



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV EKONOMIKY

INSTITUTE OF ECONOMICS

PROGNÓZA VÝVOJE TRHU ZLATA

GOLD MARKET TREND FORECAST

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Jan Šimek

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Luňáček, Ph.D., MBA

BRNO 2018

Zadání diplomové práce

Ústav: Ústav ekonomiky
Student: **Bc. Jan Šimek**
Studijní program: Ekonomika a management
Studijní obor: Podnikové finance a obchod
Vedoucí práce: **Ing. Jiří Luňáček, Ph.D., MBA**
Akademický rok: 2017/18

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

Prognóza vývoje trhu zlata

Charakteristika problematiky úkolu:

Úvod
Vymezení problému a cíle práce
Teoretická východiska práce
Analýza problému a současné situace
Vlastní návrhy řešení, přínos návrhů řešení
Závěr
Seznam použité literatury
Přílohy

Cíle, kterých má být dosaženo:

Globálním cílem práce je vytvoření ekonometrického modelu vývoje cen investičního zlata. Parciálním cílem je definovat klíčové proměnné, vytvořit a verifikovat předpovědní model a kriticky zhodnotit jeho využitelnost.

Základní literární prameny:

CIPRA, Tomáš. Finanční ekonometrie. 2., upr. vyd. Praha: Ekopress, 2013. ISBN 978-80-86929-93-4.
HANČLOVÁ, Jana. Ekonometrické modelování: klasické přístupy s aplikacemi. Praha: Professional Publishing, 2012. ISBN 978-80-7431-088-1.
HUŠEK, Roman. Ekonometrická analýza. Praha: Ekopress, 1999. ISBN 80-86119-19-X.
REJNUŠ, Oldřich. Finanční trhy. 4., aktualiz. a rozš. vyd. Praha: Grada, 2014. Partners. ISBN 978-8-247-3671-6.

WOOLDRIDGE, Jeffrey M. Introductory econometrics: a modern approach. 3rd ed. Mason: Thomson/South-Western, 2006. ISBN 0-324-28978-2.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2017/18

V Brně dne 28.2.2018

L. S.

doc. Ing. Tomáš Meluzín, Ph.D.
ředitel

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

Abstrakt

Diplomová práce se zabývá ekonometrickým modelováním a prognózou tržní ceny zlata. Klíčovou funkci plní model vícerozměrné regrese a model ARIMA. První část diplomové práce obsahuje teoretická východiska. Analytická část se věnuje modelování tržní ceny zlata a následnému prognózování. Velmi důležitou roli hraje statistická a ekonometrická verifikace s využitím statistických metod. Poslední část shrnuje výsledky a předkládá návrhy na zlepšení.

Abstract

The diploma thesis deals with econometric modelling and gold price forecast. A key factor is the multiple regression model and the ARIMA model. The first part of the diploma thesis contains a theoretical basis. The analytical part deals with modelling of gold market price and subsequent forecasting. Statistical and econometric verification using statistical methods play a very important role. The last part summarizes the results and makes suggestions for improvement.

Klíčová slova

zlato, prognóza, model, časové řady, regresní analýza, ARIMA

Key words

gold, forecast, model, time series, regression analysis, ARIMA

Bibliografická citace

ŠIMEK, J. *Prognóza vývoje trhu zlata*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2018. 82 s. Vedoucí diplomové práce Ing. Jiří Luňáček, Ph.D., MBA.

Čestné prohlášení

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

V Brně dne 14. května 2018

.....

podpis studenta

Poděkování

Tímto bych chtěl poděkovat vedoucímu mé diplomové práce, panu Ing. Jiřímu Luňáčkovi, Ph.D., MBA, za cenné rady a připomínky, které mi pomohly při zpracování této práce.

Rád bych také poděkoval panu Ing. Karlu Doubravskému, Ph.D., MSc za poskytnutí odborných rad při modelování v ekonometrickém softwaru Gretl.

OBSAH

ÚVOD	11
VYMEZENÍ PROBLÉMU A CÍLE PRÁCE	13
1 TEORETICKÁ VÝCHODISKA PRÁCE	14
1.1 Finanční trh	14
1.1.1 Členění finančního trhu.....	14
1.2 Investice	15
1.2.1 Reálné a finanční investice	15
1.3 Komodity	16
1.4 Zlato	17
1.4.1 Zajímavosti o žlutém kovu.....	19
1.4.2 Držitelé fyzického zlata	19
1.4.3 Determinanty ceny zlata	20
1.5 Ekonometrie a statistika	22
1.5.1 Ekonometrické modelování	22
1.5.2 Typy dat	24
1.5.3 Finanční a ekonomické časové řady	24
1.5.4 Stacionarita a nestacionarita časových řad	25
1.5.5 Kointegrace časových řad	25
1.5.6 Klasické modely lineární regrese.....	25
1.5.7 Vícerozměrný regresní model.....	26
1.5.8 Metoda obyčejných nejmenších čtverců	26
1.5.9 Předpoklady lineárního regresního modelu	27
1.5.10 Specifikační chyby	27
1.5.11 Testování specifikace modelu.....	28
1.5.12 Koeficient determinace	28

1.5.13 Informační kritéria .	29
1.5.14 Autokorelovanost reziduí .	29
1.5.15 Multikolinearita .	30
1.5.16 Heteroskedasticita .	31
1.5.17 Normalita reziduí .	32
1.5.18 Verifikace odhadnutého modelu .	32
1.6 Box-Jenkins metodologie .	33
1.6.1 Modely nestacionárních časových řad .	34
1.6.2 Modely ARIMA .	34
1.7 Ekonometrické prognózování a charakteristika předpovědí .	34
1.7.1 Klasifikace předpovědí .	35
2 PRAKTICKÁ ČÁST .	37
2.1 Ekonomická formulace modelu a forma dat .	37
2.1.1 Vysvětlující proměnné .	37
2.1.2 Sběr dat .	39
2.1.3 Zdroje dat .	39
2.2 Statistická a ekonometrická analýza modelu .	40
2.2.1 Ověření stacionarity .	40
2.2.2 Kointegrace .	41
2.2.3 První diference časových řad .	41
2.2.4 Funkční forma ekonometrického modelu .	42
2.2.5 Odhad modelu metodou nejmenších čtverců .	43
2.2.6 Koeficienty determinace .	44
2.2.7 Graf vyrovnaných a skutečných hodnot .	45
2.2.8 Konfidenční intervaly koeficientů .	46
2.2.9 Analýza rozptylu (ANOVA) .	46

2.2.10 Analýza extrémních hodnot	47
2.2.11 Informační kritéria	47
2.3 Statistická verifikace	48
2.3.1 Statistická významnost modelu.....	48
2.3.2 Statistická významnost parametrů	49
2.4 Ekonometrická verifikace	49
2.4.1 Testy chybné specifikace	50
2.4.2 Multikolinearita.....	51
2.4.3 Autokorelace	51
2.4.4 Heteroskedasticita	53
2.4.5 Analýza reziduí	55
2.4.6 Test stability parametrů.....	57
2.5 Ekonomická verifikace	59
2.6 Prognóza tržní ceny zlata regresním modelem	59
2.6.1 Výběr modelu ARIMA	59
2.6.2 Prognóza z regresního modelu.....	60
2.7 Model ARIMA.....	62
2.7.1 Výběr modelu ARIMA	62
2.7.2 Odhad koeficientů modelu ARIMA.....	63
2.7.3 Diagnostika modelu ARIMA.....	64
2.8 Prognóza tržní ceny zlata z modelu ARIMA.....	70
2.9 Komparace regresního modelu a modelu ARIMA	72
3 VYHODNOCENÍ PRAKTICKÉ ČÁSTI	73
4 NÁVRHY NA ZLEPŠENÍ	75
ZÁVĚR	76
SEZNAM POUŽITÝCH ZDROJŮ	78
SEZNAM TABULEK, OBRÁZKŮ, GRAFŮ A ROVNIC	81

ÚVOD

Zlato se řadí mezi nejznámější a nejdůležitější kovy světa. Od starověku plnilo mnoho významných funkcí, od monetární, kterou hojně využívaly banky ke stabilizaci měnového vývoje, přes průmyslovou, díky které je zlato dodnes velmi významnou a nezastupitelnou součástí takřka každého průmyslového odvětví, až po investiční, jež je jak odrazem situace na konkurenčních trzích aktiv, tak reakcí na celosvětovou ekonomickou a finanční nestabilitu.

Finanční ekonometrie patří mezi velmi zajímavé vědní obory. Kvantitativní analýza finančních dat pomáhá porozumět složitostem a nejasnostem finančních a ekonomických jevů. Předmětem této analýzy bývají problémy řešené na mikroekonomické a makroekonomické úrovni. Oblast finančních trhů je často tématem statistického zpracování dat. Ekonometrické modelování se doporučuje provádět (vzhledem ke svojí složitosti) s ekonometrickým softwarem. Velmi důležité je vyhledat adekvátní spolehlivý datový zdroj. Zkreslená, nedůvěryhodná či zmanipulovaná data mohou výrazně ovlivnit důvěryhodnost modelu. V některých případech je hledání vhodného datového zdroje časově náročné a někdy nemožné. Klíčový zdroj ekonomických a finančních dat představovaly webové stránky Federální rezervní banky St. Louis. Další obtížnou úlohou je výběr vhodných vysvětlujících proměnných. Záleží na konkrétním předmětu ekonometrického modelování. Někdy je výběr relativně snadnou záležitostí, v oblasti finanční ekonometrie bývá volba regresorů náročná. Zlato se řadí spíše k těm vysvětlovaným proměnným, které nemají jasně stanovený výběr vhodných regresorů. V ekonometrickém modelování se v mnohých případech nelze vyhnout kompromisům. Často postačí selský rozum a znalost ekonomické teorie. Modelování se snaží modely více zjednodušovat a nebere v potaz detailní vlivy.

Diplomová práce řeší problematiku ekonometrického modelování a predikce tržní ceny zlata. Klíčovou roli plní model vícerozměrné regrese a model ARIMA. Hlavním cílem práce je vytvoření ekonometrického modelu k prognóze tržní ceny zlata. Diplomová práce se zabývá analýzou časové řady zlata, snaží se porozumět dynamice této řady a vyvodit z průběhu důsledky.

První část popisuje teoretická východiska, ve kterých stručně charakterizuje zlato, pojednává o základních problémech ekonometrického modelování, procesu modelování

a statistiky. Druhá část se zabývá vytvářením ekonometrických modelů a verifikací modelů tržní ceny zlata. Třetí oddíl praktické části je věnován prognóze. Předposlední část vyhodnocuje výsledky ekonometrického modelování. Poslední část předkládá návrhy na zlepšení.

VYMEZENÍ PROBLÉMU A CÍLE PRÁCE

Cíle

Hlavním cílem práce je vytvoření ekonometrického modelu k prognóze tržní ceny zlata. Parciální cíle zahrnují sběr dat, definování klíčových proměnných, zpracování dat pomocí statistické analýzy, sestavení a verifikace prognostického modelu a následné kritické zhodnocení jeho využitelnosti. Další dílčí cíl zahrnuje vytvoření a verifikaci předpovědního modelu ARIMA a komparace jeho výsledků predikce s regresním modelem.

Metodika řešení

K naplnění stanovených cílů se využije literární rešerše z odborné literatury. Další krok bude představovat určení možných vysvětlujících proměnných, které pomohou sestavit vícerozměrný regresní model. Klíčovou fází je vytváření modelů v ekonometrickém softwaru Gretl. Zásadní význam v ekonometrickém modelování mají metody vícerozměrné regrese a metoda ARIMA. Model vícerozměrné regrese bude následně statisticky, ekonometricky a ekonomicky verifikován. Poté bude diagnostikován model ARIMA. Pokud modely splní podmínky verifikace, budou doporučeny k prognóze tržní ceny zlata. V poslední fázi se porovnají prognózy obou metod.

Klíčovou roli budou hrát metody statistické a ekonometrické analýzy dat. Komparace ekonometrických modelů a napředikovaných předpovědí představuje další velmi důležitou metodu použitou v průběhu ekonometrického modelování. Metoda komparace bude aplikována při porovnání p-hodnoty se zvolenou hladinou významnosti α . V některých případech se komparace použije ke srovnání doporučené a výsledné hodnoty testu. Vytváření matematicko-statistických modelů je hlavním předmětem regresní analýzy. Metoda deskripce bude využita k popisu grafického aparátu z ekonometrického softwaru Gretl. V počátečních fázích vytváření modelů byla aplikována metoda pokus – omyl. Tato metoda byla použita při výběru potenciálně vhodných vysvětlujících proměnných.

1 TEORETICKÁ VÝCHODISKA PRÁCE


V následující části bude velmi stručně probrána problematika finančních trhů, zlata, ekonometrie, statistiky a předpovědí.

1.1 Finanční trh

Prvořadým úkolem finančních trhů je přemísťovat peněžní prostředky od přebytkových subjektů k deficitním (Rejnuš, 2014).

1.1.1 Členění finančního trhu

Finanční trh lze dělit pomocí různých hledisek, nejčastěji se dělí podle určitých druhů finančních investičních instrumentů, které se na jeho segmentech obchodují. Klíčové trhy jsou peněžní trh a kapitálový trh, které jsou doplněny specifickými trhy, trhem s cizími měnami a trhem drahých kovů. Trh krátkodobých cenných papírů a trh dlouhodobých cenných papírů tvoří dohromady trh cenných papírů (tamtéž).



Obrázek č. 1: Členění finančního trhu


(Zdroj: Vlastní zpracování dle: Rejnuš, 2014, s. 61)

1.2 Investice

Investici lze chápat jako obětování přesně dané současné hodnoty s cílem získat v budoucnu vyšší hodnotu, i když ne jistou. Investici může podnikatel realizovat podnikatelskou činností za účelem dosažení zisku, nebo pořízením různých investičních nástrojů se záměrem jejich držby (Rejnuš, 2014).

1.2.1 Reálné a finanční investice

Investice se dělí na dvě základní skupiny, reálné investice a finanční investice.



Obrázek č. 2: Rozdělení investic

(Zdroj: Vlastní zpracování dle: Rejnuš, 2014, s. 53)

1.3 Komodity

Komodity se vyskytují téměř všude na zemi, patří mezi hmotná aktiva, mají odlišné vlastnosti od finančních investičních instrumentů a nezahrnují žádné kreditní riziko. Většina komodit je také velmi likvidních. Komodity se obchodují na otevřených trzích po celém světě. Komodity mají potenciál růstu, i když se ekonomice nedaří. Výnosy z komodit se zpravidla pohybují nad inflací. Komodity nemohou na rozdíl od akcií nebo dluhopisů spadnout na nulu. Komodity mají a vždycky budou mít pro někoho nějakou hodnotu vzhledem k tomu, že patří mezi reálná aktiva (Rogers, 2008).

Mezi tyto základní statky patří ropa, zemní plyn, pšenice, kukuřice, bavlna, sojové boby, hliník, měď, stříbro, zlato, dobytek, vepřové maso, cukr, káva, kakao, rýže, vlna a další. Komodity patří do každého diverzifikovaného portfolia. Investování do komodit může sloužit jako ochrana proti klesajícím trhům akcií, inflaci a poklesu ekonomiky. Investování do komodit může představovat vynikající příležitost pro zhodnocení prostředků.

Historie vícekrát dokázala negativní korelaci s cenami akcií, dluhopisů a s jinými finančními aktivy, tento fakt je důvodem pro zařazení komodit do svého osobního portfolia. Když se akcie nacházejí u dna, komodity jsou nahoře a naopak. Pokud se tedy neinvestuje do komodit, není portfolio diverzifikované. Federální rezervní systém Spojených států amerických (FED) a mnohé další centrální banky po celém světě udržují politiku znehodnocování papírových měn. Komodity mají tu výhodu, že není možné je natisknout, to se o penězích říci nedá. Federální rezervní systém Spojených států amerických (FED) se svojí dluhovou politikou tlačí ceny drahých kovů a ostatních komodit vzhůru. Centrálním bankám stačí zahřát tiskařské stroje, zatímco suroviny se takto lehce získat nedají (Rogers, 2008).

1.4 Zlato

Zlato na sebe poutá pozornost po dlouhá staletí. Je obecně považováno za symbol bohatství. Disponuje jedinečnými vlastnostmi (je stejnorodé, přenosné, nerezaví, uchovává si teplou barvu). Funkci měny zlato plnilo od 7. století před naším letopočtem až do roku 1971, kdy byla zrušena vnější směnitelnost dolaru za zlato, která platila pro centrální banky (tzv. standard zlaté devizy), tímto byl dokončen proces demonetizace zlata. Zlato následně ztratilo význam v měnovém systému, zůstalo však symbolem bohatství, prostředkem k investování, výrobní surovinou a součástí devizových rezerv (Veselá, 2011).

Nashromážděné zásoby se v současné době odhadují na více jak 150 000 tun. Roční těžba činí asi 1700 – 2200 tun zlata. Nabídku netvoří pouze těžba zlata, ale i recyklace starého zlata. Mezi největší světové producenty zlata patří Jihoafrická republika, USA, Austrálie, Kanada, Rusko a Čína. Významnou roli na trhu zlata hrály v nedávné době také centrální banky, které držely významnou část zlata ve svých devizových rezervách (tamtéž).

Zlato patří mezi dlouhodobě uznávanou měnu s omezenými zásobami. Je považováno za bezpečný přístav v dobách nejistoty. Zlato těží z ekonomické nejistoty. Může tvořit stabilní součást investičního portfolia (Mellon a Chalabi, 2008).



Obrázek č. 3: Zlatá mince Wiener Philharmoniker

(Zdroj: celticgold.eu)

Rozhodne-li se investor investovat do zlata, určitě na začátku bude řešit otázku, jakou formou investici realizovat. Možností je hned několik a každá má své příznivce i odpůrce (Maloney, 2010).

Základními možnostmi je investování do fyzického zlata, do hmotných zlatých produktů (slitků a mincí), nebo do nefyzického zlata nazývaného zjednodušeně „papírové zlato“. Zlato je velmi vhodným doplňkem portfolia pro každého investora (Bocker, 2009).

Zlato se velmi často obchoduje v uncích, trojská unce váží přibližně 31,1035 gramu. Investování do fyzického zlata si drží dlouholetou tradici. Mezi nejznámější trhy fyzického zlata se řadí Londýn, Curych, New York, Hongkong, Singapur, Tokio, Dubaj, Paříž, Lucemburk, Frankfurt a Brusel. Investoři na trhu s fyzickým zlatem uzavírají promptní, nebo termínové obchody. Promptní obchody se vyznačují fyzickým nákupem nebo prodejem zlatých cihel s termínem dodání zpravidla do dvou pracovních dnů. Investor má možnost zlaté slitky přebrat fyzicky nebo si je nechat uložit v bance a obdržet certifikát o jejich vlastnictví. Zlaté cihly se liší svými rozměry, standardní zlatou cihlou je cihla, která váží 400 trojských uncí (12,44 kg). Pro takovouto cihlu se používá označení Bar. Pro potřeby menších investorů se vyrábí menší cihly (slitky), jejich váha může být i několik gramů. Termínové obchody s fyzickým zlatem probíhají zejména ve formě zlatých swapů (gold swaps), zlatých půjček (gold loans) a forwardových prodejů (forward sales). Uskutečňují se na neorganizovaných OTC trzích. Mezi účastníky těchto obchodů se řadí producenti zlata, zpracovatelé zlata, dealeři a centrální banky. Zlaté swapy se uzavírají v několika variantách. Tradiční forma zlatého swapu znamená kombinaci promptního a termínového obchodu, kdy dnes dochází výměnou za platbu v hotovosti k převodu zlatých cihel na subjekt B s dohodnutým zpětným odkupem zlatých prutů subjektem A v budoucím termínu za předem dohodnutou cenu. Jiný druh swapů představují kvalitativní zlaté swapy, v těchto swapech se obchoduje s různou ryzostí zlata. Forwardové prodeje využívají těžařské společnosti k prodeji nevytěženého zlata. Hlavním nástrojem je hedging, jinými slovy zajištění proti poklesu ceny zlata. Zajištění forwardových obchodů zprostředkovávají specializované bullion banky, které si na počátku obchodu vypůjčí (zpravidla od centrální banky) určitý objem zlata, který těžařská společnost má v plánu prodat. Vypůjčené zlato bullion banka okamžitě prodá na promptním trhu a inkasované finanční prostředky uloží na peněžním trhu. Po několika měsících dodá těžařská společnost zlato, které s úroky obdrží centrální banka. Těžařská

společnost dostane finanční prostředky včetně úroků z peněžního trhu, které se poníží o úroky zaplacené centrální bance a sníží se o provizi bullion bance. Další možností může být investování do zlatých mincí. Tyto obchody běžně zprostředkovávají banky, brokerské firmy, specializované firmy nebo klenotníci. Nepřímou formu investování představuje investování do papírového zlata. V tomto případě se může jednat o investování do zlatých opcí, warrantů a futures, které se obchodují na komoditních burzách. Odlišnou formou nepřímého investování je investice do akcií zlatých dolů. Ceny akcií jsou významně ovlivňovány vývojem ceny zlata, proto cena těchto akcií nekoreluje s ostatními akciemi (Veselá, 2011).

1.4.1 Zajímavosti o žlutém kovu

- Ke zlatu neexistují žádné náhradní kovy.
- Velkoobchodní spotový trh s fyzickým zlatem má pověst velmi likvidního trhu.
- Nejvýznamnější spotový trh fyzického zlata se nachází v Londýně (London Bullion Market).
- Cena fyzického zlata vychází z ceny zlata na světových komoditních burzách, avšak zahrnuje i výrobní náklady a obchodní marže obchodníků.
- Zlato vykazuje značnou odolnost vůči inflaci.
- Nejznámější futures burza se nachází v New Yorku (COMEX division).
- Odkupní ceny bývají na rozdíl od prodejních cen výrazně nižší (Rejnuš, 2014).

1.4.2 Držitelé fyzického zlata

Centrální banky – zlato jim slouží jako část devizových rezerv. Toto zlato představuje určitou pojistku proti ekonomickým krizím či vzniku politické nestability. Zlato má funkci ručitele finanční stability státu.

Obchodní banky – banky musí dodržovat kapitálovou přiměřenost a adekvátní likviditu. Bezrizikové zlato a téměř stoprocentně likvidní fyzické zlato tuto podmínku splňuje. Používá se také jako vysoce likvidní záruka s velmi malým úvěrovým a tržním rizikem.

Instituce nabízející investiční služby – především se mají na mysli různí správci investičních portfolií, může se například jednat o investiční společnosti, investiční fondy (včetně hedgeových fondů) a další instituce.

Fyzické osoby – tyto osoby nakupují fyzické zlato s vidinou ochrany svého majetku před inflací, případně pro nenadálé životní události. Spíš se jedná o účel zajištění majetku, než o možnost dosažení zisku. Někteří lidé nakupují fyzické zlato i s obavami, že se současný monetární systém zhroutí. Dalším motivem může být ukrytí zlata před rodinnými příslušníky či před státními institucemi (Rejnuš, 2014).

1.4.3 Determinanty ceny zlata

Determinantů tržní ceny zlata existuje velké množství, těmito determinanty mohou být (gold.org, ©2018):

1. Globální krize

Cena zlata má tendenci růst, když lidé nedůvěřují vládám či finančním trhům. Světové události mají velmi často vliv na cenu zlata. Zlato představuje pocit bezpečí během ekonomické a politické nejistoty. Lidé berou zlato jako bezpečný přístav v dobách nejistoty a politického chaosu.

2. Inflace

Velmi častým důvodem pro držení zlata je ochrana proti inflaci a devalvaci měny. Hodnoty měn kolísají, ale hodnota zlata, pokud se jedná o to, co si za něho můžeme v dlouhodobém horizontu koupit, zůstává stabilní. Investoři mohou projevit větší zájem o zlato, když cítí, že hodnota jejich papírových peněz bude klesat.

3. Hodnota amerického dolaru

Americký dolar zůstává nadále dominantní rezervní měnou. Cena zlata a síla dolaru tvoří vzájemně inverzní vztah, pokud je dolar silný, zlato je slabé a naopak.

4. Nestabilita centrálních bank

Ve Spojených státech amerických zastupuje funkci centrální banky Federální rezervní systém. Většina zemí má ale svoji jednu centrální banku, mezi ty celosvětově nejdominantnější patří Evropská centrální banka, Banka Japonska a Švýcarská národní banka. Krachy velkých komerčních bank patří mezi základní potenciály růstu ceny zlata. Lidé výrazně zvyšují poptávku zlata, když mají pocit,

že systém papírových peněz selhává. V takovýchto situacích je na místě nákup fyzického zlata. Na druhé straně zvýšená poptávka žene nahoru hodnotu zlata ještě více.

5. *Úrokové sazby*

Ze zlata se nemusí platit zdaněné úroky jako je tomu u státních cenných papírů, spořicíh účtů a různých vkladových produktů. Na cenu zlata má velký vliv globální úroková míra, s růstem úrokových sazeb klesá cena zlata, s poklesem naopak má tendenci růst. Nízké úrokové sazby vyznívají pro zlato vzhledem k nízkým nákladům příležitosti alternativních investic.

6. *Kvantitativní uvolňování*

Kvantitativní uvolňování znamená nákup cenných papírů centrální bankou s cílem zvýšení množství peněz v oběhu. Zaplavením finančních institucí penězi centrální banka, stejně jako Federální rezervní systém, doufá, že na podporu bank půjčí více peněz a zvýší tím nabídku peněz. Větší peněžní zásoby tlačí úrokové sazby směrem dolů, což by mohlo povzbudit investory ke koupi zlata z důvodu nižších nákladů příležitosti. Tato taktika může vyvolat vyšší inflaci, která je dalším signálem pro nákup zlata.

7. *Rezervy centrálních bank*

Centrální banky stejně jako Federální rezervní systém drží zlato a papírovou měnu v rezervě. Spojené státy a některé evropské státy drží značnou část svých rezerv ve zlatě. Mezi evropské státy, které drží zlato, patří například Francie, Německo, Itálie, Řecko a Portugalsko. Pokud se centrální banky rozhodnou nakupovat zlato ve větším množství, než prodávají, cena zlata začne stoupat. Dostupné zlato se tímto stane vzácnější.

8. *Šperkařství a průmysl*

Zlato je nejen vhodným bezpečným přístavem, zlato se také využívá ve šperkařství a průmyslu. Přibližně jedna polovina poptávky po zlatě je z oboru šperkařství. Největší poptávku po zlatě vytváří Čína, Indie a Spojené státy americké. V některých částech Indie je zlato považováno za druh měny, demonstraci bohatství, dar a samozřejmě zajištění proti krizovým situacím. Poptávka v Indii tak poměrně výrazně zvyšuje cenu zlata. Zlato je v Číně symbolem bohatství, rostoucí ekonomika v Číně znamená, že více lidem zbývá

peníze na nákup zlata. Kromě šperků dalších přibližně 12 % poptávky vygeneruje použití v průmyslu. Výrobci používají zlato na nejrůznější elektronická zařízení, mezi tato zařízení patří například počítače, systémy GPS a zdravotnické prostředky.

9. *Těžba zlata*

Přibližně jen 2 500 tun zlata se vytěží každý rok. Celosvětová nabídka se odhaduje na 165 000 tun. Veškeré zlato na světě by odhadem zaplnilo tři a půl olympijského bazénu. I přesto se objem roční těžby zlata může zdát jako poměrně nízký v porovnání s celosvětovou nabídkou. Produkční náklady mohou výrazně ovlivnit cenu veškerého zlata na světě. Pokud vzrostou náklady na těžbu, horníci aby udrželi své zisky, budou zlato prodávat draž. Až dojde na prodej zlata, nikoho nebude zajímat, kdy bylo vytěženo.

10. *Poptávka vs nabídka*

Pokud máte v plánu koupit zlato, je třeba si uvědomit, že cena je ovlivněna výrobními náklady, peněžní zásobou, finanční či geopolitickou stabilitou, poptávkou generovanou šperky, průmyslem a opatřeními přijatými centrálními bankami. Jinými slovy, zlato je omezený zdroj a při globálních ekonomických podmínkách, kdy roste poptávka po zlatě, dochází také ke zvyšování ceny zlata. Ale skutečná hodnota zlata zůstává poměrně stabilní v dlouhodobém horizontu, v krátkém horizontu by cena mohla jednoduše odrážet dočasnou nejistotu nebo prosté fluktuace měn.

1.5 Ekonometrie a statistika

Ekonometrie je vědní disciplína, která používá nástroje statistiky a matematiky v oblasti ekonomie a využívá při tom informatiky (Hančlová, 2012).


1.5.1 Ekonometrické modelování

Základní podstatou ekonometrie je vytváření modelů zkoumaných jevů. Model zjednodušeně zobrazuje reálnou situaci. Tvorba modelu závisí na složitosti jevu a nemožnosti vymezit detaily dostupnými teoretickými prostředky. Model potom zobrazuje hlavní rysy ekonomického jevu, které ho následně charakterizují, nepodstatné

rysy se neberou v potaz. Modelování tedy znamená proces vytváření modelů (Mezník, 2003).

Ekonometrické modelování zahrnuje pět základních etap (Hančlová, 2012):

- 1) formulace modelu,
- 2) sběr a analýza dat,
- 3) odhad výběrového modelu,
- 4) verifikace modelu,
- 5) využití modelu.



Obrázek č. 4: Fáze ekonometrického modelování

(Zdroj: Vlastní zpracování dle: Hančlová, 2012, s. 12)

1.5.2 Typy dat

➤ Časová data

Časovými daty se rozumí data ve tvaru časových řad, hodnoty některé veličiny pozorované během určitého časového intervalu s příslušnou frekvencí záznamu. Pokud se hovoří o frekvenci pozorování, má se na mysli velikost intervalu mezi jednotlivými pozorováními (např. kalendářní týden), nebo pravidelnost s jakou je záznam uskutečněn. Časová data je nezbytné chronologicky uspořádat v čase (Cipra, 2013).

➤ Průřezová data

Průřezovými daty se rozumí data ve tvaru průřezového výběru, hodnoty některé veličiny (veličin) pozorované během stejného časového okamžiku přes určitý populační soubor. Průřezová data obvykle nevyžadují uspořádání, lze je tedy ve většině případů libovolně přerovnávat.

➤ Panelová data

Panelová data kombinují časová a průřezová data (např. denní uzavírací ceny všech akcií obchodovaných na NYSE během roku 2016). Ekonometrické modely určené pro panelová data se vyznačují řadou specifík.

Ekonometrická data lze klasifikovat i podle dalších hledisek, např. na kvantitativní data (ceny, kursy, počty apod.) a kvalitativní data (rating, dny v týdnu apod.), (Cipra, 2013).

1.5.3 Finanční a ekonomické časové řady

Ekonomické a finanční časové řady se vyznačují:

- trendem,
- podmíněnou heteroskedasticitou,
- nelinearitou,
- společným trendem.

V praktickém modelování se někdy časové řady logaritmicky transformují. Důvodů může být několik. Finanční a ekonomické časové řady bývají charakteristické exponenciálním trendem a logaritmická transformace představuje jeho linearizaci. Tímto se časová řada stává stabilní z hlediska variability. U finančních časových řad se vychází z toho, že cena nemůže být záporná, očekává se tedy, že by hodnoty mohly být generovány logaritmicko-

normálním rozdělením. Během konstrukce modelů se vychází z předpokladu, že teoretické ekonomické modely jsou v exponenciálním tvaru. Logaritmování umožní jejich linearizaci (Arlt a Arltová, 2007).

1.5.4 Stacionarita a nestacionarita časových řad

Stacionární časová řada je taková, jejíž základní vlastnosti, například její průměr a rozptyl se nemění v čase. Na rozdíl od nestacionárních časových řad, u kterých se tyto vlastnosti v průběhu času mění. Často se předpokládá jen slabá stacionarita. Stacionárních časových řad se obvykle dosahuje pomocí prvních diferencí, výjimečně se musí aplikovat druhé difference. Stacionarita časových řad je pro účely ekonometrického modelování naprosto nezbytná (Wooldridge, 2006).

Hlavním důsledkem nestacionarity časových řad pro regresní analýzu je výskyt zdánlivé regrese. Zdánlivá regrese výrazně zvyšuje koeficient determinace a t-statistiku, tím dochází k nesprávné specifikaci modelu. Stacionarita se obvykle testuje pomocí rozšířeného Dickey-Fuller testu, KPSS testu a dalších (Studenmund, 2013).

Další možnost testování slabé stacionarity může poskytnout korelogram autokorelační funkce (Gujarati a Porter, 2009).

1.5.5 Kointegrace časových řad

Kointegrace znamená dlouhodobou rovnováhu několika časových řad. Přestože některé časové řady jsou nestacionární, může být kombinace dvou nebo více časových řad stacionární. Kointegrované časové řady mohou ekonometrické modelování zbavit problému zdánlivé regrese. Kointegrační testy se aplikují na rezidua časové řady. Používá se například rozšířený Dickey-Fuller test a KPSS test (Wooldridge, 2006).

1.5.6 Klasické modely lineární regrese

Klasická jednoduchá lineární regresní analýza náleží mezi jeden z nejdůležitějších nástrojů ekonometrického modelování. U této analýzy je nezbytné kvantifikovat neznámé parametry ekonometrického modelu (Hušek, 1999).

Nejznámější technikou, která se používá pro odhady, je metoda nejmenších čtverců. Každá metoda disponuje při svém užití určitými předpoklady, tyto předpoklady je potřeba znát (Wooldridge, 2006).

Testování statistické významnosti regresních parametrů náleží do části verifikace ekonometrického modelu. Odhadnuté regresní modely, které byly verifikovány, se mohou použít k bodové nebo intervalové predikci ex post, případně ex ante (Hančlová, 2012).

1.5.7 Vícerozměrný regresní model

Ekonomická teorie je velmi zřídka jednoduchou záležitostí, proto jednoduchý regresní model velmi často nestačí. Nejjednodušší vícerozměrný regresní model obsahuje dvě vysvětlující proměnné. V regresním modelu se analytik musí vyvarovat zdánlivého vztahu, korelace mezi vysvětlující a vysvětlovanou proměnnou neznamena jasnou příčinou závislost mezi těmito proměnnými. V empirické analýze se mluví o odhadech regresních funkcí. Teoretická funkce zůstává neznámá. U vícerozměrného regresního modelu hrozí nebezpečí multikolinearity (kolinearity) vysvětlujících proměnných. Regresní model může být lineární, nebo nelineární v parametrech, stejně tak vysvětlující proměnné mohou mít lineární (nelineární) funkční formu. Některé modely nelineární v parametrech lze převést na lineární. Obtížnou záležitostí u modelu vícerozměrné regrese bývá výběr správné funkční formy (Gujarati a Porter, 2009).

Rovnice č. 1: Jednoduchá forma vícerozměrné regrese

(Zdroj: Zpracováno dle Wooldridge, 2006, s. 162)

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \varepsilon$$

1.5.8 Metoda obyčejných nejmenších čtverců

Metoda obyčejných nejmenších čtverců (OLS = ordinary least squares) je nejpoužívanější metodou pro odhadování hodnot koeficientů regrese. Metodu lze aplikovat jen na modely, které jsou lineární v parametrech, případně na modely, které lze linearizovat. Metoda se relativně snadno používá. Odhady koeficientů metodou OLS vykazují několik užitečných vlastností (vydatnost, konzistenci a nestrannost). Podstatou metody OLS je minimalizace součtu čtverců reziduí (Studenmund, 2013).

Rovnice č. 2: OLS minimalizuje součet čtverců reziduí

(Zdroj: Zpracováno dle Studenmund, 2013, s. 37)

$$\text{minimum} \sum_{i=1}^N e_i^2$$

$i = (1, 2, \dots, N)$

1.5.9 Předpoklady lineárního regresního modelu

Aby byl odhad regresního modelu metodou nejmenších čtverců nejlepší mezi lineárními odhady, musí splnit některé předpoklady. Tento odhad bývá označen anglickou zkratkou BLUE (Best Linear Unbiased Estimator). Mezi tyto předpoklady se dle Gujaratiho a Portera (2009) řadí:

- I. Regresní model je lineární v parametrech.
- II. V modelu se vyskytuje nulová kovariance mezi jednotlivými vysvětlujícími proměnnými a chybovým členem.
- III. Chybový člen má nulovou střední hodnotu.
- IV. Chybový člen vykazuje homoskedasticitu.
- V. V modelu se nevyskytuje perfektní multikolinearita.
- VI. Nevyskytuje se autokorelace (sériová korelace).
- VII. Počet pozorování musí být větší než počet odhadovaných parametrů.
- VIII. Model je správně specifikovaný.

Pokud chybový člen splní podmínku normálního rozdělení, pak je odhad metodou nejmenších čtverců nejlepší ze všech možných odhadů (tamtéž).

1.5.10 Specifikační chyby

Vícerozměrné regresní modely se poměrně často potýkají s problémem nesprávné specifikace. Mezi časté specifikační chyby dle Wooldridge (2006) patří:

- opomenutí důležité vysvětlující proměnné,
- zahrnutí nepodstatné vysvětlující proměnné,
- nesprávná funkční forma regresního modelu,
- chyby v měření,
- nesprávná specifikace chybového členu.

1.5.11 Testování specifikace modelu

Nedílnou součástí specifikační analýzy jsou testy chyb specifikace, které mohou upozornit na možný výskyt specifikační chyby i stupeň její významnosti. Je vhodné rozlišovat mezi testy specifikace a testy chybné specifikace. Liší se v tom, že u testu specifikace je přesně určena alternativní hypotéza, zatímco u testu chybné specifikace nikoliv (Hušek, 1999).

Mezi testy specifikace patří testování významnosti proměnných pomocí t-testů a statistické významnosti jednotlivých regresních koeficientů, F-testů a statistické testování významnosti celého regresního modelu. Pokud není stanovena alternativní hypotéza při testování specifikačních chyb, použijí se k ověření modelu následující přístupy:

- analýza reziduální složky,
- Durbin-Watson test sériové závislosti reziduální složky,
- Ramsey test (RESET test).

Analýza reziduální složky vychází z grafické analýzy a srovnává reziduální složky jednotlivých modelů. V případě, že rezidua nevykazují systematické změny, pak model nenaznačuje špatnou specifikaci. **Durbin-Watson test** (DW test) popisuje závislost reziduální složky na svých zpožděných hodnotách. Pokud se podaří odhalit silnou pozitivní (negativní) závislost, potom model zpravidla postrádá vysvětlující proměnnou, další příčinou může být špatně zvolená funkční forma ekonometrického modelu. **RESET test** slouží k diagnostice specifikačních chyb, které mohly vzniknout vlivem nesprávné specifikace funkční formy nebo opomenutím relevantních vysvětlujících proměnných (Hančlová, 2012).

1.5.12 Koeficient determinace

Koeficient determinace vyjadřuje jaká část vysvětlované proměnné je vysvětlena pomocí vysvětlujících proměnných. Jedná se o relativní míru. Koeficient determinace dosahuje hodnot intervalu $\langle 0,1 \rangle$. Obecně platí, že čím je hodnota bližší jedné, tím model lépe popisuje data. Koeficient determinace má tu nevýhodu, že s přidáním další vysvětlující proměnné nikdy neklesne. To může vést k modelům, které obsahují zbytečně velké množství vysvětlujících proměnných. Tato nevýhoda vedla k zavedení adjustovaného

(upraveného) koeficientu determinace, který má lepší vypovídací schopnosti. Jako doplňkové měřítko kvality regresního modelu se doporučuje používat informační kritéria (Wooldridge, 2006).

Rovnice č. 3: Koeficient determinace

(Zdroj: Zpracováno dle Gujarati a Porter, 2009, s. 201)

$$R^2 = \frac{RSS}{TSS} = 1 - \frac{ESS}{TSS}$$

TSS = úplný součet čtverců

RSS = reziduální součet čtverců


ESS = vysvětlený součet čtverců

1.5.13 Informační kritéria

Informační kritéria se řadí mezi velmi důležité zdroje vypovídající o kvalitě modelu. Používají se při porovnávání modelů s podobnými hodnotami koeficientů determinace. Mezi tato kritéria patří Akaike, Schwarz (Bayes) a Hannan-Quinn kritérium. Vybírá se takový model, který tato kritéria minimalizuje. Kritéria penalizují počet parametrů, tím se předchází nadbytečnému množství vysvětlujících proměnných. Často se kritéria aplikují při výběru vhodného modelu ARIMA (Brooks, 2014).

1.5.14 Autokorelovanost reziduí

Autokorelovanost reziduí porušuje klasický předpoklad lineárního regresního modelu. Reziduální složka ε je korelována se svými zpožděnými a budoucími hodnotami. K autokorelaci dochází především v časových řadách (Wooldridge, 2006).



Obrázek č. 5: Neautokorelovanost reziduí (vlevo) a autokorelovanost reziduí (vpravo)

(Zdroj: Gujarati a Porter, 2009, s. 71)

1.5.15 Multikolinearita

Multikolinearita popisuje lineární vztah mezi vysvětlujícími proměnnými. Žádná z nezávislých proměnných nesmí být přesnou lineární kombinací jiné nezávislé proměnné. Výskyt perfektní multikolinearity znamená porušení Gauss-Markových předpokladů (Stock a Watson, 2011).

Příčiny multikolinearity

Velmi častou příčinou multikolinearity je náchylnost ekonomických časových řad vyvíjet se stejným směrem. Vysokou multikolinearitu způsobuje zařazení zpožděných endogenních i exogenních proměnných, mezi kterými existuje silná lineární závislost. Významná multikolinearita se nemusí nezbytně týkat jen časových řad, objevuje se i v průřezové analýze. Příčinou může být i model, ve kterém se využívají polynomy (Hampel, Blašková a Střelec, 2016).

Důsledky multikolinearity


Multikolinearita se projevuje růstem rozptylu a standardních chyb, to znamená, že se sníží přesnost odhadu koeficientů. Odhady parametrů jsou následně náchylnější na změny ve specifikaci modelu. Vysoké hodnoty standardních chyb naznačují pochybnosti o správné specifikaci modelu. Může docházet k poklesům vypočítaných hodnot t-statistiky, tím se může daný parametr jevit jako statisticky nevýznamný (tamtéž).

VIF

Ke zjištění multikolenearity lze použít VIF (The variance inflation factor), je to metoda, která detekuje závažnost lineární závislosti vysvětlujících proměnných. Vysoký VIF zvyšuje odchylku odhadu. Hodnota vyšší než deset obvykle signalizuje multikolinearitu vysvětlující proměnné (Studenmund, 2014).

1.5.16 Heteroskedasticita

Výskyt heteroskedasticity znamená porušení jednoho z klasických předpokladů lineární regrese. Chybový člen v tomto případě vykazuje nekonzantní rozptyl. Dochází tak k variabilitě reziduí v čase. Heteroskedasticitu lze zkoumat graficky pomocí grafů reziduí. Testování heteroskedasticity může probíhat pomocí Breusch-Pagan, White, Park, ARCH a dalších testů. Heteroskedasticita může být způsobena i nesprávnou specifikací modelu (nadbytečnou proměnnou, opomenutou proměnnou, chybným funkčním tvarem). Výskyt heteroskedasticity znamená, že metoda OLS (ordinary least squares) není nejlepším odhadem parametrů (Wooldridge, 2006).



Obrázek č. 6: Heteroskedasticita

(Zdroj: Hill, Griffiths a Lim, 2011, s. 303)

1.5.17 Normalita reziduí

Normální rozdělení patří mezi rozdělení, která jsou spojitá a symetrická. Toto rozdělení definují dva parametry, střední hodnota μ a rozptyl σ^2 . Normální rozdělení se řadí mezi velmi používaná a detailně prozkoumaná rozdělení. Pokud dojde ke splnění předpokladu normality reziduí, potom jsou odhady koeficientů regrese BUE (best unbiased estimator), vykazují minimální rozptyl ze všech estimátorů. Normalita představuje nutnou podmínku pro použití t-testů a F-testu. V případě, že chybový člen vykazuje normalitu, lze usuzovat, že odhady regresních parametrů mají také normální rozdělení. Normalita se ověřuje graficky Q-Q grafem, P-P grafem a histogramem. Testů normality je velké množství. Mezi nejznámější patří test Jarque-Bera, Kolmogor-Smirnov, Shapiro-Wilk a Anderson-Darling. Předpoklad normality reziduální složky je velmi důležitý v malých výběrech cca do sta pozorování. Normalita v ekonometrické praxi bývá zaručena centrální limitní větou (Gujarati a Porter, 2009).

1.5.18 Verifikace odhadnutého modelu

Verifikace odhadnutého modelu znamená ověření validity daného modelu pomocí tří úrovní. Mezi tyto úrovně patří:

- statistická verifikace,
- ekonometrická verifikace,
- ekonomická verifikace.

Pokud se hovoří o *statistické verifikaci*, má se na mysli ověření statistické reálnosti jednotlivých odhadnutých parametrů. K tomu slouží testování statistické významnosti na předem stanovené hladině významnosti. Mimo to se také provádí další testování hypotéz (Hančlová, 2012).

Ekonometrická verifikace vyžaduje ověření předpokladů, které jsou nezbytné k úspěšné aplikaci zvolených ekonometrických metod, testů a dalších technik. Základním kamenem této fáze je testování náhodné složky z hlediska normálního rozdělení s nulovou střední hodnotou a konstantním rozptylem. Mezi další části této verifikace patří volba rozsahu pozorování a stabilita odhadu regresních parametrů v čase. Pokud se zjistí nedostatky při ekonometrické verifikaci, je nutné se vrátit k předcházejícím etapám, provádí se korekce

při formulaci modelu, dochází k přehodnocování postupů a technik při tvorbě odhadu. Dále je nezbytné provést opakovaně statistickou verifikaci.

Poslední částí je *ekonomická verifikace* odhadnutých regresních parametrů i celého modelu. Vychází se z předem stanovených ekonomických omezení, ekonomicky se interpretují odhadnuté regresní parametry, sleduje se shoda s očekáváním vzhledem ke znaménkám, úrovni a ekonomické teorii. Také se hodnotí vypovídací schopnost modelu (Hančlová, 2012).

Pokud zjistíme v průběhu verifikace neadekvátní validitu, pak je nutné určit příčinu poruchy, provést adekvátní korekci a návrat do předcházejících fází ekonometrického modelování. V případě, že etapy modelování proběhly zdárně, potom následuje konečná fáze *využití odhadnutého modelu*. Možnosti využití odhadnutého regresního modelu by měly bezpodmínečně souviset s hlavním cílem, tedy motivem realizace ekonometrického modelování. Motiv užití ekonometrického modelu se dle (Hančlové, 2012) dá v podstatě rozdělit do tří základních skupin:

- analýza vývoje nebo chování zkoumaného ekonomického jevu (např. simulace),
- predikce vývoje zkoumané veličiny v budoucnosti,
- využití odhadnutého modelu optimálního řízení hospodářské politiky (simulace scénářů a jejich dopadů).

1.6 Box-Jenkins metodologie

Box-Jenkins metodologie se zabývá analýzou stochastických časových řad. Využívá při tom lineární stochastické modely (např. ARMA, ARIMA a SARIMA), které umožňují modelovat i časové řady, které jsou pro dekompoziční přístupy nezvladatelné. Velký důraz je kladen na autokorelační analýzu. Lineární modely ARMA představují nejpropracovanější přístup modelování korelovanosti (Cipra, 2013).

Metodologie vychází z určení závislostí mezi jednotlivými daty. Mezi hlavní modely patří autoregresní proces řádu p – AR (p) a proces klouzavých průměrů reziduální složky řádu q – MA (q). Autoregresní proces (AR) popisuje proces, ve kterém je hodnota časové řady v čase t tvořena lineární kombinací minulých hodnot časové řady a náhodnou veličinou. Proces klouzavých průměrů (Moving Averages) popisuje proces, kdy hodnota

nezávislé veličiny v čase t je tvořena lineární kombinací současné a minulých hodnot náhodné veličiny. Pro odhady parametrů nestačí metoda nejmenších čtverců, používají se speciální odhadové techniky. Box-Jenkins metodologie předpokládá stacionaritu časové řady, případně lze časovou řadu na stacionární převést (Hampel, Blašková a Střelec 2016).

1.6.1 Modely nestacionárních časových řad

Modely nestacionárních časových řad se velmi často vyskytují v ekonomické praxi. Nestacionaritu může způsobovat střední hodnota měnící se v čase, případně rozptýl procesu. Mezi nestacionární procesy patří náhodná procházka (random walk) a procesy ARIMA (Arl a Arltová, 2003).

1.6.2 Modely ARIMA

Model ARIMA je určen pro časové řady se stochastickým trendem, které lze stacionarizovat. Jinými slovy se stacionarizuje časová řada pomocí difference, tato řada se následně modeluje pomocí smíšeného modelu ARMA. Konstrukce modelů Box-Jenkins metodologie se doporučuje provádět ve třech krocích:

- 1) identifikace modelu,
- 2) odhad modelu,
- 3) diagnostika modelu.

Pokud se nepodaří dosáhnout uspokojivých výsledků, potom je nutné všechny tři kroky zopakovat pro jiný model (Cipra, 2013).

1.7 Ekonometrické prognózování a charakteristika předpovědí

Mezi hlavní cíle ekonometrického modelování patří predikce (Hušek, 1999).

Když se řekne předpověď, tak si lidé nejčastěji vybaví odhadování budoucí hodnoty na základě znalosti minulých a přítomných hodnot. Toto pojetí vychází z endogenních hodnot a je typické pro předpovědi v časových řadách nevyužívající informace o vlivu exogenních faktorů, které vystupují jako vysvětlující proměnné a mohou zvýšit účinnost předpovědi (Cipra, 2013).

1.7.1 Klasifikace předpovědí

Kritérií, podle kterých lze členit předpovědi, existuje celá řada. Termín prognóza se většinou používá pro extrapolaci modelu do budoucna, v ekonometrickém pojetí se předpověď také chápe jako extrapolace odhadnutého modelu do minulosti (Hušek, 1999). Konstrukce předpovědí patří mezi důležité úkoly analýzy časových řad. Předpovědi hrají důležitou roli v oblasti financí. Rozhodování se velmi často týká finančních investic či dlouhodobých závazků. U finančních investic rozhodnutí závisí na skutečnostech, které se stanou až v relativně daleké budoucnosti, proto přesnost předpovědí zásadně ovlivňuje užitek z dané investice. Mezi tyto příklady lze dle Cipry (2013) uvést:

- předpověď výnosnosti a rizikovosti investičního portfolia v příštím roce,
- předpověď volatility dluhopisových výnosů pro příštích pět let,
- předpověď zítřejší ceny akciového titulu na burze,
- krátkodobá předpověď korelace mezi americkými a evropskými trhy,
- dlouhodobá předpověď počtu úvěrových defaultů v našich bankách.

1. Bodová a intervalová předpověď

Bodová předpověď označuje odhad budoucí hodnoty časové řady. Může se jednat o bodovou předpověď měnového kurzu v nějaký stanovený okamžik, např. měnový kurz za půl roku 18,9 CZK/USD. Bodová předpověď v sobě vždy zahrnuje určitou chybu, proto je nezbytné konkrétní číslo brát s jistou rezervou.

Intervalová předpověď představuje předpovědní interval, který vyjadřuje analogii intervalu spolehlivosti z matematické statistiky s tím rozdílem, že místo neznámého parametru se odhaduje neznámá (většinou budoucí) hodnota řady. Například 95procentní předpovědní interval zobrazuje dolní a horní mez, mezi kterými bude ležet predikovaná hodnota řady s pravděpodobností 0,95. Pokud byl výše stanoven kurz s 95procentním předpovědním intervalem pro příslušný měnový kurz (18,45; 19,35) CZK/USD, potom tuzemský vývozce nemusí se značnou důvěrou očekávat horší výsledek, než že za jeden dolar obdrží 18,45 Kč. Pro praktické užití jsou pro uživatele zajímavější intervalové než bodové předpovědi (Cipra, 2013).

2. Předpověď ex post a ex ante

Předpovědi ex post vysvětlované proměnné lze získat, pokud je možné stanovit s jistotou hodnoty endogenních i exogenních proměnných. Pokud se porovná hodnota předpovědi ex post se skutečnou hodnotou predikované proměnné, tak podobnost obou hodnot může signalizovat vhodnost modelu k predikci. Předpověď ex ante odhaduje hodnoty vysvětlující a vysvětlované proměnné, tyto proměnné nejsou v době predikce známy. Ex ante je klasickou předpovědí v pravém slova smyslu (Hušek, 1999).

3. Kvantitativní a kvalitativní předpověď

Velmi zjednodušeně řečeno se jedná o stupeň objektivitu při konstrukci předpovědi. Kvantitativní předpovědní metody vytváří předpovědi na základě statistické analýzy naměřených údajů, tj. využitím objektivních matematicko-statistických postupů. To ale určitě neznamena, že tímto postupem dosáhnou nejlepší předpovědní výsledky (tamtéž).

2 PRAKTICKÁ ČÁST

Hlavním cílem praktické části diplomové práce je vytvoření vhodného ekonometrického modelu, který stanoví prognózu vývoje trhu zlata. Prognózy budou vytvořeny pomocí vícerozměrného regresního modelu a lineárního stochastického modelu ARIMA. Hodnoty vysvětlujících proměnných budou do modelu vícerozměrné regrese napředikovány pomocí modelu ARIMA. Zásadní roli ve vytváření modelu hraje statistická, ekonometrická a ekonomická verifikace. Celý proces ekonometrického modelování byl proveden v softwaru Gretl.

2.1 Ekonomická formulace modelu a forma dat

Zlato ovlivňuje velké množství aspektů. Není jednoduché vybrat ty správné. Některé vlivy je nemožné popsat, jiné nelze doložit daty. Není možné kvantifikovat chování lidí, turbulence na burzách, euforii, paniku lidí a nejistotu na finančních trzích. Často také může dojít k přehnané reakci na určitou událost, která má vliv na tržní cenu zlata. Rozhodující je vybrat především podstatné vysvětlující proměnné (regresory), které pomohou namodelovat cenu zlata. Širší výběr vysvětlujících proměnných obsahoval více jak čtyřicet regresorů, přestože je všeobecně známo asi deset vysvětlujících proměnných, které významně ovlivňují tržní cenu zlata. Tento rozsah proměnných měl především zvýšit šance na dosažení vhodného modelu k prognóze tržní ceny zlata. Během procesu modelování se v podstatě potvrdila finanční teorie a vliv nejznámějších determinantů tržní ceny zlata.

2.1.1 Vysvětlující proměnné

Stříbro

Stříbro se řadí mezi nezbytnou komoditu, bez které si ekonometrický model zlata lze jen stěží představit. Toto tvrzení potvrdilo i samotné modelování v ekonometrickém softwaru Gretl. Vztah zlata a stříbra je velmi úzce provázán. Stříbro se vyznačuje vysokou volatilitou. Stříbro nachází uplatnění v průmyslovém odvětví. Pro ekonometrické modelování byla zvolena měsíční frekvence dat. Cena stříbra vychází z měsíčních průměrů denních uzavíracích kurzů London Bullion Market.

S&P 500

Index Standard & Poor's 500 měří vývoj 500 amerických akcí, které vybral tým expertů agentury Standard & Poor's. Tento index je považován za nejpresnější měřítko výkonnosti amerického akciového trhu. Akcie jsou vybírány podle tržní kapitalizace, likvidity, odvětví a dalších faktorů. Jedná se o hodnotově vážený index. Akciové indexy bývají zpravidla záporně korelovány s tržní cenou zlata. Pro ekonometrické modelování byly použity měsíční průměry denních uzavíracích kurzů.

Desetiletý americký státní dluhopis

Úzký vztah se zlatem mají i výnosy amerických státních dluhopisů. Tyto dluhopisy se vyznačují různou dobou splatnosti od několika měsíců až po třicetiletou dobu splatnosti. Úrokové sazby amerických státních dluhopisů určuje Federální rezervní systém. Variant amerických státních dluhopisu bylo v průběhu ekonometrického modelování použito několik, ve většině případů nejlépe vyhovoval modelu desetiletý americký státní dluhopis.

Dolarový index

Dolarový index je obchodně vážený. Index tvoří měny šesti států a země, které platí eurem. Mezi tyto státy patří Spojené království Velké Británie, Japonsko, Kanada, Austrálie, Švýcarsko, Švédsko a eurooblast (eurozóna). Největší váhu má v indexu jednoznačně euro, dále následuje japonský jen a britská libra.

Měnový agregát M2

Měnový agregát M2 obsahuje M1 plus menší termínované vklady s částkami, které jsou nižší než 100 000 dolarů, spořicí vklady, vklady peněžního trhu, podílové listy fondů, které nevlastní institucionální investoři a jednodenní eurodolary. Měnovým agregátem M2 disponují především domácnosti. Měnový agregát působí na vysvětlovanou proměnnou po více období, proto byl do modelu dosazen jako zpožděný. Měnový agregát je sezónně upravený.

Předpokládaný vztah vysvětlujících proměnných dle ekonomické (finanční) teorie

Vysvětlující proměnné se dle teorie vyznačují pozitivním, nebo negativním vztahem k trendu zlata. Předpokládaný vztah shrnuje stručný přehled níže.

- 1) stříbro – pozitivní vztah mezi vysvětlující a vysvětlovanou proměnnou
- 2) index S&P 500 – negativní vztah mezi vysvětlující a vysvětlovanou proměnnou

- 3) desetiletý americký státní dluhopis – pozitivní vztah mezi vysvětlující a vysvětlovanou proměnnou
- 4) dolarový index – negativní vztah mezi vysvětlující a vysvětlovanou proměnnou
- 5) měnový agregát M2 – pozitivní vztah mezi vysvětlující a vysvětlovanou proměnnou

funkční zápis s předpokládanými znaménky koeficientů:

+ - - - +

$$\text{gold} = f(\text{silver}, \text{S\&P 500}, \text{10-year treasury}, \text{dollar index}, \text{M2}_{t-1})$$

2.1.2 Sběr dat

Data jednotlivých proměnných mají měsíční frekvenci pozorování. Rozsah dat začíná lednem 1988 a končí prosincem 2017. Celkový počet pozorování dosahuje 360 hodnot. U vysvětlujících proměnných, které se obchodují na denní bázi, byly zvoleny měsíční průměry denních uzavíracích kurzů.

Většina makroekonomických veličin se zaznamenává v měsíčních intervalech, kratší intervaly se téměř nevyskytují. Hlavním důvodem je finanční a časová náročnost sběru dat. Finanční instrumenty se obchodují vysokofrekvenčně, v jejich případě jsou naprosto běžné časové řady s denní frekvencí záznamu. Jediný měnový agregát M2 se neeviduje na denní bázi. V modelu převažují finanční časové řady nad ekonomickými časovými řadami.

2.1.3 Zdroje dat

Nejdůležitějším zdrojem dat pro ekonometrické modelování je databáze Federální rezervní banky St. Louis. Data zlata a stříbra pocházejí z jiného zdroje než z London Bullion Market Association, jedná se však o měsíční průměry dat Londýnského PM fixu. Názvy proměnných jsou v tabulce uvedeny v anglických ekvivalentech. Tabulky a grafy v ekonometrickém softwaru Gretl obsahují také popisky a názvy v anglickém jazyce.

Tabulka č. 1: Přehled zdrojů dat k proměnným

(Zdroj: Vlastní zpracování)

Proměnná	Zdroj
gold	gold.org
silver	indexmundi.com
S&P 500	finance.yahoo.com
10-year treasury	fred.stlouisfed.org
dollar index	fred.stlouisfed.org
M2	fred.stlouisfed.org


2.2 Statistická a ekonometrická analýza modelu

Před statistickou a ekonometrickou verifikací je vhodné popsat základní charakteristiky a atributy, kterými se vícerozměrný regresní model vyznačuje nebo které musí splňovat.

2.2.1 Ověření stacionarity

Základní charakteristikou nestacionárních časových řad je přítomnost trendu. Předpoklad stacionarity je rozhodující pro ekonometrické modelování. Pokud nejsou časové řady stacionární, pak při modelování hrozí nebezpečí zdánlivé regrese. Většina ekonomických i finančních časových řad se řadí k nestacionárním časovým řadám. Tyto časové řady vykazují trend, který se musí eliminovat. Pro finanční časové řady je typické, že se vyvíjejí stejným směrem. Ověření stacionarity musí být provedeno patřičnými testy. Rozšířený (augmented) Dickey-Fuller test potvrdil u všech vybraných časových řad nestacionaritu. Test KPSS (Kwiatkowski-Phillips-Schmidt-Shin) také zamítl nulovou hypotézu o stacionaritě daných časových řad. KPSS test platí spíše za spolehlivější než Dickey-Fuller test.

Znárodně časové řady nejsou stacionární z důvodu vysoké variability, která podporuje nestacionaritu časových řad. Použití nestacionárních časových řad může vést k problému zdánlivé regrese. V tomto případě je regresní vztah významný jen zdánlivě bez racionální podstaty. Vizuální kontrola také potvrzuje nestacionaritu časových řad.



Obrázek č. 7: Časové řady proměnných

(Zdroj: Vlastní zpracování v softwaru Gretl)


2.2.2 Kointegrace

Kointegrace v podstatě znamená stav dlouhodobé rovnováhy. Zkombinováním jednotlivých časových řad se může dosáhnout eliminace trendu. Testování kointegrace umožňuje odlišit pravou regresi od zdánlivé regrese. Rozšířený ADF a KPSS test potvrdily, že zvolené časové řady vysvětlujících proměnných nejsou v dlouhodobém ekvilibriu. Kointegrace časových řad nenastala.

2.2.3 První difference časových řad

Nestacionární časové řady je nutné převést na stacionární pomocí prvních diferencí. U finančních časových řad většinou stačí použít první difference, poměrně výjimečně se aplikují druhé difference. Všechny časové řady byly po prvních diferencích náležitě otestovány na přítomnost jednotkových kořenů rozšířeným ADF a KPSS testem, které jednoznačně potvrdily stacionaritu. Grafy potvrzují pravidlo, že volatilita má tendenci se

více zvětšovat po poklesu ceny než po jejím nárůstu. Stacionární časové řady zobrazuje obrázek níže.



Obrázek č. 8: Stacionární časové řady proměnných

(Zdroj: Vlastní zpracování v softwaru Gretl)

2.2.4 Funkční forma ekonometrického modelu

Jedinou vyhovující formou proměnných se ukázaly difference přirozených logaritmů. Logaritmická transformace redukuje heteroskedasticitu a šikmost. Exponenciální trend finančních a ekonomických časových řad se převede logaritmováním na trend lineární a zároveň se zredukuje sešikmené rozdělení. Časová řada se zlogaritmováním stabilizuje z hlediska variability. Odlogaritmováním lze získat intervaly v původním modelu. Transformace pomocí difference do určité míry potlačí lineární trend. V reziduální složce nesmí přetrvávat zbytky trendu.

2.2.5 Odhad modelu metodou nejmenších čtverců

Pro použití metody nejmenších čtverců je rozhodující linearita v parametrech a splnění klasických předpokladů metody OLS. Všechny tyto předpoklady byly v ekonometrickém modelu splněny. Ekonometrický software Gretl mohl odhadnout model pomocí metody nejmenších čtverců. Ověření předpokladů lineárního regresního modelu proběhne v následujících částech práce. Znaménka koeficientů potvrdila ekonomickou teorii. Všechny vysvětlující proměnné jsou statisticky významné na 5% hladině významnosti α .

obecný zápis vícerozměrného lineárního regresního modelu

$$\Delta \ln \text{gold} = \beta_0 + \beta_1 \Delta \ln \text{dollar index} + \beta_2 \Delta \ln M2_{t-1} + \beta_3 \Delta \ln \text{S\&P 500} + \beta_4 \Delta \ln \text{treasury 10year} + \beta_5 \Delta \ln \text{silver price} + \varepsilon$$

odhad modelu vícerozměrné regrese

$$\Delta \widehat{\ln \text{gold}} = \hat{\beta}_0 + \hat{\beta}_1 \Delta \ln \text{dollar index} + \hat{\beta}_2 \Delta \ln M2_{t-1} + \hat{\beta}_3 \Delta \ln \text{S\&P 500} + \hat{\beta}_4 \Delta \ln \text{treasury 10year} + \hat{\beta}_5 \Delta \ln \text{silver price} + e$$

$$\Delta \widehat{\ln \text{gold}} = -0,00104345 + (-0,530488) \Delta \ln \text{dollar index} + 0,791395 \Delta \ln M2_{t-1} + (-0,119714) \Delta \ln \text{SP} + (-0,0926581) \Delta \ln \text{treasury 10year} + 0,346696 \Delta \ln \text{silver price} + e$$

Hodnoty parametrů naznačují, že největší vliv na tržní cenu zlata má měnový agregát M2, mezi další vysvětlující proměnné, které zásadním způsobem ovlivňují tržní cenu zlata lze zařadit index dolaru a tržní cenu stříbra. Zbylé dvě proměnné nepůsobí na tržní cenu zlata tak silně jako ty předchozí. Působení jednotlivých regresorů se musí posuzovat za podmínky ceteris paribus.

Obrázek se základním výstupem modelu shrnuje základní charakteristiky modelu.

```

Model 23: OLS, za použití pozorování 1988:03-2017:12 (T = 358)
Závisle proměnná: ld_gold_price
HAC standardní chyby, šířka okénka 5 (Bartlettovo jádro)

      koeficient  směř. chyba  t-podíl  p-hodnota
-----
const      -0,00104345  0,00199637  -0,5227  0,6015
ld_dollar_index  -0,530488  0,0912558  -5,813  1,37e-08 ***
ld_M2adjusted_1   0,791395  0,359296    2,203  0,0283 **
ld_SP_close      -0,119714  0,0353794  -3,384  0,0008 ***
ld_treasury_10ye~ -0,0926581  0,0202550  -4,575  6,62e-06 ***
ld_silver_price    0,346696  0,0336110   10,31  5,68e-022 ***

Střední hodnota závisle proměnné      0,002928
Sm. odchylka závisle proměnné          0,035051
Součet čtverců reziduí                  0,186114
Sm. chyba regrese                        0,022994
Koeficient determinace                   0,575658
Adjustovaný koeficient determinace       0,569630
F(5, 352)                               61,55244
P-hodnota(F)                            5,45e-46
Logaritmus věrohodnosti                  845,6050
Akaikovo kritérium                       -1679,210
Schwarzovo kritérium                     -1655,927
Hannan-Quinnovo kritérium                -1669,950
rho (koeficient autokorelace)             0,090895
Durbin-Watsonova statistika               1,816648

```

Obrázek č. 9: Odhad modelu metodou nejmenších čtverců

(Zdroj: Vlastní zpracování v softwaru Gretl)

2.2.6 Koeficienty determinace

Koeficient determinace R^2 udává, kolik procent proměnlivosti závislé proměnné se modelem podařilo vysvětlit. Hodnota rovna jedné vyjadřuje úplný popis empirických dat regresním modelem. Vzhledem k vyššímu počtu vysvětlujících proměnných je vhodnější používat adjustovaný koeficient determinace. Koeficient determinace R^2 se nikdy nesníží v důsledku přidání nevýznamné proměnné. Koeficient determinace se často udává v procentuálním vyjádření. Ekonometrický model vysvětlil téměř 58 % proměnlivosti tržní ceny zlata. Vzhledem k dlouhé časové řadě a použití lineárního modelu v parametrech lze tuto hodnotu považovat za dostatečnou. Není však možné usuzovat o kvalitě ekonometrického modelu jen na základě koeficientu determinace a korigovaného (adjustovaného) koeficientu determinace.


Tabulka č. 2: Koeficienty determinace

(Zdroj: Vlastní zpracování)

Koeficienty determinace	Hodnota
koeficient determinace	0,575658
adjustovaný koeficient determinace	0,569630

2.2.7 Graf vyrovnaných a skutečných hodnot

Graf vyrovnaných a skutečných hodnot posuzuje, jak vhodně se podařilo proložit hodnoty lineárním modelem. Určité odchylky jsou zřejmé, některé hodnoty se nacházejí relativně daleko od přímky. Hodnoty diferencí přirozených logaritmů určují měřítka jednotlivých OS.



Obrázek č. 10: Graf vyrovnaných a skutečných hodnot

(Zdroj: Vlastní zpracování v softwaru Gretl)

2.2.8 Konfidenční intervaly koeficientů

Konfidenční interval je interval, ve kterém se hodnota neznámého parametru vyskytuje s požadovanou pravděpodobností, kterou si analytik sám určí. Zpravidla se volí hodnota blízká jedné. Obrázek zobrazuje 95% konfidenční interval. Interval je velmi spolehlivý, ale méně přesný. Hodnoty jsou vyčísleny v diferencích přirozených logaritmů.

PROMĚNNÁ	KOEFICIENT	95% KONFIDENČNÍ INTERVAL	
const	-0,00104345	-0,00496975	0,00288285
ld_dollar_index	-0,530488	-0,709963	-0,351012
ld_silver_price	0,346696	0,280592	0,412799
ld_treasury_10y~	-0,0926581	-0,132494	-0,0528220
ld_SP_close	-0,119714	-0,189295	-0,0501321
ld_M2adjusted_1	0,791395	0,0847585	1,49803

Obrázek č. 11: Konfidenční intervaly koeficientů

(Zdroj: Vlastní zpracování v softwaru Gretl)

2.2.9 Analýza rozptylu (ANOVA)

Celkový součet čtverců se rozkládá na vysvětlený součet čtverců regresním lineárním vztahem k tržní ceně zlata a reziduální součet čtverců. Toto rozdělení je patrné i z obrázku níže. Platí rovnice $TSS = RSS + ESS$.

Analýza rozptylu umožňuje výpočet koeficientu determinace, jeho výpočet je také znázorněn na obrázku. Regresní model vysvětlil téměř 58 % proměnlivosti. Zbýlá část, kterou se nepodařilo vysvětlit, zůstala v reziduální části.

Analýza rozptylu:

	Součet čtverců	df	Střední kvadrát
Regrese	0,25248	5	0,0504961
Reziduum	0,186114	352	0,000528734
Úplné	0,438595	357	0,00122856

$$R^2 = 0,25248 / 0,438595 = 0,575658$$


$$F(5, 352) = 0,0504961 / 0,000528734 = 95,5038 \text{ [p-hodnota } 2,35e-063]$$

Obrázek č. 12: Analýza rozptylu

(Zdroj: Vlastní zpracování v softwaru Gretl)

2.2.10 Analýza extrémních hodnot

Pro finanční časové řady jsou typické větší rozdíly mezi nejmenší a největší hodnotou pozorování. Z krabicového grafu lze vyčíst, že extrémní hodnoty se vyskytují. Není jich však mnoho v porovnání s celkovým množstvím hodnot. Datový soubor obsahuje 360 pozorování. Nejvíce extrémních hodnot se vyskytuje v krabicovém grafu stříbra, které je známé svojí vysokou volatilitou. Další vysvětlovaná a vysvětlující proměnná (zlato a desetiletý státní dluhopis) také signalizují několik extrémních hodnot. Zbylé tři vysvětlující proměnné obsahují jen několik extrémních hodnot.



Obrázek č. 13: Analýza extrémních hodnot

(Zdroj: Vlastní zpracování v softwaru Gretl)

2.2.11 Informační kritéria

Informační kritéria se používají jako doplňkový zdroj, který pojednává o kvalitě regresního modelu. Slouží ke srovnání různých specifikací modelu. Volí se model, který vykazuje nejnižší hodnoty informačních kritérií. Hodnoty mají svůj význam především v porovnání s hodnotami ostatních modelů, které aspirují na finální vícerozměrný regresní model.

V tabulce jsou zobrazena informační kritéria dosažená finálním modelem.

Tabulka č. 3: Informační kritéria

(Zdroj: Vlastní zpracování)

Informační kritéria	Hodnota
Akaike	-1679,210
Schwarz (Bayes)	-1655,927
Hannan-Quinn	-1669,950

2.3 Statistická verifikace

Statistická verifikace zahrnuje testování statistické významnosti regresních parametrů prostřednictvím t-testu. F-test testuje statistickou významnost všech regresních koeficientů bez úrovnové konstanty. Dále se mohou aplikovat koeficienty determinace a střední chyby odhadnutých parametrů.

2.3.1 Statistická významnost modelu

U testu byla stanovena 5% hladina významnosti α , která zůstane shodná pro všechny testy hypotéz. Normální rozdělení reziduální složky představuje základní předpoklad použití testu. Rozhodnutí o statistické významnosti modelu bude učiněno na základě p-hodnoty (dosažené hladiny významnosti). Mezi další možnosti patří rozhodování na základě kritického oboru a pomocí intervalu spolehlivosti. Hladina významnosti by měla být klesající dle velikosti datového souboru.

stanovení hypotéz pro F-test:

$H_0: \beta_i = 0$, β_i jsou statisticky nevýznamné koeficienty (simultánně nulové)

$H_1: \beta_i \neq 0$, β_i nejsou statisticky významné koeficienty (simultánně nenulové)

P-hodnota určuje výsledek testu. P-hodnota je nižší než 5% hladina významnosti α , to znamená, že dochází k zamítnutí nulové hypotézy na 5% hladině významnosti α . Ekonometrický model je statisticky významný.

Tabulka č. 4: F-test

(Zdroj: Vlastní zpracování)

F-test	Statistika	P-hodnota
významnost modelu	61,5524	5,45e-46

2.3.2 Statistická významnost parametrů

Testování statistické významnosti parametrů modelu probíhá podobně jako testování významnosti modelu jako celku. Hladina významnosti je určena také na 5% hladině významnosti α . Normální rozdělení reziduální složky je nutnou podmínkou pro použití testu.

stanovení hypotéz pro t-test:

$H_0: \beta_i = 0$, β_i parametr je statisticky nevýznamný (neprůkazný)

$H_1: \beta_i \neq 0$, β_i parametr je statisticky významný (průkazný)

Z tabulky je patrné, že p-hodnoty všech parametrů dosahují hodnot nižších než hladina významnosti α , proto dochází k zamítnutí všech nulových hypotéz o statistické nevýznamnosti parametrů modelu. Všechny parametry jsou statisticky významné.

Tabulka č. 5: T-test

(Zdroj: Vlastní zpracování)

T-test (proměnná)	Koeficient	P-hodnota
$\Delta \ln$ silver price	0,3467	5,68e-022
$\Delta \ln$ treasury 10year	-0,0927	6,62e-06
$\Delta \ln$ SP close	-0,1197	0,0008
$\Delta \ln$ dollar index	-0,5305	1,37e-08
$\Delta \ln$ M2	0,7914	0,0283

2.4 Ekonometrická verifikace

Těžištěm ekonometrické verifikace je ověřování nutných podmínek pro úspěšnou aplikaci ekonometrických metod a testů. Používají se především testy specifikace modelu, testy autokorelace chybového členu, testy heteroskedasticity chybového členu, testy normality chybového členu a vyhodnocuje se stupeň multikolinearity vícerozměrného regresního modelu.

2.4.1 Testy chybné specifikace

Správná specifikace modelu tvoří základ každého kvalitního modelu, je jedním z předpokladů metody nejmenších čtverců. Mezi základní specifikační chyby náleží vynechání důležité vysvětlující proměnné, zahrnutí nepodstatných vysvětlujících proměnných a volba nevhodné funkční formy. Testování specifikace bude provedeno pomocí Ramsey RESET testu a LM (Lagrange multiplier) testu.

stanovení hypotéz Ramsey RESET testu:

H_0 : model vykazuje správnou specifikaci

H_1 : model nevykazuje správnou specifikaci

stanovení hypotéz LM testu:

H_0 : zvolená funkční forma je správná

H_1 : zvolená funkční forma není správná

Výsledky v tabulce potvrzují správnou specifikaci modelu. P-hodnoty všech testů dosahují vyšších hodnot než je stanovená 5% hladina statistické významnosti modelu. Nedochozí k zamítnutí nulových hypotéz. Model je správně specifikovaný.

Tabulka č. 6: Testy specifikace

(Zdroj: Vlastní zpracování)

Testy specifikace	Statistika	P-hodnota
RESET (druhé a třetí mocniny)	0,4136	0,662
RESET (druhé mocniny)	0,2083	0,648
RESET (třetí mocniny)	0,7628	0,383
LM test specifikace	7,2478	0,203

2.4.2 Multikolinearita

Multikolinearita se řadí mezi běžné problémy finančních i ekonomických časových řad. Nejčastější příčinou vzniku multikolinearity je stejná trendová tendence časových řad. Správná volba vysvětlujících proměnných může tomuto problému zcela předejít. Nejjednodušší řešení často bývá nahrazení vysvětlující proměnné jinou proměnnou. V jiných případech lze tolerovat nepatrně vyšší multikolinearitu.

Žádná z vysvětlujících proměnných nesignalizuje výskyt multikolinearity. Hodnoty VIF by musely být vyšší než 10, aby se dalo uvažovat o problému multikolinearity. Další ověření možnosti výskytu multikolinearity nebude použito. VIF nepotvrdil možný výskyt lineární závislosti mezi vysvětlujícími proměnnými. Multikolinearita nepředstavovala v průběhu ekonometrického modelování takový problém jako heteroskedasticita a autokorelace.

Tabulka č. 7: Faktor změny variability (VIF)

(Zdroj: Vlastní zpracování)

Faktor změny variability (VIF)	Hodnota
$\Delta \ln \text{ silver price}$	1,111
$\Delta \ln \text{ treasury 10year}$	1,043
$\Delta \ln \text{ SP close}$	1,066
$\Delta \ln \text{ dollar index}$	1,191
$\Delta \ln \text{ M2}$	1,054


2.4.3 Autokorelace

Sériová korelace (autokorelace) je úzce spjata s daty ve formě časových řad. Ve finančních časových řadách bývají hodnoty determinovány minulými hodnotami. Autokorelace zjednodušeně znamená závislost mezi sousedními rezidui. Tato závislost je pro ekonometrické modelování nežádoucí, chybová složka musí vykazovat nesystematičnost. Pokud hodnoty ACF (autokorelační funkce) nepřekračují toleranční meze, je možné předpokládat, že rezidua mají charakter bílého šumu. Graf autokorelační a parciální autokorelační funkce se zpravidla volí do zpoždění dvanáctého řádu, pokud se používají měsíční časové řady. Důležité je především testování prvního řádu zpoždění DW testem.

Grafická analýza autokorelace reziduí

Korelogram popisuje krátkodobou dynamiku stacionární řady. Chování autokorelační funkce může pomoci určit typ modelu. Parciální autokorelace podávají informaci o korelaci veličin X_t a X_{t-k} očištěnou o vliv veličin ležících mezi nimi.

V grafu parciální autokorelační funkce je patrné porušení toleranční meze druhého řádu. Tento mírný nedostatek zásadním způsobem neovlivňuje kvalitu ekonometrické modelu, proto může být tolerován. Autokorelace byla testována do dvanáctého řádu zpoždění.



Obrázek č. 14: Grafy autokorelačních funkcí

(Zdroj: Vlastní zpracování v softwaru Gretl)

Testování autokorelace pomocí testů

Testování autokorelace pomocí grafického aparátu je nezbytné doplnit testy autokorelace, kterých ekonometrické softwary nabízejí několik. Durbin-Watson test pro testování sériové korelace prvního řádu nebo další tři, které lze v softwaru Gretl nalézt (Breusch-Godfrey, Box-Pierce a Ljung-Box).

Durbin-Watson test nebude aplikován kvůli přítomnosti zpožděné vysvětlující proměnné. DW test ztrácí svojí vypovídací schopnost, pokud je v ekonometrickém modelu zahrnuta zpožděná vysvětlovaná nebo vysvětlující proměnná. DW test se používá jen při testování sériové korelace prvního řádu. Durbin-Watson statistika vyšla po matematickém zaokrouhlení 1,82. Za minimální hodnotu Durbin-Watson statistiky, která splňuje podmínku vhodnosti k predikci, se obvykle považuje hodnota 1,5. Hodnoty Durbin-Watson statistiky závisí na množství pozorování a na počtu regresorů. V ideálním případě by se Durbin-Watson statistika měla co nejvíce blížit hodnotě 2.

stanovení hypotéz:

H_0 : autokorelace (sériová korelace) prvního nebo vyššího řádu se nevyskytuje

H_1 : autokorelace (sériová korelace) prvního nebo vyššího řádu se vyskytuje

Testy autokorelace do dvanáctého řádu zpoždění nepotvrdily výskyt autokorelace. P-hodnoty vybraných testů převyšují stanovenou 5% hladinu významnosti. Ekonometrický model z hlediska sériové korelace splňuje předpoklady pro predikci tržní ceny zlata.

Tabulka č. 8: Testy autokorelace

(Zdroj: Vlastní zpracování)


Testy autokorelace	Statistika	P-hodnota
Breusch-Godfrey	1,0419	0,41
Box-Pierce	12,6974	0,39
Ljung-Box	11,1134	0,52

2.4.4 Heteroskedasticita

Homoskedasticita chybového členu patří mezi základní předpoklady klasického lineárního regresního modelu odhadovaného metodou nejmenších čtverců. Rozptyl reziduální složky musí být v čase konstantní a konečný (homoskedastický). Heteroskedasticita se řadí mezi běžné problémy finančních časových řad, které se vyznačují vyšší cenovou volatilitou. V těchto časových řadách se často vyskytují větší rozdíly mezi nejmenší a největší hodnotou pozorování.

Grafická analýza rozptylu reziduí

Graf reziduí v závislosti na čase potvrzuje vyšší volatilitu reziduí. Graf signalizuje spíše homoskedasticitu než heteroskedasticitu reziduí. Některé extrémní výkyvy jsou zjevné. Za vhodnější a také exaktnější metodu analýzy heteroskedasticity se obecně považuje testování heteroskedasticity patřičnými testy.



Obrázek č. 15: Vývoj reziduí v čase

(Zdroj: Vlastní zpracování v softwaru Gretl)

stanovení hypotéz:

H_0 : heteroskedasticita chybového členu (reziduí) není v modelu přítomna

H_1 : heteroskedasticita chybového členu (reziduí) je v modelu přítomna

Všechny testy potvrdily nulovou hypotézu o výskytu homoskedasticity (konstantního rozptylu reziduální složky). ARCH test podmíněné heteroskedasticity také neprokázal výskyt heteroskedasticity v ekonometrickém modelu. ARCH test se používá při detekci podmíněné heteroskedasticity, kdy rezidua závisí na svých zpožděných hodnotách. Heteroskedasticita byla dále testována White testem, který může odhalit různé formy zvyšujícího se rozptylu reziduí. Zbylé dva testy také nezamítly nulovou hypotézu ve formě konstantního rozptylu reziduální složky. Určitým způsobem k tomuto výsledku přispěla funkční forma modelu, přirozené logaritmy mají schopnost redukovat

heteroskedasticitu. Určitou výhodu v případě testování heteroskedasticity představuje delší časový horizont třiceti let, ve kterém je nižší podíl odlehlých hodnot. Zvyšující se rozptyl reziduální složky by byl více patrný v časové řadě posledních deseti až patnácti let. Toto období v roce 2008 zasáhla finanční krize, která se podepsala na vyšších výkyvech v hodnotách finančních časových řad.

Tabulka č. 9: Testy heteroskedasticity


(Zdroj: Vlastní zpracování)

Testy heteroskedasticity	Statistika	P-hodnota
White	15,8184	0,7278
Breusch-Pagan	9,9168	0,0780
ARCH	7,8171	0,7993
Koenker	2,6579	0,7526

2.4.5 Analýza reziduí

Normalita reziduí se řadí mezi základní předpoklady klasického lineárního regresního modelu. Normalitu reziduí lze často zdůvodnit pomocí centrální limitní věty, která považuje reziduální složku za agregaci většího počtu náhodných jevů.


Histogram reziduí dokumentuje, že rezidua mají normální rozdělení. Pro finanční časové řady je typické rozdělení s vyšší špičkou, jedná se o tzv. leptokurtické rozdělení s vyšší hustotou na svých koncích. V histogramu lze spatřit některá odlehlá pozorování (outliers), která charakterizují průběh finančních časových řad.



Obrázek č. 16: Histogram reziduí

(Zdroj: Vlastní zpracování v softwaru Gretl)

Normalitu reziduální složky je potřeba testovat i dalšími grafickými prostředky. Mezi které patří P-P graf a Q-Q graf. První zmiňovaný ekonometrický software Gretl bohužel nenabízí. Q-Q graf porovnává teoretické a empirické kvantily. Ideálně by rezidua měla ležet na úsečce pod úhlem 45°. Tento předpoklad je až na malé výjimky v podobě odlehlých hodnot splněn. Ve finančních časových řadách se běžně vyskytují odlehlá pozorování, často nazývána jako outliers. Q-Q graf také signalizuje normalitu reziduální složky.



Obrázek č. 17: Q-Q graf reziduí

(Zdroj: Vlastní zpracování v softwaru Gretl)

Normalitu reziduální složky nestačí ověřit jen graficky, musí být ověřena i exaktnějšími postupy ve formě různých testů normality reziduí. Ekonometrické softwary zpravidla obsahují více testů normality ve srovnání s testy ostatních předpokladů klasického lineárního regresního modelu.

stanovení hypotéz:

H_0 : chybový člen má normální rozdělení

H_1 : chybový člen nemá normální rozdělení

Všechny testy normality reziduí zamítly nulovou hypotézu na 5% hladině významnosti. Dle testů rezidua nemají normální rozdělení. Vzhledem k dostatečnému množství pozorování, které zahrnuje 360 hodnot, není nezbytné akceptovat výsledky těchto testů. Testy jsou velmi citlivé na odlehlá pozorování, která dosahují vysokých hodnot. Ve finančních časových řadách se tento problém vyskytuje poměrně často, kdy extrémní reziduum zamítne nulovou hypotézu o normálním rozdělení. Další možností je zdůvodnění předpokladu normality pomocí centrální limitní věty. Z tabulky jsou patrné i velmi rozdílné p-hodnoty jednotlivých testů. Větší množství napozorovaných hodnot se zpravidla více přibližuje normálnímu rozdělení.

Tabulka č. 10: Testy normality reziduí


(Zdroj: Vlastní zpracování)

Testy normality reziduí	Statistika	P-hodnota
Doornik-Hansen	140,923	2,505e-031
Shapiro-Wilk	0,954	3,362e-009
Lilliefors	0,054	0,01
Jarque-Bera	467,658	2,814e-102
Chí-kvadrát	140,923	0,000

2.4.6 Test stability parametrů

Stabilita parametrů modelu se řadí mezi další důležité podmínky, které vypovídají o kvalitě regresního modelu. Pro kvalitní ekonometrický model je nezbytné, aby parametry vykazovaly stabilitu v čase.

Stabilita parametrů ekonometrického modelu se testuje pomocí CUSUM testu. Z grafu vyplývá, že v průběhu času není 95% konfidenční pás překročen. Dle vizuálního posouzení lze usoudit, že parametry ekonometrického modelu jsou v čase stabilní.



Obrázek č. 18: Graf stability parametrů

(Zdroj: Vlastní zpracování v softwaru Gretl)

Testování stability parametrů prostřednictvím testu

Jako u většiny testů se grafická analýza musí doplnit příslušným testem, který pomůže určit případnou shodu s grafickým aparátem. P-hodnota je vyšší než stanovená 5% hladina významnosti, nedochází k zamítnutí nulové hypotézy. Regresní parametry lze považovat za stabilní v čase.

stanovení hypotéz:

H_0 : regresní parametry ekonometrického modelu jsou stabilní

H_1 : regresní parametry ekonometrického modelu nejsou stabilní

Tabulka č. 11: Test stability parametrů

(Zdroj: Vlastní zpracování)

Test stability parametrů	Statistika	P-hodnota
Harvey-Collier	1,8493	0,0653

2.5 Ekonomická verifikace

Ekonomická verifikace ověřuje, zda jsou odhady parametrů v souladu s ekonomickou teorií. Nejdůležitější je ověření správnosti znamének. Znaménka musí být ve shodě s ekonomickou teorií. Všechny parametry rovnice splňují podmínku $\beta_i > 0$.

Ekonomická verifikace parametrů i celého modelu byla potvrzena. Znaménka parametrů potvrdila soulad s ekonomickou teorií. Statistická a ekonometrická verifikace potvrdily kvalitu modelu. Model se ukázal jako vhodný pro finální fázi predikce.

2.6 Prognóza tržní ceny zlata regresním modelem

Ekonometrický software Gretl odhadne tržní cenu zlata za každý měsíc kalendářního roku 2018. Předpověď bude vytvořena bodově i intervalově s 95% spolehlivostí. Aby byl regresní model schopen predikovat tržní cenu zlata, musí mít napredikovány hodnoty vysvětlujících proměnných za měsíce kalendářního roku 2018. K tomuto účelu se aplikoval lineární stochastický model ARIMA.

2.6.1 Výběr modelu ARIMA

U lineárního stochastického modelu ARIMA se musí nejprve určit jeho řád. To platí pro každou z vysvětlujících proměnných. K určení řádu všech vysvětlujících proměnných bylo použito Akaike a Schwarz kritérium. Vybírá se model, který minimalizuje hodnoty těchto kritérií. Tabulka níže dokumentuje finální modely určené pro predikci hodnot vysvětlujících proměnných, které se následně dosadí do vícerozměrného regresního modelu.

Tabulka č. 12: Výběr modelu pro vysvětlující proměnné

(Zdroj: Vlastní zpracování)

Vysvětlující proměnná	Model ARIMA
$\Delta \ln \text{ silver price}$	(1,1,1)
$\Delta \ln \text{ treasury 10year}$	(1,1,1)
$\Delta \ln \text{ SP close}$	(0,1,1)
$\Delta \ln \text{ dollar index}$	(1,1,1)
$\Delta \ln \text{ M2}$	(1,1,1)

2.6.2 Prognóza z regresního modelu

Model ARIMA určil hodnoty vysvětlujících proměnných v hodnotách diferencí přirozených logaritmů. Tyto hodnoty byly následně dosazeny do regresního modelu, který vykázal výsledky v diferencích přirozených logaritmů. Kvůli lepší interpretaci byly hodnoty přepočítány do standardních hodnot vyjádřených v dolarech za unci zlata. Stejným způsobem se postupovalo při určení dolní a horní meze 95% intervalu spolehlivosti. Všechny hodnoty byly matematicky zaokrouhleny. Konečné výsledky dokumentuje tabulka.

Tabulka popisuje rostoucí trend predikce tržní ceny zlata. Průměrné přírůstky za každý měsíc odpovídají přibližně šesti dolarům za unci zlata. Lepších výsledků by bylo dosaženo, pokud by se předpověď průběžně aktualizovala doplněním průměrné hodnoty z předcházejícího měsíce. Prognóza byla ovlivněna nízkým měsíčním průměrem za měsíc prosinec. V toto období se tržní cena zlata pohybovala na relativně nízké úrovni. Průměrná tržní cena zlata se v lednu zvýšila cca o 71 dolarů, v relativním vyjádření se jednalo o přírůstek 5,6 %. Lednová horní mez intervalu spolehlivosti neudržela tento vysoký nárůst. Lze zaznamenat, že 95% interval spolehlivosti není příliš široký.

Tabulka č. 13: Predikce tržní ceny zlata z regresního modelu

(Zdroj: Vlastní zpracování)

Rok 2018	Dolní mez	Bodová předpověď	Horní mez
leden	1207	1262	1321
únor	1214	1266	1330
březen	1220	1271	1335
duben	1225	1276	1341
květen	1230	1282	1346
červen	1235	1287	1352
červenec	1240	1292	1357
srpen	1245	1297	1363
září	1250	1302	1368
říjen	1255	1308	1374
listopad	1260	1313	1379
prosinec	1265	1319	1385


Průměrné měsíční ceny zlata za první čtvrtletí roku 2018 zobrazuje tabulka níže.

Tabulka č. 14: Průměrné měsíční ceny zlata za první čtvrtletí roku 2018

(Zdroj: Vlastní zpracování)

Měsíc	Hodnota
leden	1331
únor	1329
březen	1334

Tabulku s prognózovanými hodnotami doplňuje graf, který potvrzuje vzestupný trend predikce tržní ceny zlata. Z grafu je patrné, že měsíční přírůstky ceny zlata se pohybují téměř v konstantní výši.



Graf č. 1: Predikce tržní ceny zlata z regresního modelu

(Zdroj: Vlastní zpracování)

2.7 Model ARIMA

Předpokladem stochastického modelu ARIMA je slabá stacionarita časových řad. Zlato se vyznačuje stochastickým trendem, proto byl pro předpověď vybrán model ARIMA. V případě modelu ARIMA se hovoří o integrovaném procesu, který se používá na nestacionární časové řady. Základní podmínkou Box-Jenkins metodologie je stacionarita časové řady. Tato metodologie je založena na autokorelační analýze a velmi dobře se adaptuje na změny ve vývoji časových řad, její předností je modelování dlouhých časových řad. Před výběrem modelu je nutné časovou řadu zlogaritmovat (kvůli linearizaci) a následně upravit do stacionární podoby pomocí první difference. U většiny ekonomických nebo finančních časových řad stačí použít první difference.

Základní časová řada vývoje trhu zlata je nestacionární. Ověření stacionarity proběhlo v předchozí části práce pomocí rozšířeného Dickey-Fuller a KPSS testu. U těchto dvou testů je nutné být opatrný, nulové hypotézy testů vyjadřují opak. Rozšířený Dickey-Fuller test volí nulovou hypotézu v podobě existence jednotkového kořene, naproti tomu KPSS test považuje přítomnost stacionarity za nulovou hypotézu. U prvního zmiňovaného testu musí být nulová hypotéza zamítnuta, u KPSS testu nesmí být nulová hypotéza zamítnuta.

Model ARIMA byl řešen Box-Jenkins metodou ve třech krocích:

- 1) identifikace a výběr řádu modelu,
- 2) odhad koeficientů metodou maximální věrohodnosti,
- 3) testování modelu – stacionarity, autokorelace, heteroskedasticity a normality reziduí.

2.7.1 Výběr modelu ARIMA

Správná volba modelu ARIMA může být obtížnou záležitostí. Nejspolehlivější postup při výběru modelu představuje výběr na základě nejnižších informačních kritérií. Další možností je výběr modelu dle průběhu autokorelační (ACF) a parciální autokorelační funkce (PACF). Tento postup představuje subjektivní výběr a nemusí být vždy správný. Volba pomocí informačních kritérií vyloučí subjektivní zásah analytika. Aplikují se Akaike a Schwarz (Bayes) kritéria.

Z tabulky je zřejmé, že nejnižších informačních kritérií (Akaike i Bayes) dosahuje model o řádech (1,1,1). Tento model je tedy nejvhodnější pro predikci tržní ceny zlata. Bayes kritérium je v softwaru Gretl označeno jako Schwarz kritérium. Hannan-Quinn kritérium bylo při výběru modelu vynecháno.

Tabulka č. 15: Výběr modelu ARIMA

(Zdroj: Vlastní zpracování)

Model	Akaike kritérium	Model	Bayes kritérium
(0,1,0)	-1182,456	(0,1,0)	-1174,695
(1,1,0)	-1235,568	(1,1,0)	-1227,813
(0,1,1)	-1353,159	(0,1,1)	-1341,517
(1,1,1)	-1376,746	(1,1,1)	-1361,224

2.7.2 Odhad koeficientů modelu ARIMA

K odhadu parametrů modelu ARIMA byla použita metoda maximální věrohodnosti. Charakteristiky modelu popisuje obrázek níže.

```

Vyhodnocování funkce: 90
Vyhodnocování gradientu: 15

Model 26: ARIMA, za použití pozorování 1988:03-2017:12 (T = 358)
Odhad proveden pomocí Kalmanova filtru (přesné ML)
Závisle proměnná: (1-L) ld_gold_price
Směrodatné chyby založené na Hessiánu

```

	koeficient	směr. chyba	z	p-hodnota	
const	2,37182e-05	6,20474e-05	0,3823	0,7023	
phi_1	0,107350	0,0549545	1,953	0,0508	*
theta_1	-0,973131	0,0151579	-64,20	0,0000	***

```

Střední hodnota závisle proměnné 0,000164
Sm. odchylka závisle proměnné 0,046208
Střední hodnota inovací 0,000790
Sm. odchylka inovací 0,034848
Logaritmus věrohodnosti 692,3731
Akaikeovo kritérium -1376,746
Schwarzovo kritérium -1361,224
Hannan-Quinnovo kritérium -1370,573
zde je poznámka o zkratkách statistik modelu

```

		Reálná	Imaginární	Abs. hodnota	Frekvence
AR					
Kořen	1	9,3153	0,0000	9,3153	0,0000
MA					
Kořen	1	1,0276	0,0000	1,0276	0,0000

Obrázek č. 19: Odhad modelu ARIMA


(Zdroj: Vlastní zpracování v softwaru Gretl)

2.7.3 Diagnostika modelu ARIMA

Model ARIMA bude diagnostikován z hlediska normality, heteroskedasticity a autokorelace reziduí. Stacionarita reziduí byla potvrzena již dříve Dickey-Fuller a KPSS testem.

Normalita

V modelu ARIMA je patrná vyšší špička normálního rozdělení. Vyšší špička patří mezi typické znaky leptokurtického rozdělení. Dalším charakteristickým znakem jsou odlehlá pozorování (outliers), která často patří mezi hlavní příčiny nenormality. V histogramu se nevyskytuje velké množství odlehlých pozorování, proto je možné normalitu připustit. Dostatečně velké množství pozorování potvrzuje normalitu reziduální složky. Asymptotická normalita je zaručena centrální limitní větou, kdy reziduální složka je výsledkem velkého množství náhodných vlivů. Histogram modelu ARIMA se podobá histogramu vícerozměrné regrese.




Obrázek č. 20: Histogram reziduí

(Zdroj: Vlastní zpracování v softwaru Gretl)

Normalitu reziduální složky se doporučuje testovat i dalšími grafickými nástroji. Mezi tyto nástroje patří P-P graf a Q-Q graf. Q-Q graf porovnává teoretické a empirické kvantily. Ideálně by rezidua měla ležet na úsečce pod úhlem 45° . Tato podmínka je až na několik výjimek v podobě odlehklých hodnot splněna. Ve finančních časových řadách se běžně vyskytují odlehlá pozorování, často nazývána jako outliers. Dle Q-Q grafu lze také usoudit na normalitu reziduální složky. V porovnání s vícerozměrným regresním modelem rezidua více přiléhají k úsečce.

Testování normality Chí-kvadrát testem spolu s testy heteroskedasticity a autokorelace je umístěno v samostatné podkapitole. Podkapitola se nachází za grafickou analýzou normality, heteroskedasticity a sériové korelace (autokorelace).



Obrázek č. 21: Q-Q graf reziduí


(Zdroj: Vlastní zpracování v softwaru Gretl)

Heteroskedasticita modelu ARIMA

Výskyt heteroskedasticity je porušením základního předpokladu klasického lineárního regresního modelu. Heteroskedasticita značí zvětšující se rozptyl reziduí v čase. Grafy reziduí v tomto případě mívají podobu trychtýře. Heteroskedasticita se často vyskytuje u finančních časových řad, které se vyznačují vysokou volatilitou. V těchto časových řadách jsou často k vidění větší rozdíly mezi nejmenší a největší hodnotou pozorování.

Grafická analýza rozptylu reziduí

Graf reziduí v závislosti na čase signalizuje vyšší volatilitu reziduí. Graf naznačuje spíš homoskedasticitu než heteroskedasticitu reziduální složky. V porovnání s regresním modelem se nevyskytují extrémní výkyvy v hodnotách reziduí. Za vhodnější a také exaktnější metodu analýzy heteroskedasticity se obecně považuje testování rozptylu reziduální složky adekvátními testy. Heteroskedasticita bude testována ARCH testem v další části práce (po grafické analýze autokorelace).




Obrázek č. 22: Vývoj reziduí v čase

(Zdroj: Vlastní zpracování v softwaru Gretl)

Autokorelace modelu ARIMA

Sériová korelace (autokorelace) úzce souvisí s daty ve formě časové řady. Ve finančních časových řadách závisí aktuální hodnoty na minulých hodnotách. Graf autokorelační a parciální autokorelační funkce byl vytvořen do dvanáctého řádu zpoždění. Nejvýznamnější je první řád zpoždění, který se obvykle testuje DW testem.

V grafu parciální autokorelační funkce je patrné zpoždění jedenáctého řádu. Tento nedostatek zásadním způsobem neovlivňuje kvalitu modelu ARIMA.



Obrázek č. 23: Grafy autokorelačních funkcí

(Zdroj: Vlastní zpracování v softwaru Gretl)

Testování autokorelace, heteroskedasticity a normality reziduí

Model ARIMA musí být testován exaktnějšími metodami, než které poskytuje grafická analýza. Grafická analýza je založena na subjektivním odhadu analytika. Testování bylo provedeno pomocí testu Ljung-Box (autokorelace), ARCH testu (podmíněná heteroskedasticita) a Chí-kvadrát testu dobré shody (normalita). Řád zpoždění pro ARCH test odpovídá dvanáctému řádu zpoždění. Zvolená hladina významnosti má hodnotu 5 %.

stanovení hypotéz pro test autokorelace:

H_0 : autokorelace se nevyskytuje

H_1 : v reziduální složce se vyskytuje autokorelace

stanovení hypotéz pro test podmíněné heteroskedasticity: H_0 : homoskedasticita chybového členu H_1 : heteroskedasticita chybového členu**stanovení hypotéz pro test normality:** H_0 : rezidua mají normální rozdělení H_1 : rezidua nemají normální rozdělení

Ljung-Box test nezamítl nulovou hypotézu o neexistenci autokorelace. ARCH test podmíněné heteroskedasticity neprokázal existenci zvyšujícího se rozptylu reziduální složky. Jediný Chí-kvadrát test dobré shody zamítl nulovou hypotézu o normalitě reziduí. Důvodem byla vysoká citlivost testu na odlehlá pozorování (outliers). Přes tento mírný nedostatek byla normalita reziduální složky doložena grafickým aparátem a teoretickým podkladem.


Tabulka č. 16: Test autokorelace, heteroskedasticity a normality reziduí

(Zdroj: Vlastní zpracování)

Autokorelace, heteroskedasticita, normalita	Statistika	P-hodnota
Ljung-Box (autokorelace)	14,4469	0,1536
ARCH (heteroskedasticita)	19,7954	0,0711
Chí-kvadrát (normalita reziduí)	47,4150	0,0000

Graf vyrovnaných a skutečných hodnot v závislosti na čase

Graf porovnává skutečnou a vyrovnanou tržní cenu zlata v závislosti na čase. Hodnoty diferencí přirozených logaritmů určují měřítko vertikální osy. Je zřetelná vysoká volatilita tržní ceny zlata, kterou se lineárním stochastickému modelu ARIMA nepodařilo vhodně aproximovat. Tento graf potvrzuje pověst modelu ARIMA, že hůře reaguje na vyšší cenové výkyvy oproti modelům podmíněné heteroskedasticity GARCH.




Obrázek č. 24: Graf vyrovnané a skutečné ceny zlata v čase

(Zdroj: Vlastní zpracování v softwaru Gretl)

Graf vyrovnaných a skutečných hodnot

Graf vyrovnaných a skutečných hodnot zobrazuje aproximaci hodnot lineárním stochastickým modelem ARIMA. Reziduální složka nesmí mít systematický průběh. Hodnoty diferencí přirozených logaritmů určují měřítka jednotlivých os. V časové řadě zlata se rezidua vyskytují ve shlucích. Tento jev je charakteristický pro finanční časové řady.



Obrázek č. 25: Graf vyrovnaných a skutečných hodnot

(Zdroj: Vlastní zpracování)

2.8 Prognóza tržní ceny zlata z modelu ARIMA

Lineární stochastický model ARIMA určil predikční hodnoty v diferencích přirozených logaritmu. Kvůli lepší interpretaci byly hodnoty přepočítány do standardních hodnot vyjádřených v dolarech za unci zlata. Stejným způsobem se postupovalo při určení dolní a horní meze 95% intervalu spolehlivosti. Všechny hodnoty byly matematicky zaokrouhleny. Konečné výsledky dokumentuje tabulka.


Tabulka znázorňuje rostoucí trend zlata. Průměrný měsíční nárůst ceny zlata odpovídá přibližně třem dolarům za unci zlata. Lepších výsledků by bylo dosaženo, pokud by se předpověď průběžně aktualizovala doplněním průměrné hodnoty z předcházejícího měsíce. Prognóza byla ovlivněna nízkým měsíčním průměrem za měsíc prosinec. V toto období se cena tržního zlata pohybovala na relativně nízké úrovni. Lze zaznamenat, že 95% interval spolehlivosti je širší než u regresního modelu. Dolní mez intervalu spolehlivosti dosahuje nižší hodnoty v porovnání s regresním modelem. Rozdíly horních mezí regresního modelu a stochastického modelu ARIMA jsou naproti tomu minimální. Měsíční ceny zlata za první čtvrtletí roku 2018 jsou uvedeny v tabulce u prognózy vícerozměrného regresního modelu. Podle těchto měsíčních hodnot nedošlo u modelu ARIMA k překročení horní meze.

Tabulka č. 17: Predikce tržní ceny zlata z modelu ARIMA

(Zdroj: Vlastní zpracování)

Rok 2018	Dolní mez	Bodová předpověď	Horní mez
leden	1178	1261	1350
únor	1181	1263	1355
březen	1183	1266	1358
duben	1185	1268	1361
květen	1187	1270	1363
červen	1190	1272	1366
červenec	1192	1275	1368
srpen	1194	1277	1371
září	1196	1279	1374
říjen	1199	1282	1376
listopad	1201	1284	1379
prosinec	1203	1287	1382

Tabulku s prognózovanými hodnotami doplňuje graf, který zachycuje mírně vzestupný trend prognózy tržní ceny zlata. Z grafu lze odhadnout, že měsíční přírůstky ceny zlata se pohybují přibližně v konstantní výši tři dolarů za unci zlata.




Graf č. 2: Predikce tržní ceny zlata z modelu ARIMA

(Zdroj: Vlastní zpracování)

2.9 Komparace regresního modelu a modelu ARIMA

Graf znázorňuje srovnání napředikovaných hodnot vícerozměrného regresního modelu a lineárně stochastického modelu ARIMA. Z porovnání obou modelů lze vypožorovat, že trend předpovědi regresního modelu roste přibližně dvakrát rychleji než rostoucí trend modelu ARIMA. Prognózy obou modelů rostou mírným tempem. Ani jednomu z modelů se nepodařilo adekvátně vypořádat s vyšší cenovou volatilitou zlata. Zlato obvykle zaznamenává vyšší měsíční přírůstky, než predikuje model regrese a model ARIMA. Tyto přírůstky však bývají vyváženy určitými poklesy, které mohou být i většího rázu. Potom záleží na spoustě okolností, které určí vzájemné kompenzace přírůstků a poklesů. Determinanty ceny zlata se obtížně předpovídají. Aktuálnímu vývoji tržní ceny zlata lépe odpovídá bodová předpověď vícerozměrného regresního modelu. Prognózy obou modelů doporučují nákup zlata. Důvodem je predikovaný rostoucí trend tržní ceny zlata.



Graf č. 3: Srovnání bodové predikce regresního modelu a ARIMA modelu

(Zdroj: Vlastní zpracování)

3 VYHODNOCENÍ PRAKTICKÉ ČÁSTI

V praktické části byl vytvořen model vícerozměrné regrese a model ARIMA. U **regresního modelu** se vybralo pět vysvětlujících proměnných, které mají dle teorie vliv na cenu zlata. Data těchto proměnných byla následně stacionarizována pomocí prvních diferencí. Model vícerozměrné regrese vysvětlil téměř 58 % proměnlivosti tržní ceny zlata, zbylá část zůstala v reziduální části. Problém představoval výskyt extrémních hodnot některých proměnných. Pro finanční časové řady je vysoká volatilita a výskyt extrémních hodnot běžnou součástí jejich průběhu. Statistická verifikace potvrdila významnost celého modelu i všech parametrů. Klíčovou fází ekonometrického modelování představovala ekonometrická verifikace. Fáze ekonometrické verifikace se neobešla bez komplikací. To je v ekonometrické praxi obvyklé. Jedinou vhodnou formou se ukázala lineární funkce v parametrech a s diferencemi přirozených logaritmů v proměnných. Normalita reziduí byla potvrzena graficky. Testy normality ukazovaly na nenormalitu. Testy jsou citlivé na odlehle hodnoty (outliers). Normalita byla zdůvodněna pomocí centrální limitní věty. Faktor změny variability (VIF) nepotvrdil možný výskyt multikolinearity. Multikolinearitě lze předejít vhodnou volbou vysvětlujících proměnných. Nepatrná autokorelace se vyskytovala jen ve druhém řádu zpoždění. Žádný z testů nepotvrdil výskyt autokorelace. Heteroskedasticita představovala největší problém ekonometrické verifikace. Testy finálního modelu neprokázaly výskyt heteroskedasticity. Logaritmická forma regresního modelu přispěla ke snížení heteroskedasticity. Adekvátní výběr regresorů může zvyšujícímu se rozptylu reziduí předejít. CUSUM test nezamítl nulovou hypotézu o stabilitě parametrů regresního modelu. Regresní model byl úspěšně verifikován. K odhadnutí hodnot vysvětlujících proměnných regresního modelu byl použit model ARIMA. Následně regresní model napredikoval bodovou a intervalovou předpověď tržní ceny zlata. Prognóza tržní ceny zlata má vzestupný trend, každý měsíc roste cena unce zlata přibližně o šest dolarů. Čas vyhodnotí výsledek predikce. Za měsíc leden měsíční průměr ceny zlata přesáhl horní mez intervalu spolehlivosti regresního modelu jen o několik jednotek uncí. Za měsíc únor a březen nebyla horní mez intervalu porušena. Nízká prosincová hodnota tržní ceny zlata pokračovala v lednu velkým nárůstem v přibližné hodnotě 71 dolarů za unci zlata. Na tento nárůst regresní model nezareagoval dostatečně vysokou bodovou a intervalovou předpovědí. Respektive horní

mez předpovědního intervalu nebyla dost vysoká, aby tento nárůst zastavila. Model podmíněné heteroskedasticity GARCH by pravděpodobně zareagoval na tuto situaci lépe.

Model ARIMA vyžaduje stacionaritu časových řad. Stacionarita časové řady zlata byla ověřena patřičnými testy. Následně nejnižší Akaike a Schwarz kritéria doporučila vhodný model. U tohoto modelu byly dále odhadnuty koeficienty a provedena diagnostika. Grafická analýza normality reziduí pomocí histogramu a Q-Q grafu signalizovala normalitu, Chí-kvadrát test dobré shody však nulovou hypotézu o existenci normality zamítl. V tomto případě byla normalita připsána ze stejných důvodů jako u regresního modelu. Grafická analýza heteroskedasticity naznačovala, že by se mohlo jednat o homoskedasticitu reziduí. ARCH test nezamítl nulovou hypotézu o homoskedasticitě reziduí. Graf autokorelační a parciální autokorelační funkce identifikoval překročení toleranční meze u jedenáctého řádu zpoždění. Ljung-Box test nezamítl nulovou hypotézu o neexistenci autokorelace, proto lze usuzovat, že v modelu se nevyskytuje autokorelace. Model ARIMA napredikoval bodovou a intervalovou předpověď tržní ceny zlata. Cena zlata roste přibližně tři dolary za unci měsíčně. Tyto přírůstky jsou oproti modelu vícerozměrné regrese přibližně poloviční. Trend však zůstává rostoucí. Ani modelu ARIMA se nepodařilo dostatečně zareagovat na lednový nárůst tržní ceny zlata. Ve srovnání s regresním modelem nedošlo během prvního čtvrtletí k překročení horní hranice intervalu spolehlivosti.

Srovnání predikční schopnosti modelu ARIMA a modelu vícerozměrné regrese vyšlo z hlediska bodové předpovědi lépe pro model vícerozměrné regrese. Aktuální měsíční průměry tržní ceny zlata se více blíží bodové předpovědi regresního modelu. Intervalová předpověď modelu ARIMA lépe odpovídá aktuální tržní ceně zlata. Toto hodnocení je platné pouze pro první čtvrtletí roku 2018. Výsledky prognózy tržní ceny zlata doporučily nákup zlata. Důvodem byl predikovaný rostoucí trend tržní ceny zlata.

4 NÁVRHY NA ZLEPŠENÍ

Model vícerozměrné regrese by mohl být doplněn o jednu až dvě vysvětlující proměnné, které by pomohly zlepšit koeficient determinace a další charakteristiky modelu. Během procesu ekonometrického modelování nebyla další vhodná proměnná nalezena. Výnos amerických korporátních dluhopisů ratingu Baa (rating B u jiných agentur) představoval vhodnou proměnnou ze statistického pohledu, mírně ale zhoršoval ekonometrickou stránku modelu. Tato vysvětlující proměnná nebyla použita. Dalšími možnostmi zdokonalení modelu mohou být například:

- sestavení pozměněného modelu,
- volba jiné délky časové řady,
- volba různé frekvence pozorování,
- vytvoření nového modelu s odlišnými regresory,
- modelování strukturálního zlomu.

Do modelu ARIMA není možné tolik zasahovat na rozdíl od modelu vícerozměrné regrese. Regresní model lze ovlivnit podstatně více než model ARIMA. Určitou možnost by představovala změna délky časové řady nebo frekvence pozorování.

Pro účely predikce se jeví vhodnější aktualizovat měsíční hodnoty závislé proměnné. Tímto způsobem lze lépe reagovat na větší výkyvy tržní ceny zlata. Pravděpodobně lepších výsledků by bylo dosaženo použitím modelu podmíněné heteroskedasticity GARCH. Modely GARCH umí lépe zachytit nejistotu na finančních trzích v podobě vysoké volatility. Modely ARIMA a vícerozměrné regrese nedisponují tak dobrými předpoklady pro modelování volatility jako modely typu GARCH. Otazníkem zůstává použití nelineárního regresního modelu tržní ceny zlata. Za zkoušku by stála i prognóza pomocí procesu náhodné procházky (random walk process).

.

ZÁVĚR

Hlavním cílem diplomové práce bylo vytvoření ekonometrického modelu k prognóze tržní ceny zlata. Vícerozměrný regresní model se podařilo sestavit a úspěšně verifikovat. Model byl následně použit k prognóze tržní ceny zlata. Dále byl vytvořen a verifikován model ARIMA, který napredikoval tržní cenu zlata. Výsledky prognózy tržní ceny zlata doporučily nákup zlata. Důvodem byl predikovaný rostoucí trend tržní ceny zlata. Čas ukáže, zda vývoj tržní ceny zlata potvrdí vykázané výsledky obou modelů. Po třech měsících není příliš vhodné hodnotit výsledky prognózy.

První kapitola se zabývala teoretickými východisky, ve kterých byly představeny základní informace o zlatě, oblasti ekonometrie a statistiky. V ekonometrické části byl stručně popsán proces vytváření ekonometrického modelu a problémy, které se běžné vyskytují při tvorbě modelu vícerozměrné regrese. Poslední část teoretických východisek se věnovala modelu ARIMA a charakteristice předpovědi.

Druhá kapitola se zabývala praktickou stránkou modelování vícerozměrného regresního modelu a vytvářením ARIMA modelů. Větší úsek praktické části obsahovala formulace regresního modelu, statistická a především ekonometrická verifikace regresního modelu. Obsahově menší prostor byl vyčleněn diagnostice modelu ARIMA. Poslední část praktické části byla určena pro predikci modelů a následnou komparaci předpovědí.

Předposlední kapitola vyhodnotila výsledky praktické části.

Poslední kapitola představila návrhy na zlepšení.

Zlato se řadí mezi komodity, které se vyznačují relativně vysokou volatilitou a nelineárně-stochastickým trendem časové řady. Vysoká volatilita (variabilita) se projevuje v heteroskedasticitě reziduí. Autokorelace může být také problémem. Finanční i ekonomická data se mohou vyznačovat autokorelací i po dlouhá časová období. V modelu vícerozměrné regrese a modelu ARIMA je rozhodující, aby všechny časové řady vykazovaly slabou stacionaritu. Bez tohoto předpokladu by mohlo dojít k problému zdánlivé regrese. Při modelování tržní ceny zlata je rozhodující zaměřit pozornost na heteroskedasticitu, autokorelaci, specifikaci modelu a normalitu reziduí. Vývoj tržní ceny zlata nejvíce odpovídá modelu náhodné procházky.

Mnohdy existuje několik akceptovatelných modelů, často bývá lepší spokojit se s nižší hodnotou koeficientu determinace. Model, který má vysoký koeficient determinace, může dosahovat horších výsledků v ekonometrické verifikaci. V některých případech není volba modelu snadná, pak je možné použít informační kritéria. U testů může hrát roli, jak silně (slabě) je daná hypotéza zamítnuta (potvrzena). Některé testy jsou považovány za velmi citlivé.

Důležité je mít na paměti, že některé determinanty ceny zlata se nedají kvantifikovat a předpovídat. Typickým příkladem je chování lidí, které způsobuje na burze časté výkyvy, které bývají spojeny s nejistotou, panikou, eufórií, podceněním či přeceněním reakce na určitou událost. Velmi dobrý model po statistické i ekonometrické stránce může vykazovat horší predikční schopnosti než model, který neprošel statistickou a ekonometrickou verifikací. Primárním zdrojem chyb predikce je výskyt reziduální složky. Ekonometrické modelování provází mnohá úskalí, ve kterých často rozhoduje zkušenost, odhad a intuice analytika. Některé subjektivní vlivy nelze potlačit.

Další možností modelování a predikce tržní ceny zlata může být využití modelu podmíněné heteroskedasticity GARCH, případně regresního modelu nelineárního v parametrech. Nelineární modely by měly poskytnout lepší výsledky, čelí však problémům technického rázu. Zásadní roli hraje volba délky časové řady. Časové řady se mohou velmi lišit variabilitou a autokorelační strukturou. Důležité je upozornit na fakt, že s delší časovou řadou se mění charakteristiky modelu a konstrukce adekvátního lineárního modelu se může stát velmi obtížnou úlohou. Ekonometrické modelování je v podstatě o posuzování většího počtu kritérií, na která neexistují objektivní měřítka.

SEZNAM POUŽITÝCH ZDROJŮ

- ARLT, Josef a Markéta ARLTOVÁ, 2007. *Ekonomické časové řady: [vlastnosti, metody modelování, příklady a aplikace]*. Praha: Grada. ISBN 978-80-247-1319-9.
- ARLT, Josef a Markéta ARLTOVÁ, 2003. *Finanční časové řady: [vlastnosti, metody modelování, příklady a aplikace]*. Praha: Grada. ISBN 80-247-0330-0.
- BOCKER, Hans J, 2009. *Svoboda jménem zlato: vzpoura ve světě papírových peněz*. Praha: Austria Gold CZ. ISBN 978-80-254-4979-0.
- BROOKS, Chris, 2014. *Introductory econometrics for finance*. Third edition. Cambridge: Cambridge University Press. ISBN 978-1107661455.
- CIPRA, Tomáš, 2013. *Finanční ekonometrie*. 2., upr. vyd. Praha: Ekopress. ISBN 978-80-86929-93-4.
- GUJARATI, D.N. & PORTER, D.C., c2009. *Basic econometrics* 5th ed., Boston: McGraw-Hill Irwin. ISBN 978-0-07-127625-2.
- HAMPEL, David, Veronika BLAŠKOVÁ a Luboš STŘELEČEK, 2016. *Ekonometrie 2*. Třetí přepracované vydání. V Brně: Mendelova univerzita. ISBN 978-80-7509-427-8.
- HANČLOVÁ, Jana, 2012. *Ekonometrické modelování: klasické přístupy s aplikacemi*. Praha: Professional Publishing. ISBN 978-80-7431-088-1.
- HILL Carter R., GRIFFITHS William E. a LIM Guay C., 2011. *Principles of econometrics*. 4th ed. Hoboken, NJ: Wiley. ISBN 978-0-471-72360-8.
- HUŠEK, Roman, 1999. *Ekonometrická analýza*. Praha: Ekopress. ISBN 80-86119-19 X.
- HUŠEK, Roman, 2007. *Ekonometrická analýza*. Praha: Oeconomica. ISBN 978-80-245-1300-3.
- MALONEY, Michael, c2010. *Investujte do zlata a stříbra: všechno, co potřebujete vědět o drahých kovech*. Hodkovičky [Praha]: Pragma. Poradci bohatého táty. ISBN 978-80-7349-156-7.
- MELLON, Jim a CHALABI Al, 2008. *10 nejlepších investic na příštích 10 let: [spořte, investujte, prosperujte]*. Brno: Computer Press. ISBN 978-80-251-2144-3.

- MEZNÍK, Ivan, 2003. *Ekonometrie: pro magisterské studijní programy*. Vyd. 3. Brno: Zdeněk Novotný. Učební texty vysokých škol. ISBN 80-214-2453-2.
- REJNUŠ, Oldřich, 2014. *Finanční trhy*. 4., aktualiz. a rozš. vyd. Praha: Grada. Partners. ISBN 978-80-247-3671-6.
- ROGERS, Jim, 2008. *Žhavé komodity: jak může kdokoli investovat se ziskem na světových trzích*. Praha: Grada. Investice. ISBN 978-80-247-2342-6.
- STOCK James H., Harvard UNIVERSITY, WATSON Mark W. and Princeton UNIVERSITY, 2015. *Introduction to econometrics*. Third edition update. Boston: Pearson. ISBN 9780133486872.
- STUDENMUND A. H., 2014. *Using econometrics: a practical guide*. 6th ed., Pearson new international ed. Harlow: Pearson. ISBN 1292021276.
- VESELÁ, Jitka, 2011. *Investování na kapitálových trzích*. 2., aktualiz. vyd. Praha: Wolters Kluwer Česká republika. ISBN 978-80-7357-647-9.
- WOOLDRIDGE, Jeffrey M., 2006. *Introductory Econometrics: a modern approach*. 1st ed. Mason: Thomson/South-Western. ISBN 0-324-28978-2.
- WOOLDRIDGE Jeffrey M., 2012. *Introductory econometrics: a modern approach*. 5th ed. Mason, Ohio: South-Western Cengage Learning. ISBN 9781111531041.
- Celticgold AG, 2018. Vienna Philharmonic 1oz Gold Coin different years. Celticgold.eu [online]. © 2018 [cit. -01-20]. Dostupné z: <https://www.celticgold.eu/en/vienna-philharmonic-1oz-gold-coin.html>
- Federal reserve bank of St. Louis, 2018. 10-Year Treasury Constant Maturity Rate. Fred.stlouisfed.org [online]. © 2018 [cit. 2018-02-08]. Dostupné z: <https://fred.stlouisfed.org/series/DGS10>
- Federal reserve bank of St. Louis, 2018. M2 Money Stock. Fred.stlouisfed.org [online]. © 2018 [cit. 2018-02-11]. Dostupné z: <https://fred.stlouisfed.org/series/M2SL>

Federal reserve bank of St. Louis, 2018. Trade Weighted U.S. Dollar index: Major Currencies. Fred.stlouisfed.org [online]. © 2018 [cit. 2018-02-06]. Dostupné z: <https://fred.stlouisfed.org/series/TWEXMMTH>

Finance.yahoo, 2018. S&P 500 real time price, currency in USD. Finance.yahoo.com [online]. © 2018 [cit. 2018-02-05]. Dostupné z: <https://finance.yahoo.com/quote/%5EGSPC/history?period1=-313635600&period2=1516748400&interval=1mo&filter=history&frequency=1mo>

Indxmundi, 2018. Silver Monthly Price – US Dollars per Troy Ounce. Indxmundi.com [online]. © 2018 [cit. 2018-02-03]. Dostupné z: <https://www.indxmundi.com/commodities/?commodity=silver&months=360>

World gold council, 2018. Gold price in a range of currencies since December 1978. Gold.org [online]. © 2018 [cit. 2018-01-19]. Dostupné z: <https://www.gold.org/research/download-the-gold-price-since-1978>

World gold council, 2018. Short-run and long-run determinants of the price of gold. Gold.org [online]. © 2018 [cit. 2018-01-13]. Dostupné z: <https://www.gold.org/research/short-run-and-long-run-determinants-price-gold>

SEZNAM TABULEK, OBRÁZKŮ, GRAFŮ A ROVNIC

Seznam tabulek:

Tabulka č. 1: Přehled zdrojů dat k proměnným.....	40
Tabulka č. 2: Koeficienty determinace	45
Tabulka č. 3: Informační kritéria	48
Tabulka č. 4: F-test	48
Tabulka č. 5: T-test	49
Tabulka č. 6: Testy specifikace.....	50
Tabulka č. 7: Faktor změny variability (VIF).....	51
Tabulka č. 8: Testy autokorelace	53
Tabulka č. 9: Testy heteroskedasticity.....	55
Tabulka č. 10: Testy normality reziduí	57
Tabulka č. 11: Test stability parametrů	58
Tabulka č. 12: Výběr modelu pro vysvětlující proměnné	59
Tabulka č. 13: Predikce tržní ceny zlata z regresního modelu	60
Tabulka č. 14: Průměrné měsíční ceny zlata za první čtvrtletí roku 2018.....	61
Tabulka č. 15: Výběr modelu ARIMA	63
Tabulka č. 16: Test autokorelace, heteroskedasticity a normality reziduí.....	68
Tabulka č. 17: Predikce tržní ceny zlata z modelu ARIMA	70

Seznam obrázků:

Obrázek č. 1: Členění finančního trhu	14
Obrázek č. 2: Rozdělení investic	15
Obrázek č. 3: Zlatá mince Wiener Philharmoniker	17
Obrázek č. 4: Fáze ekonometrického modelování.....	23
Obrázek č. 5: Neautokorelovanost reziduí a autokorelovanost reziduí	30
Obrázek č. 6: Heteroskedasticita	31
Obrázek č. 7: Časové řady proměnných	41

Obrázek č. 8: Stacionární časové řady proměnných.....	42
Obrázek č. 9: Odhad modelu metodou nejmenších čtverců	44
Obrázek č. 10: Graf vyrovnaných a skutečných hodnot	45
Obrázek č. 11: Konfidenční intervaly koeficientů.....	46
Obrázek č. 12: Analýza rozptylu	46
Obrázek č. 13: Analýza extrémních hodnot.....	47
Obrázek č. 14: Grafy autokorelačních funkcí	52
Obrázek č. 15: Vývoj reziduí v čase	54
Obrázek č. 16: Histogram reziduí	55
Obrázek č. 17: Q-Q graf reziduí	56
Obrázek č. 18: Graf stability parametrů.....	58
Obrázek č. 19: Odhad modelu ARIMA	63
Obrázek č. 20: Histogram reziduí	64
Obrázek č. 21: Q-Q graf reziduí	65
Obrázek č. 22: Vývoj reziduí v čase	66
Obrázek č. 23: Grafy autokorelačních funkcí	67
Obrázek č. 24: Graf vyrovnané a skutečné ceny zlata v čase	69
Obrázek č. 25: Graf vyrovnaných a skutečných hodnot	69

Seznam grafů:

Graf č. 1: Predikce tržní ceny zlata z regresního modelu	61
Graf č. 2: Predikce tržní ceny zlata z modelu ARIMA.....	71
Graf č. 3: Srovnání bodové predikce regresního modelu a ARIMA modelu	72

Seznam rovnic:

Rovnice č. 1: Jednoduchá forma vícerozměrné regrese	26
Rovnice č. 2: OLS minimalizuje součet čtverců reziduí	27
Rovnice č. 3: Koeficient determinace	29