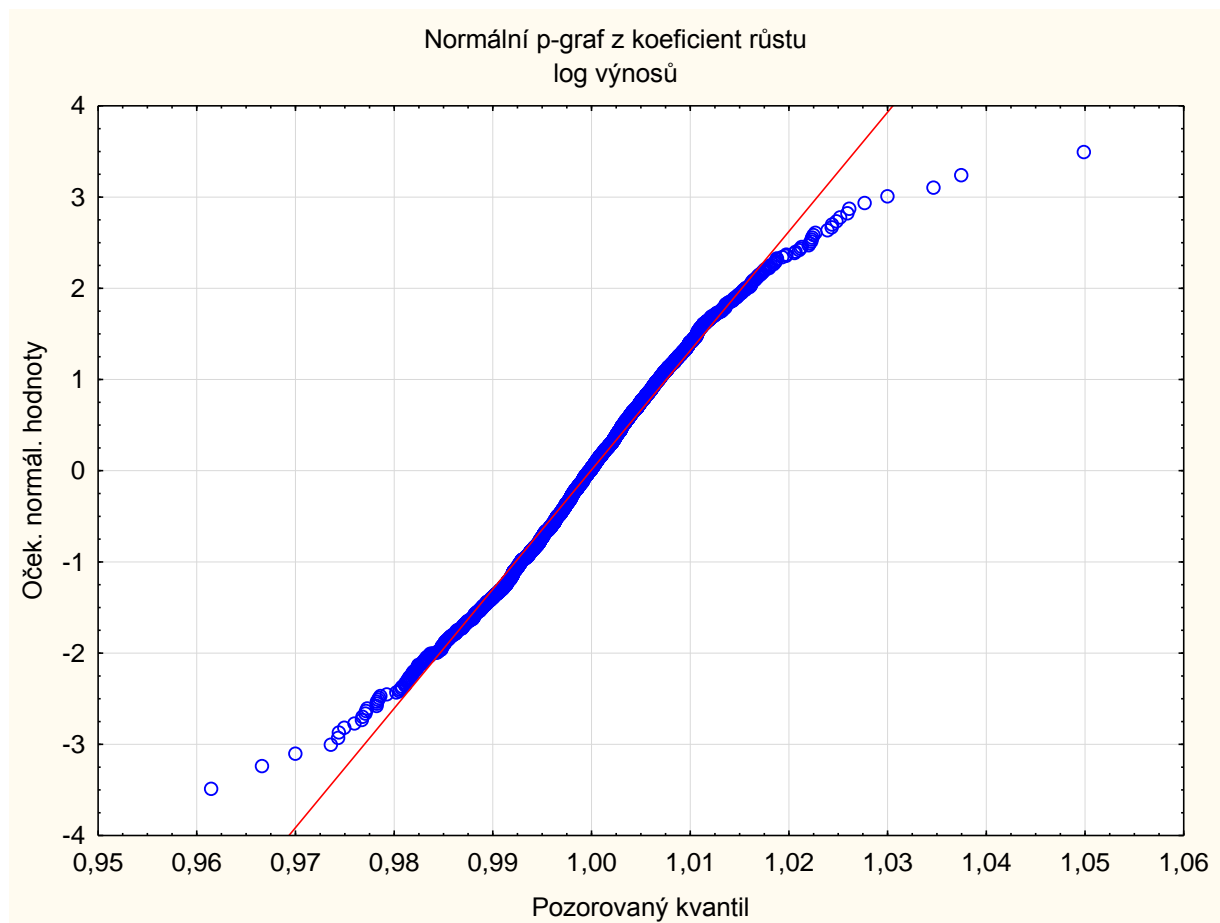
²⁷ ARLT, J.; ARLTOVÁ, M.; RUBLÍKOVÁ, E.: *Analýza ekonomických časových řad s příklady*. vyd. 2. Praha: Oeconomica, 2004. 10 s.

4.1 Předpoklady finančních časových řad

V následujících podkapitolách budou vypočteny a otestovány základní předpoklady finančních časových řad, které byly popsány v teoretické části.

4.1.1 Předpoklad normality

Pro zjištění zda data pocházejí z normálního rozdělení, byl použit **statistický test Shapiro-Wilkův test normality**, který byl vypočítán a graficky znázorněn pomocí softwaru STATISTICA.




Obrázek 2: Normální rozdělení logaritmy výnosů

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Z obrázku č. 2 je patrné, že data pocházejí z normálního rozložení. K zjištění byl použit normální graf pravděpodobnostního rozdělení. Tyto data obsahují odlehle hodnoty,

ale nijak neovlivňují ostatní data, která pocházejí z normálního rozdělení. Z tohoto grafu vychází, že logaritmy výnosů mají normální rozdělení.



Obrázek 3: Histogram proložený hustotou normálního rozdělení

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Z obrázku č. 3 a z výsledku provedeného testu můžeme říci, že logaritmy výnosů pocházejí z normálního rozložení.

Tabulka 1: Popisné statistiky logaritmy výnosů kurzu CAD/CZK

	n	Průměr	Medián	Modus	Minimum	Maximum	Dolní - kvartil	Horní - kvartil	Rozpětí	Rozptyl	Sm.odch.	Šikmost	Špičatost
Koeficient růstu	2771	0,999	0,999	1,000	0,961	1,049	0,995	1,004	0,088	0,00005	0,007	0,107	1,872

Zdroj: vlastní zpracování

Z těchto popisných charakteristik, které zachycuje tabulka č. 1, můžeme vidět **šikmost** a **špičatost** logaritmů výnosů. Symetrické rozdělení znamená, že hodnota šikmosti se pohybuje kolem 0 a hodnota špičatosti je kolem 1,8. Z tabulky můžeme také vyčíst, že se jedná o 2771 platných pozorování, které je rozloženo v intervalu od 0,961 do 1,049. Průměrná hodnota, medián i modus mají stejnou hodnotu, jak můžeme vidět z tabulky, což vypovídá o normálním rozdělení.

4.1.2 Předpoklad nelinearity

Předpoklad linearity určíme pomocí **korelačního koeficientu R** z logaritmů výnosu, který byl vypočten pomocí programu MS Office Excel. Linearita se obecně považuje za prokázanou, když $R > 0,99$. Pokud hodnota korelačního koeficientu R klesne pod hodnotu 0,98 nebo je hodnota rovna 0, je splněn předpoklad nelinearity.²⁸ Po dosazení do vzorce a výpočtu byl určen korelační koeficient $R = 0$, můžeme tedy říci, že je *splněn předpoklad nelinearity*.

4.1.3 Předpoklad podmíněné heteroskedasticity

Z teoretické části víme, že pokud logaritmy výnosů mají normální rozdělení s konstantní střední hodnotnou nebo konstantním rozptylem v čase a vyskytuje se u časové řady variabilita či volatilita, tak se jedná o **podmíněnou heteroskedasticitu**.²⁹ To je ověřeno viz, obrázek č. 2 a 4. Můžeme i otestovat předpoklad podmíněné heteroskedasticity pomocí **Spearmanova testu korelace pořadí** viz tabulka č.2.

Tabulka 2: Spearmanův test korelace

Proměnná	Spearmanovy korelace pořadí Označ. korelace jsou významné na hl. $p < 0,05$	
	Datum	Kurz
Datum	1,00	0,909
Kurz	0,909	1,00

Zdroj: vlastní zpracování

²⁸ TSAY, S., RUEY: *Analysis of financial time series*. 2nd ed. Hoboken, N.J.: Wiley Interscience, 2005. 205 p.

²⁹ HUŠEK, R.: *Ekonomická analýza*. vyd.1. Praha: Oeconomica, 2007. 74-78 s.


Z tabulky můžeme vyčíst, že se zde podmíněná heteroskedasticita v časové řadě vyskytuje, jelikož hodnota je blízká jedné.

4.1.4 Předpoklad autokorelace

Pro otestování výskytu autokorelace použijeme **Durbinův-Watsonův test**. Po dosazení a výpočtu reziduí e_i v testovací statistice vyšel výsledek Durbinovy-Watsonovy statistiky $d=0,00857$ po stanovení tabulkových hodnot. Po porovnání s již zmíněnými intervaly a na základě pozice d můžeme říci, že se jedná o **pozitivní autokorelaci**, a že předpoklad autokorelace je splněn.

Výsledek a předpoklad autokorelace si můžeme ověřit i dle znázorněného obrázku č. 20, kde je znázorněna autokorelační funkce.


4.1.5 Testování předpokladu volatility



Obrázek 4: Stacionarizovaná časová řada - první diference

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Na tomto obrázku č. 4 je vidět měnící se průběh **volatility** časové řady. Můžeme říci, že čím je volatilita nižší, tím je odhad modelu přesnější.



Obrázek 5: Bodový graf s intervalem spolehlivosti

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázek č. 5 zachycuje **intervaly spolehlivosti**, které ukazují vývoj volatility časové řady.

4.2 Základní charakteristiky časových řad

Tyto základní charakteristiky a jejich vzorce byly vysvětleny v teoretické části v kapitole č. 1.5. Než začneme se samotnou analýzou pomocí metod, jsou důležité následující body uvedené v podkapitolách.

4.2.1 Popisné charakteristiky

Chronologický průměr

Když pracujeme s časovými řadami, je důležité zjistit i jejich průměrné hodnoty. V našem případě máme stejné vzdálenosti jednotlivých okamžiků sledování, a proto použijeme *prostý chronologický průměr*.

Průměrná hodnota denního kurzu CAD/CZK za **10 let je 30,15** po dosažení hodnot do vzorce a výpočtu průměrného prostého chronologického průměru.

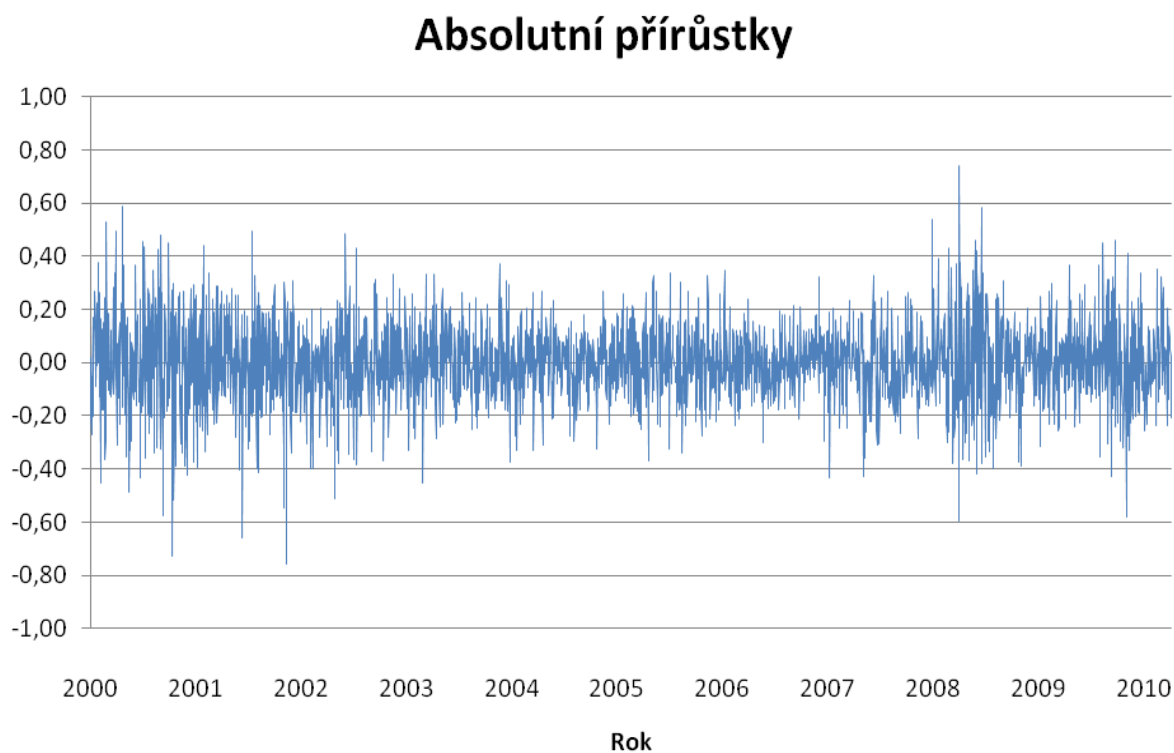
4.2.2 Míry dynamiky

Nyní se zaměříme na charakterizování základních rysů chování časových řad. Pro velký počet dat jsou některé míry dynamiky vyjádřeny graficky.

Absolutní přírůstek (první diference)

Tato první diference má velký význam v analýze časových řad a později se k ní vrátíme, až budeme modelovat trend.

Graf 3: Absolutní přírůstek



Zdroj: vlastní zpracování


Průměrný absolutní přírůstek

Průměrný absolutní přírůstek je roven **-0,002**.

Koeficient růstu

Tempo růstu bylo vynásobeno stem, aby nám hodnoty ukázaly na kolik procent hodnoty v čase $t-1$ vzrostla hodnota v čase t . Koeficient růstu se používá jako jedno z kritérií pro nalezení vhodné trendové funkce, kterou později budeme vytvářet.

Graf 4: Koeficient růstu



Zdroj: vlastní zpracování

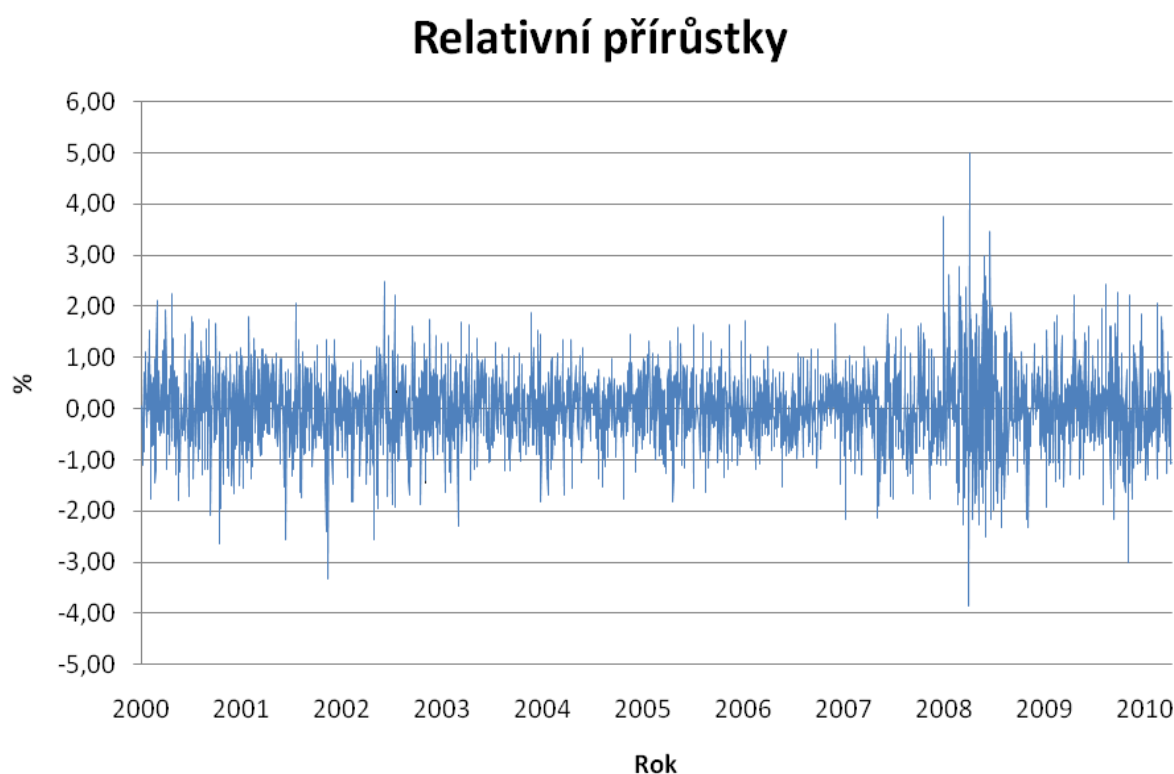
Průměrný koeficient růstu

Neboli také *průměrné tempo růstu*, které bylo vypočteno jako geometrický průměr jednotlivých koeficientů růstu, je roven **0,999**.

Relativní přírůstek

Opět byl tento relativní přírůstek vynásoben stem, jelikož nám říká, o kolik procent se změnila hodnota časové řady v čase t ve srovnání s časem $t-1$.

Graf 5: Relativní přírůstky



Zdroj: vlastní zpracování

4.3 Modelování trendu a sezónní složky

V následujících podkapitolách se budeme zabývat dekompozicí časové řady, pomocí které budeme modelovat trend a sezónní složku.

4.3.1 Dekompozice časové řady

Časovou řadu můžeme rozdělit do třech základních složek a to na trend, periodickou složku a náhodnou složku.

Tyto složky se teď budeme snažit analyzovat a sezónní výkyvy, které mají negativní dopad na predikci, se budeme snažit odstranit.

Zjištění, zda se v analyzované časové řadě nacházejí *sezónní výkyvy*, provedeme opět pomocí softwaru Statistica. Tuto analýzu provedeme pomocí klasického sezónního rozkladu.

Nejdříve vypočteme hodnoty *sezónních faktorů* pro jednotlivá období časové řady. Po výpočtu vidíme, že hodnoty leží v intervalu od 99% do 100% viz obrázek č. 15.

Hodnoty jsou odlišné maximálně o jedno procento, proto můžeme říci, že vliv sezónní složky na danou časovou řadu je *nevýznamný*. Proto nemusíme časovou řadu vyhlazovat či provádět očištění.

4.3.2 Základní metody modelování trendové složky

Analýza trendu


Nejdříve musíme vybrat správnou trendovou funkci a ohodnotit její kvalitu, kterou zjistíme podle **indexu determinace** viz tabulka č. 3.

Tabulka 3: Výsledky regrese

Výsledky regrese se závislou proměnnou: Kurz CAD/CZK R=0,833 R ² =0,694 Upravené R ² =0,693 F (1,277)=6269,1 p<0,000 Směrod. chyba odhadu: 1,629						
n=2772	<i>b</i> *	Sm. chyba z <i>b</i> *	<i>b</i>	Sm. chyba z <i>b</i>	<i>t</i> (2770)	<i>p</i> -hodn.
Abs. člen			24,348	0,062	393,376	0,00
Pořadí	-0,833	0,011	-0,003	0,000	-79,178	0,00

Zdroj: vlastní zpracování

V tabulce č. 3 jsou zobrazeny výsledky regrese, kde jsou vypočítány odhady regresních koeficientů ve sloupečku *b*. V posledních dvou sloupečcích jsou vypočteny **hodnoty t-testu** (testuje hypotézu o nevýznamnosti regresních koeficientů). V horní části pak můžeme vidět hodnotu námi požadovaného **indexu determinace R = 0,833**. Hodnota tohoto indexu se blíží k *jedné* a tím bylo spočteno, že volba modelu je správná.

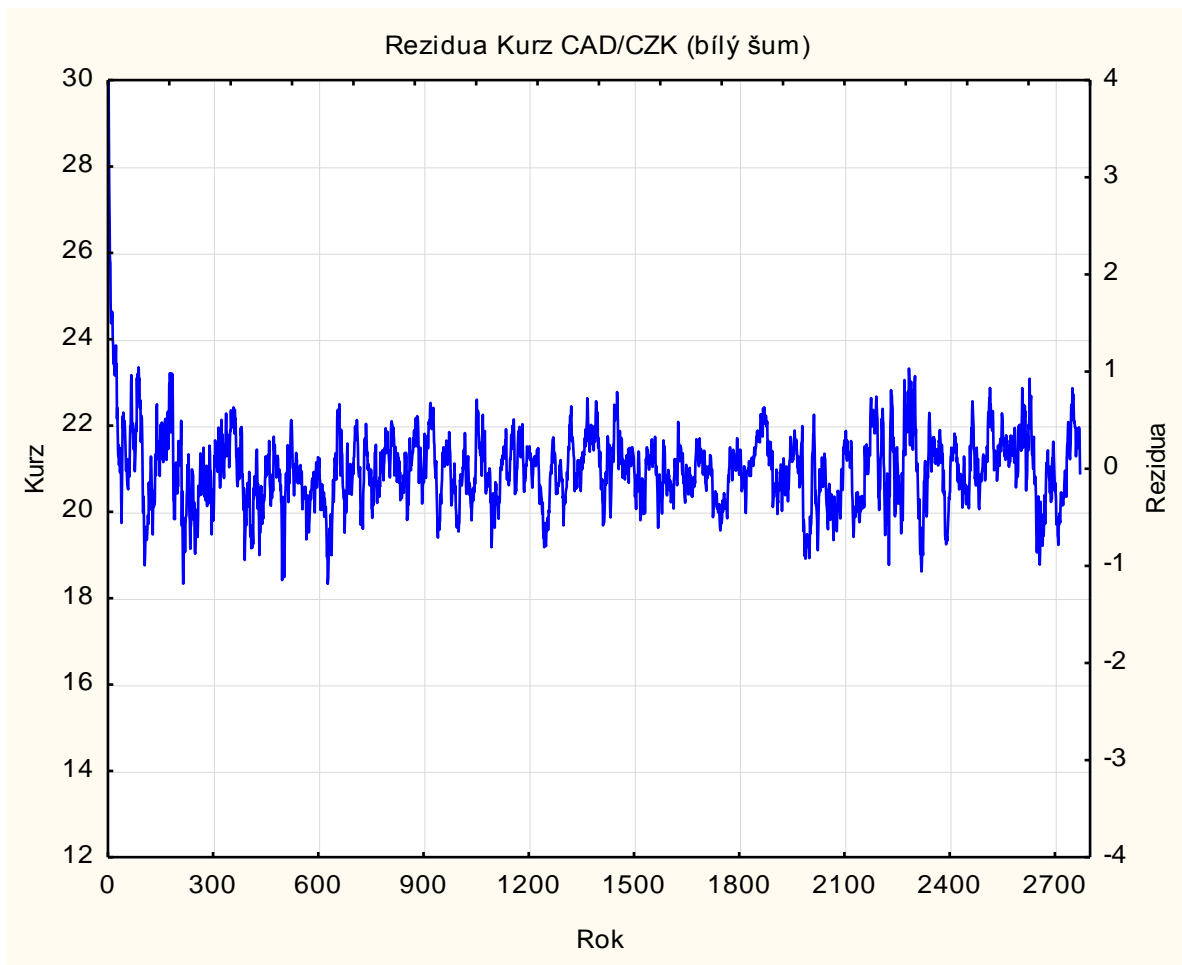


Obrázek 6: Předpověď trendové funkce

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázek č. 6 zachycuje *předpověď trendové funkce* dle vypočtených parametrů a dle výsledků regrese. Podle tohoto znázorněného grafů můžeme porovnat časovou řadu a její trend.

V trendové funkci se vyskytují i rezidua tzv. **bílý šum**, který je potřeba eliminovat či odstranit při predikci a trendu časové řady. Následující obrázek č. 7 znázorňuje rezidua v časové řadě.




Obrázek 7: Bílý šum kurz CAD/CZK

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

4.3.3 Metoda klouzavých průměrů

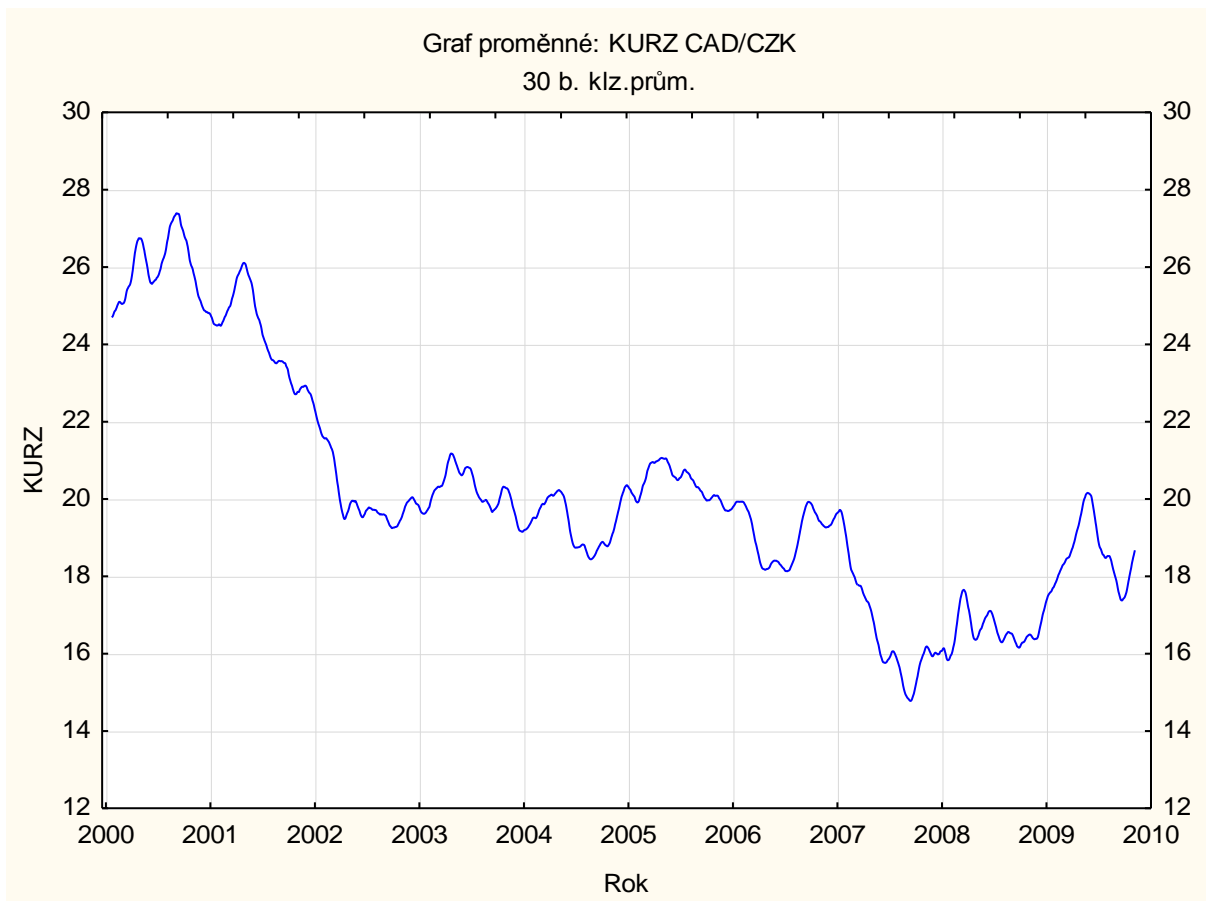
Tato metoda se zabývá *vyrovnáváním* časové řady, která byla zpracována podle daných vzorců, a modelů viz obrázek č. 8.



Obrázek 8: Klouzavé průměry délky 5

Zdroj: vlastní zpracování pomocí softwaru STATISTICA


Po dosazení hodnot do softwaru jsme získali graf, který je zachycen na obrázku č. 8, je to graf vyrovnaných hodnot proměnné kurz CAD/CZK pomocí klouzavých průměrů délky 5, jelikož máme denní hodnoty.



Obrázek 9: Klouzavé průměry délky 30

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Pro zajímavost byl vytvořen graf, který zachycuje obrázek č. 9. Graf zachycuje klouzavé průměry délky 30. Na tomto grafu je více zřetelné vyrovnaní hodnot. S přibývajícím délkou se snižuje vypovídací váha.




Obrázek 10: Kurz CAD/CZK a klouzavé průměry

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Na tomto obrázku č. 10 jsou výsledné grafy kurz CAD/CZK a klouzavé průměry. Můžeme z něho vidět, že při volbě délky klouzavých průměrů **délky 30** došlo k očištění od sezónní složky a výsledný trend ukazuje charakter časové řady.

4.3.4 Exponenciální vyrovnání


Další metodou pro vyrovnání časové řady je exponenciální vyrovnání. Existují dva druhy exponenciálního vyrovnání, buď je to *jednoduché*, nebo *dvojitě* vyrovnání. Rozlišuje se to tehdy, pokud víme, že nějaký úsek časové řady je konstantní, lineární či kvadratický.



Obrázek 11: Jednoduché exponenciální vyrovnání

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázek č. 11 zobrazuje **jednoduché exponenciální vyrovnání** další metoda pro vyrovnání. Tento model vyrovnání se použije, pokud je časová řada v nějakém úseku konstantní.




Obrázek 12: Kurz CAD/CZK a jednoduché exponenciální vyrovnání

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

V obrázku č. 12 jsou zachyceny dva grafy, jeden odpovídá základnímu grafu kurz CAD/CZK a druhý je jednoduché exponenciální vyrovnání. Tento obrázek ukazuje oba dva grafy a můžeme vidět, že ani pomocí jednoduchého exponenciálního vyrovnání nedošlo ke zřetelnému vyrovnání, jako tomu bylo obdobně u vyrovnání pomocí klouzavých průměrů.

Proto ještě vyzkoušíme druhou metodu tzv. **dvojitě exponenciální vyrovnání**, které je vyobrazeno v obrázku č. 13. Toto vyrovnání se zase použije, pokud nějaký úsek časové řady je lineární.



Obrázek 13: Dvojité exponenciální vyrovnání


Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Na obrázku č. 13 jsou zachyceny tři grafy. Jeden odpovídá základnímu grafu kurz CAD/CZK (modrý), druhý znázorňuje vytvořené dvojitě exponenciální vyrovnání (červený) a poslední jsou rezidua (zelený). Opět si můžeme všimnout, že dvojitě exponenciální vyrovnání je stejné, jako u jednoduchého vyrovnání pouze u dvojitěho vyrovnání jsou zohledněna i rezidua.

4.3.5 Základní metody modelování sezónní složky

Identifikace sezónnosti

Analýza časové řady byla vytvořena pomocí **periodogramu**, což znamená rozklad časové řady na sinusové vlny s různými frekvencemi. Na obrázku č. 14 je možné vidět vysoké hodnoty periodogramu, které ukazují přítomnost periody (cyklu).



Obrázek 14: Periodogram

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Z vyobrazeného periodogramu je možné vidět 3 vrcholy, můžeme tedy očekávat tři cykly s různou délkou. Bohužel se z grafu nedají přečíst přesné frekvence vrcholů, proto jsou zde vypsány hodnoty periodogramu a frekvence 5 nejvyšších píků (hodnoty periodogramu: frekvence): (1)3343:0,0007 (2)1543:0,0004 (3)437,9:0,0018 (4)396,7:0,0029 (5)244:0,0014.

Maximální hodnota je ve frekvenci 0,0007, což vyjadřuje přítomnost periody délky zhruba okolo 1386 let. Minimální hodnota je ve frekvenci 0,0014, což opět vyjadřuje periodu délky 693 let.

Sezónní dekompozice, určení sezónních indexů

Nyní se podíváme na identifikaci **sezónnosti** a jak ji modelovat. Metoda, která byla vybrána pro odhad sezónních výkyvů, je *metoda dekompozice*. Sezónní složka byla odhadnuta pomocí *sezónních indexů* (tzv. multiplikativní model). Pomocí této dekompozice získáme odhady sezónních výkyvů a sezónně očištěné časové řady.

Sezónní dekompozice : Vícenás. sezóna (5) (multiplikativní model)							
KURZ CAD/CZK							
Případ	KURZ	Klouzavé Průměry	Poměry	Sezónní Faktory	Očištěné Řady	Vyrovň. Trend-c.	Neprav. Kompon.
1	24,62200			99,9813	24,62662	24,64796	0,999134
2	24,63800			99,9889	24,64074	24,56717	1,002995
3	24,43700	24,39580	100,1689	100,0117	24,43415	24,40559	1,001170
4	24,16500	24,27380	99,5518	100,0118	24,16214	24,24921	0,996409
5	24,11700	24,18260	99,7287	100,0064	24,11547	24,14695	0,998696
6	24,01200	24,09080	99,6729	99,9813	24,01650	24,08746	0,997054
7	24,18200	24,04720	100,5606	99,9889	24,18469	24,06635	1,004917
8	23,97800	24,04680	99,7139	100,0117	23,97520	24,03481	0,997520
9	23,94700	24,09300	99,3940	100,0118	23,94416	24,04912	0,995636
10	24,11500	24,15940	99,8162	100,0064	24,11347	24,13508	0,999104
11	24,24300	24,29140	99,8008	99,9813	24,24755	24,28692	0,998379
12	24,51400	24,41120	100,4211	99,9889	24,51673	24,44134	1,003084
13	24,63800	24,51220	100,5132	100,0117	24,63512	24,54344	1,003735
14	24,54600	24,57540	99,8804	100,0118	24,54309	24,57964	0,998513
15	24,62000	24,62900	99,9635	100,0064	24,61844	24,60984	1,000349
16	24,55900	24,65520	99,6098	99,9813	24,56361	24,64516	0,996691
17	24,78200	24,71520	100,2703	99,9889	24,78476	24,71947	1,002641
18	24,76900	24,76620	100,0113	100,0117	24,76611	24,77678	0,999569
19	24,84600	24,90520	99,7623	100,0118	24,84306	24,87241	0,998820
20	24,87500	24,99900	99,5040	100,0064	24,87342	24,98264	0,995628
21	25,25400	25,14840	100,4199	99,9813	25,25874	25,15408	1,004160
22	25,25100	25,25640	99,9786	99,9889	25,25381	25,28460	0,998782
23	25,51600	25,39180	100,4891	100,0117	25,51302	25,40242	1,004354
24	25,38600	25,36040	100,1009	100,0118	25,38299	25,40348	0,999194
25	25,55200	25,36240	100,7476	100,0064	25,55038	25,37748	1,006813
26	25,09700	25,27380	99,3005	99,9813	25,10171	25,26517	0,993530
27	25,26100	25,17600	100,3376	99,9889	25,26381	25,17549	1,003508
28	25,07300	25,04120	100,1270	100,0117	25,07007	25,05601	1,000561
29	24,89700	25,02260	99,4981	100,0118	24,89405	24,98307	0,996437
30	24,87800	24,93560	99,7690	100,0064	24,87642	24,92595	0,998013
31	25,00400	24,91620	100,3524	99,9813	25,00869	24,92262	1,003454
32	24,82600	24,92980	99,5836	99,9889	24,82876	24,92092	0,996302
33	24,97600	24,91160	100,2585	100,0117	24,97308	24,92166	1,002063
34	24,96500	24,91740	100,1910	100,0118	24,96204	24,91884	1,001734

Obrázek 15: Sezónní dekompozice

Zdroj: vlastní zpracování pomocí softwaru STATISTICA


Na obrázku č. 15 je vyobrazen pro příklad výběr dat **sezónní dekompozice** analyzované časové řady pomocí multiplikativního modelu. V tabulce můžeme vidět *klouzavé průměry, sezónní faktory, očištěnou řadu a vyrovnaný trend* a v posledním sloupci *rezidua*.

Klouzavé průměry vyjadřují odhad trendové-cyklické složky. *Sezónní faktory* jsou uvedeny v procentech a vyjadřují *sezónní indexy* (viz obrázek č. 16 označená data). Hodnoty sezónně očištěné časové řady můžeme chápat jako odhad trendové složky.

Sezónní dekompozice : Vícenás. sezóna (5) (kurz stat)							
KURZ							
Případ	KURZ	Klouzavé Průměry	Poměry	Sezónní Faktory	Očištěné Řady	Vyrovn. Trend-c.	Neprav. Kompon.
1	24,62200			99,9813	24,62662	24,64796	0,999134
2	24,63800			99,9889	24,64074	24,56717	1,002995
3	24,43700	24,39580	100,1689	100,0117	24,43415	24,40559	1,001170
4	24,16500	24,27380	99,5518	100,0118	24,16214	24,24921	0,996409
5	24,11700	24,18260	99,7287	100,0064	24,11547	24,14695	0,998696
6	24,01200	24,09080	99,6729	99,9813	24,01650	24,08746	0,997054
7	24,18200	24,04720	100,5606	99,9889	24,18469	24,06635	1,004917
8	23,97800	24,04680	99,7139	100,0117	23,97520	24,03481	0,997520
9	23,94700	24,09300	99,3940	100,0118	23,94416	24,04912	0,995636
10	24,11500	24,15940	99,8162	100,0064	24,11347	24,13508	0,999104
11	24,24300	24,29140	99,8008	99,9813	24,24755	24,28692	0,998379
12	24,51400	24,41120	100,4211	99,9889	24,51673	24,44134	1,003084
13	24,63800	24,51220	100,5132	100,0117	24,63512	24,54344	1,003735
14	24,54600	24,57540	99,8804	100,0118	24,54309	24,57964	0,998513
15	24,62000	24,62900	99,9635	100,0064	24,61844	24,60984	1,000349
16	24,55900	24,65520	99,6098	99,9813	24,56361	24,64516	0,996691
17	24,78200	24,71520	100,2703	99,9889	24,78476	24,71947	1,002641
18	24,76900	24,76620	100,0113	100,0117	24,76611	24,77678	0,999569
19	24,84600	24,90520	99,7623	100,0118	24,84306	24,87241	0,998820
20	24,87500	24,99900	99,5040	100,0064	24,87342	24,98264	0,995628
21	25,25400	25,14840	100,4199	99,9813	25,25874	25,15408	1,004160
22	25,25100	25,25640	99,9786	99,9889	25,25381	25,28460	0,998782
23	25,51600	25,39180	100,4891	100,0117	25,51302	25,40242	1,004354
24	25,38600	25,36040	100,1009	100,0118	25,38299	25,40348	0,999194
25	25,55200	25,36240	100,7476	100,0064	25,55038	25,37748	1,006813
26	25,09700	25,27380	99,3005	99,9813	25,10171	25,26517	0,993530
27	25,26100	25,17600	100,3376	99,9889	25,26381	25,17549	1,003508
28	25,07300	25,04120	100,1270	100,0117	25,07007	25,05601	1,000561
29	24,89700	25,02260	99,4981	100,0118	24,89405	24,98307	0,996437
30	24,87800	24,93560	99,7690	100,0064	24,87642	24,92595	0,998013
31	25,00400	24,91620	100,3524	99,9813	25,00869	24,92262	1,003454
32	24,82600	24,92980	99,5836	99,9889	24,82876	24,92092	0,996302
33	24,97600	24,91160	100,2585	100,0117	24,97308	24,92166	1,002063
34	24,96500	24,91740	100,1910	100,0118	24,96204	24,91884	1,001734

Obrázek 16: Sezónní indexy

Zdroj: vlastní zpracování pomocí softwaru STATISTICA



Obrázek 17: Kurz CAD/CZK a sezónně očištěná data

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázek č. 17 zachycuje dva grafy. Jeden je základní graf kurz CAD/CZK a druhý je graf, který zobrazuje námi vypočtené hodnoty časové řady *sezónně očištěné*.


4.4 Boxova-Jenkinsova metodologie

Tato metoda má za cíl zjistit, zdali daná časová řada je stacionární a otestovat ji pomocí autokorelační funkce.

4.4.1 Stochastický proces, stacionarita a autokorelační struktura

Na následujícím grafu č. 6 je vyobrazen spojnicový graf kurzu CAD/CZK za jednotlivé roky.


Graf 6: Kurz CAD/CZK



Zdroj: vlastní zpracování


Z grafu č. 6 analyzované časové řady je na první pohled zřejmé, že není **stacionární**. Pro lepší zjištění byla provedena autokorelační analýza (ACF), která je zobrazena v obrázku č. 13, kde je zřetelné, že daná řada není stacionární.

Pro modelování časové řady budeme potřebovat, aby byla daná časová řada stacionární. Proto u této časové řady provedeme stacionarizaci a byla vybrána stacionarizace podle **diferencování**. Po stacionarizaci budou zřetelně patrné náhlé výkyvy v průběhu časové řady.



Obrázek 18: Autokorelační funkce (ACF) kurzu CAD/CZK

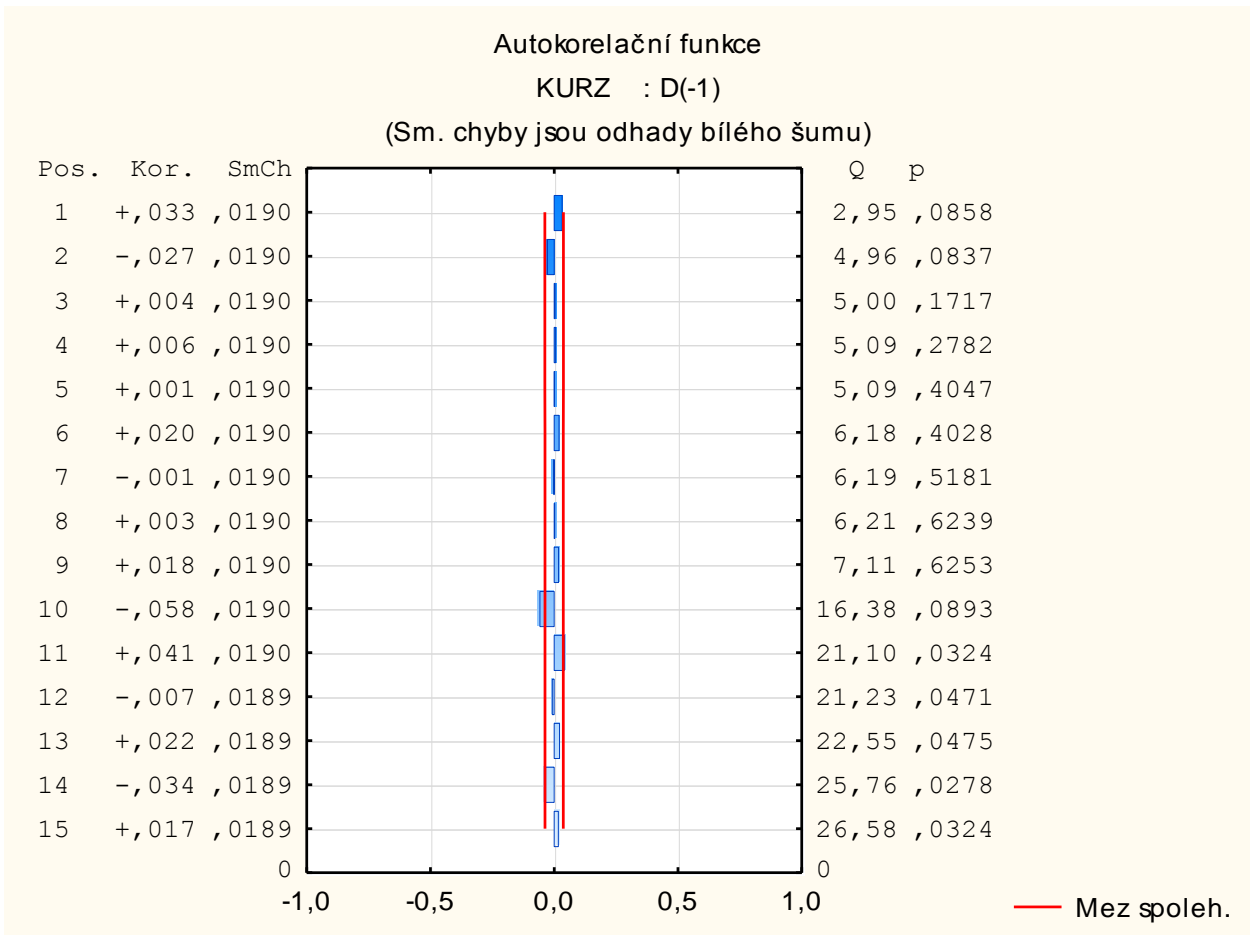
Zdroj: vlastní zpracování pomocí softwaru STATISTICA



Obrázek 19: Stacionarizovaná časová řada - první diference

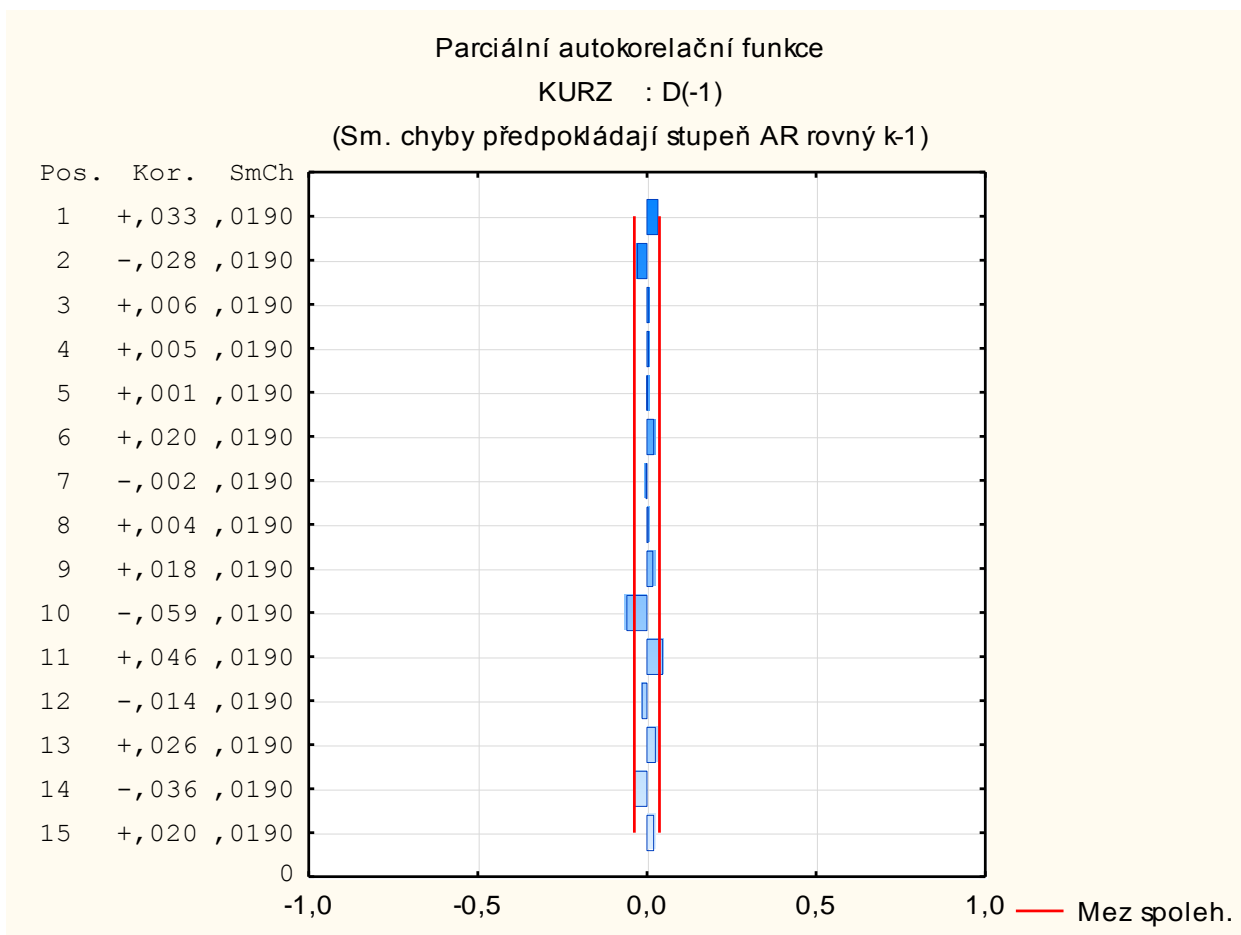
Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Na obrázku č. 19 je zachycena **stacionární řada**, která byla stacionarizovaná pomocí **první diference**. Na grafu je zřejmé, že nyní je časová řada stacionární. Pro lepší kontrolu byla opět stacionarita vyjádřena pomocí *autokorelační funkce (ACF)* a *parciální autokorelační funkce (PACF)* viz obrázek č. 20 a 21.



Obrázek 20: Autokorelační funkce (ACF) - první diference

Zdroj: vlastní zpracování pomocí softwaru STATISTICA



Obrázek 21: Parciální autokorelační funkce (PACF) - první diference

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Pomocí těchto dvou obrázků č. 20 a 21 můžeme posoudit vztahy jak mezi závislostí rozptylu tak i závislostí ve střední hodnotě pomocí autokorelační funkce (ACF) a parciální autokorelační funkce (PACF) diferencovaných časových řad. Právě tyto zjištěné výsledky nás dovedou k závěru, že vhodným modelem uvažovaných časových řad je **lineární stochastický a stacionární model**.

5. PREDIKCE FINANČNÍCH ČASOVÝCH ŘAD


Prognózovat budeme zadané hodnoty kurzu CAD/CZK. Předpověď určíme pro dalších **5 let** denního kurzu a první rok porovnáme s dostupnými údaji. V případě predikce dat na delší časové období se výrazně snižuje jejich vypovídací váha a data by byla nepřesná.

5.1 Předpovídání časových řad po sezónní dekompozici

Provádět predikci časové řady klouzavými průměry není vhodné, jelikož se to považuje za předběžný odhad, neboť řada je zkrácena.

Proto je lepší předpovídat časovou řadu ze **sezónně očištěné řady**. Na jejím základě pak lépe určíme vhodný model trendu a odhadneme jeho parametry. Na konci výpočtu předpovědi původní časové řady vynásobíme sezónními indexy.

Na sezónně očištěnou časovou řadu aplikujeme exponenciální vyrovnání, které již bylo provedeno (viz výše).



Obrázek 22: Sezónně očištěná časová řada s exponenciálním vyrovnáním

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázek č. 22 byl vytvořen pro zobrazení **sezónně očištěné časové řady**, která navíc byla vyhlazena **exponenciálním vyrovnáním se sezónní komponentou 5**. Jako prognostický model byl zvolen právě model jednoduchého exponenciálního vyrovnání.

5.1.1 Stacionární procesy

Následující výstupní tabulky obsahují výpočet jednotlivých modelů. Tabulka obsahuje počet pozorování, vypočtené parametry, odhad a směrodatnou odchylku.

5.1.1.1 Procesy ARIMA

Tabulka 4: Výstupní tabulka modelu ARIMA (1,0,0)

Proměnná: KURZ CAD/CZK: D(-1) (stacionarizovaná řada, první diferencí) Transformace: Model: (1,0,0) Poč. pozor.:2771 Počát. SS=62,991 Koncov. SS=62,912 (99,87%) MS=,02272 Parametry (p/AR-Autoregresní, q/MA-Klouzavé prům.); zvýr. pro: p<.05 Konst. p(1) AR(1) Odhad.: -,0021 ,03264 Sm.Ch.: ,00296 ,01900
--

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Tabulka 5: Výstupní tabulka modelu ARIMA (0,0,1)

Proměnná: KURZ CAD/CZK: D(-1) (stacionarizovaná řada, první diferencí) Transformace: Model: (0,0,1) Poč. pozor.:2771 Počát. SS=62,991 Koncov. SS=62,908 (99,87%) MS=,02272 Parametry (p/AR-Autoregresní, q/MA-Klouzavé prům.); zvýr. pro: p<.05 Konst. q(1) MA(1) Odhad.: -,0021 -,0345 Sm.Ch.: ,00296 ,01954
--

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Tabulka 6: Výstupní tabulka modelu ARIMA (2,0,0)

Proměnná: KURZ CAD/CZK: D(-1) (stacionarizovaná řada, první diferencí) Transformace: Model: (2,0,0) Poč. pozor.:2771 Počát. SS=62,991 Koncov. SS=62,863 (99,80%) MS=,02271 Parametry (p/AR-Autoregresní, q/MA-Klouzavé prům.); zvýr. pro: p<.05 Konst. p(1) p(2) AR(1) AR(2) Odhad.: -,0021 ,03353 -,0280 Sm.Ch.: ,00288 ,01901 ,01902

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Tabulka 7: Výstupní tabulka modelu ARIMA (1,0,1)

Proměnná: KURZ CAD/CZK: D(-1) (stacionarizovaná řada, první diferencí)

Transformace:

Model: (1,0,1)

Poč. pozor.: 2771 Počát. SS=62,991 Koncov. SS=62,874 (99,81%) MS=,02271

Parametry (p/AR-Autoregresní, q/MA-Klouzavé prům.); zvýr. pro: $p < .05$

Konst. p(1) AR(1) q(1) MA(1)

Odhad.: -,0021 -,4328 -,4697

Sm.Ch.: ,00294 ,30274 ,29631

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Tabulka č. 4, 5, 6 a 7 obsahuje charakteristiky modelu **ARIMA (1,0,0)**, **ARIMA (0,0,1)**, **ARIMA (2,0,0)** a **ARIMA (1,0,1)**.

5.1.1.2 Procesy AR(1)

Vstup: KURZ CAD/CZK: D(-1) Transformace: žádná Model: (1,0,0) PČ Rezid. = ,02272						
Paramet.	Param.	Asympt. SmCh	Asympt. t(2769)	p	Dolní 95% spol	Horní 95% spol
Konstant	-0,002105	0,002960	-0,711269	0,476977	-0,007908	0,003698
p(1)	0,032637	0,019002	1,717556	0,085990	-0,004623	0,069897

Obrázek 23: Výstupní data proces AR(1)

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázek č. 23 zobrazuje **model AR(1)** a jeho výstupní data. Je zde parametr procesu AR(1) 0,033. Ve třetím sloupci je výsledek t-testu pro střední hodnotu, který je roven 1,72 a p je rovna 0,086 s hladinou významnosti α (0,05).

5.1.1.3 Procesy MA(1)

Vstup: KURZ CAD/CZK: D(-1) Transformace: žádná Model:(0,0,1) PČ Rezid. = ,02272							
Paramet.	Param.	Asympt. SmCh	Asympt. t(2769)	p	Dolní 95% spol	Horní 95% spol	
Konstant	-0,002105	0,002962	-0,71053	0,477434	-0,007914	0,003704	
q(1)	-0,034548	0,019541	-1,76793	0,077182	-0,072865	0,003769	

Obrázek 24: Výstupní data proces MA(1)

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázek č. 24 zobrazuje **model MA(1)** a jeho výstupní data. Je zde parametr procesu MA(1) -0,035. Ve třetím sloupci je výsledek t-testu pro střední hodnotu, který je roven -1,768 a p je rovna 0,077 s hladinou významnosti α (0,05).

5.1.1.4 Procesy AR (2)

Vstup: KURZ CAD/CZK : D(-1) Transformace: žádná Model:(2,0,0) PČ Rezid. = ,02271							
Paramet.	Param.	Asympt. SmCh	Asympt. t(2768)	p	Dolní 95% spol	Horní 95% spol	
Konstant	-0,002099	0,002879	-0,72897	0,466079	-0,007745	0,003547	
p(1)	0,033533	0,019009	1,76408	0,077830	-0,003740	0,070806	
p(2)	-0,028025	0,019018	-1,47362	0,140698	-0,065316	0,009266	

Obrázek 25: Výstupní data proces AR (2)

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázek č. 25 zobrazuje **model AR(1) a AR (2)** a jejich výstupní data. Jsou zde parametry procesu AR(1) 0,034 a AR (2) -0,028. Ve třetím sloupci jsou výsledky t-testu pro střední hodnotu, které jsou rovny 1,764 a -1,474 a p jsou rovny 0,078 a 0,141 s hladinou významnosti α (0,05).

5.1.1.5 Procesy AR(1) MA(1)

Vstup: KURZ CAD/CZK: D(-1) Transformace: žádná Model:(1,0,1) PČ Rezid. = ,02271							
Paramet.	Param.	Asympt. SmCh	Asympt. t(2768)	p	Dolní 95% spol	Horní 95% spol	
Konstant	-0,002103	0,002936	-0,71627	0,473884	-0,00786	0,003655	
p(1)	-0,432841	0,302740	-1,42974	0,152903	-1,02646	0,160778	
q(1)	-0,469655	0,296314	-1,58499	0,113083	-1,05067	0,111364	


Obrázek 26: Výstupní data proces AR(1) a MA(1)

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázek č. 26 zobrazuje **model AR(1) a MA(1)** a jejich výstupní data. Jsou zde parametry procesu AR(1) -0,433 a MA(1) -0,469. Ve třetím sloupci jsou výsledky t-testu pro střední hodnotu, které jsou rovny -1,429 a -1,584 a p jsou rovny 0,153 a 0,113 s hladinou významnosti α (0,05).

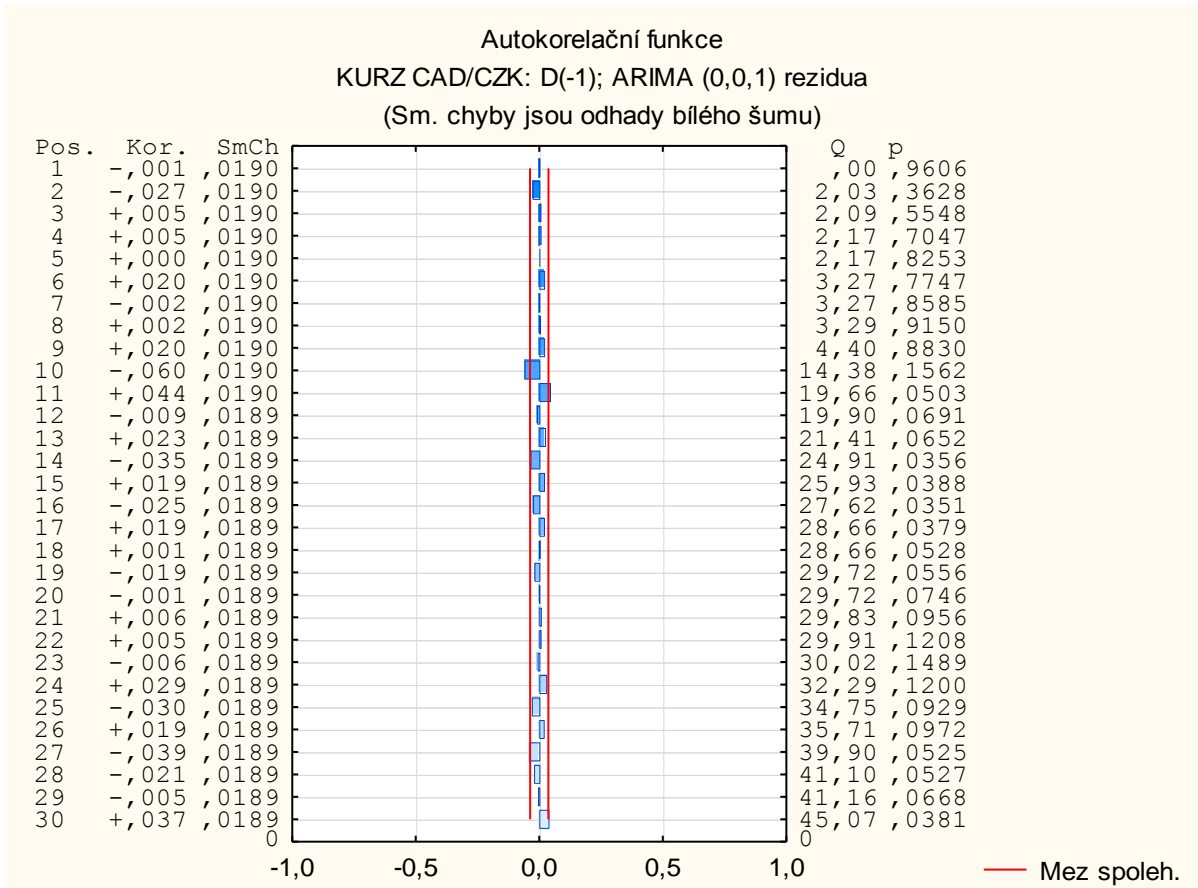
5.1.1.6 Procesy ARIMA rezidua

Autokorelaci reziduí vyjádříme pomocí grafického znázornění (viz obrázek č. 27, 28, 29 a 30). Z grafů je patrné, že dané hodnoty leží uvnitř tolerančních mezí.



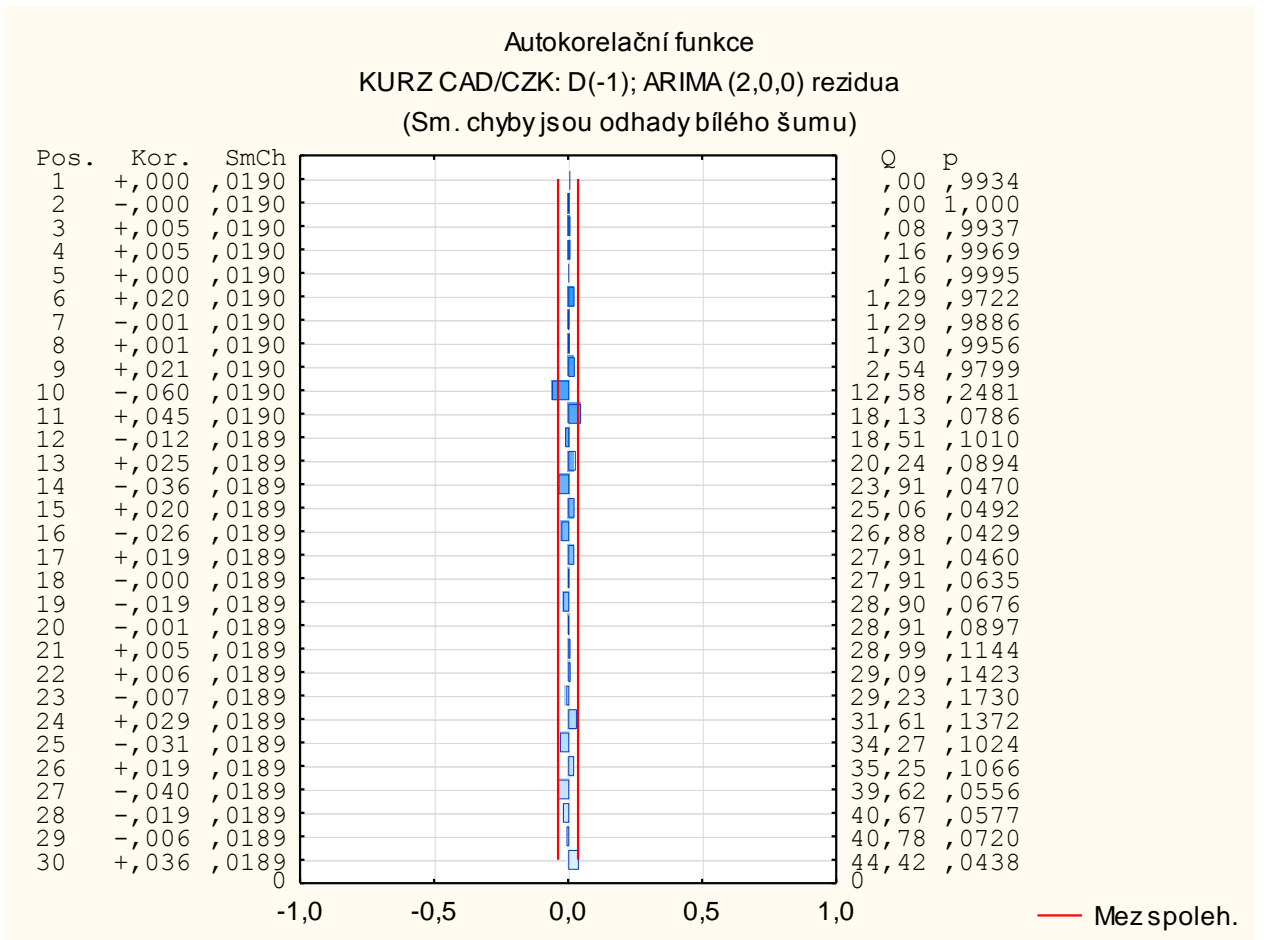
Obrázek 27: Autokorelační funkce procesu ARIMA (1,0,0) rezidua

Zdroj: vlastní zpracování pomocí softwaru STATISTICA




Obrázek 28: Autokorelační funkce procesu ARIMA (0,0,1) rezidua

Zdroj: vlastní zpracování pomocí softwaru STATISTICA



Obrázek 29: Autokorelační funkce procesu ARIMA (2,0,0) rezidua

Zdroj: vlastní zpracování pomocí softwaru STATISTICA




Obrázek 30: Autokorelační funkce procesu ARIMA (1,0,1) rezidua

Zdroj: vlastní zpracování pomocí softwaru STATISTICA


5.2 Předpovídání časových řad pomocí modelů

Identifikovali jsme model časové řady a nyní můžeme provést výpočet **denních předpovědí na 5 let pomocí modelů ARIMA**. Předpovědi jsou provedeny ze stacionární řady s 1. diferencí viz obrázek č. 31 a 32. Modely ARIMA (1,0,0), ARIMA (0,0,1) a ARIMA (1,0,1) mají stejnou předpověď, jelikož se jedná o dva řádově stejné parametry AR(1) a MA (1). Obrázek č. 32 pak zachycuje proces ARIMA (2,0,0) s modelem AR(2).




Obrázek 31: Předpověď na 5 let modelu ARIMA (1,0,0) s diferencováním1

Zdroj: vlastní zpracování pomocí softwaru STATISTICA




Obrázek 32: Předpověď na 5 let modelu ARIMA (2,0,0) s diferencováním1

Zdroj: vlastní zpracování pomocí softwaru STATISTICA




Obrázek 33: Předpověď původní časové řady na 5 let, model AR(1)

Zdroj: vlastní zpracování pomocí softwaru STATISTICA




Obrázek 34: Předpověď původní časové řady na 5 let, model MA(1)

Zdroj: vlastní zpracování pomocí softwaru STATISTICA



Obrázek 35: Předpověď původní časové řady na 5 let, model AR(2)

Zdroj: vlastní zpracování pomocí softwaru STATISTICA



Obrázek 36: Předpověď původní časové řady na 5 let, model AR(1) MA(1)

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

Obrázky č. 33, 34, 35 a 36 znázorňují **denní předpovědi původní časové řady kurz CAD/CZK na pět let dopředu**. Jsou vyjádřeny ve třech modelech pomocí *procesu ARIMA* – *AR(1)*, *MA(1)*, *AR(2)* a *AR(1) MA(1)*.

Předpovědi - Model: (1,0,0)(0,0,1)(2,0,0) Sezónní po Vstup: KURZ CAD/CZK				
ČísloPřip.	Předpověď	Dolní 90,0000%	Horní 90,0000%	SmCh
2773	18,79605	18,54793	19,04417	0,150797
2774	18,79710	18,44624	19,14797	0,213239
2775	18,79815	18,36847	19,22783	0,261140
2776	18,79920	18,30309	19,29531	0,301512
2777	18,80025	18,24564	19,35487	0,337070
2778	18,80130	18,19381	19,40880	0,369208
2779	18,80235	18,14624	19,45847	0,398755
2780	18,80340	18,10205	19,50475	0,426248
2781	18,80445	18,06063	19,54828	0,452064
2782	18,80550	18,02151	19,58949	0,476474
2783	18,80655	17,98437	19,62873	0,499685
2784	18,80760	17,94894	19,66627	0,521857
2785	18,80865	17,91500	19,70230	0,543117
2786	18,80970	17,88240	19,73699	0,563568
2787	18,81075	17,85099	19,77050	0,583296
2788	18,81179	17,82065	19,80294	0,602371
2789	18,81284	17,79129	19,83440	0,620854
2790	18,81389	17,76281	19,86497	0,638796
2791	18,81494	17,73516	19,89472	0,656241
2792	18,81599	17,70825	19,92372	0,673229
2793	18,81703	17,68205	19,95202	0,689792
2794	18,81808	17,65649	19,97967	0,705961
2795	18,81913	17,63154	20,00672	0,721762
2796	18,82017	17,60715	20,03320	0,737219
2797	18,82122	17,58330	20,05915	0,752354
2798	18,82227	17,55994	20,08459	0,767184
2799	18,82331	17,53706	20,10957	0,781728
2800	18,82436	17,51462	20,13410	0,796001
2801	18,82540	17,49260	20,15821	0,810018
2802	18,82645	17,47098	20,18192	0,823791
2803	18,82750	17,44975	20,20525	0,837333
2804	18,82854	17,42887	20,22821	0,850654

Obrázek 37: Předpovědi modelů kurzu CAD/CZK

Zdroj: vlastní zpracování pomocí softwaru STATISTICA

V obrázku č. 37 je tabulka, která obsahuje část dat. Data se týkají sledovaného kurzu CAD/CZK a jeho denní předpovědi na pět let. V prvním sloupci jsou vidět **data předpovědi** dle daných modelů a ve třetím a čtvrtém sloupci pak intervaly v jakém rozmezí se může daný kurz pohybovat.

ZÁVĚR

Cílem této diplomové práce bylo provést analýzu vybrané finanční časové řady, konkrétně měnového kurzu CAD/CZK a jeho predikci. Podle zpracované teorie byly aplikovány hlavní postupy a metody, pomocí nichž byla ověřena a otestována zvolená data a následně byla určena předpověď vybrané finanční časové řady.

Nejprve byly definovány teorie, ve kterých se finanční časové řady řeší, tedy časové řady a úzce tím spojené ekonomické časové řady. U časových řad bylo uvedeno rozdělení časových řad, které je stejné pro všechny ostatní časové řady. Poté byly podrobně popsány finanční časové řady a především jejich charakteristické vlastnosti z teoretického hlediska. V další navazující části byly objasněny předpoklady finančních časových řad, ve které se zaměřilo na normalitu, nelinearitu, podmíněnou heteroskedasticitu, autokorelaci a volatilitu. Důležitá je i předposlední teoretická část, jež se zabývala modelováním časových řad, kde byly zpracovány hlavní komponenty jako trend a sezónní složka. V poslední teoretické části je vysvětlen princip Boxovy-Jenkinsovy metodologie, ve které se popisuje stacionarita a jednotlivé stacionární procesy a to ARIMA, AR a MA v jednotlivých řádech. Vytyčeným cílem, který je v praktické části, bylo provést analýzu měnového kurzu CAD/CZK a jeho predikci.

Veškeré výpočty byly zpracovány pomocí softwaru STATISTICA a programu MS Office Excel. Na základě analýzy finančních časových řad se došlo k následujícím poznatkům, které jsou uvedeny níže. Postup analýzy může být rozdělen do několika na sebe navzájem navazujících kroků.

Nejprve než jsme provedli analýzu, bylo důležité si průběh měnového kurzu CAD/CZK zobrazit graficky. To bylo znázorněno pomocí spojnicového a krabičkového grafu. Byl také znázorněn výchozí graf logaritmů výnosů. Trend je zde mírně klesající, ale v průběhu času se dosti mění jeho průběh

Prvním krokem analýzy je otestování předpokladů časové řady. Z předpokladu normality bylo zjištěno, že data pochází z normálního rozdělení. Z předpokladu nelinearity a podmíněné heteroskedasticity se došlo k závěru, že jsou splněny. Předposlední předpoklad autokorelace byl otestován a také vyšel jako pozitivní autokorelace. V posledním testování byl zjištěn výskyt volatility, která byla znázorněna pomocí stacionarizované časové řady první difference. Všechny uvedené předpoklady byly testovány pomocí statistických testů. Dalším krokem byly vypočteny popisné charakteristiky a míry dynamiky, které nám udávají základní rysy chování časové řady.

Důležitou částí bylo modelování trendu a sezónní složky. Nejdříve byla vysvětlena dekompozice časové řady, kde bylo zjištěno, že daná časová řada se skládá z trendu a sezónní složky, jež jsou nevýznamné. Z analýzy trendu byl zjištěn lineární trend pomocí indexu determinace. Byl zobrazen i graf reziduí neboli bílého šumu, který je potřeba odstranit. Pro vyrovnání časové řady byly použity metody klouzavých průměrů délky 5 a 30 pro lepší vyhlazení a exponenciální jednoduché a dvojitě vyrovnání. K identifikaci sezónnosti byl vytvořen periodogram. Poté byly určeny sezónní indexy a bylo zobrazeno grafické znázornění sezónně očištěné časové řady.

Předposlední část se zabývala analýzou Boxovy-Jenkinsovy metodologie, pomocí které jsme zjistili, že daná časová řada není stacionární a proto jsme pomocí první difference získali stacionární časovou řadu. Stacionarita byla otestována pomocí autokorelační a parciální autokorelační funkce.

V poslední části byla popsána prognóza finanční časové řady. Hodnoty byly predikovány formou denního kurzu na 5 let. Parametry vhodné pro predikci byly získány pomocí stacionárního procesu a to konkrétně ARIMA, AR a MA a jejich první a druhé řády a kombinace. Poté tyto procesy byly otestovány pomocí autokorelační funkce reziduí, kde bylo zjištěno, že dané hodnoty odpovídají určeným mezím. Po získání parametrů pomocí procesů bylo provedeno grafické předpovídání časové řady. Z predikovaných hodnot můžeme vidět, že trend je mírně rostoucí s 90 % intervalem spolehlivosti.

POUŽITÁ LITERATURA

Literatura:

1. ANDĚL, J.: *Statistická analýza časových řad*. vyd. 1. Praha: SNTL, 1976. 272 s.
2. ANDERSEN, T., G.; DAVIS, R., A.: *Handbook of Financial Time Series*. 1st ed. Berlin: Springer, 2009. 1079 p. ISBN 978-3-540-71296-1
3. ARLT, J.: *Moderní metody modelování ekonomických časových řad*. vyd. 1. Praha: Grada Publishing a.s., 1999. 312 s. ISBN 80-7169-539-4
4. ARLT, J.; ARLTOVÁ M.: *Ekonomické časové řady*. vyd. 1. Praha: Grada Publishing a.s., 2007. 288 s. ISBN 978-80-247-1319-9
5. ARLT, J.; ARLTOVÁ M.: *Finanční časové řady*. vyd. 1. Praha: Grada Publishing a.s., 2003. 220 s. ISBN 80-247-0330-0
6. ARLT, J.; ARLTOVÁ, M.; RUBLÍKOVÁ, E.: *Analýza ekonomických časových řad s příklady*. vyd. 2. Praha: Oeconomica, 2004. 146 s. ISBN 80-245-0777-3
7. ARLT, J.; ARLTOVÁ, M.: *Příklady z analýzy ekonomických časových řad*. vyd. 1. Praha: Vysoká škola ekonomická v Praze, 1997. 147 s. ISBN 80-7079-056-3
8. CIPRA, T.: *Finanční a pojistné vzorce*. vyd. 1. Praha: Grada Publishing a.s., 2006. 376 s. ISBN 80-247-1633-X
9. CIPRA, T.: *Finanční ekonometrie*. vyd. 1. Praha: Ekopress s.r.o., 2008. 538 s. ISBN 978-80-86929-43-9
10. CIPRA, T.: *Analýza časových řad as aplikacemi v ekonomii*. vyd. 1. Praha: Alfa, SNTL, 1986. 246 s.
11. HAMILTON, D., J.: *Time Series Analysis*. 1st ed. Princeton: Princeton University Press, 1994. 820 p. ISBN 0-691-04289-6
12. HEBÁK, P.; HUSTOPECKÝ, J.: *Vícerozměrné statistické metody s aplikacemi*. vyd. 1. Praha: SNTL, 1987. 456 s.
13. HINDLS, R.; HRONOVÁ, S.; SEGER, J.; FISCHER, J.: *Statistika pro ekonomy*. vyd. 7. Praha: Professional Publishing, 2006. 417 s. ISBN 80-86946-16-9
14. HUŠEK, R.: *Základy ekonometrické analýzy I*. vyd. 1. Praha: Vysoká škola ekonomická v Praze, 1995. 225 s. ISBN 80-7079-102-0

15. HUŠEK, R.: *Základy ekonometrické analýzy II*. vyd. 1. Praha: Vysoká škola ekonomická v Praze, 1998. 265 s. ISBN 80-7079-441-0
16. HUŠEK, R.: *Ekonometrická analýza*. vyd. 1. Praha: Oeconomica, 2007. 368 s. ISBN 978-80-245-1300-3
17. HUŠEK, R.: *Ekonometrické modely řízení a plánování*. vyd. 1. Praha: SNTL, 1987. 276 s.
18. KOČENDA, E.; ČERNÝ, A.: *Elements of Time Series Econometrics: an Applied Approach*. 1st ed. Prague: Charles University, Karolinum Press, 2007. 228 p. ISBN 978-80-246-1370-3
19. KOZÁK, J.; HINDLS R.: *Úvod do analýzy ekonomických časových řad*. vyd. 1. Praha: Vysoká škola ekonomická v Praze, 1994. 208 s. ISBN 80-7079-760-6
20. MILLS, C., T.: *The Econometric Modelling of Financial Time Series*. 3rd ed. New York: Cambridge University Press, 2008. 445 p. ISBN 978-0-521-71009-1
21. RUBLÍKOVÁ, E.: *Analýza časových radov*. vyd. 1. Bratislava: Iura Edition, 2007. 207 s. ISBN 978-80-8078-139-2
22. SEGER, J.; HINDLS, R.: *Statistické metody v ekonomii*. vyd. 1. Jinonice: H&H, 1993. 445 s. ISBN 80-85787-26-1
23. TAYLOR, J., S.: *Modelling Financial Times Series*. 2nd ed. London: World Scientific Publishing Company, 2007. 296 p. ISBN 981-277-084-4
24. TSAY, S., R.: *Analysis of financial time series*. 2nd ed. Hoboken, N.J.: Wiley Interscience, 2005. 605 p. ISBN 04-716-9074-0

Dostupné z WWW:

1. *Analýza časových řad – Přírodovědecká fakulta, Ivan Křivý* [online]. c2006-2011 [cit. 2011-03-15] Dostupné z WWW: http://www.informatika-osu.czechian.net/files/is/ancas/ANCAS_DiV.pdf
2. *Analýza časových řad* [online]. c2011 [cit. 2011-03-27] Dostupné z WWW: http://www.cihak.com/petr/Analyza_CR.doc
3. *Časové řady* [online]. c2011 [cit. 2011-03-15] Dostupné z WWW: <http://www.fzp.ujep.cz/~synek/statistika/prednasky/Less9Time2.doc>
4. *Časové řady* [online]. c2006-2011 [cit. 2011-03-11] Dostupné z WWW: <http://homen.vsb.cz/~oti73/cdpast1/KAP10/KAP10.HTM>
5. *Český statistický úřad – časové řady* [online]. c2011 [cit. 2011-04-09] Dostupné z WWW: http://www.czso.cz/csu/redakce.nsf/i/casove_rady
6. *Česká národní banka* [online]. c2003-2011 [cit. 2011-04-10] Dostupné z WWW: <http://www.cnb.cz/cs/index.html>
7. *Informační Bulletin, České Statistické Společnosti* [online]. c2004-2011 [cit. 2011-03-11] Dostupné z WWW: <http://www.statspol.cz/bulletiny/ib-03-3.pdf>
8. *Kurzy měn* [online]. c2011 [cit. 2011-04-09] Dostupné z WWW: <http://www.kurzy-men.biz/graf-vyvoj-kurzu-mesic-CAD>
9. *Strukturální fondy, Měsíční monitorovací zpráva* [online]. c2011 [cit. 2011-03-02] Dostupné z WWW: <http://www.strukturalni-fondy.cz/Files/00/00989c8f-e211-4b14-a593-ce6f88c3001b.pdf>
10. *Time Series Analysis* [online]. c2011 [cit. 2011-03-27] Dostupné z WWW: <http://www.statsoft.com/textbook/time-series-analysis/?button=3>
11. *Úvod do analýzy časových řad – VŠB-TU, Jana Hančlová, Lubor Tvrдый* [online]. c2005-2011 [cit. 2011-03-19] Dostupné z WWW: http://gis.vsb.cz/pan-old/Skoleni_Texty/TextySkoleni/AnalyzaCasRad.pdf
12. *Úvod do časových řad, Vítězslav Veselý* [online]. c2004-2011 [cit. 2011-03-27] Dostupné z WWW: <http://www.econ.muni.cz/~vesely/educ/sptext.pdf>

13. *Úvod do problematiky sezónního očišťování ekonomických časových řad – Josef Arlt, Markéta Škuthanová* [online]. c2003-2011 [cit. 2011-02-20] Dostupné z WWW:
http://nb.vse.cz/~arlt/publik/AS_UPSOECR_95.pdf
14. *Úvod do problematiky časových řad, SPSS CR, Ondřej Háva* [online]. c2007-2011 [cit. 2011-02-23] Dostupné z WWW:
http://www.spss.cz/files/ruzne/vsb/casove_rady.pdf
15. *Vybrané měnové kurzy* [online]. c2011 [cit. 2011-04-09] Dostupné z WWW:
<http://www.spcr.cz/statistika/ceny.htm>
16. *Základní analýza časových řad v SPSS v rámci předmětu Analýzy dat v regionalistice* [online]. c2011 [cit. 2011-03-03] Dostupné z WWW:
http://homel.vsb.cz/~tvr12/analyza_dat_v_regionalistice/body/Download/Zakladni_analyza_casovych_rad.doc