

DIPLOMOVÁ PRÁCE

Ekonometrické modelování cen nemovitostí v České republice

Econometric Modelling of House Prices in the Czech Republic

STUDIJNÍ PROGRAM

STUDIJNÍ OBOR

Projektové řízení inovací

VEDOUCÍ PRÁCE

doc. Ing. David Vaněček, Ph.D.

PŘÍJMENÍ: NGUYENOVÁ

JMÉNO: THI YEN

2021

NGUYENOVÁ, Thi Yen. *Ekonometrické modelování cen nemovitostí v České republice*. Praha: ČVUT
2020. Diplomová práce. České vysoké učení technické v Praze, Masarykův ústav vyšších studií.



**MASARYKŮV ÚSTAV
VYŠŠÍCH STUDIÍ
ČVUT V PRAZE**



ZADÁNÍ DIPLOMOVÉ PRÁCE

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Nguyenová** Jméno: **Thi Yen** Osobní číslo: **484161**
Fakulta/ústav: **Masarykův ústav vyšších studií**
Zadávací katedra/ústav: **Institut ekonomických studií**
Studijní program: **Projektové řízení inovací**

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Ekonometrické modelování cen nemovitostí v České republice

Název diplomové práce anglicky:

Econometric Modelling of House Prices in the Czech Republic

Pokyny pro vypracování:

CÍL PRÁCE: Cílem diplomové práce je vytvořit ekonometrický model analyzující ceny bytů na českém trhu a specifikovat modely, které hrubě vysvětlují pohyb cen bytů v ČR z makroekonomického hlediska.

PŘÍNOS PRÁCE: Přínosem diplomové práce je analýza tržních cen za pomoci počítačového statistického systému/programu Gretl.

Seznam doporučené literatury:

CIPRA, Tomáš. Finanční ekonometrie. 2., upr. vyd. Praha: Ekopress, 2013. ISBN 978-80-86929-93-4.

Jméno a pracoviště vedoucí(ho) diplomové práce:

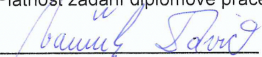
doc. Ing. David Vaněček, Ph.D., katedra inženýrské pedagogiky

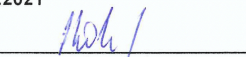
Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **12.12.2020**

Termín odevzdání diplomové práce: **14.02.2021**

Platnost zadání diplomové práce: **30.09.2021**


doc. Ing. David Vaněček, Ph.D.
podpis vedoucí(ho) práce

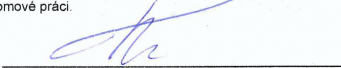

Mgr. František Hřebík, Ph.D.
podpis vedoucí(ho) ústavu/katedry


prof. PhDr. Vladimíra Dvořáková, CSc.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Diplomantka bere na vědomí, že je povinna vypracovat diplomovou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v diplomové práci.

- 9. 02. 2021
Datum převzetí zadání


Podpis studentky

Prohlášení

Prohlašuji, že jsem svou bakalářskou práci vypracovala samostatně. Dále prohlašuji, že jsem všechny použité zdroje správně a úplně citovala a uvádím je v příloženém seznamu použité literatury. Nemám závažný důvod proti zpřístupňování této závěrečné práce v souladu se zákonem č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) v platném znění.

V Praze dne: 07. 01. 2021

Podpis:

Poděkování

Tímto bych chtěla poděkovat vedoucím práce doc. Ing. Davidu Vaněčkovi, Ph.D. a doc. Ing. Vítu Poštovi, Ph.D. za cenné rady, věcné připomínky a vstřícnost při konzultacích pro vypracování závěrečné diplomové práce. Zároveň bych chtěla poděkovat Mgr. Janě Krajčové, Ph.D., M.A. za trpělivost a cenné rady při pravidelných konzultacích.

Abstrakt

Cílem diplomové práce je vytvořit ekonometrický model analyzující ceny bytů na českém trhu a specifikovat modely, které hrubě vysvětlují pohyb cen bytů v ČR z makroekonomického hlediska. K vytvoření vhodných modelů byl využit program Gretl. Metody zvolené k analýze jsou modely OLS a ARIMA model časových řad. Pomocí jednoduché lineární regresní analýzy byly vytvořeny modely popisující významnost či nevýznamnost proměnných stejně jako váhu významnosti a vypovídající schopnost modelu. U ARMA modelu se v první řadě vytvořil unit root test neboli test stacionarity (ADF test). Následně se testovaly ARIMA modely. Nejvhodnější modely byly vybrány jako finální výstup práce. Dostupná data se čerpala hlavně z databáze z Českého statistického úřadu (ČSÚ) a databáze České Národní Banky (ČNB), ARAD.

Klíčová slova

trh nemovitostí, ceny nemovitostí, OLS, ARIMA, ADF test

Abstract

The aim of the diploma thesis is to create an econometric model analyzing housing prices in the Czech market and to specify models that roughly explain the movement of housing prices in the Czech Republic from a macroeconomic point of view. The Gretl program was used to create suitable models. The methods chosen for the analysis are the OLS models and the ARIMA time series model. Using a simple linear regression analysis, models describing the significance or insignificance of variables as well as the weight of significance and the telling ability of the model were created. The ARMA model primarily developed a unit root test or stationarity test (ADF test). Subsequently, ARIMA models were tested. The most suitable models were selected as the final output of the work. The available data were drawn mainly from the database from the Czech Statistical Office (CSO) and the Czech National Bank (CNB) ARAD database.

Key words

real estate market, real estate prices, OLS, ARIMA, ADF test

OBSAH

ÚVOD	5
1 TRH NEMOVITOSTÍ V ČESKÉ REPUBLICE	8
1.1 DETERMINANTY POPTÁVKY	8
1.1.1 Příjem domácností	8
1.1.2 Index cen bytových nemovitostí	11
1.1.3 Míra ekonomické aktivity	12
1.1.4 Míra nezaměstnanosti	13
1.1.5 Demografický vývoj	14
1.1.6 Nájemné	17
1.1.7 Ostatní faktory	18
1.2 DETERMINANTY NABÍDKY	19
1.2.1 Ceny stavebních pozemků	19
1.2.2 Počet dokončených rezidenčních bytů	20
1.2.3 Ceny bytové výstavby	21
2 DETERMINANTY	23
3 KONSTRUKCE MODELU	26
3.1 ČASOVÉ ŘADY	26
3.1.1 Bílý šum	27
3.1.2 Stacionarita	27
3.1.3 Trend a sezónnost	27
3.2 LINEÁRNĚ REGRESNÍ MODEL	28
3.3 ARMA MODEL	29
4 ODHAD MODELU	30
4.1 LINEÁRNĚ REGRESNÍ MODEL	30
4.1.1 Ekonometrická verifikace	32
4.2 ARMA	35
4.2.1 Ekonometrické verifikace	38
5 HODNOCENÍ VÝSLEDKŮ	41
ZÁVĚR	43
SEZNAM POUŽITÉ LITERATURY	44
SEZNAM GRAFŮ	46
SEZNAM TABULEK	47

SEZNAM OBRÁZKŮ	48
PŘÍLOHY	49

ÚVOD

Trh nemovitostí je dnes velmi živě diskutované téma nejen v České republice, ale i po celém světě. I proto je toto téma velmi oblíbené mezi ekonomy po celém světě. Realitní trh je na českém trhu vnímán jako velmi lukrativní investiční nástroj. Vlastnictví bytu je v ČR stále vnímáno jako bezpečné a jisté uložení finančních prostředků. Tato skutečnost je částečně daná již historicky zavedením socialistické bytové politiky. Na základě této transformace začaly vznikat podnikové a družstevní výstavby a po převratu v roce 1989 začal proces privatizace. Od roku 2007 dochází k silné akceleraci cen nemovitostí v ČR, a to i přes světovou finanční krizi.

Ekonometrie patří mezi velmi zajímavé, ač relativně mladé vědní obory. Ekonometrie je založena na vývoji statistických metod pro odhad ekonomických vztahů, testování ekonomických teorií a vyhodnocování. Nejběžnější aplikací ekonometrie je předpovídání různých makroekonomických a mikroekonomických proměnných, jako jsou např. úrokové sazby, míry inflace a hrubý domácí produkt. Při ekonometrickém modelování je vzhledem ke komplexitě běžné využívat počítačové softwary jako jsou např. EViews, SPSS, XLSTAT a mnoho jiných. Pro potřeby diplomové práce byl zvolen software Gretl. Klíčovým předpokladem ekonometrického modelování je věrohodný datový zdroj bez zkreslených a zmanipulovaných dat. Klíčové zdroje dat pro diplomovou práci jsou národní databáze ČSÚ, ARAD a evropský EUROSTAT. Stěžením může však být obtížné získání dat, neexistence všech potřebných dat v databázích či zpožděná data.

Cílem práce je vytvoření ekonometrického modelu vysvětlující ceny bytů v České republice. K tomuto cíli lze dojít po splnění následujících dílčích cílů:

- sběr dat z národních databází,
- definování klíčových proměnných,
- analýza dat,
- sestavení modelu,
- zhodnocení výstupů.

Práce je rozdělena do pěti hlavních částí. První kapitola se zabývá vybranými determinanty trhu nemovitostí v České republice. Vybrané proměnné jsou kategorizovány do poptávkové a nabídkové části. Jednotlivé determinanty jsou zanalyzované a graficky doplněné.

Kapitola 2 s názvem „Determinanty“ má za úkol popsat determinanty nabídkové a poptávkové vlivy na ceny nemovitostí v ČR. Pro vhodnější porovnání a zbavení se změny struktury byla majorita determinantů přepočítaná na index porovnávající hodnotu s předešlým obdobím. Tato kapitola má také za úkol vysvětlit zkratky použité v modelování za pomoci softwaru Gretl.

Následující kapitola (3. kapitola) nazvaná „Konstrukce modelu“ popisuje charakteristiky časové řady a metodologie zvolené k modelování cen nemovitostí. Identifikuje a vysvětluje jednoduchý lineární regresní model a v neposlední řadě popisuje ARMA model podle Box-Jenkins metodologie

V kapitole 4 jsou pomocí softwaru Gretl na základě ekonometrického modelování odhadnuty modely popisující ceny bytů v České republice pro období od roku 2009 do roku 2018. Pro

konstrukci byly použity jednoduchá lineární regrese a ARMA model a následně obě varianty ekonometricky verifikované za pomoci patřičných testů. Metoda komparace ekonometrických modelů a hypotéz je nedílnou součástí této kapitoly. Stejně tak jako komparace p-hodnot se zvolenou hladinou významnosti α . Při konstrukci jednoduché lineární regrese je aplikována metoda pokus-omyl pro výběr potenciálních adekvátních vysvětlujících proměnných.

Cíl 5. kapitoly je zhodnocení vytvořených modelů. Porovnání obou modelů a také návrhy na zlepšení modelů. Po této kapitole následuje kapitola Závěr, Seznam použité literatury, Seznam grafů, Seznam tabulek, seznam obrázků a Přílohy.

TEORETICKÁ ČÁST

1 TRH NEMOVITOSTÍ V ČESKÉ REPUBLICE

V této kapitole se budeme zabývat vývojem vybraných determinantů na trhu nemovitostí v České republice. Fundamentální faktory ovlivňující ceny nemovitostí v ČR můžeme rozdělit na determinanty poptávky a determinanty nabídky. Vybrané determinanty budou posléze sloužit v praktické části k vytvoření vhodného ekonometrického modelu pro stanovení cen nemovitostí v ČR.


1.1 Determinanty poptávky

Mezi hlavní determinanty poptávky patří příjem domácností, který se skládá primárně z příjmů ze zaměstnání (dále pak příjmy z pronájmu atp.). Tyto faktory ovlivňují celkové úspory i bohatství domácností, dostupnost hypotečních úvěrů a rizikovitost splácení hypotečních úvěrů. Mezi další faktory, které mohou ovlivnit poptávku po nemovitostech, můžeme zařadit míru nezaměstnanosti, míra ekonomické aktivity, demografické faktory a další. (Hlaváček a Komárek 2009)

1.1.1 Příjem domácností

Mezi nejdůležitější faktor ovlivňující poptávku můžeme řadit příjem domácností. Nejběžnějším forma příjmů jsou měsíční příjem ze zaměstnání (příjmy ze závislé činnosti, příjmy z podnikání a jiné samostatně výdělečné činnosti). Dalšími zdroji příjmů domácností mohou být dávky státní podpory, příjmy z pronájmu nemovitostí a movitých věcí.

Graf 1: Průměrná hrubá měsíční mzda v ČR




Zdroj: ČSÚ, vlastní zpracování

Vývoj průměrné hrubé měsíční mzdy byl v období od roku 2005 do 2008 příznivý díky posílení české ekonomiky v rámci začlenění do hospodářského prostoru EU a také silným přílivům přímých zahraničních investic. Za tyto tři roky byl roční průměrný nárůst o téměř 7 p. b. Od roku 2009 do roku 2013 můžeme sledovat dvě období potýkající se s recesí. První v roce 2009, kdy se Česká republika potýkala s prudkým poklesem zahraniční poptávky a druhé období 2012 až 2013, kdy se propadla poptávka domácí (ČNB 2019a). V tomto období byl průměrný roční nárůst hrubé měsíční mzdy o 2,1 p. b. Od roku 2015 zažívá česká ekonomika období konjunktury. Roční nárůst průměrné mzdy je v průměru o 5 p. b.

1.1.1.1 Zadlužení soukromého sektoru

Meziroční nárůst zadluženosti domácího soukromého nefinančního sektoru v poměru k HDP vzrostl o více než 1 p. b. – tvořící téměř 89 % HDP ke konci roku 2018. Toto navýšení znamená nárůst o 13 p. b. za posledních 10 let. V relaci s HND tvoří míra zadluženosti téměř 96 % hrubého národního důchodu. Česká národní banka (ČNB) vzhledem k současnému vývoji celkové zadluženosti upozorňuje na možnost výskytu strukturálního rizika, zejména za předpokladu nedostatečného růstu HND. (ČNB 2019a)

Graf 2: Zadluženost domácností v ČR



Zdroj: ARAD, vlastní zpracování

Jak lze sledovat v grafu 2, celková zadluženost domácností na bydlení v porovnání se zadlužeností na spotřebu a ostatními zadluženostmi stabilně roste. Za sledované období můžeme vypozařovat 2 období zvýšeného růstu zadluženosti. První nárůst sledujeme v letech od roku 2007 až 2009. Trend celkové zadluženosti domácností na bydlení od roku 2015 je také strmější než dosavadní vývoj zadluženosti. Můžeme proto říci, že v posledních letech zadluženost domácností na bydlení roste rychleji.

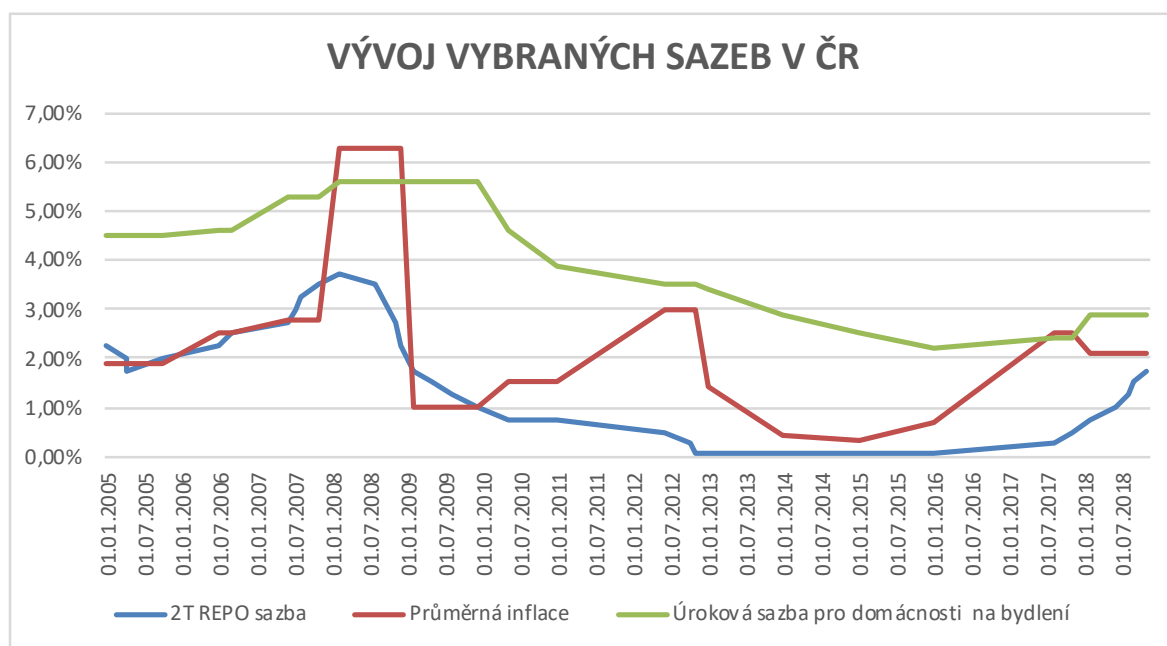
1.1.1.2 Vybrané úrokové sazby a inflace

Hlavním cílem ČNB je cenová stabilita, především stabilita spotřebitelských cen. Měnová politika je v České republice prováděna v režimu cílování inflace od roku 1998. Pro realizaci měnové politiky využívá centrální banka měnovopolitické nástroje efektivní za předpokladu nezávislosti centrální banky. (ČNB 2020b)

Jedním z nástrojů měnové politiky je cílování inflace pomocí úrokových sazeb. Nástrojem měnové politiky mohou být přímé (limity úvěrů, pravidla likvidity, limity úrokových sazeb či povinné vklady) či nepřímé (diskontní nástroje, operace na volném trhu a kurzové intervence). (Dvořák et al. 2015)

Jedním způsobem diskontního nástroje je regulace dvoutýdenní REPO sazby (2T REPO) určená pro transakce mezi komerčními bankami a centrální bankou. Tato úroková sazba se odráží ve vývoj hypoteční úrokové sazby pro domácnosti.

Graf 3: Vývoj vybraných úrokových sazeb a inflace



Zdroj: ARAD, vlastní zpracování

Jak lze zpozorovat na grafu 3, úroková sazba pro domácnosti téměř kopíruje vývoj 2T REPO sazby s lehkým zpožděním. Vývoj úrokových sazeb má v období od roku 2005 do roku 2018 dvě výraznější období růstu úrokové sazby. Od roku 2008 do roku 2010 je úroková míra nejvyšší za celé období. Úroková míra na vrcholu představovala 5,5 % p. a. Od roku 2018 můžeme znovu sledovat růst úrokových sazeb pro domácnosti na bydlení. Růst hypoteční úrokové míry způsobuje snížení poptávky po nemovitostech, jelikož se zvyšují splátky domácností.


Růst průměrné inflace v České republice byl mírný od roku 2005 do roku 2007. Největší růst zaznamenává rok 2008, kdy se inflace zvýšila o více než dvojnásobek v porovnání s předešlým

rokem a z hodnoty 2,8 % se vyšplhala na 6,3 %. Poté následoval prudký pokles v souvislosti s krizí v roce 2009. Poté následuje mírný nárůst v období tří let. Od roku 2013 se inflace zase snižuje. Od roku 2015 má inflace tendenci růst.

1.1.2 Index cen bytových nemovitostí

Index cen bytových nemovitostí neboli House Price Index (HPI) je cenový index měřící vývoj cenové hladiny všech bytů v České republice. Jeho výhodou je mezinárodní srovnatelnost díky harmonizovaným normám dle EU. Index odráží pouze nákupy domácností včetně daňových poplatků. (ČSÚ 2019a)

Graf 4: Vývoj HPI v ČR



Zdroj: ČSÚ, vlastní zpracování

Cenová hladina nákupu obydlí včetně pozemků a starších obydlí je do roku 2015 téměř totožná. Nestabilnější ze sledovaných nemovitostí je trend nákupu starších obydlí. Od roku 2015 však cenové hladiny všech sledovaných nemovitostí prudce roste. Významný růst cenové hladiny je hlavně u nákupu nových obydlí. Je nutné dodat, že struktura HPI je z nákupu všech rezidenčních nemovitostí, z toho přibližně 85 % - 90 % tvoří nákupy stávajících obydlí a zbytek nákup nových obydlí.

Tabulka 1: Indexy cen vybraných nemovitostí v ČR

Druh nemovitosti	Průměr roku <i>Annual average</i>					
	2010 = 100					
	2012	2013	2014	2015	2016	2017
Byty	98,6	98,4	100,4	103,5	115,0	129,6
Bytové domy	104,4	104,3	98,7	106,9	107,5	121,8
Rodinné domy	101,9	103,1	104,8	106,1	108,6	114,3
Stavební pozemky	103,2	103,8	107,5	110,6	113,6	117,7

Zdroj: ČSÚ, vlastní zpracování


Porovnáme-li vývoj index cenové hladiny vybraných nemovitostí, je patrné z Tabulky 1, že růst cenové hladiny nákupu bytů je za sledované období nejmarkantnější. Kontrasně je nejmenší nárůst u stavebních pozemků. Index bytových domů byl v roce 2014 velmi nízký a propadl se pod 100.

1.1.3 Míra ekonomické aktivity

Míra ekonomické aktivity je indikátor popisující míru participace populace na pracovním trhu. Vztahuje se na obyvatele ČR ve věku 15–64 let a její výše souvisí se vzděláním. Vzdělanější lidé jsou ekonomicky aktivnější než lidé méně vzdělaní. (VŠPS 2020) Číselně je vyjádřena podílem pracovní síly na počet osob starších 15 let.

Tento indikátor je odlišný v závislosti na genderu. Ženy jsou zastávají nižší míru ekonomické aktivity a tvoří i větší podíl nezaměstnaných. (ČSÚ 2020a)

Graf 5: Míra ekonomické aktivity



Zdroj: ČSÚ, vlastní zpracování

Z Grafu 5 o míře ekonomické aktivity v ČR je patrné, že v posledních letech došlo k jejímu zvýšení. Od roku 2011 dochází nepřetržitě ke každoročnímu růstu. Nejstrmější nárůst tohoto indikátoru zaznamenává období 2011 až 2013 a meziroční růst 2015 až 2016. Příznivý vývoj může souviset s migrací, v poslední době především cizinců.


Tradičně je tento ukazatel odlišný u pohlaví. U žen se míra ekonomické aktivity ve sledovaném období pohybuje okolo 51 a u mužů okolo 68.

1.1.4 Míra nezaměstnanosti

Obecná míra nezaměstnanosti je procentuální vyjádření podílu počtu zaměstnaných na celkové pracovní síle. Stejně jako u míry ekonomické aktivity je i obecná míra nezaměstnanosti měřena na populaci ve věku 15 až 65 let a údaje jsou očištěny od sezónních vlivů. (ČNB 2020a)

Faktor míry nezaměstnanosti působí na ceny nemovitostí nepřímo přes disponibilní příjem. Vyšší nezaměstnanost znamená při dané mzdě nižší disponibilní důchod domácnosti. (Hlaváček a Komárek 2009)

Graf 6: Míra nezaměstnanosti dle pohlaví



Zdroj: ARAD, ČSÚ, vlastní zpracování

Vývoj míry nezaměstnanosti v ČR je od roku 2013 velmi příznivý. V posledních letech setrvává tato míra u svého dna a zůstává nejnižší ze všech zemí EU. Pokles může být vysvětlen poklesem počtu nezaměstnaných a zároveň růstu volných pracovních míst. (ČNB 2019b) Od začátku sledovaného období do konce sledovaného období můžeme sledovat pokles míry nezaměstnanosti o 7 p. b., Hodnota klesla ze 7,9 % nezaměstnaných na 2.2 %, v absolutních hodnotách je to o téměř 289 000

nezaměstnaných méně. V období od roku 2008 do roku 2013 se míra nezaměstnanosti pohybovala okolo 8 %.

Míra nezaměstnanosti je odlišný u pohlaví. Dlouhodobě je nezaměstnanost u mužů nižší než u žen. V roce 2018 bylo celkem 67,8tis. nezaměstnaných žen a v porovnání 53,8tis. nezaměstnaných mužů.


1.1.5 Demografický vývoj

Ceny nemovitostí mohou být ovlivněny různými demografickými a populačními faktory. Do demografických determinantů můžeme zařadit porodnost, úmrtí, manželství, rozvodovost, migrace, věkovou strukturu a více. Pro účely diplomové práce byly zvoleny k širšímu zkoumání následující determinanty.

1.1.5.1 Přirozený přírůstek obyvatelstva

Bilance obyvatelstva je tvořena dvěma složkami. Přirozeným přírůstkem obyvatelstva a mechanickým pohybem osob neboli migrací. Přirozený přírůstek udává rozdíl počtu nově narozených dětí a počtu zemřelých ve sledované populaci za určité období. (ČSÚ 2004)

Graf 7: Přirozený přírůstek ČR



Zdroj: ČSÚ, vlastní zpracování

Za sledované období můžeme sledovat 2 období, kdy byl přirozený úbytek (tzn. zemřelých bylo více než nově narozených). Vývoj přirozené reprodukce je za sledované období spíše nestabilní. Nejvyšší

přirozený přírůstek byl v období od roku 2007 do 2010, kdy byl průměrný meziroční nárůst o 11,5 tisíce obyvatel. Od roku 2016 můžeme sledovat pokles přírůstku. V roce 2018 se živě narodilo 114 tisíc dětí a je evidováno 113 tis. zemřelých, přírůstek je tedy přibližně 1000 obyvatel.


Věková strukturu obyvatel ČR na konci roku 2018 tvořilo z 15,9 % děti do 15 let, 19,6 % populace starších 65 let a 64,5 % obyvatel ve věku 15–64 let. I přestože získává ČR obyvatele zahraničním stěhováním, trend počtu obyvatel v produktivním věku má za posledních 10 let klesající charakter. V roce 2018 byly zaznamenány dvě silné věkové kategorie. První je „generace X“ narozená v průběhu 70. let 20. století. Druhá skupina věkově starších 65 let. V roce 2018 tvořila tato skupina 1,69 milionu obyvatel.(ČSÚ 2020b) V důsledku snížení úmrtnosti u mužů a imigraci se poměrové zastoupení mužů a žen sblíží. V roce 2005 byl poměr žen 51,2 % kdežto v roce 2018 se snížil zastoupení žen na 50,8 %. (ČSÚ 2019c)

1.1.5.2 Migrační saldo

Migrační saldo neboli rozdíl mezi počtem přistěhovalých a počtem vystěhovalých udává přírůstek stěhováním. Je-li migrační saldo kladné, jedná se o migrační růst a je-li naopak saldo záporné, jde o migrační úbytek. Součet přirozeného přírůstku a migračního přírůstku nám udává celkový přírůstek populace. (ČSÚ 2004)

Determinant přírůstku stěhováním může ovlivňovat ceny nemovitostí nepřímo prostřednictvím trhu práce. Má vliv na míru nezaměstnanosti stejně tak jako na míru ekonomické aktivity a průměrnou hrubou mzdu. Ovlivňuje tedy nepřímo disponibilní příjem domácnosti.

Graf 8: Migrační saldo ČR



Zdroj: ČSÚ, vlastní zpracování


Migrační saldo je v ČR dlouhodobě kladné. Česká republika zahraničním stěhováním získává obyvatele. Výjimka je ve sledovaném období pouze rok 2013, kdy počet přistěhovalých byl nižší než počet vystěhovalých. V roce 2018 bylo výsledné saldo 38,6 tisíc obyvatel – tedy migrační přírůstek. (ČSÚ 2020b)

Populační vývoj je v ČR dlouhodobě příznivý a růst populace v období od roku 2005 do roku 2018 byl pouze jednou úbytek celkové populace, a to v roce 2013. V důsledku záporného migračního saldo a zároveň i úbytku přirozenou měnou byl celkový roční úbytek o 3 706 obyvatel. V posledních letech můžeme sledovat přírůstky přirozenou měnou, ale také migrací. Počet obyvatel činil na konci roku celkem 10 649 800 lidí. (ČSÚ 2019b)

1.1.5.3 Manželství A Rozvodovost

K růstu cen nemovitostí přispívá vyšší počet uzavřených sňatků, která často vedou k založení úplně nové domácnosti, a je tedy třeba nových domácností. Stejným směrem by také měla působit vyšší počet rozvodů, kdy z jedné domácnosti vznikají domácnosti dvě. (Hlaváček a Komárek 2009)

Graf 9: Počet sňatků a rozvodů v ČR



Zdroj: ČSÚ, vlastní zpracování

Trend vývoje počtu sňatků je od 70. let 20. století dlouhodobě klesající a byl poprvé zastaven v roce 2013, kdy počet sňatků klesl na historicky nejnižší hodnotu. V tomto roce 43,5 tisíce párů vstoupilo do manželství. Od roku 2014 počet sňatků každoročně roste. V roce 2018 uzavřelo sňatek 54,5 tisíce svobodných i rozvedených párů. (ČSÚ 2020b)


Počet rozvodů je ve sledovaném období spíše klesající. V roce 2005 bylo 31,3 tisíce rozvodů a v roce 2018 se počet snížil na 24,3 tisíce rozvodů. Průměrný věk rozvedených v roce 2018 byl u mužů 44,8 let a u žen 41,9 let. Od roku 2001 se míra rozvodovosti pohybuje okolo 45-50 %. Nejvyšší hodnota rozvodovosti byla v roce v roce 2010, kdy byla rozvodovost 50 % (tzn. 50 % manželství zanikla). Vezmeme-li dlouhodobý vývoj (od 70. let 20. století) je trend rozvodů mírně rostoucí. (ČSÚ 2019b)

1.1.6 Nájemné

Dalším faktorem poptávky může být nájemné. S rostoucím nájmem roste i poptávka po bytech ze dvou prostých důvodů. Za prvé, roste-li cena nájmu, preference vlastního bydlení je vyšší. Za druhé, roste-li cena nájmu, zvyšují se investiční spekulativní nákupy, jelikož dochází ke zvýšení výnosnosti těchto investic. (Hlaváček a Komárek 2009)

Data nájemného dle metodiky ČNB zahrnuje nájemné, úhrady a služby spojené s užíváním bytů, výrobky a služby pro běžnou údržbu bytů, náklady na dodávku vody, všech druhů energií a tuhých paliv.

Graf 10: Ceny nájemného v ČR



Zdroj: ARAD, vlastní zpracování

Ceny nájemného jsou důležitou složkou celkových spotřebních cen. Z grafu můžeme zpozorovat, že inflace se silně odráží na ceně nájemného. V roce 2008, kdy byla průměrná inflace ve své maximální výši za sledované období, byla i roční nárůst nájemného ve svém vrcholu. Meziroční index nabyl hodnoty 111,2. Naopak v roce 2014 až 2016, kdy byla míra inflace nižší, se i ceny nájemného tolik nezvyšovaly. V roce 2014 dokonce došlo k meziročnímu poklesu cen nájemného.

1.1.7 Ostatní faktory

Důležitými faktory jsou i specifické charakteristiky obydlí jako je např. typ vlastnictví, příslušenství (garáž či sklep), balkon, terasa, stav obydlí, počet obytných místností, výtah, podlahová plocha, podlaží atp. Další kvalitativní faktory mohou být atraktivita a společenská vybavenost, kriminalita, etnické menšiny aj. Pro účely diplomové práce však tyto proměnné nebudeme brát v potaz.

1.2 Determinanty nabídky

Nabídkové faktory jsou závislé hlavně na ziskovosti stavebního odvětví. Trh bytových nemovitostí může být rozdělen na 2 segmenty:


1. Segment existujících obydlí,
2. Segment výstavby nových obydlí, kde je rozsah dán cenou výstavby.

Pro aproximaci nabídky bytů na trhu lze použít např. počet nově dokončených bytů. Vyšší počet dokončených bytů by za stejných podmínek měl vést k nižšímu růstu cen nemovitostí. Dalšími determinanty nabídky mohou být nákladové faktory jako jsou ceny pozemků či náklady na výstavbu. Nákladové faktory se však projevují na cenách nemovitostí s velkým zpožděním z důvodu dlouhé doby přípravy a výstavky jako takové. Růst nákladů by za jinak neměnných podmínek měl projevit na růstu hodnoty nemovitosti, tudíž na růstu ceny nemovitosti. (Hlaváček a Komárek 2010)

1.2.1 Ceny stavebních pozemků

Důležitým nabídkovým faktorem je cena stavebních pozemků. Růst cen stavebních pozemků by se za jinak neměnných podmínek měl projevit na růstu ceny nemovitosti. Česká republika dlouhodobě bojuje s problémem převisu poptávky nad nabídkou u stavebních pozemků. Zvýšený zájem je hlavně u větších krajských měst. Ceny pozemků mohou být ovlivněny dopravní dostupností a dosah služeb a sociální vybaveností.

Graf 11: Ceny stavebních pozemků v ČR



Zdroj: ČSÚ, vlastní zpracování

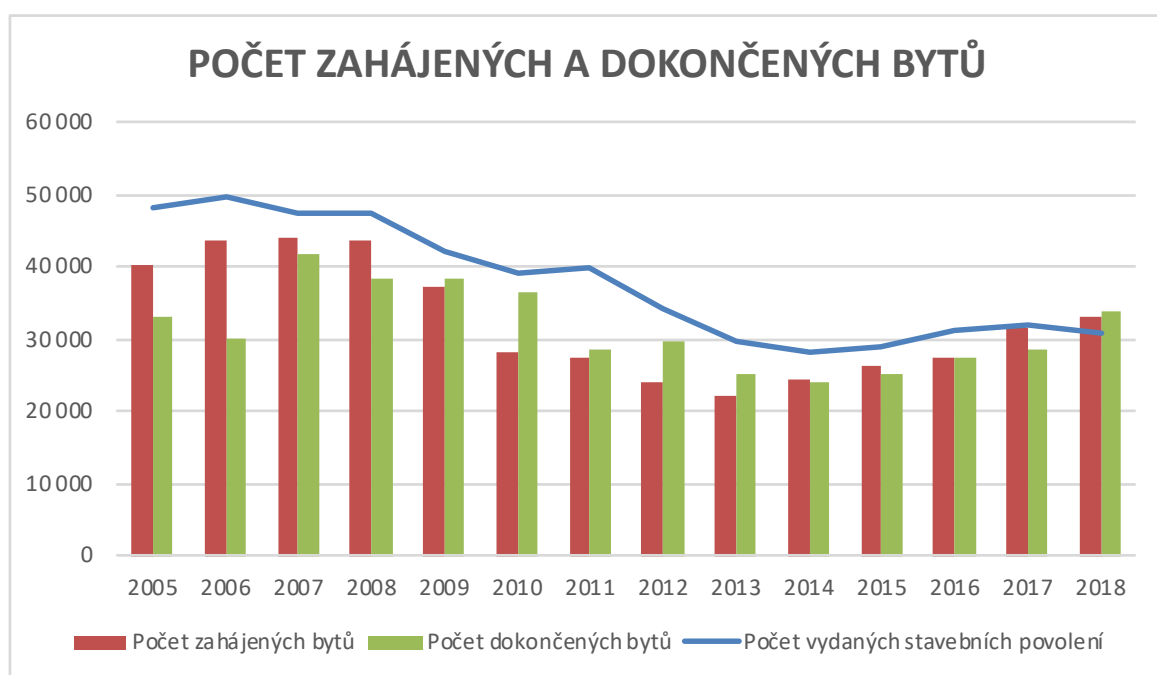
Ceny stavebních pozemků se v České republice od roku 2005 téměř každý rok rostly až do roku 2012. Pokles cen v následujícím roce byl začátek prudkého poklesu, který byl zaznamenán v roce 2014, kde průměrná cena za m^2 byl 822 Kč. Od roku 2016 jsou ceny stavebních pozemků opět každoročně rostoucí. Na konci roku 2018 byla průměrná cena stavebního pozemku 978 Kč/ m^2 .

Porovnáme-li indexy cen stavebních pozemků, můžeme sledovat dva prudké meziroční nárůsty indexů. První na v letech 2006 a 2007, kdy byl meziroční růst o cca 12 p. b. Za druhé období můžeme považovat rok 2018, kdy byl meziroční nárůst o 7,9 p. b.

1.2.2 Počet dokončených rezidenčních bytů

Dlouhodobým problémem nabídkového charakteru, který podporuje růst cen nemovitostí, je počet volných a cenově dostupných bytů v ČR. Počet zahájených výstaveb bytových jednotek je brzděn rozhodovacími procesy a také přísnou regulace výstavby. (Somogyi 2019)

Graf 12: Počet zahájených a dokončených bytů v ČR



Zdroj: ČSÚ, vlastní zpracování

Počet zahájených bytů převyšoval počet dokončených bytů ve sledovaném období ve dvou vlnách. První úsek od roku 2005 až 2008, kdy počty zahájených bytů nabývaly svého maxima a v roce 2007 se dostala hodnota na svoji píku. Celkem bylo zaznamenáno 43 796 zahájených bytů a v tom samém roce se dostal i počet dokončených bytů na svojí maximální hodnotu a celkem 41 649 bytů bylo dokončeno. Druhá vlna začala v roce 2014 a skončila v roce 2017. V roce 2014 také sledujeme nejnižší počet dokončených bytů a pochopitelně v roce 2013 nejnižší počet zahájených bytů.

Počet stavebních povolení téměř vždy převyšoval počet zahájených bytů až na rok 2018, kde bylo vydáno téměř 2400 méně stavebních povolení, než byl počet zahájených bytů. Trend počtu


vydaných stavebních povolení koreluje s trendem počtu zahájených bytů a v letech 2005 až 2008 dosahuje svého maxima. Nejméně stavebních povolení bylo vydáno v letech od 2013 až 2015.

1.2.3 Ceny bytové výstavby

Celkový objem stavebních prací v ČR se skládá ze dvou složek. První složka obsahuje nové výstavby, rekonstrukce a modernizace a druhá složka tvoří opravy a údržby.

Do stavebních prací na nové výstavbě můžeme zahrnout stavební práce na budovách a stavbách, které byly nově pořízené. Do rekonstrukce a modernizace patří nástavby, přístavby či stavební úpravy budov a staveb sloužící ke změně účelu nebo změně technických parametrů, případně k rozšíření jeho vybavenosti a použitelnosti. Stavební opravy a údržby jsou práce spojené se zajištěním běžné provozní funkce stavebních objektů. (ČSÚ 2020c)

Graf 13: Ceny stavebních prací v ČR



Zdroj: ČSÚ, vlastní zpracování

Ve sledovaném období bylo možné zaznamenat tři období, ve kterých dynamika růstu objemu stavebních prací překonala vývoj v předchozím období. Prvním obdobím byla ekonomická konjunktura vrcholící v letech 2007 až 2008, kdy byl také počet zahájených bytů ve svém maximu. V roce 2008 tak stavební práce dosáhly celkového objemu 536 013 mil. Kč. Za druhé období lze označit roky 2014 a 2015, kdy byl růst celkového objemu pozvolnější než předchozí období růstu. Třetí vlna růstu celkového objemu stavebních prací byla od roku 2017 do 2018. Meziroční růst v tomto období byl nejvyšší za sledované období a dosáhl hodnoty růstu o 11,4 % (v absolutní hodnotě nárůst o téměř 50 000 mil. Kč).

PRAKTICKÁ ČÁST

2 DETERMINANTY

V následující kapitole budou vymezené proměnné, které budou v práci použity k modelování cen nemovitostí. Data použitá v práci jsou získána z národních databází ARAD, ČSÚ a EUROSTAT v období od 2009 až 2018, jedná se o kvartální data. Pro vhodnější porovnání, majorita proměnných byla přepočítaná na index ve formátu (SOPR = 100) – očištěná hodnota o změnu struktury. Počítá se jako:

$$\frac{\text{aktuální období}}{\text{předchozí období}} * 100$$

Tabulka 2: Tabulka proměnných

	Proměnná	Jednotky
Vysvětlovaná	Tempo růstu cen bytů	SOPR = 100
Nabídkové faktory	Tempo růstu cen stavebních pozemků	SOPR = 100
	Počet dokončených bytů	SOPR = 100
Poptávkové faktory	Míra nezaměstnanosti	SOPR = 100
	Průměrná mzda	SOPR = 100
	2T repo	v %
	Hypoteční úroky	v %
	Celkové zadlužení na bydlení	SOPR = 100
	Míra ekonomické aktivity	SOPR = 100
	Sňatečnost	SOPR = 100
	Přirozený přírůstek	SOPR = 100
	Saldo migrace	SOPR = 100
	Index nájemného	SOPR = 100

Zdroj: vlastní zpracování

Tempo růstu cen bytů

U prodeje se jedná o realizovanou cenu za celý byt. Jde o vysvětlovanou proměnnou. Ceny bytů jsou v modelu pojmenované *ApartPrice*. Zbytek faktorů považujeme za vysvětlující proměnné. Jednotky ceny bytů udáváme v Kč za metr čtvereční.

Tempo růstu cen stavebních pozemků

První vysvětlující proměnná nabídkové povahy jsou ceny pozemků. V modelu je pojmenovaná jako *LandPrice*. Jednotky proměnné jsou Kč/m². Roste-li cena pozemku, rostou celkové náklady, a tak roste i hodnota nemovitosti. Můžeme tedy předpokládat kladnou korelaci mezi proměnnými.

Počet dokončených bytů

Jako poslední vysvětlující nabídkového charakteru je počet dokončených bytů v ČR. Tento faktor je označen jako *Finished*. Roste-li počet dokončených bytů, za jinak stejných podmínek roste nasycenost trhu nemovitostí a ceny bytů by měly za stejných podmínek klesat.

Sňatečnost

Počet sňatků je vysvětlující proměnnou označována jako *marriage* udávaná v procentuálním vyjádření. S růstem sňatkovosti můžeme předpokládat vytvoří zcela nové domácnosti, a tak s růstem uzavřených manželství roste poptávka po novém obydlí, a tím stoupají ceny bytů.

Přirozený přírůstek obyvatelstva

Přirozený přírůstek obyvatelstva je vysvětlující proměnnou, která nepřímo ovlivňuje poptávkovou stranu determinantů ovlivňující ceny nemovitostí přes celkový přírůstek obyvatelstva a tím i trh práce. Trh práce ovlivňuje disponibilní příjem domácnosti a tím i poptávku po nemovitostech a ceny nemovitostí na trhu. Tento determinant je označován jako *přírůstek_přirozený* a je udáván v procentuálních jednotkách.

Migrační saldo

Přírůstek nebo úbytek stěhováními neboli migrační saldo je vysvětlující proměnnou, která stejně jako u přírůstku přirozenou měnou nepřímo ovlivňuje ceny nemovitostí přes trh práce a tím nepřímo ceny nemovitostí na trhu. Tato proměnná je v modelu pojmenovaná jako *migration* a je udávaná v procentuálních jednotkách.

Míra nezaměstnanosti

Míra nezaměstnanosti je vysvětlující proměnnou poptávkového charakteru. Tento determinant přímo ovlivňuje trh práce. Je nutné dodat, že je míra nezaměstnanosti obsažena v míře ekonomické aktivity. V modelu je faktor označen jako *unemployment*. Jednotky jsou procenta.

Míra ekonomické aktivity obyvatelstva

Míra ekonomické aktivity je procentuální vyjádření participace populace na pracovním trhu. V modelu je tento determinant označován *EconActivity* a je poptávkového charakteru. Tato proměnná ovlivňuje disponibilní příjem domácnosti, a tak i poptávku po obydlí a cenu nemovitostí na trhu.

Průměrná měsíční mzda

Další vysvětlující proměnnou je průměrná měsíční mzda, která přímo ovlivňuje disponibilní příjem domácností a tím i poptávku po nemovitostech a cenu nemovitostí. V modelu je determinant pojmenován jako *Avgwage* a je udán v jednotkách Kč za měsíc.

Hypoteční úrokové míry

Průměrná hypoteční úroková míra je procentuální vyjádření úrokové míry uplatňována na hypotéky pro spotřebitele na bydlení. V modelu je označena jako *Ir*. S rostoucí úrokovou mírou rostou i

splátky domácností, a tím snižováním poptávky po hypotékách a po nemovitostech. Klesající poptávka snižuje ceny nemovitostí na trhu.

REPO sazba

Tato sazba určená pro transakce mezi komerčními bankami a centrální bankou. Tato úroková sazba se odráží ve vývoj hypoteční úrokové sazby pro domácnosti. S rostoucí REPO sazbou roste i hypoteční úroková míra jako reakce komerčních bank, tudíž klesne poptávka po hypotečních úvěrech. Tato veličina je v modelu označena jako *REPO* v procentuálních jednotkách.

Celkové zadlužení na bydlení

S rostoucí poptávkou po nemovitostech roste i objem hypotečních úvěrů. V modelu je tato proměnná označena jako *úvěry_bydlení*. Jednotky byly převedeny na index $SOPR = 100$, tudíž porovnání stejného období předchozího roku.

Index nájemného

Index nájemného sleduje změnu průměrné dosažené ceny nájmu oproti stejnému období předchozího roku. V modelu je označen jako *rent*.

3 KONSTRUKCE MODELU

Tato kapitola se bude zabývat popisem a specifikací časových řad. Na to naváže charakterizace ARIMA modelu a lineárně regresního modelu neboli jednoduchého lineárního modelu (OLS). Jedná se o statisticko-ekonometrické modely, které byly vybrány pro konstrukci příkladu.

3.1 Časové řady

Obecně existují dva typy datových souborů studovaných ekonometrií, průřezové datové soubory a časové řady. Průřezové datové soubory jsou data shromážděná najednou napříč několika entitami, jako jsou země, průmyslová odvětví, společnosti atd. Časová řada je libovolná sada dat seřazená podle času.

Kombinace průřezových dat a časových řad vytváří soubor panelových dat. Sady dat panelu lze studovat pomocí nástrojů typických pro ekonometrii dat panelu nebo pomocí nástrojů charakteristických pro analýzu více časových řad.

Skutečnost, že data časových řad jsou řazena časem, implikuje jejich speciální vlastnosti a některé speciální způsoby jejich analýzy. Umožňuje odhad modelů obsahujících pouze jednu proměnnou, takzvaný jednorozměrný odhad časové řady. V takovém případě se hodnota proměnné odhaduje podle jejích minulých hodnot a případně také podle času. Z důvodu časového řazení dat získávají otázky autokorelace v ekonometrii časových řad velký význam.

Základní popis časových řad jsou definovány následující vlastnosti: frekvence, časové rozpětí, průměr, rozptyl a kovariance.

- Frekvence souvisí s časovým rozdílem mezi y_t a y_{t+1} . Údaje lze sbírat s roční, čtvrtletní, denní nebo ještě větší frekvencí.
- Časové rozpětí je časové období, za které byly údaje shromážděny. Pokud v datech nejsou žádné mezery, je časové rozpětí ekvivalentní počtu pozorování T krát frekvence.
- Střední hodnota μ_t je definována jako $\mu_t = E(y_t)$. To znamená, že průměr je definován pro každý prvek časové řady, takže existuje N takových prostředků.
- Rozptyl je $\text{var}(y_t) = E(y_t - \mu_t)$. Podobně jako v průměru, rozptyl je definován pro každý prvek časové řady.
- Kovariance je $\text{cov}(y_t, y_{t-s}) = E[(y_t - \mu_t)(y_{t-s} - \mu_{t-s})]$. Důvěra je definována pro každý čas t a pro každý časový rozdíl s , takže v obecném případě existují $t^2 - t$ kovarianty; kvůli symetrii však může být odlišná pouze polovina z nich. (Kočenda a Černý, 2016)

3.1.1 Bílý šum

Bílý šum je termín často používaný v ekonometrii časových řad. Jak název napovídá, bílý šum je časová řada, která neobsahuje žádné další informace, které by pomohly při odhadu, samozřejmě kromě jeho rozptylu. Zbytky ze správně specifikovaného „skutečného“ modelu, který plně zachycuje proces generování, jsou bílý šum. V budoucím textu bude chybový proces, kterým je bílý šum, obvykle označen jako ε_t . (Kočenda a Černý, 2016)

3.1.2 Stacionarita

Stacionarita je klíčovou vlastností časové řady. Intuitivně musí být časová řada stacionární, abychom mohli dělat nějaké předpovědi jejího budoucího chování. Nestacionární časové řady jsou v tomto smyslu nepředvídatelné, protože mají tendenci „explodovat“. Pokud je časová řada stacionární, pak jakýkoli šok, který nastane v čase t , má v průběhu času slábnoucí účinek, a nakonec zmizí v čase $t + s$ jako $s \rightarrow \infty$. Tato vlastnost se nazývá průměrná reverze. U nestacionární časové řady tomu tak není a účinek šoku „exploduje“ v průběhu času. Zvláštním případem nestacionárního procesu je takzvaný proces kořenové jednotky. Při jednotkovém kořenovém procesu šok, který nastal v čase t , „nevybuchne“, ale zůstává přítomen ve stejné velikosti ve všech budoucích datech.

Nejpoužívanějším konceptem stacionarity v ekonometrii je koncept kovarianční stacionarity.

Časová řada $\{y_t\}_{t=1}^T$ je kovarianční stacionární právě tehdy, jsou-li splněny následující formální podmínky:

1. $\mu_t = \mu_{t-s} = \mu$ pro všechna t, s .
2. $var(y_t) = var(y_{t-s}) = \sigma^2$ pro všechna t, s .
3. $cov(y_t, y_{t-s}) = cov(y_{t-j}, y_{t-j-s}) = \gamma_s$ pro všechna t, j a s .

Znamená to, že časová řada je kovarianční stacionární, pokud je její průměr a rozptyl konstantní a konečné v čase a pokud kovariance závisí pouze na časové vzdálenosti s mezi dvěma prvky časové řady, ale ne na čase t samotném. (Kočenda a Černý, 2016)

3.1.3 Trend a sezónnost

Obecná časová řada se může skládat ze tří základních složek, deterministického trendu, sezónního vzoru a nepravidelného vzoru. Naším úkolem pomocí odhadů a předpovědí je rozložit řadu na tyto tři komponenty. Sérii lze poté napsat jako:

$$Y_t = T_t + S_t + I_t$$

1. Trend (T_t) lze obecně popsat pomocí trendu $T_t = i = 0$. Obvykle se budeme zabývat pouze lineárním nebo kvadratickým trendy ($n = 1$ nebo 2). Pokud řada roste exponenciálně, musíme vzít přirozený logaritmus, abychom transformovali exponenciál na lineární růst.

2. Sezónnost (S_t) lze popsat jako $S_t = c \sin(\frac{t2\pi}{d})$, kde d je období sezónního vzoru.
3. Náhodná složka (I_t) může být vyjádřena obecným modelem ARMA. Ve skutečnosti se většina následujících částí i většina jednorozměrné ekonometrie časových řad zabývá zejména odhadem nepravidelných vzorců.

3.2 Lineárně regresní model

Velká část aplikované ekonometrické analýzy začíná následující premisou: y a x jsou dvě proměnné, které představují určitou populaci, a nás zajímá „vysvětlení y ve smyslu x “ nebo „studium toho, jak se y mění se změnami v x “.

Při psaní modelu, který „vysvětlí y ve smyslu x “, musíme čelit třem problémům.

- Nikdy neexistuje přesný vztah mezi dvěma proměnnými, jak umožníme ovlivnění y jinými faktory?
- Jaký je funkční vztah mezi y a x ?
- Jak si můžeme být jisti, že zachycujeme vztah y a x ?

Tyto nejasnosti můžeme vyřešit napsáním rovnice vztahující se y a x . Jednoduchá rovnice je

$$y = \beta_0 + \beta_1 x + u.$$

Rovnice, o které se předpokládá, že bude v populaci zájmu, definuje jednoduchý lineární regresní model. Nazývá se také lineární regresní model se dvěma proměnnými nebo dvojrozměrný lineární regresní model, protože se týká dvou proměnných x a y a pojednává o významu každé z veličin v rovnici.

y se nazývá závislá proměnná a x se nazývá nezávislá proměnná. Proměnná u , nazývaná chybovost nebo error, představuje jiné faktory než x , které ovlivňují y . Jednoduchá regresní analýza účinně považuje všechny faktory ovlivňující y kromě x za nepozorované. (Wooldridge, 2016)

3.3 ARMA model

Jedním z nejčastěji využívaných modelů Box-Jenkinsovy metodologie je analýza stochastických časových řad ARMA. Mezi nejpropracovanější přístup modelování korelovanosti řadíme právě lineární modely ARMA. (Cipra, 2013)

Přístup ARMA modelu neklade důraz na konstrukční systematické složky, ale na korelační analýzu případně i závislých pozorování. Vznikají tak autoregresní procesy (AR), procesy klouzavých průměrů (MA), smíšené modely (ARMA), nebo jejich další modifikace (ARIMA, AR, MA, ...)

- I. ARMA model je ekonometrický model vznikl ze zkratky autoregresní klouzavý průměr. Autoregresní proces řádu p , $AR(p)$, je popsán rovnicí:

$$y_t = a_0 + \sum_{i=1}^p a_i y_{t-1} + \varepsilon_t.$$

- II. Proces klouzavý průměr řádu q , $MA(q)$ je popsán rovnicí:

$$y_t = \sum_{i=0}^q \beta_i \varepsilon_{t-i}.$$

- III. Proces autoregresní klouzavý průměr ARMA (p,q) je popsán jako:

$$y_t = a_0 + \sum_{i=1}^p a_i y_{t-1} + \varepsilon_t + \sum_{i=0}^q \beta_i \varepsilon_{t-i}.$$

Koeficient β_0 v rovnici II. a III. je standardně normalizovaná na 1. Je nutné podotknout, že v rovnicích výše se neexistuje žádný trend, protože odhadujeme nepravidelné (případně sezónní) vzorce. Z toho důvodu používáme časové řady bez trendu, diferencované nebo logaritmicky diferencované. Odhad časové řady pomocí modelu ARMA má smysl pouze v případě, když jsou řady stacionární. (Kočenda a Černý, 2016)

4 ODHAD MODELU

Tato kapitola se zabývá samotným odhadem modelů – jednoduché lineární regrese (OLS) a ARIMA, resp. ARMA modelu. V jednotlivých podkapitolách je popsán odhadovaný model a významnost jednotlivých proměnných. Také je popsána a otestována ekonometrická specifikace ověřující podmínky pro úspěšnou analýzu. U obou modelů byla zvolena 1% hladina významnosti.

4.1 Lineárně regresní model

Model 44: OLS, za použití pozorování 2009:1–2018:4 (T = 40)
Závisle proměnná: ApartPrice

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	68,0531	13,1149	5,189	9,77e-06	***
avrwave	0,324780	0,0992099	3,274	0,0024	***
finished	0,0405734	0,0155056	2,617	0,0132	**
LandPrice	-0,0216142	0,0810957	-0,2665	0,7914	
REPO	-1,76385	0,479291	-3,680	0,0008	***
unemployment	-0,0195866	0,0102559	-1,910	0,0646	*
Střední hodnota závisle proměnné		100,7300			
Sm. odchylka závisle proměnné		1,920230			
Součet čtverců reziduí		38,51746			
Sm. chyba regrese		1,064362			
Koeficient determinace		0,732153			
Adjustovaný koeficient determinace		0,692764			
F(5, 34)		18,58763			
P-hodnota(F)		7,12e-09			
Logaritmus věrohodnosti		-56,00219			
Akaikovo kritérium		124,0044			
Schwarzovo kritérium		134,1376			
Hannan-Quinnovo kritérium		127,6682			
rho (koeficient autokorelace)		-0,206003			
Durbin-Watsonova statistika		2,349687			

Obrázek 1: OLS Model 1

Zdroj: vlastní zpracování pomocí programu Gretl

Obrázek 1 popisuje model skládající se z:

- Závislé (vysvětlující) proměnné: *cena bytů*,
- Nezávislé (vysvětlované) proměnné: *průměrná měsíční mzda, počet dokončených bytů, cena pozemků, REPO sazba a míra nezaměstnanosti*.

Výsledná analýza pomocí jednoduché regrese popisuje 73,22 % celého modelu. Z výstupu také vidíme, že do skupiny významné proměnných řadíme: měsíční průměrnou mzdu, REPO sazbu. Méně

významná je proměnná počet dokončených bytů a míra nezaměstnanosti. Jelikož se vyskytuje i nevýznamná proměnná cena pozemků, v následujícím kroku byla stažena tato proměnná z modelu.

Model 5: OLS, za použití pozorování 2009:1–2018:4 (T = 40)
Závisle proměnná: ApartPrice

	koeficient	směr. chyba	t-podíl	p-hodnota	
const	65,8369	10,0065	6,579	1,34e-07	***
finished	0,0388994	0,0139871	2,781	0,0087	***
unemployment	-0,0186257	0,00947315	-1,966	0,0573	*
avrgwage	0,325673	0,0978286	3,329	0,0021	***
REPO	-1,82034	0,424130	-4,292	0,0001	***
Střední hodnota závisle proměnné		100,7300			
Sm. odchylka závisle proměnné		1,920230			
Součet čtverců reziduí		38,59794			
Sm. chyba regrese		1,050142			
Koeficient determinace		0,731593			
Adjustovaný koeficient determinace		0,700918			
F(4, 35)		23,84980			
P-hodnota(F)		1,39e-09			
Logaritmus věrohodnosti		-56,04393			
Akaikovo kritérium		122,0879			
Schwarzovo kritérium		130,5323			
Hannan-Quinnovo kritérium		125,1411			
rho (koeficient autokorelace)		-0,189348			
Durbin-Watsonova statistika		2,325367			

zde je poznámka o zkratkách statistik modelu

Obrázek 2: OLS model 2

Zdroj: vlastní zpracování pomocí programu Gretl

Z obrázku 2 můžeme vidět, že odebráním proměnné ceny pozemků se téměř nezměnila vypovídací hodnota modelu, která je stále na 73 %.

Výsledný vzorec můžeme zapsat jako:

$$\text{ApartPrice} = 65,8369 + 0,3257\text{avrgwage} + 0,0389\text{finished} - 1,8203\text{REPO} - 0,0186\text{unemployment} + u$$

Zvýší-li se průměrná mzda o jednotku, za jinak nezměněných podmínek se zvýší cena bytů o 0,3257. S vyšší průměrnou mzdou vzroste bohatství, a tudíž vzroste i poptávka po nemovitostech.

Zvýší-li se počet dokončených bytů o jednotku, za jinak nezměněných podmínek se zvýší cena bytů o 0,0389. I když na první pohled není tento vztah logický, může být způsoben stále vyšší poptávkou a nedostatečnou nabídkou nemovitostí na trhu.

Zvýší-li se REPO sazba o jednotku, za jinak neměnných podmínek se sníží cena bytů o 1,8203
Rostoucí REPO sazba zvýší hypoteční úrokovou míru, která způsobí pokles poptávky po hypotečních
úvěrech a tím i poptávka po nemovitostech.

Zvýší-li se míra nezaměstnanosti o jednotku, za jinak neměnných podmínek se sníží cena bytů o
0,0186 z důvodu snížení poptávky po nemovitostech.

4.1.1 Ekonometrická verifikace

Pro ověření podmínek je potřeba otestovat podmínky nezbytné pro aplikaci ekonometrických
metod. V našem případě byly použity reziduální testy autokorelace, heteroskedasticity, test
normality a test specifikace modelu.

4.1.1.1 Test chybné specifikace

Základem kvalitního modelu je správná specifikace. Časté chyby jsou vynechání důležité vysvětlující
proměnné či zahrnutí nevýznamných vysvětlujících proměnných. Pro testování správné specifikace
jsme využili Ramsey RESET test.

Hypotézy Ramsey RESET test:

H_0 : model vykazuje správnou specifikaci

H_1 : model nevykazuje správnou specifikaci

Pomocná regrese pro test specifikace RESET
OLS, za použití pozorování 2009:1–2018:4 (T = 40)
Závisle proměnná: ApartPrice

	koeficient	směr. chyba	t-podíl	p-hodnota
const	-3678,23	32707,5	-0,1125	0,9111
finished	-4,24517	39,3785	-0,1078	0,9148
unemployment	2,03520	18,8521	0,1080	0,9147
avrgwage	-35,5218	329,666	-0,1078	0,9148
REPO	198,684	1842,64	0,1078	0,9148
yhat^2	1,14896	10,0630	0,1142	0,9098
yhat^3	-0,00398529	0,0333421	-0,1195	0,9056

Varování: matice dat je téměř singulární!

Testovací statistika: $F = 0,300113$,
s p-hodnotou = $P(F(2,33) > 0,300113) = 0,743$

Obrázek 3: Ramsey RESET test

Zdroj: vlastní zpracování pomocí programu Gretl

Výsledná tabulka nezamítá H_0 na hladině stanovené 1% významnosti, jelikož je p-hodnota vyšší než 0,01. Model tudíž považujeme za správně specifikovaný.

4.1.1.2 Autokorelace

Autokorelace popisuje závislost mezi rezidui, která je nežádoucí. Při ekonometrickém modelování je potřeba nesystematičnost chybových složek. Pro testování autokorelace je použit DW (Durbin-Watson) test.

H_0 : autokorelace se nevyskytuje

H_1 : autokorelace se vyskytuje

Durbin-Watsonova statistika = 2,32537

p-hodnota = 0,724488

Durbin-Watsonova statistika by se ideálně měla blížit k 2. U našeho modelu ukazuje tento model 2,32. P-hodnota je větší než 0,01. Na základě výsledků nezamítáme H_0 na 1% hladině významnosti.

4.1.1.3 Heteroskedasticita

Předpokladem OLS patří homoskedasticita reziduí tzn. variance reziduí je konstantní. Pro otestování heteroskedasticity byl využit Whiteův test.

H_0 : homoskedasticita

H_1 : heteroskedasticita

Whiteův test heteroskedasticity
 OLS, za použití pozorování 2009:1–2018:4 (T = 40)
 Závisle proměnná: uhat²

	koeficient	směr. chyba	t-podíl	p-hodnota
const	-1059,76	1157,35	-0,9157	0,3686
finished	-1,96766	2,17457	-0,9049	0,3742
unemployment	1,97327	1,68678	1,170	0,2531
avrgwage	21,4714	22,6344	0,9486	0,3519
REPO	-67,0709	66,8229	-1,004	0,3251
sq_finished	0,00103049	0,00153386	0,6718	0,5079
X2_X3	-1,18244e-05	0,00248116	-0,004766	0,9962
X2_X4	0,0165899	0,0213908	0,7756	0,4453
X2_X5	0,108697	0,0981547	1,107	0,2787
sq_unemployment	0,00100321	0,00134155	0,7478	0,4616
X3_X4	-0,0218604	0,0179952	-1,215	0,2358
X3_X5	0,101102	0,100522	1,006	0,3242
sq_avrgwage	-0,105503	0,110703	-0,9530	0,3497
X4_X5	0,476874	0,614076	0,7766	0,4447
sq_REPO	-2,30830	2,18894	-1,055	0,3017

Neadjustovaný koeficient determinace = 0,564515

Testovací statistika: $TR^2 = 22,580614$,
 s p-hodnotou = $P(\text{Chí-kvadrát}(14) > 22,580614) = 0,067445$

Obrázek 4: Whiteův test heteroskedasticity

Zdroj: vlastní zpracování pomocí programu Gretl

Výsledný test ukazuje p-hodnotu vyšší než 0,01, tudíž na hladině významnosti 1% nezamítáme H_0 . Model považujeme za homoskedasticitní.

4.1.1.4 Test normality

Předpokladem OLS patří normální rozdělení reziduí. Pro otestování byl využit Doornik-Hansenův test, Shapiro-Wilkův W test, Lillieforsův test a test Jarque-Bery.
 H_0 : rezidua mají normální rozdělení

H_1 : rezidua nemají normální rozdělení

Test normality residua

Doornik–Hansenův test = 11,8575, s p–hodnotou 0,00266184

Shapiro–Wilkův W test = 0,944995, s p–hodnotou 0,0510808

Lillieforsův test = 0,12025, s p–hodnotou \approx 0,15

Test Jarque–Bery = 6,54638, s p–hodnotou 0,0378854

Obrázek 5: Test normality

Zdroj: vlastní zpracování pomocí programu Gretl

U testu normality jsou p–hodnoty u 3 testů vyšší než 0,01 a pouze Doornik–Hansenův test vykazuje hodnotu nižší než 0,01. Test normality tedy nezamítá nulovou hypotézu na 1% hladině významnosti.

4.2 ARMA

Předpoklad stacionarity časových řad je zásadní pro další ekonometrické šetření. V případě, že nejsou časové řady stacionární, hrozí zdánlivá regrese. Pro ověření stacionarity můžou být využity patřičné testy KPSS (Kwiatkowski-Phillips-Schmidt-Shin) test a ADF (Augmented Dickey-Fuller) test.

V případě nestacionarity časové řady je nutné převést časové řady na stacionární pomocí diference. U našeho modelu byla zjištěna nestacionarita časových řad u míry nezaměstnanosti, průměrné měsíční mzdy a REPO sazby. U těchto determinantů byla aplikována první diference, které následně potvrdily stacionaritu.

Vyhodnocování funkce: 303
 Vyhodnocování gradientu: 105

Model 9: ARMAX, za použití pozorování 2009:2–2018:4 (T = 39)
 Estimated using AS 197 (přesné ML)
 Závisle proměnná: ApartPrice
 Směrodatné chyby založené na Hessiánu

	koeficient	směr. chyba	z	p-hodnota	
const	112,469	5,40191	20,82	2,84e-96	***
phi_1	1,43237	0,221558	6,465	1,01e-10	***
phi_2	-0,440314	0,221832	-1,985	0,0472	**
theta_1	-1,78267	0,110865	-16,08	3,55e-58	***
theta_2	0,999999	0,105502	9,479	2,58e-21	***
LandPrice	-0,163604	0,0504873	-3,240	0,0012	***
finished	0,0465492	0,00893971	5,207	1,92e-07	***
ld_unemployment	-5,63574	1,57833	-3,571	0,0004	***
ld_avrgwage	-2,04338	11,2658	-0,1814	0,8561	
ld_REPO	-0,129648	0,232167	-0,5584	0,5766	

Střední hodnota závisle proměnné 100,8205
 Sm. odchylka závisle proměnné 1,856876
 Střední hodnota inovací 0,322458
 Sm. odchylka inovací 0,936401
 Logaritmus věrohodnosti -56,61179
 Akaikovo kritérium 135,2236
 Schwarzovo kritérium 153,5228
 Hannan-Quinnovo kritérium 141,7892

zde je poznámka o zkratkách statistik modelu

		Reálná	Imaginární	Abs. hodnota	Frekvence
AR					
Kořen	1	1,0146	0,0000	1,0146	0,0000
Kořen	2	2,2385	0,0000	2,2385	0,0000
MA					
Kořen	1	0,8913	-0,4533	1,0000	-0,0749
Kořen	2	0,8913	0,4533	1,0000	0,0749

Obrázek 6: ARMA model 1

Zdroj: vlastní zpracování pomocí programu Gretl

Pozn.: const = konstanta vygenerovaná softwarem, phi_1 = regresní koeficient u AR procesů u 1. zpoždění, phi_2 = regresní koeficient u AR procesů u 2. zpoždění, theta_1 = regresní koeficient u MA procesů u 1. zpoždění, theta_2 = regresní koeficient u MA procesů u 2. zpoždění

P-hodnota proměnných je u všech kromě průměrné měsíční mzdy a REPO sazby nižší než 1% hladina významnosti, proto mezi statisticky významné proměnné řadíme: cenu pozemků, počet zhotovených bytů a míru nezaměstnanosti. V následujícím ARMA modelu jsme již vypustili nevýznamné proměnné.

Vyhodnocování funkce: 396
 Vyhodnocování gradientu: 122

Model 6: ARMAX, za použití pozorování 2009:2–2018:4 (T = 39)
 Estimated using AS 197 (přesné ML)
 Závisle proměnná: ApartPrice
 Směrodatné chyby založené na Hessiánu

	koeficient	směr. chyba	z	p-hodnota	
const	111,814	5,32880	20,98	9,38e-98	***
phi_1	1,45980	0,227235	6,424	1,33e-10	***
phi_2	-0,468676	0,227391	-2,061	0,0393	**
theta_1	-1,79347	0,124165	-14,44	2,73e-47	***
theta_2	1,00000	0,123196	8,117	4,77e-16	***
finished	0,0488057	0,00863097	5,655	1,56e-08	***
ld_unemployment	-5,54563	1,62092	-3,421	0,0006	***
LandPrice	-0,159892	0,0511611	-3,125	0,0018	***

Střední hodnota závisle proměnné 100,8205
 Sm. odchylka závisle proměnné 1,856876
 Střední hodnota inovací 0,307257
 Sm. odchylka inovací 0,944177
 Logaritmus věrohodnosti -56,81597
 Akaikovo kritérium 131,6319
 Schwarzovo kritérium 146,6040
 Hannan-Quinnovo kritérium 137,0038
 zde je poznámka o zkratkách statistik modelu

		Reálná	Imaginární	Abs. hodnota	Frekvence
AR					
Kořen	1	1,0173	0,0000	1,0173	0,0000
Kořen	2	2,0975	0,0000	2,0975	0,0000
MA					
Kořen	1	0,8967	-0,4426	1,0000	-0,0730
Kořen	2	0,8967	0,4426	1,0000	0,0730

Obrázek 7: ARMA model 2

Zdroj: vlastní zpracování pomocí programu Gretl

Pozn.: const = konstanta vygenerovaná softwarem, phi_1 = regresní koeficient u AR procesů u 1. zpoždění, phi_2 = regresní koeficient u AR procesů u 2. zpoždění, theta_1 = regresní koeficient u MA procesů u 1. zpoždění, theta_2 = regresní koeficient u MA procesů u 2. zpoždění

Výsledný vzorec můžeme zapsat jako:

$$\begin{aligned}
 \text{ApartPrice} = & 112,469 + 1,43237y_{t-1} - 0,440314y_{t-2} + \varepsilon_t - 1,78267\varepsilon_{t-1} \\
 & + 0,999999\varepsilon_{t-2} - 0,163604\text{LandPrice} + 0,0465492\text{finished} \\
 & - 5,63574\text{ld_unemployment}
 \end{aligned}$$

Na základě testování byl vybrán model ARMA(2,2) jako nejvhodnější vzorek sledování. Tento model se skládá z proměnných: cena pozemků, počet zhotovených bytů a míra nezaměstnanosti. Z modelu můžeme sledovat jev, kdy při odstranění nestacionarity u proměnných REPO sazby a průměrné mzdy došlo k poklesu statistické významnosti determinantů.

4.2.1 Ekonometrické verifikace

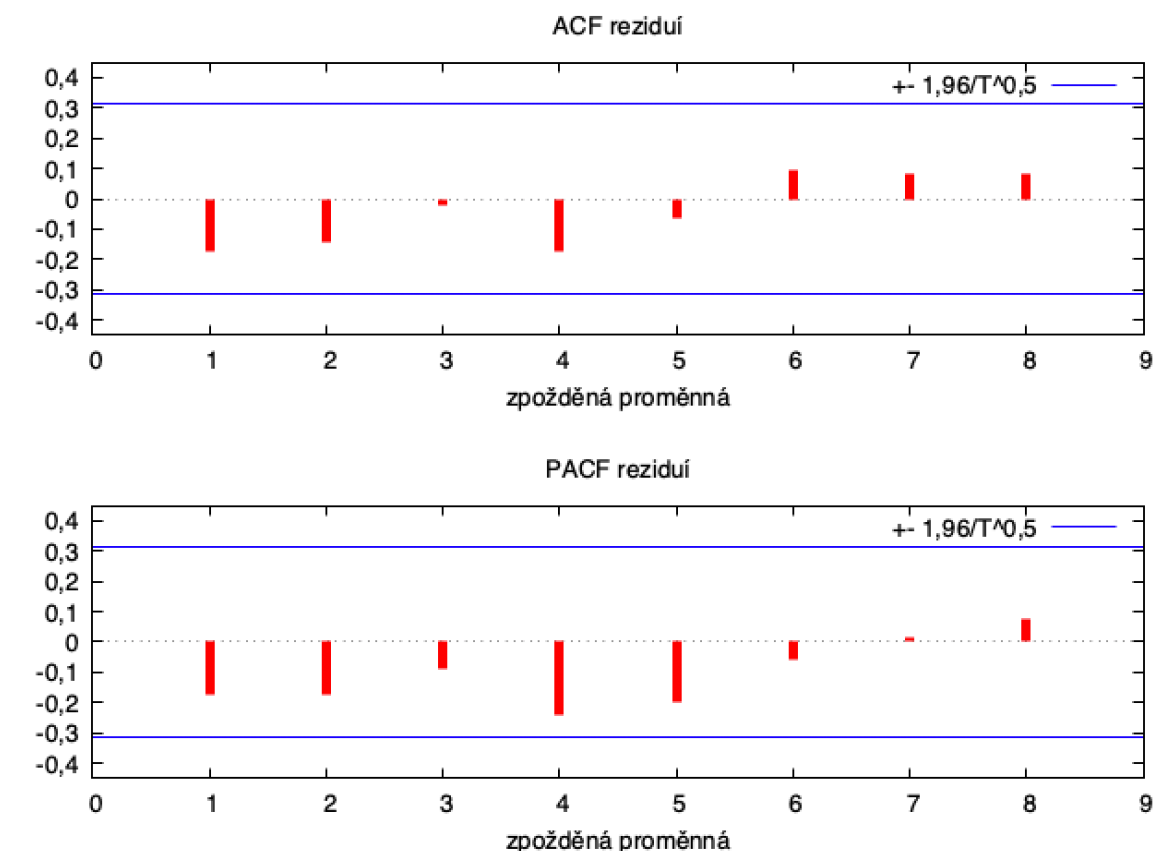
4.2.1.1 Autokorelace

Sériová korelace zjednodušeně znamená závislost mezi chybovými složkami. Je velmi častá u časových řad, jelikož bývají hodnoty determinovány minulými hodnotami. Tato závislost je u ekonometrického modelování nežádoucí. Rezidua musí prokázat nesystematičnost.

Autokorelaci můžeme otestovat graficky či testy. Pro potřeby práce jsme zvolili grafické znázornění doplněné testem Ljung-Box.

H_0 : autokorelace se nevyskytuje

H_1 : autokorelace se vyskytuje



Obrázek 8: Grafy autokorelačních funkcí

Zdroj: vlastní zpracování pomocí programu Gretl

Graf ACF ukazuje koeficienty autokorelace mezi časovou řadou a jejími zpožděními. Graf PACF potom ukazuje pouze přímou závislost mezi jednotlivými zpožděními časové řady.

V grafu parciální autokorelační funkce není žádné patrné porušení toleranční meze, a tudíž můžeme předpokládat, že rezidua mají charakter bílého šumu. Autokorelace byla testována do osmého řádu zpoždění.

Grafické testování autokorelace bylo doplněno testem autokorelace nabízeno softwarem Gretl, a to Ljung-Box test.

```
Test for autocorrelation up to order 8
Ljung-Box Q' = 4,895,
s p-hodnotou = P(Chí-kvadrát(4) > 4,895) = 0,2982
```

Obrázek 9: Test autokorelace Ljung-Box

Zdroj: vlastní zpracování pomocí programu Gretl

Testy autokorelace do osmého řádu zpoždění nepotvrdily výskyt autokorelace. P-hodnota testu je vyšší než 0,01 - stanovené hladině významnosti. Na základě obou testů nezamítáme H_0 na hladině významnosti 1 %.

4.2.1.2 Heteroskedasticita

Předpokladem OLS patří homoskedasticita reziduí tzn. variance reziduí je konstantní. Pro otestování heteroskedasticity byl využit ARCH test.

H_0 : homoskedasticita

H_1 : heteroskedasticita

Test pro ARCH řádu 4

	koeficient	směr. chyba	t-podíl	p-hodnota	
alpha(0)	0,573027	0,224220	2,556	0,0159	**
alpha(1)	-0,0989927	0,172117	-0,5751	0,5695	
alpha(2)	-0,0356066	0,175072	-0,2034	0,8402	
alpha(3)	-0,0598702	0,0820088	-0,7300	0,4710	
alpha(4)	0,157207	0,0728203	2,159	0,0390	**

Nulová hypotéza: není zde žádný efekt ARCH

Testovací statistika: LM = 5,20272

s p-hodnotou = $P(\text{Chí-kvadrát}(4) > 5,20272) = 0,267122$

Obrázek 10: ARCH test heteroskedasticity

Zdroj: vlastní zpracování pomocí programu Gretl

Výsledný test ukazuje p-hodnotu vyšší než 0,01, tudíž na hladině významnosti 1% nezamítáme H_0 . Model považujeme za homoskedasticitní.

4.2.1.3 Test normality

U testování normality u ARMA modelu jsme zvolili Chí-kvadrát test dobré shody.

H_0 : rezidua mají normální rozdělení

H_1 : rezidua nemají normální rozdělení

Testovací statistika: Chí-kvadrát(2) = 8,02668

p-hodnota = 0,0180729

P-hodnota je větší než 0,01, tudíž nezamítáme nulovou hypotézu na 1% hladině významnosti a předpokládáme, že rezidua mají normální rozdělení.

5 HODNOCENÍ VÝSLEDKŮ

V praktické části práce by provedena analýza determinantů cen bytů v České republice pomocí dvou přístupů – model jednoduché lineární regrese a model ARMA. Regresní model popisuje čtyři zvolených vysvětlujících proměnných, které mají vliv na vysvětlovanou proměnnou, v našem případě na cenu bytů v České republice. Model OLS vysvětlil přibližně 73 % proměnlivosti ceny bytů. Výsledky lineárně regresní analýzy ukázaly, že růst cen bytů lze zejména vysvětlit růstem měsíční průměrnou mzdou a poklesem REPO sazby. Vliv také pozorujeme u počtu zhotovených bytů a míry nezaměstnanosti. Další použité proměnné nebyly signifikantní na požadované míře významnosti. Zásadní roli při ekonometrickém modelování je ekonometrická verifikace, kde se analyzovala rezidua a správnost specifikace modelu. U našeho modelu se testovala autokorelace, heteroskedasticita, normalita reziduí a test specifikace modelu. Autokorelace se u regresního modelu neprokázala podle testu Durbin-Watsona, tzn. že jsou chybové složky nesystematické. Whiteův test potvrdil požadovanou homoskedasticitu tedy, že rezidua mají stejný konstantní rozptyl. Test specifikace modelu byl proveden pomocí Ramsey RESET test, který potvrdil vhodnost modelu se správnou specifikací. Poté následovalo testování normality reziduí, kde téměř všechny testy (3 ze 4) normality prokázaly normalitu chybových složek na stanovené hladině významnosti.

Předpokladem modelu autoregresního klouzavého průměru je stacionarita proměnných. V prvním kroku byly otestovány proměnné pomocí ADF testu neboli unit root testu (test jednotkového kořene), který prokázal nestacionaritu u průměrné měsíční mzdy a REPO sazby. Časové řady musely být tedy převedeny na stacionární pomocí difference, která stacionaritu zajistila. V našem případě byla dostačující první difference. Dále následovalo modelování ARMA modelu, kdy nejvhodnější model byl zvolen ARMA(2,2) tzn. 2. zpoždění u AR procesů a 2. zpoždění u MA procesů. Tento model prokázal statistickou významnost u cen pozemků, počtu zhotovených nemovitostí a míry nezaměstnanosti. V neposlední řadě byl proveden test verifikace autokorelace modelu, který je u časových řad klíčový. Bylo provedeno grafické testování, které bylo doplněno Ljung-Box testem. Oba testy prokázaly nepřítomnost autokorelace. Heteroskedasticita byla analyzována ARCH testem, který nezamítl nulovou hypotézu homoskedasticity. V neposlední řadě byl proveden test normality za pomoci Chí-kvadrátu dobré shody, který stejně jako u regresního modelu prokázal normalitu reziduí na stanovené hladině významnosti.

Srovnání vypovídací hodnoty modelu ARMA a jednoduché lineární regrese vyšlo z hlediska informací lépe OLS model. Regresní model je také preferovanější i kvůli omezenému počtu časových

řad a jeho frekvenci sledování. ARMA model je vhodnější pro šetření časových řad s vyšším počtem sledování.

Návrhy na zlepšení modelu lineární regrese mohou např.:

- Volba různé délky časové řady,
- Volba jiné frekvence sledování,
- Vytvoření nového modelu s jinými determinanty,
- Přidání determinantů dle regionů.

U ARMA modelů není možné tolik zasahovat jako u OLS. Vhodnější by však byl model s vyšším počtem sledování a delší časové řady.

ZÁVĚR

Hlavním cílem diplomové práce bylo vytvoření ekonometrického modelu popisující cenu bytů v České republice. Jednoduchý lineární regresní model byl úspěšně vytvořen a následně i ekonometricky verifikován. Byl vytvořen i ARMA model, který byl následně taktéž verifikován. I přestože byly oba modely verifikovány, vhodnější model k určení ceny bytů v ČR a se zvolenými determinanty v práci považujeme OLS model. Tento model má vyšší vypovídací hodnotu a zároveň je méně citlivý na délku pozorování než ARMA model.

Dílčí sběr dat z národních databází byla časově náročná aktivita, která se však vyplatila. Z důvodu potřeby stejné délky a frekvence sledování všech determinantů vzniklo optimální sledovací období od roku 2009 do roku 2018 na kvartální bázi, i když je toto období považováno za spíše kratší a žádanější by bylo období delší. Z důvodu vyhnutí se zkreslujících a nepřesných dat byly využity pouze národní a nadnárodní databázové systémy, a to ARAD od ČNB, ČSÚ databáze a EUROSTAT databáze. I přestože jsou data z těchto databází aktualizovaná se zpožděním, mohou garantovat přesnost a kvalitu dat.

Definování klíčových proměnných bylo uchopeno v teoretické části sloužící k pochopení, jak funguje vysvětlující proměnná, jakých hodnot nabývá, jaký byl historický vývoj a také vztah k vysvětlované proměnné. Tyto potenciální vysvětlující proměnné byly po analýze použité při konstrukci příkladu, na základě kterého došlo k sestavení nevhodnějších modelů.

Pro sestavení modelů, bylo třeba v první řadě popsat časové řady a jejich charakteristiku. Práce je věnovaná analýze determinant pomocí dvou přístupů OLS a ARMA. Tyto modely byly v praktické části přestaveny a zformulovány. Po konstrukci byla potřeba také modely ekonometricky verifikovat.

Zhodnocení výstupů se věnuje kapitola 5, která popisuje výsledky jednotlivých přístupů. Model OLS vysvětluje 73 % proměnlivosti cen bytů v ČR a je vysvětlen zejména měsíční průměrnou mzdou a REPO sazbou. Vliv také pozorujeme u počtu zhotovených bytů a míry nezaměstnanosti. U ARMA modelu se prokázaly statisticky významné proměnné ceny pozemků, počet zhotovených nemovitostí a míra nezaměstnanosti. Oba modely tedy indikují významnost dvou vysvětlujících proměnných.

Všechny dílčí cíle byly naplněny, a tudíž lze konstatovat, že celkový cíl práce byl splněn. Kromě zadaných cílů, práce také popisuje návrhy na zlepšení modelu. Konkrétně se jedná o zvolení jiné délky pozorování, a to zejména při využití ARMA modelu. Stejně pravidlo platí i při jiné frekvenci sledování, tzn. přesnější by byly namísto kvartálních dat, data měsíční. Dalším návrhem je konstrukce nového modelu s jinými determinanty. Model pracuje převážně z makroekonomickými daty, tudíž lze sestavit model s jinými determinanty jako např. region, vlastnictví, počet pokojů, přítomnost lodžie atp.

SEZNAM POUŽITÉ LITERATURY

CIPRA, Tomáš. Finanční ekonometrie. 2., upr. vyd. Praha: Ekopress, 2013. ISBN 978-80-86929-93-4.

ČNB, 2019a. Zpráva o finanční stabilitě 2018/2019. 130.

ČNB, 2019b. *Zpráva o inflaci 2019*. 2019.

ČNB, 2020a. *ARAD - Systém časových řad - Česká národní banka* [online] [vid. 2020-03-24]. Dostupné

z: https://www.cnb.cz/cnb/STAT.ARADY_PKG.PARAMETRY_SESTAVY?p_strid=ACHAB&p_sestuid=21751&p_tab=2&p_lang=CS

ČNB, 2020b. *Úloha měnové politiky - Česká národní banka* [online] [vid. 2020-03-17]. Dostupné z: <https://www.cnb.cz/cs/menova-politika/uloha/>

ČSÚ, 2004. Metodické vysvětlivky. *METODICKÉ VYSVĚTLIVKY V předklá* [online] [vid. 2020-03-25]. Dostupné z: https://www.czso.cz/csu/czso/13-2103-04--metodicke_vysvetlivky

ČSÚ, 2019a. Index cen bytových nemovitostí (House Price Index) - 3. čtvrtletí 2019. *Index cen bytových nemovitostí (House Price Index) - 3. čtvrtletí 2019* [online] [vid. 2020-03-23]. Dostupné z: <https://www.czso.cz/csu/czso/index-cen-bytovych-nemovitosti-house-price-index-3-ctvrtleti-2019>

ČSÚ, 2019b. Pohyb obyvatelstva - rok 2018. *Pohyb obyvatelstva - rok 2018* [online] [vid. 2020-03-25]. Dostupné z: <https://www.czso.cz/csu/czso/cri/pohyb-obyvatelstva-rok-2018>

ČSÚ, 2019c. Věková struktura populace se výrazně mění. *Věková struktura populace se výrazně mění* [online] [vid. 2020-03-24]. Dostupné z: <https://www.czso.cz/csu/czso/vekova-struktura-populace-se-vyrazne-meni>

ČSÚ, 2020a. 3.2.1 Ekonomická aktivita obyvatel. *3.2.1 Ekonomická aktivita obyvatel* [online] [vid. 2020-03-21]. Dostupné z: https://www.czso.cz/csu/czso/13-1134-07-2006-3_2_1_ekonomicka_aktivita_obyvatel

ČSÚ, 2020b. Aktuální populační vývoj v kostce. *Aktuální populační vývoj v kostce* [online] [vid. 2020-03-23]. Dostupné z: <https://www.czso.cz/csu/czso/aktualni-populacni-vyvoj-v-kostce>

ČSÚ, 2020c. Stavebnictví - metodika. *Stavebnictví - metodika* [online] [vid. 2020-03-28]. Dostupné z: https://www.czso.cz/csu/czso/10n1-05-_2005-stavebnictvi___metodika

DVOŘÁK, Petr, Martin MANDEL, Zbyněk REVENDA, Petr MUSÍLEK a Jan KODERA, 2015. *Peněžní ekonomie a bankovníctví*. B.m.: Albatros Media a.s. ISBN 978-80-7261-303-8.

HLAVÁČEK, Michal a Luboš KOMÁREK, 2009. *Housing Price Bubbles and their Determinants in the Czech Republic and its Regions*. 2009. B.m.: ČNB.

HLAVÁČEK, Michal a Luboš KOMÁREK, 2010. Rovnovážnost cen nemovitostí v České republice. *Politická ekonomie* [online]. 2010, 326–342. Dostupné z: doi:10.18267/j.polek.733

- KOČENDA, Evžen a Alexandr ČERNÝ. Elements of Time Series Econometrics: an Applied Approach [online]. 2nd edition. Prague: Karolinum, 2016 [cit. 2020-12-06]. ISBN 978-80-246-3198-1. Dostupné z: https://www.cupress.cuni.cz/ink2_ext/index.jsp?include=podrobnosti&id=262746
- SOMOGYI, Tomáš, 2019. ANALÝZA VÝVOJE CEN NEMOVITOSTÍ V ČR [online]. 2019. B.m.: ČBA. Dostupné z: <https://cbaonline.cz/upload/371-studie-cba-2019.pdf>
- VŠPS, 2020. Míra ekonomické aktivity [online] [vid. 2020-03-24]. Dostupné z: <http://www.dvmonitor.cz/system-indikatoru/metodika-vsech-indikatoru?id=28>
- WOOLDRIDGE, Jeffrey M. Introductory econometrics: a modern approach. Sixth edition. Boston: Cengage Learning, [2016]. ISBN 978-1-305-27010-7.

SEZNAM GRAFŮ

Graf 1: Průměrná hrubá měsíční mzda v ČR	8
Graf 2: Zadluženost domácností v ČR	9
Graf 3: Vývoj vybraných úrokových sazeb a inflace	10
Graf 4: Vývoj HPI v ČR	11
Graf 5: Míra ekonomické aktivity	12
Graf 6: Míra nezaměstnanosti dle pohlaví	13
Graf 7: Přirozený přírůstek ČR.....	14
Graf 8: Migrační saldo ČR.....	15
Graf 9: Počet sňatků a rozvodů v ČR	16
Graf 10: Ceny nájemného v ČR	17
Graf 11: Ceny stavebních pozemků v ČR.....	19
Graf 12: Počet zahájených a dokončených bytů v ČR	20
Graf 13: Ceny stavebních prací v ČR	21

SEZNAM TABULEK

Tabulka 1: Indexy cen vybraných nemovitostí v ČR12

Tabulka 2: Tabulka proměnných **Chyba! Záložka není definována.**

SEZNAM OBRÁZKŮ

Obrázek 1: OLS Model 1.....	30
Obrázek 2: OLS model 2.....	31
Obrázek 3: Ramsey RESET test.....	32
Obrázek 4: Whiteův test heteroskedasticity.....	34
Obrázek 5: Test normality.....	35
Obrázek 6: ARMA model 1.....	36
Obrázek 7: ARMA model 2.....	37
Obrázek 8: Grafy autokorelačních funkcí.....	38
Obrázek 9: Test autokorelace Ljung-Box.....	39
Obrázek 10: ARCH test heteroskedasticity	40

PŘÍLOHY

Příloha č. 1 ADF test stacionarity

Rozšířený Dickey-Fullerův test pro ApartPrice
testing down from 9 lags, criterion AIC
počet pozorování 39
nulová hypotéza jednotkového kořenu: $a = 1$

s konstantou a trendem
s použitím 0 zpožděných proměnných $(1-L)ApartPrice$
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + e$
odhadovaná hodnota $(a - 1)$: $-0,904684$
testovací statistika: $\tau_{ct}(1) = -5,30422$
p-hodnota $0,0005331$
autokorelační koeficient 1. řádu pro e : $-0,075$

Rozšířený Dickey-Fullerův test pro LandPrice
testing down from 9 lags, criterion AIC
počet pozorování 38
nulová hypotéza jednotkového kořenu: $a = 1$

s konstantou a trendem
s použitím jedné zpožděné proměnné $(1-L)LandPrice$
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota $(a - 1)$: $-0,405316$
testovací statistika: $\tau_{ct}(1) = -4,1662$
asymptotická p-hodnota $0,00496$
autokorelační koeficient 1. řádu pro e : $0,102$

Rozšířený Dickey–Fullerův test pro finished
testing down from 9 lags, criterion AIC
počet pozorování 35
nulová hypotéza jednotkového kořenu: $a = 1$

s konstantou a trendem
s použitím 4 zpožděných proměnných $(1-L)finished$
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota $(a - 1)$: -1,32208
testovací statistika: $\tau_{ct}(1) = -4,43681$
asymptotická p-hodnota 0,001855
autokorelační koeficient 1. řádu pro e: -0,015
zpožděné difference: $F(4, 28) = 2,528 [0,0629]$

Rozšířený Dickey–Fullerův test pro ld_unemployment
testing down from 9 lags, criterion AIC
počet pozorování 35
nulová hypotéza jednotkového kořenu: $a = 1$

test s konstantou
s použitím 3 zpožděných proměnných $(1-L)ld_unemployment$
model: $(1-L)y = b_0 + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota $(a - 1)$: -0,981664
testovací statistika: $\tau_c(1) = -4,9463$
asymptotická p-hodnota 2,626e-05
autokorelační koeficient 1. řádu pro e: -0,069
zpožděné difference: $F(3, 30) = 6,304 [0,0019]$

Rozšířený Dickey-Fullerův test pro ld_avrgwage
testing down from 9 lags, criterion AIC
počet pozorování 36
nulová hypotéza jednotkového kořenu: $a = 1$

test s konstantou
s použitím 2 zpožděných proměnných $(1-L)ld_avrgwage$
model: $(1-L)y = b_0 + (a-1)*y(-1) + \dots + e$
odhadovaná hodnota $(a - 1)$: -1,47123
testovací statistika: $\tau_c(1) = -3,36838$
asymptotická p-hodnota 0,01212
autokorelační koeficient 1. řádu pro e: 0,108
zpožděné diference: $F(2, 32) = 4,759 [0,0155]$

Rozšířený Dickey-Fullerův test pro ld_REP0
testing down from 9 lags, criterion AIC
počet pozorování 38
nulová hypotéza jednotkového kořenu: $a = 1$

test s konstantou
s použitím 0 zpožděných proměnných $(1-L)ld_REP0$
model: $(1-L)y = b_0 + (a-1)*y(-1) + e$
odhadovaná hodnota $(a - 1)$: -0,807188
testovací statistika: $\tau_c(1) = -4,93574$
p-hodnota 0,0002575
autokorelační koeficient 1. řádu pro e: -0,042

