

VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE

Fakulta financí a účetnictví

Katedra bankovníctví a pojišťovnictví

DIPLOMOVÁ PRÁCE

2020

Bc. Jana Sotáková

VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE

Fakulta financí a účetnictví

Katedra bankovníctví a pojišťovnictví

Studijní obor: Finance

**Analýza faktorov pôsobiacich na hypotekárny
trh v ČR**

Autor diplomové práce:

Bc. Jana Sotáková

Vedoucí diplomové práce:

doc. RNDr. Jarmila Radová, Ph.D.

Rok obhajoby:

2020

Čestné prohlášení

Prohlašuji, že jsem diplomovou práci na téma „Analýza faktorov pôsobiacich na hypotekárny trh v ČR“ vypracovala samostatně a veškerou použitou literaturu a další prameny jsem řádně označila a uvedla v příloženém seznamu.

V Praze dne 28.1.2020

.....
Bc. Jana Sotáková

Pod'akovanie

Touto cestou chcem úprimne pod'akovať doc. RNDr. Jarmile Radovej, Ph.D za ústretovosť, cenné rady a odborné vedenie diplomovej práce. Taktiež ďakujem Mgr. Milanovi Baštovi, Ph.D za ochotu, pripomienky a čas, ktorý mi venoval počas vypracovania praktickej časti práce.

Abstrakt

Cieľom diplomovej práce je odhadnúť silu a smer vplyvu každého z vybraných faktorov na objem novoposkytnutých hypotekárnych úverov. Prvá kapitola popisuje históriu hypotekárneho úveru, jeho základné charakteristiky a špecifiká, vplyv centrálnej banky a situáciu v priebehu finančnej krízy. Druhá kapitola poukazuje na dominantné faktory, ktoré vedú k zmene objemu novoposkytnutých hypotekárnych úverov. Postupne analyzujem časové rady od prvého kvartálu roku 2005 do druhého kvartálu roku 2019, zisťujem závislosť na minulých pozorovaniach a identifikujem model, ktorý by tieto súvislosti popísal. Súčasťou kapitoly je taktiež zhodnotenie vzťahu medzi skúmaným faktorom a objemom hypoték. Zo zistení vyplýva, že väzby medzi veličinami sú veľmi diskutabilné a vzťahy medzi dvoma premennými sú zjednodušením skutočností a preto som v tretej časti použila účinnejšiu metódu: viacnásobnú lineárnu regresiu.

Kľúčové slová

hypotekárny úver, HDP, nezamestnanosť, priemerná mzda, cena nehnuteľností, úroková sadzba, inflácia, viacnásobná lineárna regresia

Abstract

The thesis aims to estimate the impact of mortgage market factors. The first chapter describes the history of the mortgage loan, its basic characteristics and specifics, the influence of the central bank and the situation during the financial crisis. The second chapter points to the dominant factors that lead to a change in the volume of newly granted mortgage loans. Gradually I analyze the time series from the first quarter of 2005 to the second quarter of 2019. I find out the coherence of past observations and identify a model that would describe these connections. The chapter also includes an evaluation of the relationship between the investigated factor and the volume of mortgages. To capture the complexity of the data, I used a more efficient method in the third part: multiple linear regression.

Key words

mortgage credit, GDP, unemployment, average wage, real estate price, interest rate, inflation, multiple linear regression

Zoznam skratiek

ACF	Autokorelačná funkcia
ADF	Dickey-Fuller test
AIC	Akaikeho informačné kritérium
AR(p)	Autoregresný proces radu p
ARMA(p, q)	Proces radu p, q
Atd’.	A tak ďalej
a.s.	Akciová spoločnosť
CRA	Community Reinvestment Act
ČNB	Česká národná banka
CPI	Index spotrebiteľských cien
ČSÚ	Český statistický úrad
ČR	Česká republika
EU	Európska únia
HDP	Hrubý domáci produkt
Kč	Česká koruna
LTV	Loan to value = „úver k hodnote“
MA(q)	Proces kľzavých priemerov radu q
Mld.	Miliarda
Napr.	Napríklad
PACF	Parciálna autokorelačná funkcia
PPI	Index cien výrobcov
Tis.	Tisíc
USA	Spojené štáty americké

Obsah

Úvod	9
1 Hypotekárne bankovníctvo v ČR	11
1.1 História hypotekárneho úveru	11
1.2 Základné charakteristiky hypotekárneho úveru	14
1.3 Špecifika hypotekárneho úveru	15
1.4 Vplyv CB na trh hypotekárnych úverov	16
1.5 Hypotekárny trh v priebehu finančnej krízy	19
2 Faktory pôsobiace na objem novoposkytnutých úverov	21
2.1 Postup pri konštrukciách predpovedí	21
2.2 Hrubý domáci produkt	22
2.2.1 Analýza časovej rady HDP	26
2.2.2 Miera nezamestnanosti.....	30
2.2.3 Analýza časovej rady všeobecnej miery nezamestnanosti.....	33
2.3 Priemerná mzda.....	37
2.3.1 Analýza časovej rady priemernej hrubej mzdy.....	39
2.4 Cena nehnuteľností.....	43
2.4.1 Analýza časovej rady indexu cien nehnuteľností	45
2.5 Úroková sadzba	48
2.5.1 Analýza časovej rady váženej priemernej úrokovej sadzby	50
2.6 Inflácia.....	54
2.6.1 Analýza časovej rady inflácie	56
3 Viacnásobná lineárna regresia.....	60
Záver.....	65
Zoznam použitej literatúry a prameňov.....	68

Zoznam obrázkov a grafov	73
--------------------------------	----

Úvod

Hypotéky sú veľmi populárne a stále ide o aktuálnu tému. V súčasnosti sme svedkami veľkého dopytu po nehnuteľnostiach, čo vyústilo k nedostatku voľných bytov a rastu ich cien. Hypotekárny úver je najčastejším spôsobom, ako si ľudia môžu zabezpečiť vlastné bývanie. V Českej republike sa za synonymum vlastníctva nehnuteľností považuje bezpečné uloženie financií. Keďže ide o dlhodobý záväzok je potrebné mať základný prehľad aby sme mohli zhodnotiť či je ten správny čas na kúpu. K tomu aby sme boli schopní posúdiť situáciu je potrebné taktiež vedieť, ktoré faktory trh ovplyvňujú, aby sme zbytočne neurobili zlé rozhodnutie a nevystavili sa nepríjemnostiam. Domácnosti považujú vlastné bývanie za svoj najdôležitejší statok, ktorý je ideálnou investíciou pre zaistenie v starobe.

Diplomovú prácu som rozpracovala v troch kapitolách, pričom v prvej som sa venovala teórii a zvyšné dve sú praktické. Cieľom je odhadnutie vplyvu vybraných faktorov na objem novoposkytnutých hypoték.

Prvá kapitola sa venuje histórii hypotekárneho úveru, jeho charakteristikám a špecifikám, vplyvu centrálnej banky a situácii v priebehu finančnej krízy. Aby sme boli schopní pochopiť súčasný stav hypotekárneho trhu, považujem za dôležité poznať aj históriu. Historické dáta nám môžu pomôcť s identifikáciou faktorov, ktoré spôsobujú zmeny v objeme hypoték, v cenách nehnuteľností, v dopyte zo strany domácnosti atď. V tejto práci história pokrýva obdobie od roku 1865 kedy bola založená prvá hypotekárna banka na území Českej republiky až po súčasnosť. Následne sa zaoberám členení hypotekárnych úverov podľa základných kritérií: podľa účelu, spôsobu splácania, žiadateľa a splatnosti. Čitateľ sa môže taktiež dozvedieť o špecifikách hypotekárneho úveru, o transmisnom mechanizme, o príčinách globálnej finančnej krízy a faktoroch, ktoré nám v Českej republike pomohli krízu prekonať.

Cieľom druhej kapitoly je popísať vplyv na objem hypoték každého zo zvolených faktorov zvlášť a taktiež vytvorenie modelu, ktorý by bol vhodný k predpovedi ďalšieho vývoja daného analyzovaného faktoru.

Cieľom tretej kapitoly je komplexnejší model, pozostávajúci zo všetkých mnou analyzovaných nezávislých premenných, ktorý popíše veľkosť a smer vplyvu na závislú premennú, ktorou je objem hypoték.

Pri analýze som využila dáta z verejne dostupných zdrojov ako sú : ČNB, ČSÚ, Ministerstvo pro místní rozvoj ČR, stránka kurzy.cz a Hypoindex.cz. Modely sú vytvárané v štatistickom softvéri EViews 10. Na vytvorenie tabuliek a grafov som použila Excel.

1 Hypotekárne bankovníctvo v ČR

V prvej kapitole je pozornosť venovaná histórii hypotekárneho úveru, jeho základným charakteristikám a špecifikám, vplyvu centrálnej banky a situácii v priebehu finančnej krízy.

V Českej republike sa za synonymum vlastníctva bývania považuje bezpečné uloženie financií. Domácnosti ho považujú za svoj najdôležitejší statok, ktorý chápu ako ideálnu investíciu pre zaistenie v starobe. K popularite prispieva nereformovaný penzijný systém, nerozvinutý kapitálový trh a averzia k menovému riziku.

V súčasnosti sme svedkami veľkého dopytu po nehnuteľnostiach, čo vyústilo k nedostatku voľných bytov a rastu ich cien. Zavedením doporučení zo strany ČNB dochádza však k postupnej filtrácii tých žiadateľov, ktorí nevyhovujú podmienkam získania úveru (Somogyi, 2019).

1.1 História hypotekárneho úveru

Prvou hypotekárnou bankou na území ČR bola Hypoteční banka Království českého založená v roku 1865 ako verejnoprávna inštitúcia bez zárobkových tendencií. Jej cieľom bolo najmä zlepšenie vtedajších úverových možností – predovšetkým poskytovaním dlhodobých úverov poľnohospodárskym podnikateľom (Kalabis, 2013). V roku 1890 nasledovalo založenie Zemskej banky Království českého, ktorej hlavnou činnosťou bolo poskytovanie železničných, komunálnych a melioračných úverov. V šesťdesiatych rokoch 19. stor. v čase dynamického rozvoja všetkých oblastí hospodárstva mali hypotekárne banky významnú úlohu, avšak krízu v roku 1873 mnohé z nich nezvládli. Kríza spojená s odlivom finančných prostriedkov z bánk sa prejavila taktiež stratou dôvery veriteľov v hypotekárne záložné listy. Pred prvou svetovou vojnou existovalo na našom území 6 zemských a hypotekárnych bánk, v medzivojnovom období klesol počet na štyri:


- *Zemská banka* (do roku 1920 *Zemská banka Království českého*) poskytovala hypotekárne úvery len v malej miere. V roku 1941 došlo k zlúčeniu *Zemskej banky* s *Hypoteční bankou českou*, o dva roky neskôr taktiež s *Ústřední bankou českých spořitelén*. Všetko vyvrcholilo v roku 1948 vznikom *Investičnej banky* po zlúčení s ďalšími tromi ústavmi. Jej náplň spočívala vo financovaní a úverovaní výstavby národných podnikov a družstiev a taktiež

financovaní prevádzky stavebne - montážnych organizácií. Neskôr banke ostala len správa a úschova cenných papierov.

- *Hypoteční a zemědělská banka moravská*, ktorá vznikla v roku 1922 a v roku 1941 bola zlúčená so *Zemědělskou bankou moravskou* v *Zemskou banku pro Moravu*. Predovšetkým sa zameriavala na rozvoj infraštruktúry a úverové operácie spojené s pozemkovou reformou.
- *Slezský pozemkový a komunální úvěrní ústav* (vznik v roku 1927)
- *Hypoteční banka česká* (do roku 1921 s názvom *Hypoteční banka Království českého*), ktorá mala významné postavenie, pretože za jej transakcie ručil štát (Čechlovská, 2005, s. 90-93).

Druhá svetová vojna mala na hypotekárny trh veľmi negatívny dopad – hypotéky prestali existovať. Obnovenie nastalo až v roku 1990, úvery však boli poskytované až v roku 1995 kvôli nefunkčnému kapitálovému trhu a taktiež nedostatočnému právnomu zázemiu. Do roku 2000 rástol objem novoposkytnutých úverov veľmi pomaly, čo bolo spôsobené vysokými úrokmi okolo 11-12%. Ďalším dôvodom bola neznalosť podmienok, nedôvera v nový produkt, malé skúsenosti s touto formou financovania bývania a taktiež vysoké ceny nehnuteľností.

Graf 1: Objem novoposkytnutých úverov (tis. Kč)



Zdroj: Ministerstvo pro místní rozvoj ČR (©2019), vlastné spracovanie

Graf 1 znázorňuje objem novoposkytnutých úverov (v tis. Kč) domácnostiam v období 2005Q1-2019Q3. V roku 1997 ceny vykazovali rastúci trend a súčasne sa zvyšovali úrokové sadzby, došlo teda k poklesu záujmu o hypotéky. V roku 1999 sa prelomil trend vo vývoji priemernej úrokovej sadzby kedy výrazne poklesla. ČNB

uvoľnila menovú politiku aby vytvorila ekonomický rast a znížila diskontnú sadzbu. Zatiaľ čo v roku 1999 sa pohybovali priemerné úrokové sadzby okolo 10,3%, v roku 2000 klesli na úroveň 8,4%. Rok 2000 sa vyznačoval vysokým záujmom o hypotéky keďže úrokové sadzby naďalej klesali. Vstupom nových bánk na trh sa zvýšila konkurencieschopnosť, znížila sa hranica príjmov pre získanie úverov a bola poskytovaná štátna podpora vo výške 4 percentných bodov. V roku 2001 poklesli priemerné úrokové sadzby na 7% a *Česká spořitelna a.s.* predstavila produkt *TOP bydlení* v rámci ktorého boli úrokové sadzby dotované. Podpora štátu klesla zo 4% na 2%. Rastúci trend objemu novoposkytnutých hypotekárnych úverov pokračoval aj v roku 2002, kedy boli na trh uvedené nové produkty – medzi najznámejšie patrí hypotekárny úver poskytnutý do celkovej ceny zástavy. Za zmienku určite stojí aj nová forma štátnej podpory pre mladých žiadateľov do 36 rokov. V roku 2003 boli už hypotekárne úvery vnímané ako štandardný nástroj k nadobudnutiu bývania. Pred vstupom ČR do Európskej únie panovali obavy zo zdraženia nehnuteľností a tak rástol objem a rozvíjali sa developerské projekty. Štátna podpora sa znížila u nového bývania na nulu a u staršieho bývania na dva percentné body. Rok 2004 priniesol mnohé novinky ako napríklad poskytovanie hypoték v zahraničí, cudzincom, zaistenie úveru nehnuteľnosťou, ktorá sa nachádza na území Európskej únie alebo možnosť fixácie úrokových sadzieb na obdobie od jedného do 30 rokov. Objem hypoték rástol keďže pretrvával prajný vývoj úrokových sadzieb, rástli mzdy a zvyšovala sa ponuka novopostavených bytov. V rokoch 2009-2010 dolieha na ekonomiku americká hypotekárna kríza čo spôsobilo pozastavenie developerských projektov, ukončenie poskytovania úverov bez dokladovania príjmov a do plnej ceny zástavy. Objem novoposkytnutých úverov sa rapídne znížil. Po týchto dvoch rokoch útlmu úrokové sadzby klesajú na historické minimum a objem úverov rastie (*Partners*, 2012). Rok 2016 bol rekordný: maximálny objem úverov poskytnutých domácnostiam vo výške približne 219 mld. Kč a najnižšia úroková sadzba v histórii 1,78%. Trh bol motivovaný pozitívnou ekonomickou situáciou a taktiež očakávanými dôležitými udalosťami. Prvou bolo odporúčenie ČNB o vydaní obmedzenia na LTV u úveroch na maximálnu možnú hranicu 95 percent a s tým aj spojené nariadenie, že banky nesmú poskytnúť viac hypoték v pásme 85-95% LTV než je 10% z celkového objemu nimi poskytnutých hypotekárnych úverov. Druhou

udalosťou bolo schválenie nového zákona o spotrebiteľských úveroch, ktorý výrazne upravuje podmienky pre uzatváranie a splácanie úveru. Na základe neho si poskytovateľ musí svedomito preveriť bonitu žiadateľa napr. jeho príjmy, výdaje, ako splácal doterajšie záväzky atď. (Pokorná, 2018). V roku 2017 došlo k poklesu objemu novoposkytnutých úverov v dôsledku rastu cien nehnuteľností, rastu úrokových sadzieb a obmedzeniu dostupnosti hypoték zo strany ČNB na 80% LTV. V roku 2018 napriek rastúcim cenám nehnuteľností a rastu úrokových sadzieb chcú ľudia investovať do vlastného bývania. Okrem spomínaných nepriaznivých faktorov ČNB v októbri zaviedla nové nariadenia, podľa ktorých objem všetkých úverov žiadateľa o hypotéku nemôže byť väčší ako deväťnásobok ročného čistého príjmu a zároveň mesačná splátka nemôže presiahnuť 45% mesačného príjmu. Záujem o hypotekárne úvery v roku 2019 klesol v dôsledku sprísnených podmienok keďže mnoho ľudí na ne nedosiahne a taktiež rolu zohrali vysoké ceny nehnuteľností (hypio, 2018).

1.2 Základné charakteristiky hypotekárneho úveru

Hypotekárne úvery je možné členiť podľa mnohých kritérií. Najčastejšie delenie je podľa účelu, spôsobu splácania, žiadateľa alebo splatnosti.

- Podľa účelu existujú dva typy hypoték: *účelová* a *neúčelová*. Účelový hypotekárny úver je možné používať len k účelom spojených s bývaním a to napr. na stavbu, kúpu či rekonštrukciu. Splácanie je zaistené záložným právom k tejto alebo inej nehnuteľností. Neúčelová hypotéka je známa pod názvom americká hypotéka a je ju možné využiť na čokoľvek. U tohto typu úveru sa zvyknú banke predkladať iba príjmy žiadateľa a údaje o nehnuteľností, ktorá bude slúžiť ako zástava.
- Hypotéky podľa spôsobu splácania delíme na úvery s *anuitným*, *progresívnym* alebo *degresívnym* splácaním. Najčastejším typom splácania je anuitnou splátkou, ktorá je po celú dobu fixácie úrokovej sadzby v rovnakej výške a zahrňuje úrok aj splátku istiny. Pri progresívnom splácaní sa klientovi zvyšuje veľkosť splátky po dobu splácania. Počas jedného roku je mesačná splátka rovnaká a pre nasledujúce obdobie sa zvyšuje o pevný koeficient rastu. Tento typ je výhodný napríklad pre mladých, ktorí na začiatku kariéry nemajú vysoké príjmy. Pri degresívnom splácaní sa výška

splátky postupne znižuje. Počas jedného roku je rovnaká a pre nasledujúce obdobie sa znižuje o pevný koeficient poklesu (kurzycz, ©2000–2020)

- Podľa toho, kto o úver žiada rozlišujeme hypotéky poskytnuté *fyzickým osobám, právnickým osobám, podnikateľom, obciam alebo mestám*.
- Podľa kritéria splatnosti rozlišujeme *krátkodobé, strednodobé a dlhodobé* hypotéky (Novotný, 2009). Úver určený len na bývanie môžeme splácať až po dobu 30 rokov, americká hypotéka sa poskytuje na maximálne 15-20 rokov. Čím dlhšiu dobu splatnosti si zvolíme, tým budeme mať nižšie splátky a vyššie celkové úrokové náklady. Existuje mnoho kombinácii spôsobov splácania. Navyše zákon č. 257/2016 Sb. o spotrebiteľskom úvere umožňuje predčasne splatiť hypotéku a to napríklad zdarma behom jedného mesiaca pred výročím uzatvorenia zmluvy (až 25% z celkovej čiastky), zdarma v prípade ťažkých životných situácií (až 100%) alebo s poplatkom 1%, maximálne však 50000Kč v prípade predaja nehnuteľnosti.

Výška hypotekárneho úveru by nemala prevýšiť hodnotu zástavy (Bardová, Opltová a Pavelka, 1997) . Podľa doporučení Českej národnej banky by banky mali poskytovať úver maximálne vo výške 80% hodnoty zastavenej nehnuteľností, 9 násobku čistého ročného príjmu a zároveň mesačná splátka nemôže prekročiť 45% čistého mesačného príjmu.

1.3 Špecifika hypotekárneho úveru

Základným charakteristickým rysom hypotekárnych úverov je ich zaistenie záložným právom k nehnuteľnostiam, ktoré oprávňuje veriteľa uspokojiť svoju pohľadávku z výnosu z predaja nehnuteľností, v prípade, že dlžník nebude plniť svoje záväzky (Radová, Dvořák a Málek, 2013, s. 182).

Od klasických úverov sa odlišujú najmä spomínaným zaistením, dĺžkou obdobia, na ktoré sú zjednané a nižším úročením, ktoré vyplýva z ich nízkej rizikovosti. Ide o jednu z najkvalitnejších záruk, ktoré môže banka získať od klientov a vzhľadom k tomu, že sa jedná o ich cenný majetok snažia sa plniť záväzky voči banke, ktorá je v pozícii veriteľa (Novotný, 2009). Navyše ide o veľmi transparentnú a ľahko overiteľnú zástavu.

U špecializovaných bánk sa k vyššie spomenutým charakteristikám radí taktiež špecifický spôsob refinancovania prostredníctvom emisie hypotekárnych záložných listov¹.

Ďalším špecifikom z pohľadu hypotekárnych bánk je podstúpené riziko, ktoré je spojené s výškou úveru v pomere k hodnote zastavenej nehnuteľností, s výškou zjednaných splátok v pomere k príjmu klienta a taktiež s dobou splatnosti. Čím vyššia bude nesplatená hypotéka v pomere k zastavenej nehnuteľnosti, čím vyššia bude splátka v pomere k príjmu dlžníka a čím dlhšia bude doba splatnosti, tým vyššie riziko banka podstupuje.

Tento vzťah môžeme popísať:

$$R_{HB} = f\left(\frac{HÚ}{HN}; \frac{S}{P}; DS\right) \quad (1.1)$$

kde	R_{HB}	riziko hypotekárnej banky,
	$HÚ$	výška nesplateného hypotekárneho úveru,
	HN	hodnota zastavenej nehnuteľnosti,
	S	výška splátok,
	P	výška príjmu dlžníka,
	DS	doba do splatnosti hypotekárneho úveru.

Z pohľadu klienta sa za výhodu považuje nízka úroková miera a nevýhodu vyššia administratívna náročnosť oproti iným úverom. Podmienkou je vlastníctvo nehnuteľnosti, ktorú banka považuje za prijateľnú na zástavu. Preferuje nehnuteľností určené k bývaniu, stavebné pozemky určené k výstavbe, administratívne budovy atď. Medzi najmenej prijateľný spôsob zaistenia patria napríklad výrobné haly, ktoré sú málo likvidné (Čechlovská, 2005, s. 75-78).

1.4 Vplyv CB na trh hypotekárnych úverov


Centrálna banka plní radu funkcií: emisnú funkciu, funkciu banky štátu, banky bánk, regulácie bankového systému, správcu devízových rezerv štátu, reprezentanta štátu v menovej politike atď. Medzi jej najdôležitejšie činnosti patrí menová politika. Celý proces menovej politiky sa nazýva transmisný mechanizmus a znázorňuje ho

¹ Zdroje refinancovania sa líšia podľa hypotekárneho veriteľa. Čechlovská (2005) vo svojej práci na základe dostupných dát predpokladá, že v prípade univerzálnych bánk prevláda refinančný zdroj v podobe klientskych vkladov a u špecializovaných bánk prevláda emisia hypotekárnych záložných listov.

obrázok 1. Centrálna banka nemá priamy vplyv na konečné ciele menovej politiky. Ich dosiahnutie je podmienené:

- schopnosťou centrálnej banky ovplyvniť pomocou svojich nástrojov operatívne kritérium,
- stabilnými väzbami medzi vývojom operatívneho a sprostredkujúceho kritéria,
- stabilnými väzbami medzi vývojom operatívneho a sprostredkujúceho kritéria (Revenda, 2011).

Obrázok 1: Transmisný mechanizmus menovej politiky v tržnej ekonomike



Zdroj: Revenda (2011, s. 70), vlastné spracovanie

Trh hypotekárnych úverov je v rámci plnenia makroekonomických cieľov centrálnej banky nepriamo ovplyvňovaný najmä prostredníctvom úverového transmisného mechanizmu². Centrálna banka sa usiluje svojimi nástrojmi ovplyvniť operatívne kritérium, ktorým je tržná krátkodobá úroková miera. Prostredníctvom operatívneho kritéria sa snaží ovplyvniť sprostredkujúce kritérium, ktorým je úverový agregát a to bude viesť k dosiahnutiu konečného cieľa menovej politiky. Sprostredkujúcim kritériom v závislosti na konečnom celi menovej politiky môže byť : celkový stav úverov v domácej mene v ekonomike, celkový stav bankových úverov v domácej mene v ekonomike, strednodobá úroková miera z úverov, dlhodobá úroková miera z úverov alebo potenciálne úverové zdroje bank v domácej mene (Čechlovská, 2005, s. 106-113).

² Transmisné mechanizmy menovej politiky centrálnej banky členíme na menový, úverový a kurzový transmisný mechanizmus.

Dlhodobá úroková miera z úverov je podstatným sprostredkujúcim kritériom pre posúdenie vplyvu menovej politiky na trh hypotekárnych úverov. Úverový transmisný mechanizmus, vo forme v akej je zobrazený na *obrázku 2* sa nazýva úrokový transmisný mechanizmus.

Obrázok 2: Úrokový transmisný mechanizmus



Zdroj: Čechlovská (2011), vlastné spracovanie

Konečným cieľom je rast nominálneho hrubého domáceho produktu. Nasledujúci *obrázok 3* predstavuje základné nástroje menovej politiky centrálnej banky a ich vplyv na operatívne kritérium: krátkodobú úrokovú sadzbu.

Obrázok 3: Nástroje centrálnej banky a ich vplyv na tržnú krátkodobú úrokovú mieru

Nástroj menovej politiky CB	Operácie CB	Pohyb krátkodobej úrokovej miery
Operácie s cennými papiermi	Nákup	Pokles
	Predaj	Rast
Základné úrokové sadzby vyhlasované CB	Zvýšenie	Rast
	Zníženie	Pokles
Devízové operácie	Nákup devíz	Pokles
	Predaj devíz	Rast
Povinné minimálne rezervy	Zvýšenie	Rast
	Zníženie	Pokles
Limity úverov bank	Zvýšenie	Pokles
	Zníženie	Rast
Limity úrokov z úverov poskytovaných OB	Zvýšenie	Rast
	Zníženie	Pokles
Horné limity úrokov z vkladov prijatých OB	Zvýšenie	Rast
	Zníženie	Pokles
Dolné limity úrokov z vkladov prijatých OB	Zvýšenie	Rast
	Zníženie	Pokles

Zdroj: Čechlovská (2011), vlastné spracovanie

Ak centrálna banka ovplyvní krátkodobú úrokovú mieru, potom záleží na úspešnosti transmisného mechanizmu v akej miere zareaguje na to dlhodobá úroková

miera a aký bude mať dopad na ponuku a dopyt po úveroch. Predpokladá sa, že rast krátkodobej úrokovej miery vedie k rastu úrokovej miery hypotekárnych úverov.

ČNB k dosiahnutiu jej hlavného cieľa, ktorým je cenová stabilita, využíva cieľovanie inflácie. Ide o modifikovaný transmisný mechanizmus, kde nástrojom je dvoj týždenná repo sadzba, operatívnym kritériom je tržná krátkodobá úroková sadzba a sprostredkujúce kritérium nemá. Takýmto spôsobom nepriamo ovplyvňuje hypotekárny trh (Čechlovská, 2005, s. 106-113).

1.5 Hypotekárny trh v priebehu finančnej krízy

Hypotéka ako nástroj k financovaniu bývania nebola príčinou globálnej finančnej krízy. Príčiny sú viazané so silnými intervenciami a činnosťou vládnych inštitúcií, ktoré sa snažili prostredníctvom hypotekárnych úverov zvýšiť dostupnosť bývania slabším vrstvám obyvateľstva, ktoré by na to za bežných okolností nemali finančné prostriedky. To bolo podporované v rámci v zákone stanoveným CRA (Community Reinvestment Act), ktorý bol pod kontrolou a silnými regulačnými pravidlami. Počas Clintonovej vlády došlo k výraznému uvoľneniu týchto pravidiel. V roku 2000 bola zavedená sekuritizácia hypoték, ktorá mala podporu štátu a predstavovala zaujímavú príležitosť pre investorov. Tieto inštrumenty boli zaistené cez hypotéku nehnuteľnosťami. Banky a investori očakávali pokračujúci rast cien nehnuteľností – od začiatku roka 2000 do konca roku 2006 v USA ceny nehnuteľností vzrástli o viac než 170%. Vznikali subprime hypotéky, neustále sa stavalo nové bývanie a pretrvávala eufória. Ľudia boli lákaní na lacné hypotéky v 100% výške hodnoty nehnuteľností a to aj v prípade, že nemali stabilné príjmy. Systém sa prehriat, bublina praskla a začiatkom roku 2007 prichádzali signály, že niečo nie je v poriadku pretože ceny nehnuteľností začali padať a ľudia strácali schopnosť splácať záväzky. Finančné inštitúcie si nepripúšťali krízu a naďalej obchodovali s hypotekárnymi derivátmi, ktoré boli zaistené subprime hypotékami s nereálnou hodnotou nehnuteľností a neschopnosťou dlžníka splácať. Banky balili deriváty do portfólií, ktoré prezentovali ako prvotriedne cenné papiere aby ich mohli výhodne prediť (Ostatek, 2010). Ceny nehnuteľností výrazne poklesli, čo vyústilo vo veľký problém, pretože napríklad klient, ktorý si požičil v období najvyšších cien v roku 2006 100% na nákup bytu, tak musel splácať hypotéku, ktorá vo veľkej časti nebola zaistená. Kríza sa do Českej republiky dostala v roku 2008 ako reakcia na

skrachovanie jednej z najväčších svetových investičných bánk Lehman Brothers. Problémy na svetových finančných trhoch dosiahli takých rozmerov, že to možno nazvať globálnou finančnou krízou, ktorá sa prejavila zhoršením mnohých finančných indikátorov (Musílek, 2008; Musílek, 2011, s. 139-145)

V Českej republike okamžite banky reagovali opatreniami, medzi ktoré patrilo napríklad zrušenie 100% hypoték, prísnejšie schvaľovanie úverov, zrušenie rizikových produktov (hypotéky bez preukázania príjmov), sprísnenie oceňovania nehnuteľností, príprava scenára v prípade výrazného nárastu nesplatených hypotekárnych úverov alebo vytváranie rezerv.

Česká republika mala šťastie, že napriek ochladeniu medzibankového trhu nedošlo k silnému pribrzdzeniu financovania ako v západných krajinách. Medzi faktory, ktoré nám pomohli prekonať krízu patrí:

- nerozvinutý trh subprimových hypoték, kedy banky požadovali základné kritéria pre schvaľovanie úverov,
- výrazne nižšia miera zadlženia než v západných krajinách,
- trh sekuritizovaných hypoték je u nás neznámy pojem,
- Česi boli zvyknutí šoriť cez banky alebo prostredníctvom stavebného sporenia, čo predstavovalo zásoby peňazí v dobe recesie,
- banky dostali hypotekárny trh pod kontrolu a prepád cien nebol tak razantný ako napríklad v USA, Veľkej Británii alebo Írsku. Nedošlo k zrúteniu ekonomiky, nedošlo k pádu ani jednej bankovej inštitúcie a makroekonomické ukazovatele ostali relatívne pod kontrolou. O dva roky neskôr už bola obnovená dôvera a hypotéky sa stali žiadaným produktom (Ostatek, 2010).

2 Faktory pôsobiace na objem novoposkytnutých úverov

Druhá kapitola poukazuje na dominantné faktory, ktoré vedú k zmene záujmu domácnosti o hypotéky, čo ovplyvňuje objem novoposkytnutých hypotekárnych úverov. Trh je celý previazaný, ovplyvnený mnohými faktormi avšak domnievam sa, že medzi základné patrí: *hrubý domáci produkt, nezamestnanosť, priemerná mzda, cena nehnuteľností, úroková sadzba a inflácia*.

Postupne sa pozriem na jednotlivé časové rady, zistím závislosť na minulých pozorovaniach a identifikujem model, ktorý by tieto súvislosti popisoval. Súčasťou bude taktiež zhodnotenie vzťahu medzi skúmaným faktorom a objemom hypoték.

2.1 Postup pri konštrukciách predpovedí

V tejto podkapitole stručne popíšem jednotlivé kroky identifikácie a tvorby modelov časových rad prostredníctvom štatistického softvéru Eviews 10, na základe ktorých je možné odvodiť predpovede. Pre lepšie pochopenie jednotlivých pojmov a postupov odporúčam odbornú knižnú publikáciu profesora Josefa Arlta a doktorky Markéty Arltovej (2009, s. 11- 94) s názvom „Ekonomické časové rady“.

Pri praktickej aplikácii budem postupovať v nasledujúcich krokoch:

1. Graficky zobrazím časovú radu a na základe jej priebehu sa posnažím posúdiť či sa jedná o stacionárnu časovú radu.
2. Na 95% hladine spoľahlivosti si pomocou testu jednotkových koreňov (Dickey-Fuller test) potvrdím alebo popriem svoj subjektívny názor z predchádzajúceho kroku. Pokiaľ je pôvodná časová rada nestacionárna, analyzujem jej prvú diferenciu, ak je aj rada prvých diferencií nestacionárna, zanalyzuje sa rada druhých diferencií.
3. Pomocou tvaru výberovej autokorelačnej (ACF) a parciálnej autokorelačnej funkcie (PACF) určím aký typ modelu je vhodný pre analyzovanú stacionárnu časovú radu a prostredníctvom EViews 10 odhadnem jeho parametre. Keďže niekedy je náročné určiť typ modelu na základe ACF a PACF, rozhodujúcu rolu tu hrá intuícia.

Podľa Bašty (2015, s. 1-32) jednotlivé modely je možné zapísať v tvare:

AR (p) proces: autoregresný proces radu p:

$$x_t = \emptyset_0 + \emptyset_1 x_{t-1} + \emptyset_2 x_{t-2} + \dots + \emptyset_p x_{t-p} + a_t \quad (2.1)$$

kde $\emptyset_0, \emptyset_1, \emptyset_2, \dots, \emptyset_p$ sú parametre a a_t je proces bieleho šumu.

MA(q) proces: proces klzavých priemerov radu q:

$$x_t = c + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.2)$$

kde $c, \theta_1, \theta_2, \dots, \theta_q$ sú parametre a a_t je proces bieleho šumu.

ARMA(p, q) proces radu p, q

$$x_t = \emptyset_0 + \emptyset_1 x_{t-1} + \dots + \emptyset_p x_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.3)$$

kde $\emptyset_0, \emptyset_1, \dots, \emptyset_p, \theta_1, \dots, \theta_q$ sú parametre a a_t je proces bieleho šumu.

4. Po výbere vhodného typu modelu uskutočním jeho kontrolu spočívajúcu v analýze rezíduí, teda odhadnutých hodnôt bieleho šumu. Biely šum je postupnosť nekorelovaných náhodných veličín s konštantným rozptylom a nulovou strednou hodnotou. Najlepším prostriedkom pre posúdenie je graf rezíduí. Ak sa však pozrieme na reziduálnu ACF a PACF a hodnoty ležia vo vnútri tolerančných hraníc, môžem konštatovať, že rezídua nevykazujú autokoreláciu. V prípade, že model nie je vhodný musím ho zmeniť, ak je kvalitný môžem ho využiť pre predpovede, ktoré sa počítajú posúvaním vzorku, pričom po každom posune sa model odhadne znova a vypočíta sa predpoveď v čase t.
5. Pri analýze dát môžem usúdiť, že existuje viac vhodných modelov. Keďže výber je komplikovaný využijem dodatočné kritérium: Akaikeho kritérium (AIC), na základe ktorého sa rozhodnem pre lepší model. (Arlt a Arltová, 2009, s. 24-94; Arlt, Arltová a Rublíková, 2002, s. 85-130)

2.2 Hrubý domáci produkt


Hrubý domáci produkt je kľúčový ukazovateľ ekonomiky, ktorý meria výkonnosť ekonomiky ako celku. Ide o celkovú hodnotu tovaru a služieb, vyrobených na území určitej krajiny za určité obdobie. V *grafe 2* je prezentovaný ako relatívna zmena výkonu ekonomiky v porovnaní s rovnakým obdobím minulého

roku (vychádzame zo stálych cien roku 1995). Taktiež sa zvykne používať ukazovateľ hrubého domáceho produktu v absolútnej výške (vyjadrujúci ekonomickú silu krajiny a jej postavenie v celosvetovej ekonomike) a HDP na hlavu v parite kúpnej sily (vyjadrujúci životnú úroveň v jednotlivých krajinách) (*Finance v praxi*, ©2017-2019).

HDP je možné merať tromi spôsobmi: *produkčnou*, *výdajovou* a *dôchodkovou* metódou, pričom vedú k rovnakému výsledku.

- *Produkčná metóda* spočíva v tom, že sčítava hodnotu výrobkov a služieb vyrobených v bežnom roku, pričom každý výrobok sa započítava iba raz tzn. nezahrňuje sa hodnota medziproduktov.
- *Výdajová metóda* počíta HDP ako súčet výdajov všetkých osôb na tovar a služby v danom roku. Opäť sa započítavajú iba výdaje na finálne produkty. Rozoznávame štyri druhy výdajov a to výdaje na spotrebu, investície, čistý vývoz a verejné výdaje.
- *Dôchodková metóda* je založená na poznatku, že každý výdaj je niekoho príjmom. Ide teda o súčet príjmov, ktoré sú mzdy, nájomné, úroky a zisky (Holman, 2010, s. 17-20)

Graf 2: Zmena HDP oproti rovnakému obdobiu minulého roku, vychádzame zo stálych cien roku 1995




Zdroj: Vlastné spracovanie podľa kurzy.cz (©2000-2020)

Na konci roku 1992 sa ČSFR rozdelila na dva samostatné štáty a teda od 1.1.1993 začala ČR fungovať samostatne. V roku 1994 skončila transformačná depresia a ekonomika sa nachádza vo fáze oživenia, kedy v roku 1995 dosahuje vrchol s 5,9% prírastkom HDP. Približne 78% štátneho majetku sa previedlo do súkromného vlastníctva v rámci hlavnej fáze privatizácie, ktorá skončila v roku 1994. V dôsledku negatívnych dopadov na ekonomiku, vnútornej a vonkajšej nerovnováhy spôsobenej väčším rastom domáceho dopytu než ponuky sa ČNB v roku 1996 rozhodla sprísniť monetárnu politiku, čím došlo k rastu úrokovej miery a spomaleniu rastu. Oživenie ekonomiky bolo zreteľné od druhej polovice roku 1999 (Pellešová, 2009, s. 221-232). V roku 2004 bol výkon ekonomiky ovplyvnený vstupom ČR do EU, čo spôsobilo predovšetkým širšie zapojenie do medzinárodnej smeny a to sa prejavilo výrazným rastom dovozu a vývozu tovaru. V roku 2007 ovplyvnilo výšku HDP „predzásobovanie“ verejnosti tovarom a službami, keďže od januára 2008 boli nové zákony ako napríklad rast spotrebnej dane u tabakových výrobkov, zavedenie poplatkov v zdravotníctve či zvýšenie dane z pridanej hodnoty z 5 % na 9 %. Výrazné medziročné spomalenie rastu v roku 2008 bolo ovplyvnené predovšetkým globálnou finančnou krízou, ktorá síce Českú republiku v zásade nezasiahla, ale vyvolala celosvetovo pokles dopytu po tovare a službách. Pre exportne orientovanú ČR to znamenalo problémy, ktoré boli umocnené opatrným prístupom komerčných bánk k poskytovaniu úverových produktov. Ďalším dôvodom medziročného poklesu rastu je, že ČR sa približne od polovice roku 2007 nachádza v klesajúcej fáze hospodárskeho cyklu (Urbánek, ©2000-2020). V roku 2009 poklesol HDP o 4,10% a následne v roku 2010 už vidíme znova nárast o 2,20 % oproti minulému roku. Na pokles v roku 2009 mala prevažne vplyv začínajúca recesia v EU (predovšetkým v Nemecku, ktoré je hlavným obchodným partnerom ČR). Negatívny dopad na ekonomický rast mala taktiež nižšia spotreba domácností, rast cien surovín a rýchle posilňovanie kurzu. Kurz koruny dosiahol vrchol v júli 2008, kedy sa koruna v priemere od začiatku roka zhodnotila o 11,5% voči euru a o 23,1% voči americkému doláru (Hájek a Režný, 2014, s. 20-31). V roku 2011 v dôsledku nastupujúcej dlhovej krízy v eurozóne došlo k spomaleniu ekonomického rastu a pokračovalo to aj nasledujúce dva roky. Uvoľnenie menových podmienok

prispelo v roku 2014 k návratu rastu hrubého domáceho produktu, ktoré pretrváva dodnes (ČNB, ©2003-2018) .

Graf 3: Vývoj HDP a objemu novoposkytnutých hypotekárnych úverov (v mld. Kč)




Zdroj: Vlastné spracovanie podľa Ministerstva pro místní rozvoj ČR(©2019) a kurzycz (©2000-2020)

Ak sa ekonomike darí, rastie hrubý domáci produkt, ktorý má pozitívny vplyv na rast nezamestnanosti a zlepšenie finančnej situácie domácnosti. Predpokladá sa, že za takýchto okolností sa ľudia nebudú obávať zadlžovať (zabezpečovať si vlastné bývanie prostredníctvom hypoték) a to povedie k rastu objemu úverov.

Graf 3 zobrazuje súčasne priebeh objemu novoposkytnutých hypoték a hrubého domáceho produktu. Keďže na základe jeho priebehu nie je úplne viditeľný vzťah medzi pozorovanými veličinami vytvorili sme graf 4 ich percentuálnej zmeny oproti rovnakému obdobiu minulého roku. Teoretický predpoklad, že ekonomický rast má pozitívny vplyv na objem poskytnutých hypoték nemôžem na základe dostupných dát potvrdiť.

Graf 4: Percentuálna zmena HDP a objemu novoposkytnutých hypotekárnych úverov oproti rovnakému obdobiu minulého roku




Zdroj: Vlastné spracovanie podľa Ministerstva pro místní rozvoj ČR(©2019) a kurzycz (©2000-2020)

2.2.1 Analýza časovej rady HDP

K analýze časovej rady hrubého domáceho produktu (v mld. Kč) mám k dispozícii štvrťročné dáta od roku 2005 do druhého kvartálu roku 2019.

Obrázok 4: Časová rada HDP



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Obrázok 4 je graficky zobrazená časová rada a na základe jej priebehu usudzujem, že nie je stacionárna keďže nevidím rovnováhu (= nepodmienenu strednú hodnotu) do ktorej sa mi časová rada stále vracia. Aby som svoj subjektívny názor potvrdila alebo poprela tak použijem Dickey Fuller test jednotkového koreňa.

H_0 : ČR má jednotkový koreň

H_1 : ČR nemá jednotkový koreň

Obrázok 5: ADF test časovej rady HDP


	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.319232	0.9882
Test critical values:		
1% level	-4.130526	
5% level	-3.492149	
10% level	-3.174802	

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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na *obrázku 5* je výstup ADF testu, kde p-hodnota = 0,9882, čo znamená: $0,9882 > 0,05$ a teda na 5% hladine významnosti nezamietam H_0 . Prítomnosť jednotkového koreňa (môže ich byť viac ako jeden) mi indikuje, že sa jedná o nestacionárnu časovú radu. Jednotkových koreňov sa zbavím diferencovaním.

Obrázok 6: Diferencovaná časová rada HDP



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Podľa *obrázku 6* usudzujem, že hodnoty diferencovanej ČR sa mi neustále vracajú k nepodmienenej strednej hodnote, ktorá je rovná 0. Po prvej diferencii sa p-hodnota ADF testu na *obrázku 7* rovná $0,0000 < 0,05$, čo znamená, že zamietam nulovú hypotézu a môžem prehlásiť, že časová rada hrubého domáceho produktu v mld. Kč je integrovaná radu jedna, pretože sa stala stacionárnou po prvom diferencovaní. S takými dátami už viem pracovať.

Obrázok 7: ADF test diferencovanej časovej rady HDP

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-11.44509	0.0000
Test critical values: 1% level	-4.130526	
5% level	-3.492149	
10% level	-3.174802	

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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Teraz sa pozriem na korelogram prvej diferencie. Pre zvolenie AR modelu sledujem priebeh PACF a pre zvolenie modelu MA sledujem ACF priebeh. Na *obrázku 8* vidím, že u PACF poslednýkrát „obdĺžnik“ presahuje kritickú hranicu u oneskorenia 4. U ACF sa hodnoty nevynulovali čo mi naznačuje vhodnosť použiť ARMU nízkeho radu. V nasledujúcich krokoch otestujem AR(4) a ARMU(3,2).


Obrázok 8: Korelogram prvej diferencie časovej rady HDP

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.365	-0.365	8.0093	0.005
		2 0.265	0.151	12.290	0.002
		3 -0.345	-0.246	19.711	0.000
		4 0.511	0.386	36.262	0.000
		5 -0.197	0.130	38.774	0.000
		6 0.176	-0.020	40.819	0.000
		7 -0.244	-0.020	44.839	0.000
		8 0.324	0.094	52.043	0.000
		9 -0.164	-0.032	53.923	0.000
		10 0.029	-0.183	53.982	0.000
		11 -0.179	-0.069	56.335	0.000
		12 0.305	0.177	63.266	0.000
		13 -0.043	0.144	63.407	0.000
		14 0.034	0.043	63.496	0.000
		15 -0.203	-0.065	66.786	0.000
		16 0.141	-0.119	68.418	0.000
		17 -0.105	-0.204	69.342	0.000
		18 0.055	-0.080	69.601	0.000
		19 -0.092	0.105	70.346	0.000
		20 -0.036	-0.187	70.463	0.000
		21 -0.121	-0.178	71.823	0.000
		22 -0.069	-0.089	72.276	0.000
		23 -0.082	-0.092	72.941	0.000
		24 0.051	0.056	73.210	0.000

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na nasledujúcom *obrázku 9* máme grafy rezíduí oboch modelov. Podľa priebehu usudzujem, že ide o biely šum.

Obrázok 9: Diagnostika rezíduí modelov AR(4) a ARMA(3,2)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Ak sa pozriem na reziduálnu ACF a PACF hodnoty ležia vo vnútri tolerančných hraníc, čo znamená, že reziduá nevykazujú autokoreláciu.

Obrázok 10: Reziduálna ACF a PACF modelov AR(4) a ARMA(3,2)

Model AR(4)						Model ARMA(3,2)					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.009	-0.009	0.0048				1 0.062	0.062	0.2293	
		2 0.023	0.022	0.0358				2 0.066	0.062	0.4925	
		3 0.005	0.005	0.0373				3 0.172	0.165	2.3294	
		4 -0.021	-0.022	0.0656				4 0.166	0.150	4.0841	
		5 0.125	0.124	1.0723	0.300			5 0.181	0.159	6.2076	
		6 0.028	0.031	1.1241	0.570			6 0.005	-0.047	6.2096	0.013
		7 0.008	0.003	1.1279	0.770			7 0.009	-0.059	6.2155	0.045
		8 -0.053	-0.057	1.3215	0.858			8 0.103	0.028	6.9439	0.074
		9 -0.007	-0.003	1.3248	0.932			9 0.053	0.009	7.1419	0.129
		10 -0.204	-0.220	4.2890	0.638			10 -0.180	-0.217	9.4526	0.092
		11 0.098	0.094	4.9927	0.661			11 0.061	0.064	9.7247	0.137
		12 0.171	0.189	7.1801	0.517			12 0.171	0.189	11.900	0.104
		13 0.161	0.197	9.1606	0.423			13 0.124	0.171	13.068	0.110
		14 -0.065	-0.085	9.4903	0.486			14 -0.093	-0.097	13.746	0.132
		15 -0.119	-0.098	10.623	0.475			15 -0.102	-0.144	14.574	0.148
		16 0.032	0.006	10.709	0.554			16 0.042	-0.086	14.718	0.196
		17 -0.072	-0.124	11.147	0.599			17 -0.109	-0.219	15.719	0.204
		18 0.107	0.034	12.137	0.595			18 -0.009	0.031	15.726	0.264
		19 -0.046	-0.009	12.326	0.654			19 -0.117	-0.003	16.928	0.260
		20 -0.172	-0.184	15.019	0.523			20 -0.185	-0.173	20.031	0.171
		21 -0.133	-0.116	16.677	0.476			21 -0.154	-0.145	22.259	0.135
		22 -0.209	-0.141	20.882	0.285			22 -0.262	-0.144	28.834	0.036
		23 0.016	0.056	20.907	0.342			23 -0.073	0.079	29.355	0.044
		24 -0.011	-0.088	20.919	0.402			24 -0.081	-0.027	30.025	0.051

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Z hľadiska diagnostiky rezíduí sú oba modely v poriadku, avšak model AR(4) má nižšiu hodnotu AIC (Akaike info criterion) a teda považujem ho za vhodnejší.

Obrázok 11: Výstup modelov AR(4) a ARMA(3,2)

Model AR(4)					Model ARMA(3,2)				
Variable	Coefficient	Std. Error	t-Statistic	Prob.	Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	12.08752	3.446025	3.507671	0.0010	C	11.78545	2.408277	4.893728	0.0000
AR(1)	-0.180800	0.130866	-1.381574	0.1731	AR(1)	-0.990906	0.543428	-1.823437	0.0742
AR(2)	0.046898	0.175496	0.267233	0.7904	AR(2)	-0.483872	0.478340	-1.011564	0.3166
AR(3)	-0.145308	0.138015	-1.052842	0.2974	AR(3)	-0.376476	0.217038	-1.734611	0.0890
AR(4)	0.464248	0.123115	3.770846	0.0004	MA(1)	0.806452	0.579691	1.391176	0.1703
SIGMASQ	368.9895	73.71361	5.005717	0.0000	MA(2)	0.351272	0.414116	0.848245	0.4003
R-squared	0.394916	Mean dependent var	12.03860		SIGMASQ	408.4734	85.04833	4.802839	0.0000
Adjusted R-squared	0.335594	S.D. dependent var	24.91394		R-squared	0.330168	Mean dependent var	12.03860	
S.E. of regression	20.30764	Akaike info criterion	8.986578		Adjusted R-squared	0.249788	S.D. dependent var	24.91394	
Sum squared resid	21032.40	Schwarz criterion	9.201636		S.E. of regression	21.57915	Akaike info criterion	9.114686	
Log likelihood	-250.1175	Hannan-Quinn criter.	9.070157		Sum squared resid	23282.99	Schwarz criterion	9.365587	
F-statistic	6.657154	Durbin-Watson stat	1.913176		Log likelihood	-252.7685	Hannan-Quinn criter.	9.212194	
Prob(F-statistic)	0.000077				F-statistic	4.107602	Durbin-Watson stat	1.778005	
Inverted AR Roots	.74	.01-.81i	.01+.81i	-.94	Prob(F-statistic)	0.001992			
					Inverted AR Roots	-.04+.64i	-.04-.64i	-.91	
					Inverted MA Roots	-.40+.43i	-.40-.43i		

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Model AR(4) môžeme zapísať³:

$$x_t = 9,850869474 - 0,1808x_{t-1} + 0,046898x_{t-2} - 0,145308x_{t-3} + 0,464248x_{t-4} + a_t \quad (2.4)$$

Pomocou rovnice (2.4) je možné predpovedať budúci vývoj hrubého domáceho produktu.

2.2.2 Miera nezamestnanosti


Nezamestnanosť patrí medzi jeden z najdôležitejších makroekonomických ukazovateľov výkonnosti ekonomiky. Vyjadruje podiel nezamestnaných ku všetkým osobám, ktoré sú schopné pracovať. V ČR máme dve miery nezamestnanosti a to mieru, ktorú zverejňuje Český štatistický úrad podľa evidencie obyvateľov na úradoch práce a druhú, ktorá sa uvádza na základe výberového šetrenia pracovných síl. Šetrenie je vykonané na náhodnom vzorku domácnosti a posudzuje sa ekonomické postavenie obyvateľstva (Krček a Smetanková, 2019). Nezamestnanosť podľa príčin rozdeľujeme na *frikčnú*, *štruktúrálnu* a *cyklickú*.

- *Frikčná nezamestnanosť* vzniká v dôsledku opustenia pôvodného zamestnania a hľadania novej práce, ktoré môže zabráť určitý čas ak uchádzač nechce prijať hneď prvú ponuku a očakáva lepšiu.
- *Štruktúrálna nezamestnanosť* vzniká v dôsledku štruktúrálnej zmien v ekonomike, kedy niektoré odvetvia expandujú a niektoré sa zmenšujú. To ma za následok prechod zamestnancov zo zmenšujúcich sa odvetví do expandujúcich a teda je potrebné aby sa rekvalifikovali.

³Výpočet $\theta_0 = c \cdot (1 - \theta_1 - \theta_2 - \theta_3 - \theta_4)$

- *Cyklická nezamestnanosť* sa objavuje v dôsledku recesie. Pri hospodárskom poklese sa prepúšťa a nezamestnaní si nemôžu nájsť prácu ani v iných odvetviach, pretože klesajúci dopyt po práci postihol všetky profesie (Holman, 2011, s. 280-284).


Graf 5: Vývoj všeobecnej miery nezamestnanosti



Zdroj: Vlastné spracovanie podľa ČNB (©2003-2020)

Graf 5 znázorňuje vývoj všeobecnej miery nezamestnanosti za obdobie 2005Q1-2019Q3. Od vzniku ČR až do roku 1996 sa všeobecná miera nezamestnanosti pohybovala okolo úrovne 3%. Následne začala prudko stúpať, v roku 2004 dosiahla svoju najvyššiu hodnotu 8,9%. Za ďalší zlom môžeme považovať obdobie prepuknutia hospodárskej krízy, kedy došlo k rastu nezamestnanosti z dôvodu zníženia zahraničného dopytu kvôli ktorému museli podniky obmedziť výrobu a prepúšťať, čo pokračovalo až do roku 2010. Ďalší nárast je v rokoch 2012-2013, ktorý môže byť reakciou na dlhovou krízou eurozóny v roku 2011. Od tohto obdobia všeobecná miera neustále klesá. Od roku 2017 Česká republika vykazuje nezamestnanosť pod 3% a v súčasnosti zastáva najnižšiu úroveň medzi členskými krajinami (najhoršie obstálo Grécko s 18,6% mierou nezamestnanosti). Podľa údajov Eurostatu bolo bez práce iba 2,1% obyvateľov. V celosvetovom merítku by sme ju mohli zrovnávať napríklad s Japonskom (Krčák a Smetanková, 2019).


Graf 6: Vývoj objemu novoposkytnutých hypotekárnych úverov (v mld. Kč) a všeobecnej miery nezamestnanosti



Zdroj: Vlastné spracovanie podľa Ministerstva pro místní rozvoj ČR(©2019) a ČNB (©2003-2020)

Pri nezamestnanosti sa predpokladá, že s jej rastom bude klesať objem novoposkytnutých hypoték pretože domácnosti nebudú mať dostatok finančných prostriedkov a taktiež nebudú spĺňať podmienky pre získanie úveru. Predpoklad na základe *grafu 6* a *grafu 7* nemôžem s istotou potvrdiť, keďže v priebehu sledovaného obdobia nebol viackrát dodržaný. Napríklad v súčasnosti sme na minimálnej úrovni nezamestnanosti a objem novoposkytnutých hypotekárnych úverov klesol v porovnaní s rovnakým obdobím minulého roku.

Graf 7: Percentuálna zmena všeobecnej miery nezamestnanosti a objemu novoposkytnutých hypotekárnych úverov oproti rovnakému obdobiu minulého roku




Zdroj: Vlastné spracovanie podľa Ministerstva pro místní rozvoj ČR(©2019) a ČNB (©2003-2020)

2.2.3 Analýza časovej rady všeobecnej miery nezamestnanosti

K analýze časovej rady všeobecnej miery nezamestnanosti (v %) mám k dispozícii štvrťročné dáta od roku 2005 do druhého kvartálu roku 2019.

Obrázok 12: Časová rada všeobecnej miery nezamestnanosti



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na *obrázku 12* je graficky zobrazená časová rada a na základe jej priebehu usudzujem, že nie je stacionárna keďže nevidím rovnováhu (= nepodmienenú strednú hodnotu) do ktorej sa mi časová rada stále vracia. Aby som si svoj subjektívny názor potvrdila alebo poprela použijem Dickey Fuller test jednotkového koreňa.

H_0 : ČR má jednotkový koreň

H_1 : ČR nemá jednotkový koreň

Obrázok 13: ADF test časovej rady všeobecnej miery nezamestnanosti

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.002757	0.5871
Test critical values:		
1% level	-4.130526	
5% level	-3.492149	
10% level	-3.174802	


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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na *obrázku 13* vidím výstup ADF testu, kde p-hodnota = 0,5871, čo znamená: $0,5871 > 0,05$ a teda na 5% hladine významnosti nezamietam H_0 . Prítomnosť jednotkového koreňa (môže ich byť viac ako jeden) mi indikuje, že mám k dispozícii nestacionárnu časovú radu. Jednotkových koreňov sa zbavím pomocou

diferencovania. *Obrázok 14* znázorňuje diferencovanú časovú radu všeobecnej miery nezamestnanosti.

Obrázok 14: Diferencovaná časová rada všeobecnej miery nezamestnanosti



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Po prvom diferencovaní vidím vo výstupe ADF testu na *obrázku 15*, že p-hodnota sa rovná $0,0590 > 0,05$ a opäť nemôžem zamietnuť nulovú hypotézu. Nastal prípad, kedy je nutné časovú radu diferencovať dvakrát pretože obsahuje dva jednotkové korene.

Obrázok 15: ADF test diferencovanej časovej rady všeobecnej miery nezamestnanosti


	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.419725	0.0590
Test critical values:		
1% level	-4.130526	
5% level	-3.492149	
10% level	-3.174802	

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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na *obrázku 16* je viditeľná rovnováha, ku ktorej sa mi vychýlené hodnoty zakaždým vrátia späť. Po druhej diferencii (viď. *obrázok 17*) sa p-hodnota rovná $0,0000 < 0,05 \rightarrow$ zamietam nulovú hypotézu a môžem prehlásiť, že časová rada všeobecnej miery nezamestnanosti je integrovaná radu dva, pretože sa stala stacionárnou po druhej diferencii. S takými dátami už vieme pracovať.

Obrázok 16: Časová rada všeobecnej miery nezamestnanosti po druhej diferencii



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Obrázok 17: ADF test dvakrát diferencovanej časovej rady všeobecnej miery nezamestnanosti

Augmented Dickey-Fuller test statistic		-9.041190	0.0000
Test critical values:			
	1% level	-4.133838	
	5% level	-3.493692	
	10% level	-3.175693	

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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Obrázok 18 znázorňuje korelogram po druhom diferencovaní. Pre zvolenie AR modelu sledujem priebeh PACF a pre zvolenie MA modelu sledujem ACF priebeh. Vidím, že u PACF poslednýkrát „obdĺžnik“ presahuje kritickú hranicu u oneskorenia 5. U ACF sa hodnoty nevynulovali čo mi naznačuje vhodnosť použiť ARMU nízkeho radu. V nasledujúcich krokoch otestujem AR(5) a ARMU(1,1).


Obrázok 18: Korelogram dvakrát diferencovanej časovej rady všeobecnej miery nezamestnanosti

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.224	-0.224	2.9517	0.086
		2 -0.020	-0.073	2.9750	0.226
		3 -0.042	-0.067	3.0842	0.379
		4 0.090	0.067	3.5955	0.464
		5 -0.317	-0.304	9.9757	0.076
		6 0.128	-0.004	11.044	0.087
		7 -0.078	-0.095	11.446	0.120
		8 -0.000	-0.070	11.446	0.178
		9 -0.117	-0.131	12.397	0.192
		10 -0.060	-0.270	12.649	0.244
		11 0.013	-0.068	12.661	0.316
		12 0.108	-0.005	13.529	0.332
		13 -0.046	-0.079	13.691	0.396
		14 0.140	0.055	15.201	0.365
		15 0.081	0.040	15.719	0.401
		16 -0.094	-0.072	16.435	0.423
		17 -0.024	-0.032	16.482	0.490
		18 0.038	-0.054	16.804	0.550
		19 -0.028	0.001	16.875	0.612
		20 0.009	0.032	16.681	0.674
		21 -0.128	-0.189	18.209	0.636
		22 0.113	0.103	19.423	0.619
		23 -0.044	-0.009	19.616	0.665
		24 0.031	0.065	19.714	0.713

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na *obrázku 19* máme grafy rezíduí oboch modelov. Podľa priebehu usudzujem, že ide o biely šum.


Obrázok 19: Diagnostika rezíduí modelov AR(5) a ARMA(1,1)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Priebeh reziduálnej ACF a PACF na *obrázku 20* nám signalizuje, že reziduá nevykazujú autokoreláciu.

Obrázok 20: Reziduálna ACF a PACF modelov AR(5) a ARMA(1,1)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Z hľadiska diagnostiky rezíduí sú oba modely v poriadku, avšak model ARMA(1,1) má nižšiu hodnotu AIC (Akaike info criterion) a teda považujem ho za vhodnejší.

Obrázok 21: Výstup modelov AR(5) a ARMA(1,1)

Model AR(5)					Model ARMA(1,1)				
Variable	Coefficient	Std. Error	t-Statistic	Prob.	Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.002603	0.024819	0.104875	0.9169	C	-0.001041	0.007882	-0.132049	0.8955
AR(1)	-0.215898	0.197316	-1.094172	0.2792	AR(1)	0.650582	0.174563	3.726920	0.0005
AR(2)	-0.101906	0.232931	-0.437496	0.6637	MA(1)	-1.000000	1616.153	-0.000619	0.9995
AR(3)	-0.066668	0.149804	-0.445037	0.6583	SIGMASQ	0.066125	2.366267	0.027945	0.9778
AR(4)	-0.000842	0.242159	-0.003476	0.9972					
AR(5)	-0.300208	0.158902	-1.889270	0.0648					
SIGMASQ	0.068001	0.009359	7.265604	0.0000					
R-squared	0.157381	Mean dependent var	0.003571		R-squared	0.180622	Mean dependent var	0.003571	
Adjusted R-squared	0.054204	S.D. dependent var	0.286651		Adjusted R-squared	0.133350	S.D. dependent var	0.286651	
S.E. of regression	0.278774	Akaike info criterion	0.409717		S.E. of regression	0.266855	Akaike info criterion	0.310129	
Sum squared resid	3.808034	Schwarz criterion	0.662886		Sum squared resid	3.703002	Schwarz criterion	0.454797	
Log likelihood	-4.472067	Hannan-Quinn criter.	0.507870		Log likelihood	-4.683599	Hannan-Quinn criter.	0.366216	
F-statistic	1.525342	Durbin-Watson stat	1.989645		F-statistic	3.820932	Durbin-Watson stat	2.082227	
Prob(F-statistic)	0.189710				Prob(F-statistic)	0.015062			
Inverted AR Roots	.57+.49i -.83	.57-.49i	-.26-.76i	-.26+.76i	Inverted AR Roots	.65			
					Inverted MA Roots	1.00			

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Model ARMA(1,1) môžeme zapísať:


$$x_t = -0,00036 + 0,650582x_{t-1} + 1a_{t-1} + a_t \quad (2.5)$$

Pomocou rovnice (2.5) je možné predpovedať budúci vývoj všeobecnej miery nezamestnanosti.

2.3 Priemerná mzda

Priemernú mzdu môžeme chápať ako mzdové prostriedky (vrátane príplatkov za cezčasy, odmeny atď.) pred znížením o poistné na všeobecné zdravotné poistenie, sociálne zabezpečenie a zálohy na dane z príjmu, pripadajúce na jedného zamestnanca za jeden mesiac (kurzycz, ©2000-2020) Výška priemernej mzdy výrazne ovplyvňuje objem novoposkytnutých hypoték, pretože žiadatelia sú ochotní viac sa zadlžovať ak majú viac peňažných prostriedkov. Ako už bolo spomenuté ČNB v októbri roku 2018 zaviedla nové nariadenia, podľa ktorých objem všetkých úverov žiadateľa o hypotéku nemôže byť väčší ako deväťnásobok ročného čistého príjmu a zároveň mesačná splátka nemôže presiahnuť 45% mesačného príjmu. Taktiež musia uchádzači mať dostatočné množstvo vlastných zdrojov, pretože banky poskytujú úver v maximálnej výške 90% z hodnoty nehnuteľností. Je zreteľné, že ide o sezónne neočistenú časovú radu- výrazné výkyvy v štvrtých kvartáloch, ktoré sú spôsobené každoročným jednorazovým navýšením (Hypoteční kalkulačka, 2018).


Graf 8: Vývoj priemernej mzdy v Kč.



Zdroj: Vlastné spracovanie podľa kurzy.cz (©2000-2020)

Graf 8 znázorňuje vývoj priemernej hrubej mzdy (v Kč) v Českej republike v období 2005Q1-2019Q3. Na časovej osi vidíme, že mzdy sa každoročne zvyšovali. V prvom kvartáli roku 2005 predstavovali 17067 Kč a navýšili sa až na čiastku 33997 Kč, čo je dvojnásobok pôvodnej hodnoty. Treba však brať v úvahu, že ide o nominálne priemerné mzdy a teda súčasťou je aj inflácia.

Graf 9: Vývoj objemu novoposkytnutých hypotekárnych úverov (v mld. Kč) a priemernej hrubej mzdy (v Kč)




Zdroj: Vlastné spracovanie podľa Ministerstva pro místní rozvoj ČR(©2019) a kurzy.cz (©2000-2020)

Pri rastúcej priemernej mzde sa predpokladá, že narastá aj ochota domácnosti sa zadlžovať. Predpoklad o pozitívnom vzťahu medzi priemernou mzdou a objemom novoposkytnutých hypotekárnych úverov nemôžem na základe grafu 9 a grafu 10 potvrdiť (ani vyvrátiť). Existencia vzťahov je však veľmi diskutabilná, pretože nie je to jediný faktor, ktorý má vplyv na objem hypoték. Môže teda nastať situácia, že pri

výraznom pôsobení iného faktoru dôjde k poklesu objemu hypoték napriek nárastu priemernej mzdy.

Graf 10: Percentuálna zmena objemu hypoték a priemernej hrubej mzdy oproti rovnakému obdobiu minulého roka




Zdroj: Vlastné spracovanie podľa Ministerstva pro místní rozvoj ČR(©2019) a kurzycz (©2000-2020)

2.3.1 Analýza časovej rady priemernej hrubej mzdy

K analýze časovej rady priemernej hrubej mzdy mám k dispozícii štvrťročné dáta od prvého kvartálu roku 2005 do druhého kvartálu roku 2019.

Obrázok 22: Časová rada priemernej hrubej mzdy



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Podľa priebehu dát na *obrázku 22* a absencii rovnováhy predpokladám, že časová rada priemernej hrubej mzdy nie je stacionárna. Pre overenie môjho predpokladu použijem Dickey Fuller test jednotkového koreňa.

H_0 : ČR má jednotkový koreň

H_1 : ČR nemá jednotkový koreň

Obrázok 23: ADF test časovej rady priemernej hrubej mzdy


	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.999863	0.5886
Test critical values: 1% level	-4.130526	
5% level	-3.492149	
10% level	-3.174802	

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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na základe ADF testu (obrázok 23) s p-hodnotou 0,5886 na 5% hladine významnosti nezamietam nulovú hypotézu a pokračujem diferencovaním časovej rady.

Obrázok 24: Diferencovaná časová rada priemernej hrubej mzdy



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

ADF test diferencovanej časovej rady priemernej hrubej mzdy na obrázku 25 nám zobrazuje, že p-hodnota 0,0000 je menšia ako 0,05 a teda zamietame nulovú hypotézu. Časová rada priemernej hrubej mzdy je integrovaná radu jedna.

Obrázok 25: ADF test diferencovanej časovej rady priemernej hrubej mzdy


	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-14.66381	0.0000
Test critical values: 1% level	-4.130526	
5% level	-3.492149	
10% level	-3.174802	

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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Obrázok 26 s korelogramom prvej diferencie nadobúda u PACF výraznú hodnotu u dvanásteho oneskorenia, čo ma presvedčilo otestovať model AR(12).


Obrázok 26: Korelogram prvej diferenciácie časovej rady priemernej hrubej mzdy



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10


Obrázok 27 zobrazuje rezíduá, ktoré sú bielym šumom a teda nie sú autokorelované. Tentokrát nebudem porovnávať viac modelov, pretože žiadny model s menším počtom parametrov neprešiel diagnostikou rezíduí. Na obrázku 28 je reziduálna ACF a PACF modelu AR(12) a na obrázku 29 výstup modelu AR(12).

Obrázok 27: Diagnostika rezíduí modelu AR(12)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Obrázok 28: Reziduálna ACF a PACF modelu AR(12)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Obrázok 29: Výstup modelu AR(12)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	287.6348	207.1301	1.388667	0.1721
AR(1)	-0.488096	0.089412	-5.458957	0.0000
AR(2)	-0.183256	0.133598	-1.371693	0.1773
AR(3)	0.000293	0.182806	0.001601	0.9987
AR(4)	-0.017165	0.242420	-0.070809	0.9439
AR(5)	0.025059	0.302606	0.082810	0.9344
AR(6)	0.049187	0.386423	0.127287	0.8993
AR(7)	0.044271	0.494472	0.089532	0.9291
AR(8)	0.044693	0.519978	0.085952	0.9319
AR(9)	-0.058892	0.601299	-0.097941	0.9224
AR(10)	-0.094826	0.727277	-0.130385	0.8969
AR(11)	-0.083749	0.252453	-0.331742	0.7417
AR(12)	0.402994	0.209906	1.919882	0.0615
SIGMASQ	800565.7	102435.9	7.815285	0.0000
R-squared	0.472310	Mean dependent var	279.6911	
Adjusted R-squared	0.312776	S.D. dependent var	1242.660	
S.E. of regression	1030.153	Akaike info criterion	16.99029	
Sum squared resid	45632246	Schwarz criterion	17.49209	
Log likelihood	-470.2232	Hannan-Quinn criter.	17.18531	
F-statistic	2.960556	Durbin-Watson stat	2.130798	
Prob(F-statistic)	0.003697			
Inverted AR Roots	.86	.75+.42i	.75-.42i	.45-.81i
	.45+.81i	-.04+.95i	-.04-.95i	-.51-.81i
	-.51+.81i	-.83+.48i	-.83-.48i	-.97

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Model AR(12), podľa ktorého je možné predpovedať ďalší vývoj priemernej hrubej mzdy, môžeme zapísať:


$$\begin{aligned}
 x_t = & 391,0107 - 0,4881x_{t-1} - 0,1833x_{t-2} + 0,0003x_{t-3} \\
 & - 0,0172x_{t-4} + 0,0251x_{t-5} + 0,0492x_{t-6} \\
 & + 0,0443x_{t-7} + 0,0447x_{t-8} - 0,0589x_{t-9} \\
 & - 0,0948x_{t-10} - 0,0837x_{t-11} + 0,403x_{t-12} + a_t
 \end{aligned}
 \tag{2.6}$$

2.4 Cena nehnuteľností

Cena nehnuteľností je jedným z hlavných faktorov ovplyvňujúcich dosiahnuteľnosť vlastného bývania na území Českej republiky a teda má aj vplyv na objem novoposkytnutých hypotekárnych úverov.

Dlhodobým problémom je nedostatočné množstvo nových a cenovo dostupných nehnuteľností. Rozhodovacie procesy a prísna regulácia brzdia výstavbu – množstvo projektov nebolo zrealizovaných práve z dôvodu administratívnej náročnosti. V súčasnosti schvaľovací proces na výstavbu trvá viac ako 5 rokov. Pred pár rokmi staršie byty nachádzajúce sa v centre Prahy alebo jeho okolí zdražovali rýchlejšie v porovnaní s novopostavenými bytmi na okraji hlavného mesta. V súčasnosti došlo k dorovnaniu rastu cien u týchto bytov čo je ukazovateľ nedostatočného množstva bytových jednotiek. Nedostatok bývania núti domácnosti k presťahovaniu na okraj hlavného mesta, kde je vyššia ponuka a ceny nižšie. V hlavnom meste je tempo rastu čistého prírastku obyvateľov 2,5krát rýchlejšie než novopostavených bytov. Výrazný nárast turistov podporil špekulatívnych investorov k vykúpeniu voľných bytov za účelom ich ďalšieho prenájmu. V budúcnosti sa môže stať, že byty v Prahe sa stanú pre obyvateľstvo nedostupné a budú sa iba prenajímať. Počet rezidentov s vlastným bývaním sa viditeľne zníži (Somogyi, 2019).

Graf 11: Vývoj indexu cien nehnuteľností (2010=100)




Zdroj: Vlastné spracovanie podľa ČSÚ (2005-2019)

Graf 11 znázorňuje vývoj indexu cien nehnuteľností (2010=100) od roku 2005 do 2019. Od roku 1997 až do vypuknutia finančnej krízy v roku 2008 pretrvával nárast cien z dôvodu dobrej dostupnosti hypotekárnych úverov čo motivovalo

domácnosti k investíciám. V roku 2002 bol výraznejší nárast (o viac ako 20%) spôsobený očakávaním rastu cien nehnuteľností po vstupe ČR do Európskej únie a teda uchádzači sa snažili si zaobstarať bývanie ešte predtým. Dobrá situácia na trhu práce a optimistické očakávania domácnosti viedli napriek rastu úrokových sadzieb v roku 2007 k ďalšiemu výraznému nárastu záujmu o nehnuteľnosti. V dôsledku vypuknutia finančnej krízy banky začali byť opatrnejšie pri poskytovaní úverov a záujem o hypotéky klesol. To spôsobilo pozastavenie zvyšovania cien a nájomné bývanie bolo pre domácnosti výhodnejšie a dostupnejšie keďže prevládala pesimistická nálada a obyvatelia sa nechceli zadlžovať. Po oživení ekonomiky opäť narástol záujem o vlastné bývanie a cena v dôsledku prevýšenia dopytu nad ponukou rástla: od roku 2010 do roku 2018 o 48,7 % a v hlavnom meste to bolo o 72,7%. Začalo sa rozvíjať stavebníctvo, remeselníci boli žiadaní, klesala nezamestnanosť a zvyšovali sa náklady na výstavbu bytov (Somogyi, 2019).

Graf 12: Percentuálna zmena objemu hypoték a rozdiel indexu cien nehnuteľností oproti rovnakému obdobiu minulého roka




Zdroj: Vlastné spracovanie podľa Ministerstva pro místní rozvoj ČR(©2019) a ČSÚ (2005-2019)

Posledné obdobie sme mohli často počuť vyjadrenia, že bankám sa blýska na horšie časy, pretože ľudia prestávajú mať záujem o hypotéky z dôvodu nedostatku cenovo dostupných nehnuteľností, ktoré by si mohla dovoliť stredná trieda. Na druhej strane ceny dlhodobo rastú a ak sa pozrieme na graf 12 vidíme obdobia kedy súčasne rástol aj objem novoposkytnutých hypotekárnych úverov. Rastúce ceny totiž podporujú očakávania pokračujúceho rastu cien čo zvyšuje obavy domácnosti, že si v budúcnosti nebudú môcť vlastné bývanie zabezpečiť a tak rastie súčasný záujem o hypotéky. Z grafu nie je jasné aký vplyv má cena nehnuteľností na objem úverov.

2.4.1 Analýza časovej rady indexu cien nehnuteľností

K analýze časovej rady indexu cien nehnuteľností (2010=100) mám k dispozícii štvrt'ročné dáta od roku 2005 do druhého kvartálu roku 2019.

Obrázok 30: Časová rada indexu cien nehnuteľností (2010=100)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na základe priebehu časovej rady na *obrázku 30* usudzujem, že nie je stacionárna keďže nevidím rovnováhu (= nepodmienenú strednú hodnotu) do ktorej sa mi stále vracia. Aby som svoj odhad potvrdila/ poprela použijem Dickey Fuller test jednotkového koreňa.

H_0 : ČR má jednotkový koreň

H_1 : ČR nemá jednotkový koreň

Obrázok 31: ADF test časovej rady indexu cien nehnuteľností

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.210559	0.4745
Test critical values:		
1% level	-4.130526	
5% level	-3.492149	
10% level	-3.174802	


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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na *obrázku 31* je výstup ADF testu, kde p-hodnota = 0,4745, čo znamená: $0,4745 > 0,05$ a teda na 5% hladine významnosti nezamietam H_0 . Prítomnosť jednotkového koreňa mi indikuje, že sa jedná o nestacionárnu časovú radu. Jednotkových koreňov sa zbavím diferencovaním.

Na nasledujúcom *obrázku 32* je priebeh časovej rady integrovanej radu jedna, pretože sa stala stacionárnou po prvom diferencovaní.


Obrázok 32: Diferencovaná časová rada indexu cien nehnuteľností



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Teraz sa pozriem na korelogram prvej diferencií, ktorý je znázornený na *obrázku 33*. Pre zvolenie AR modelu sledujem priebeh PACF a pre zvolenie modelu MA sledujem ACF priebeh. Vidím, že u PACF poslednýkrát „obdĺžnik“ presahuje kritickú hranicu u oneskorenia 1. U ACF sa hodnoty nevynulovali čo mi naznačuje vhodnosť použiť ARMU nízkeho radu. V nasledujúcich krokoch otestujem AR(1) a ARMU(1,1).


Obrázok 33: Korelogram prvej diferenciie časovej rady indexu cien nehnuteľností

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.752	0.752	33.979	0.000
		2 0.529	-0.085	51.085	0.000
		3 0.360	-0.018	59.147	0.000
		4 0.265	0.052	63.588	0.000
		5 0.210	0.026	66.439	0.000
		6 0.119	-0.115	67.374	0.000
		7 0.051	-0.002	67.552	0.000
		8 0.006	-0.006	67.554	0.000
		9 -0.049	-0.084	67.722	0.000
		10 -0.135	-0.138	69.026	0.000
		11 -0.228	-0.102	72.820	0.000
		12 -0.233	0.074	76.875	0.000
		13 -0.172	0.079	79.127	0.000
		14 -0.111	0.010	80.093	0.000
		15 -0.069	0.025	80.469	0.000
		16 -0.086	-0.084	81.070	0.000
		17 -0.165	-0.199	83.346	0.000
		18 -0.169	0.066	85.821	0.000
		19 -0.158	-0.007	88.042	0.000
		20 -0.179	-0.140	90.944	0.000
		21 -0.155	0.049	93.188	0.000
		22 -0.120	0.022	94.564	0.000
		23 -0.155	-0.230	96.949	0.000
		24 -0.195	-0.040	100.83	0.000

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na nasledujúcom *obrázku 34* máme grafy rezíduí oboch modelov. Podľa priebehu usudžujem, že ide o biely šum.

Obrázok 34: Diagnostika rezíduí modelov AR(1) a ARMA(1,1)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Ak sa pozriem na reziduálnu ACF a PACF tak usudzujem, že hodnoty ležia vo vnútri tolerančných hraníc, čo znamená, že reziduá nevykazujú autokoreláciu.

Obrázok 35: Reziduálna ACF a PACF modelov AR(1) a ARMA(1,1)

Model AR(1)						Model ARMA(1,1)					
Autocorrelation		Partial Correlation		AC	PAC	Autocorrelation		Partial Correlation		AC	PAC
1	0.074	0.074	0.3263	0.558	0.074	1	0.005	0.005	0.0014	0.005	0.0014
2	-0.016	-0.022	0.3425	0.558	-0.016	2	0.027	0.027	0.0468	0.027	0.0468
3	-0.074	-0.071	0.6822	0.711	-0.074	3	-0.044	-0.044	0.1549	-0.044	0.1549
4	-0.033	-0.023	0.7529	0.861	-0.033	4	-0.021	-0.021	0.1921	-0.021	0.1921
5	0.098	0.101	1.3787	0.848	0.098	5	0.111	0.114	0.9871	0.111	0.9871
6	-0.019	-0.040	1.4522	0.924	-0.019	6	-0.020	-0.023	1.0145	-0.020	1.0145
7	-0.021	-0.019	1.4317	0.954	-0.021	7	-0.014	-0.023	1.0277	-0.014	1.0277
8	0.015	0.031	1.4468	0.984	0.015	8	0.009	0.021	1.0336	0.009	1.0336
9	0.049	0.049	1.6151	0.991	0.049	9	0.041	0.045	1.1504	0.041	1.1504
10	-0.005	-0.028	1.6171	0.996	-0.005	10	0.001	-0.017	1.1505	0.001	1.1505
11	-0.182	-0.176	4.0294	0.946	-0.182	11	-0.173	-0.173	3.3291	-0.173	3.3291
12	-0.134	-0.101	5.3774	0.912	-0.134	12	-0.118	-0.111	4.3686	-0.118	4.3686
13	-0.026	-0.016	5.4290	0.942	-0.026	13	-0.018	-0.008	4.3938	-0.018	4.3938
14	-0.009	-0.045	5.4357	0.954	-0.009	14	-0.021	-0.040	4.4274	-0.021	4.4274
15	0.074	0.056	5.6731	0.970	0.074	15	0.058	0.045	4.6931	0.058	4.6931
16	0.075	0.100	6.3361	0.974	0.075	16	0.068	0.112	5.0772	0.068	5.0772
17	-0.135	-0.145	7.8572	0.953	-0.135	17	-0.138	-0.131	6.6688	-0.138	6.6688
18	-0.069	-0.062	8.2634	0.961	-0.069	18	-0.067	-0.068	7.0516	-0.067	7.0516
19	0.035	0.072	8.3702	0.973	0.035	19	0.041	0.076	7.2629	0.041	7.2629
20	-0.102	-0.129	9.3200	0.968	-0.102	20	-0.107	-0.114	8.2401	-0.107	8.2401
21	-0.047	-0.071	9.5289	0.976	-0.047	21	-0.055	-0.097	8.5197	-0.055	8.5197
22	0.103	0.140	10.556	0.971	0.103	22	0.099	0.137	9.4620	0.099	9.4620
23	-0.023	-0.093	10.610	0.980	-0.023	23	-0.044	-0.078	9.6543	-0.044	9.6543
24	-0.011	-0.089	10.622	0.987	-0.011	24	-0.008	-0.095	9.6609	-0.008	9.6609

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Z hľadiska diagnostiky rezíduí sú oba modely v poriadku, avšak model AR(1) má nižšiu hodnotu AIC (Akaike info criterion) a teda považujem ho za vhodnejší (vid'. obrázok 36).

Obrázok 36: Výstup modelov AR(1) a ARMA(1,1)

Model AR(1)					Model ARMA(1,1)				
Variable	Coefficient	Std. Error	t-Statistic	Prob.	Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.369789	0.809901	1.691305	0.0965	C	1.381139	0.767266	1.800079	0.0775
AR(1)	0.750088	0.056519	13.27140	0.0000	AR(1)	0.701237	0.091705	7.646661	0.0000
SIGMASQ	2.310769	0.352904	6.547876	0.0000	MA(1)	0.117289	0.132612	0.884446	0.3805
					SIGMASQ	2.290002	0.384469	5.956280	0.0000
R-squared	0.573876	Mean dependent var	1.492982		R-squared	0.577705	Mean dependent var	1.492982	
Adjusted R-squared	0.558093	S.D. dependent var	2.349381		Adjusted R-squared	0.553802	S.D. dependent var	2.349381	
S.E. of regression	1.561776	Akaike info criterion	3.795229		S.E. of regression	1.569341	Akaike info criterion	3.821670	
Sum squared resid	131.7138	Schwarz criterion	3.902758		Sum squared resid	130.5301	Schwarz criterion	3.965042	
Log likelihood	-105.1640	Hannan-Quinn criter.	3.837019		Log likelihood	-104.9176	Hannan-Quinn criter.	3.877389	
F-statistic	36.36178	Durbin-Watson stat	1.834063		F-statistic	24.16825	Durbin-Watson stat	1.972508	
Prob(F-statistic)	0.000000				Prob(F-statistic)	0.000000			
Inverted AR Roots	.75				Inverted AR Roots	.70			
					Inverted MA Roots	-.12			

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Model AR(1) môžeme zapísať:


$$x_t = 0,342327 + 0,750088x_{t-1} + a_t \quad (2.7.)$$

Pomocou rovnice (2.7) je možné predpovedať budúci vývoj indexu cien nehnuteľností.

2.5 Úroková sadzba

Základným faktorom, ktorým sa subjekty riadia pri rozhodovaní o budúcej spotrebe, ktorú chcú z určitej časti financovať prostredníctvom dlhu je cena peňazí (Somogyi, 2019). V tejto časti som sa zaoberala priemernou úrokovou sadzbou, ale treba podotknúť, že subjekty sa dokážu dostať aj na nižšiu úroveň s takzvanou variabilnou úrokovou sadzbou, ktorá je fixovaná na krátku dobu (napr. rok, mesiac alebo len na jeden deň). Odvíja sa od sadzby, ktorú vyhlasuje Česká národná banka. V prípade, že si banka požičia peniaze na 3 mesiace, tak variabilná sadzba bude odvodená od kvartálneho PRIBORu a klient musí počítať s tým, že mu to každé tri mesiace ovplyvní výšku mesačnej splátky, ktorá sa skladá zo splátky istiny, úroku podľa PRIPOR a marže banky. Klient môže mať jedno obdobie vyššiu splátku než zrovnateľná hypotéka s fixnou sadzbou a naopak ďalší mesiac môže mať nižšiu splátku, preto je dobré ak má v zálohe nejaké finančné prostriedky (*Top-hypoteky.cz*, ©2018).


Graf 13: Vývoj priemernej úrokovej sadzby



Zdroj: Vlastné spracovanie podľa Hypoindex.cz

Graf 13 znázorňuje vývoj váženej priemernej úrokovej sadzby, za ktorú sú poskytované v danom kalendárnom mesiaci nové hypotekárne úvery pre fyzické osoby. Váhami sú objemy poskytnutých úverov. Vývoj úrokovej sadzby závisí na finančnej stabilite a zásahu ČNB a ak sa pozrieme na graf, tak vidíme, že pred krízou dosiahla najnižšiu úroveň v roku 2005. Po vypuknutí krízy úrokové sadzby rástli. Na úroveň z roku 2005 sa následne dostala až v roku 2011. V roku 2016 boli úrokové sadzby na rekordnom minime. Napriek zvyšovaniu úrokovej sadzby zo strany ČNB, ceny hypoték reagovali veľmi pomaly. Taktiež nízke sadzby z vkladov znamenali, že depozitá boli oslabené infláciou (ChytryHonza.cz, ©2010–2019).


Graf 14: Vývoj objemu novoposkytnutých hypotekárnych úverov (v mld. Kč) a váženej priemernej úrokovej sadzby



Zdroj: Vlastné spracovanie podľa Ministerstva pro místní rozvoj ČR(©2019) a Hypoindex.cz

Úrokové miery predstavujú náklady financovania hypoték a tak sa predpokladá negatívny vzťah medzi priemernou úrokovou sadzbou a objemom novoposkytnutých hypoték. Na *grafe 14* vidíme, že pri poklese úrokovej sadzby vzrástol záujem o úvery (maximálny objem bol dosiahnutý v čase najnižšej úrokovej sadzby). Pre lepšie posúdenie vzťahu medzi sledovanými časovými radami nám slúži *graf 15*, ktorý znázorňuje percentuálnu zmenu objemu novoposkytnutých hypoték a priemernej úrokovej sadzby oproti rovnakému kvartálu minulého roka. Spočiatku sa vývoj neustále menil, od roku 2015 do roku 2018 platil inverzný vzťah až do doby kedy ČNB prišla s odporúčaniami.

Graf 15: Percentuálna zmena objemu hypoték a priemernej úrokovej sadzby oproti rovnakému obdobiu minulého roka




Zdroj: Vlastné spracovanie podľa Ministerstva pro místní rozvoj ČR(©2019) a Hypoindex.cz

2.5.1 Analýza časovej rady váženej priemernej úrokovej sadzby

K analýze časovej rady mám k dispozícii štvrťročné dáta od prvého kvartálu roku 2005 do druhého kvartálu roku 2019.

Obrázok 37: Časová rada váženej priemernej úrokovej sadzby



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Podľa priebehu časovej rady váženej priemernej úrokovej sadzby na *obrázku 37* usudzujem, že nie je stacionárna. Pre overenie svojho tvrdenia použijem Dickey Fuller test jednotkového koreňa.

H_0 : ČR má jednotkový koreň

H_1 : ČR nemá jednotkový koreň

Obrázok 38: ADF test časovej rady váženej priemernej úrokovej sadzby


	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.385881	0.3827
Test critical values: 1% level	-4.130526	
5% level	-3.492149	
10% level	-3.174802	

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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na *obrázku 38* máme výstup ADF testu, kde p-hodnota = 0,3827, čo znamená: $0,3827 > 0,05$ a teda na 5% hladine významnosti nezamietam H_0 . Prítomnosť jednotkového koreňa mi potvrdila môj subjektívny názor, že sa jedná o nestacionárnu časovú radu. Jednotkového koreňa sa zbavím diferencovaním.

Obrázok 39: Diferencovaná časová rada váženej priemernej úrokovej sadzby



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Podľa *obrázku 39* usudzujem, že hodnoty diferencovanej ČR sa mi neustále vracajú k nepodmienenej strednej hodnote, ktorá je rovná 0. Po prvej diferencii sa p-hodnota rovná $0,0040 < 0,05$, čo znamená, že zamietam nulovú hypotézu. Časová rada je integrovaná radu jedna, pretože sa stala stacionárnou po prvom diferencovaní.

Obrázok 40: ADF test diferencovanej časovej rady váženej priemernej úrokovej sadzby

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.455552	0.0040
Test critical values: 1% level	-4.130526	
5% level	-3.492149	
10% level	-3.174802	

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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Obrázok 41 znázorňuje korelogram prvej diferencie, kde u PACF „obdĺžnik“ poslednýkrát presahuje kritickú hranicu u oneskorenia 6. V nasledujúcich krokoch otestujem model AR(6). Ako druhý model som si zvolila ARMU (3,3) pretože žiadna ARMA nižšieho radu neprešla diagnostikou rezíduí.


Obrázok 41: Korelogram prvej diferencie časovej rady váženej priemernej úrokovej sadzby

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
		1	0.496	0.496	14.783	0.000
		2	0.163	-0.111	16.403	0.000
		3	0.225	0.255	19.548	0.000
		4	0.311	0.136	25.670	0.000
		5	0.073	-0.209	26.020	0.000
		6	0.193	0.368	28.477	0.000
		7	0.204	-0.199	31.285	0.000
		8	0.015	-0.100	31.300	0.000
		9	-0.226	-0.206	34.889	0.000
		10	-0.148	-0.125	36.450	0.000
		11	-0.204	-0.144	39.484	0.000
		12	-0.220	-0.014	43.097	0.000
		13	-0.216	-0.063	46.670	0.000
		14	-0.028	0.242	46.733	0.000
		15	-0.112	-0.040	47.733	0.000
		16	-0.157	0.074	49.765	0.000
		17	-0.165	-0.005	52.066	0.000
		18	-0.021	0.020	52.104	0.000
		19	-0.051	-0.008	52.337	0.000
		20	-0.038	-0.164	52.469	0.000
		21	-0.034	-0.065	52.575	0.000
		22	-0.037	-0.216	52.706	0.000
		23	-0.116	-0.004	54.042	0.000
		24	-0.059	-0.065	54.399	0.000

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na obrázku 42 máme grafy rezíduí oboch modelov. Podľa priebehu usudzujem, že ide o biely šum.

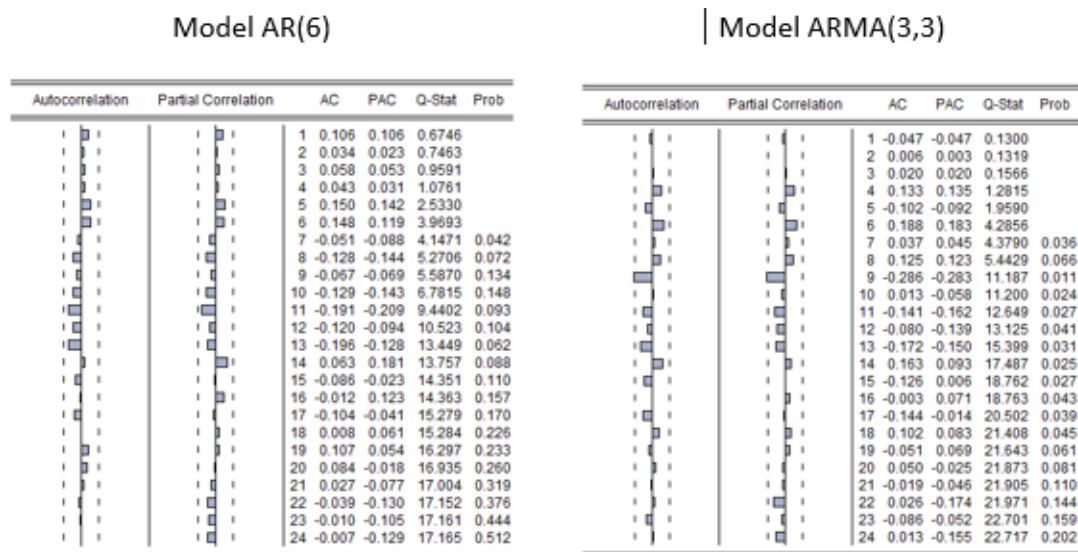
Obrázok 42: Diagnostika rezíduí modelov AR(6) a ARMA(3,3)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Ak sa pozriem na reziduálnu ACF a PACF na obrázku 43 - hodnoty ležia vo vnútri tolerančných hraníc, čo znamená, že reziduá nevykazujú autokoreláciu.

Obrázok 43: Reziduálna ACF a PACF modelov AR(6) a ARMA(3,3)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Z hľadiska diagnostiky rezíduí sú oba modely v poriadku, avšak model AR(6) má nižšiu hodnotu AIC (Akaike info criterion) a teda považujem ho za vhodnejší.

Obrázok 44: Výstup modelov AR(6) a ARMA(3,3)

Model AR(6)					Model ARMA(3,3)				
Variable	Coefficient	Std. Error	t-Statistic	Prob.	Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.026336	0.063243	-0.416420	0.6789	C	-0.035392	0.050673	-0.698435	0.4882
AR(1)	0.695082	0.127905	5.434377	0.0000	AR(1)	0.037662	0.380982	0.098855	0.9217
AR(2)	-0.337791	0.136853	-2.468285	0.0171	AR(2)	0.154651	0.353177	0.437885	0.6634
AR(3)	0.110462	0.129958	0.849982	0.3995	AR(3)	0.363167	0.174569	2.080369	0.0427
AR(4)	0.360965	0.156118	2.312137	0.0250	MA(1)	0.718447	0.425753	1.687474	0.0979
AR(5)	-0.540282	0.121378	-4.451248	0.0000	MA(2)	0.012909	0.613891	0.021028	0.9833
AR(6)	0.445790	0.144600	3.082912	0.0034	MA(3)	-0.514275	0.377131	-1.363650	0.1789
SIGMASQ	0.020829	0.004708	4.423637	0.0001	SIGMASQ	0.023557	0.005333	4.416916	0.0001
R-squared	0.494996	Mean dependent var	-0.028947		R-squared	0.428845	Mean dependent var	-0.028947	
Adjusted R-squared	0.422853	S.D. dependent var	0.204893		Adjusted R-squared	0.347252	S.D. dependent var	0.204893	
S.E. of regression	0.155657	Akaike info criterion	-0.709491		S.E. of regression	0.165539	Akaike info criterion	-0.601804	
Sum squared resid	1.187232	Schwarz criterion	-0.422747		Sum squared resid	1.342748	Schwarz criterion	-0.315060	
Log likelihood	28.22048	Hannan-Quinn criter.	-0.598052		Log likelihood	25.15140	Hannan-Quinn criter.	-0.490365	
F-statistic	6.861280	Durbin-Watson stat	1.670080		F-statistic	5.255876	Durbin-Watson stat	1.969666	
Prob(F-statistic)	0.000011				Prob(F-statistic)	0.000160			
Inverted AR Roots	.89 -.17+.91i	.52-.61i -.90	.52+.61i -.17-.91i		Inverted AR Roots	.80 .62	-.38+.56i -.67+.62i	-.38-.56i -.67-.62i	

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Model AR(6) podľa ktorého je možné predpovedať ďalší vývoj váženej priemernej úrokovej sadzby, môžeme zapísať:

$$\begin{aligned}
 x_t = & -0,006999 + 0,695082x_{t-1} - 0,337791x_{t-2} \\
 & + 0,110462x_{t-3} + 0,360965x_{t-4} \\
 & - 0,540282x_{t-5} + 0,445790x_{t-6} + a_t
 \end{aligned}
 \quad (2.8)$$


2.6 Inflácia

Inflácia predstavuje rast cien alebo znižovanie kúpnej sily peňazí → to znamená, že za peňažnú jednotku si kúpime menšie množstvo tovaru a služieb. Vývoj cenovej hladiny meriame pomocou cenových indexov. Najpoužívanějšími sú: *deflátor HDP*, *index spotrebiteľských cien (CPI)* a *index cien výrobcov (PPI)*.

- *Deflátor HDP* obsahuje ceny všetkých statkov, z ktorých je zložený HDP a teda považuje sa za najkomplexnejší ukazovateľ inflácie. Vypočítame ho ako podiel HDP (=bežného roku) v cenách bežného roku a HDP (=bežného roku) v cenách minulého roku. Deflátor nám vyjadruje ako sa zvýšila cenová hladina oproti minulému roku.
- *Index spotrebiteľských cien (CPI)* používame ak potrebujeme vedieť iba rast spotrebiteľských cien. Pre tento účel sa vytvára spotrebný kôš, ktorý odzrkadľuje štruktúru spotreby priemernej domácnosti.

- *Index cien výrobcov (PPI)* vypovedá primárne o konkurencieschopnosti našich výrobcov v porovnaní so zahraničnými (Holman, 2011, s. 526-528).


Graf 16: Vývoj inflácie



Zdroj: Vlastné spracovanie podľa ČSÚ

Graf 16 znázorňuje mieru inflácie vyjadrenú prírastkom indexu spotrebiteľských cien k rovnakému obdobiu predchádzajúceho roku, ktorá vyjadruje percentuálnu zmenu cenovej hladiny vo vykazovanom období daného roku oproti rovnakému obdobiu predchádzajúceho roku (ČSÚ, 2019)


Graf 17: Vývoj miery inflácie vyjadrenej prírastkom indexu spotrebiteľských cien k základnému obdobiu (2015=100)



Zdroj: Vlastné spracovanie podľa ČSÚ

Miera inflácie vyjadrená na grafe 17 prírastkom indexu spotrebiteľských cien k základnému obdobiu (priemer roku 2015=100) vyjadruje zmenu cenovej hladiny sledovaného obdobia daného roku oproti priemeru roku 2015.

Graf 18: Percentuálna zmena objemu hypoték a cenovej hladiny oproti rovnakému obdobiu minulého roku




Zdroj: Vlastné spracovanie podľa Ministerstva pro místní rozvoj ČR(©2019) a ČSÚ

U inflácii sa predpokladá, že jej rastom dôjde k zníženiu reálnych nákladov na hypotéky a zvýši sa záujem domácností o úvery. Z *grafu 18* nie je možné vyvodit' vzťah inflácie a objemu novoposkytnutých hypotekárnych úverov.

2.6.1 Analýza časovej rady inflácie

K analýze časovej rady indexu inflácie (2015=100) mám k dispozícii štvrťročné dáta od roku 2005 do druhého kvartálu roku 2019.

Obrázok 45: Časová rada indexu inflácie (2015=100)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Podľa priebehu dát na *obrázku 45* a absencii rovnováhy predpokladám, že časová rada priemernej hrubej mzdy nie je stacionárna. Pre overenie môjho predpokladu použijem Dickey Fuller test jednotkového koreňa.

H_0 : ČR má jednotkový koreň

H_1 : ČR nemá jednotkový koreň

Obrázok 46: ADF test časovej rady indexu inflácie (2015=100)


	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.758596	0.2187
Test critical values: 1% level	-4.140858	
5% level	-3.496960	
10% level	-3.177579	

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

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na základe ADF testu na *obrázku 46* s p-hodnotou 0,2187 na 5% hladine významnosti nezamietam nulovú hypotézu a pokračujem diferencovaním časovej rady. *Obrázok 47* nám znázorňuje časovú radu bez jednotkového koreňa, s ktorou už viem pracovať.


Obrázok 47: Diferencovaná časová rada indexu inflácie (2015=100)



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na korelograme prvej diferencie nadobúda PACF poslednú výraznú hodnotu u oneskorenia 8, čo ma presvedčilo otestovať model AR(8). U ACF sa hodnoty nevynulovali, čo mi naznačuje vhodnosť použiť model ARMA → vyskúšam model ARMA(4,3).


Obrázok 48: Korelogram prvej diferencie časovej rady indexu cien nehnuteľností



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Na nasledujúcom *obrázku 49* máme grafy rezíduí oboch modelov. Podľa priebehu usudzujem, že by sa mohlo jednať o biely šum.

Obrázok 49: Diagnostika rezíduí modelov $AR(8)$ a $ARMA(4,3)$



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Obrázok 50: Reziduálna ACF a PACF modelov AR(8) a ARMA(3,2)

Model AR(8)						Model ARMA(4,3)					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	1	1	1	1	1	1	1	1	1	1	1
2	0.054	0.054	0.1862	2	0.022	0.022	0.0353	2	0.022	0.022	0.0353
3	0.043	0.044	0.3014	3	0.058	0.059	0.3251	3	0.058	0.059	0.3251
4	-0.059	-0.072	0.6046	4	-0.049	-0.048	0.4750	4	-0.049	-0.048	0.4750
5	-0.036	-0.042	0.6877	5	-0.053	-0.058	0.6592	5	-0.053	-0.058	0.6592
6	-0.044	-0.039	0.8177	6	-0.065	-0.070	0.9419	6	-0.065	-0.070	0.9419
7	0.127	0.139	1.9038	7	-0.027	-0.020	0.9925	7	-0.027	-0.020	0.9925
8	-0.141	-0.140	3.2717	8	-0.082	-0.075	1.4566	8	-0.082	-0.075	1.4566
9	0.118	0.107	4.2552	9	0.133	0.139	2.6980	9	0.133	0.139	2.6980
10	-0.083	-0.076	4.5426	10	-0.031	-0.032	2.7661	10	-0.031	-0.032	2.7661
11	-0.160	-0.146	6.4082	11	-0.115	-0.125	3.7396	11	-0.115	-0.125	3.7396
12	-0.024	-0.038	6.4502	12	-0.054	-0.093	3.9540	12	-0.054	-0.093	3.9540
13	-0.109	-0.077	7.3528	13	-0.061	-0.054	4.2348	13	-0.061	-0.054	4.2348
14	-0.055	-0.070	7.6014	14	-0.021	-0.001	4.2678	14	-0.021	-0.001	4.2678
15	-0.017	0.015	7.6250	15	-0.042	-0.028	4.4105	15	-0.042	-0.028	4.4105
16	0.315	0.287	15.781	16	0.238	0.240	9.0544	16	0.238	0.240	9.0544
17	-0.065	-0.055	16.137	17	-0.044	-0.051	9.2297	17	-0.044	-0.051	9.2297
18	-0.052	-0.105	16.372	18	-0.019	-0.087	9.2612	18	-0.019	-0.087	9.2612
19	0.016	-0.040	16.394	19	0.065	0.050	9.6383	19	0.065	0.050	9.6383
20	-0.028	0.074	16.467	20	-0.080	-0.045	10.226	20	-0.080	-0.045	10.226
21	0.021	0.016	16.506	21	0.014	0.043	10.245	21	0.014	0.043	10.245
22	-0.031	-0.053	16.597	22	-0.028	-0.002	10.323	22	-0.028	-0.002	10.323
23	0.052	-0.036	16.864	23	0.022	0.031	10.371	23	0.022	0.031	10.371
24	-0.105	-0.071	17.988	24	-0.147	-0.167	12.569	24	-0.147	-0.167	12.569

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Ak sa pozriem na reziduálnu ACF a PACF na obrázku 50, tak hodnoty u modelu AR(8) neležia vo vnútri tolerančných hraníc, čo znamená, že reziduá vykazujú autokoreláciu. Model ARMA(4,3) je v poriadku.

Obrázok 51: Výstup modelu ARMA(3,2)

Model ARMA(4,3)				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.498827	0.131590	3.790774	0.0004
AR(1)	-0.549533	0.168157	-3.267982	0.0020
AR(2)	-0.523651	0.166468	-3.145662	0.0028
AR(3)	-0.558308	0.157458	-3.545753	0.0009
AR(4)	0.415243	0.157544	2.635728	0.0113
MA(1)	0.770128	0.210344	3.661280	0.0006
MA(2)	0.702446	0.165154	4.253265	0.0001
MA(3)	0.902527	0.260340	3.466728	0.0011
SIGMASQ	0.258682	0.075944	3.406203	0.0013
R-squared	0.481205	Mean dependent var	0.487719	
Adjusted R-squared	0.394740	S.D. dependent var	0.712408	
S.E. of regression	0.554243	Akaike info criterion	1.902532	
Sum squared resid	14.74487	Schwarz criterion	2.225119	
Log likelihood	-45.22217	Hannan-Quinn criter.	2.027900	
F-statistic	5.565271	Durbin-Watson stat	2.009104	
Prob(F-statistic)	0.000054			
Inverted AR Roots	.43	.01+.98i	.01-.98i	-1.00
Inverted MA Roots	.11+.95i	.11-.95i	-.99	

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Model ARMA(4,3) podľa ktorého je možné predpovedať ďalší vývoj indexu inflácie, môžeme zapísať:

$$\begin{aligned}
 x_t = & 1,105525 - 0,549533x_{t-1} - 0,523651x_{t-2} \\
 & - 0,558308x_{t-3} + 0,415243x_{t-4} \\
 & - 0,770128a_{t-1} - 0,702446a_{t-2} \\
 & - 0,902527a_{t-3} + a_t
 \end{aligned}
 \tag{2.9}$$

3 Viacnásobná lineárna regresia

V predchádzajúcej časti diplomovej práce som jednotlivo posudzovala vzťah daného faktoru a objemu novoposkytnutých hypotekárnych úverov. Väzby medzi veličinami sú však veľmi diskutabilné keďže vzťahy medzi dvoma premennými sú zjednodušením skutočnosti. Jednalo sa o zhodnotenie jednej z mnohých príčin zmien objemu hypoték. V skutočnosti ide o previazanosť jednotlivých premenných a ich vzájomné pôsobenie na závislú premennú. Pre prepracovanejšiu analýzu použijem model pozostávajúci z viacerých nezávislých premenných. Účinnou metódou pre analýzu vzťahov je viacnásobná lineárna regresia. Cieľom je odhadnúť vplyv každého faktoru na objem novoposkytnutých hypotekárnych úverov pri hladine významnosti 5%. Silu tohto vplyvu prezentujú regresné koeficienty.

Vzorec pre výpočet môžeme zapísať rovnicou (Rabušic, 2004):

$$y = b_0 + b_1 * x_1 + b_2 * x_2 + b_3 * x_3 + \dots + u \quad (3.1)$$

kde	y	závislá premenná,
	b_0	konštanta,
	$x_1, x_2, x_3, \dots, x_n$	nezávislé premenné,
	$b_1, b_2, b_3, \dots, b_n$	regresné koeficienty,
	u	náhodná chyba modelu.


V tomto prípade je objem hypoték (v mld. Kč) závislou premennou a za nezávislé premenné som zvolila analyzované faktory z predchádzajúcej časti diplomovej práce: *hrubý domáci produkt* (v mld. Kč), *všeobecnú mieru nezamestnanosti* (v %), *priemernú hrubú mzdu* (v Kč), *cenu nehnuteľností* (index 2010=100), *váženú priemernú úrokovú sadzbu* (v %) a *infláciu* (index 2015=100). Dáta použité pre spracovanie modelu sú uvedené v prílohe A.

Postup konštrukcie modelu:

1. sezónne očistenie použitých časových rád,
2. overenie vlastností náhodnej zložky,
3. zostavenie rovnice modelu a interpretácia výsledkov,
4. zhodnotenie modelu ako celku.

Hneď na začiatku časové rady sezónne očistím prostredníctvom štatistického softvéru EViews 10, konkrétne metódou *STL decomposition*. Obrázok 52 znázorňuje priebeh časových rád pred (horný graf daného faktoru) a po očistení (dolný graf).

Obrázok 52: Sezónne očistené časové rady



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10


Obrázok 53: Výstup viacnásobnej lineárnej regresie

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	50.93895	23.31296	2.185005	0.0335
HDP_SA	-0.006818	0.027869	-0.244631	0.8077
NEZAMESTNANOST_SA	-5.539366	0.999307	-5.543208	0.0000
MZDA_SA	-0.001439	0.000598	-2.407616	0.0197
CENA_SA	-0.112818	0.193209	-0.583916	0.5619
MIERA_SA	-4.686040	1.521875	-3.079123	0.0033
INFLACIA_SA	0.910084	0.285562	3.186988	0.0025
R-squared	0.908097	Mean dependent var	35.16071	
Adjusted R-squared	0.897285	S.D. dependent var	12.54458	
S.E. of regression	4.020441	Akaike info criterion	5.733422	
Sum squared resid	824.3613	Schwarz criterion	5.982096	
Log likelihood	-159.2692	Hannan-Quinn criter.	5.830286	
F-statistic	83.98869	Durbin-Watson stat	1.338794	
Prob(F-statistic)	0.000000			

Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Predtým ako zostavím rovnicu a interpretujem výsledky, musím si byť istá, že rezíduá sú bielym šumom. Na základe diagnostiky prostredníctvom grafu a korelogramu na obrázku 54 usudžujem, že rezíduá nie sú korelované. V prípade vzájomnej závislosti by som musela zvoliť iný typ modelu.

Obrázok 54: Diagnostika reziduí



Zdroj: Vlastné spracovanie pomocou štatistického softvéru EViews 10

Vo výstupe na *obrázku 53* – v stĺpci Coefficient mám regresné koeficienty potrebné pre zostavenie rovnice modelu:

$$y = 50,9,895 - 0,006818x_1 - 5,539366x_2 - 0,001439x_3 - 0,112818x_4 - 4,686040x_5 + 0,910084x_6 + u \quad (3.2)$$

kde x_1 HDP,
 x_2 nezamestnanosť
 x_3 mzda,
 x_4 cena,
 x_5 priemerná úroková miera,
 x_6 inflácia.

Regresné koeficienty modelu vyjadrujú zmenu objemu hypoték vyvolanú zmenou nezávislej premennej o jednotku. Znamienka určujú vzťah k závislej premennej: znamienko plus (+) znamená pozitívny a znamienko mínus (-) negatívny vzťah. V tomto prípade mám len jeden pozitívny vzťah a to medzi objemom hypoték a infláciou. Ostatné faktory: HDP, nezamestnanosť, mzda, cena a priemerná úroková sadzba majú nepriamu závislosť so závislou premennou.

- Hodnota parametra b_1 vyjadruje, že nárast HDP o 1 mld. Kč vyvolá pokles objemu novoposkytnutých hypotekárnych úverov v priemere o 0,006818 mld. Kč, za predpokladu, že ostatné faktory ostanú konštantné.

- Hodnota parametra b_2 vyjadruje, že ak dôjde k rastu všeobecnej miery nezamestnanosti o 1% a zároveň ostatné faktory остану konštantné, objem hypoték v priemere klesne o 5,539366 mld. Kč.
- Hodnota parametra b_3 vyjadruje, že nárast priemernej hrubej mzdy o 1 Kč. vyvolá pokles objemu novoposkytnutých hypotekárnych úverov v priemere o 0,001439 mld. Kč, za predpokladu, že ostatné faktory остану konštantné.
- Hodnota parametra b_4 vyjadruje, že nárast indexu cien nehnuteľností o jednotku vyvolá pokles objemu novoposkytnutých hypotekárnych úverov v priemere o 0,1128218 mld. Kč, za predpokladu, že ostatné faktory остану konštantné.
- Hodnota parametra b_5 vyjadruje, že nárast váženej priemernej úrokovej sadzby o 1% vyvolá pokles objemu novoposkytnutých hypotekárnych úverov v priemere o 4,686040 mld. Kč, za predpokladu, že ostatné faktory остану konštantné.
- Hodnota parametra b_6 vyjadruje, že nárast indexu inflácie o jednotku vyvolá nárast objemu novoposkytnutých hypotekárnych úverov v priemere o 0,910084 mld. Kč, za predpokladu, že ostatné faktory остану konštantné.

Významnosť modelu ako celku overujeme koeficientom determinácie. Hodnota 0,908270 znamená, že variabilitu závislej premennej je možné z viac ako 90% vysvetliť spoločným pôsobením faktorov, s ktorými daný model počíta. Čím je hodnota R^2 vyššia, tým je model, ktorý dokáže popísať chovanie časovej rady lepší. Model tejto práce vysvetlil 90,83% variability, zvyšné percentá predstavujú ostatné faktory, ktoré som v rámci modelu nebrala v úvahu.

Na záver by som zdôraznila, že ide o veľmi jednoduchú analýzu a som si vedomá slabín modelu na rôznych úrovniach. Jedným z problémov modelu môže byť nezahrnutie dôležitých premenných, otázkou však je, ktoré faktory sú relevantné a ktoré by v modeli nemali byť. Trh je celý previazaný a preto sa jedná o vytipovanie faktorov. Ďalším problémom môže byť slabá sila diagnostických testov pri malom množstve dostupných dát alebo reakcie premennej s určitým oneskorením. Model je založený na predpoklade, že nezávislé premenné sú striktne exogénne, to však v praxi môže byť porušené spätnou väzbou objemu novoposkytnutých hypoték k ostatným faktorom. Druhým predpokladom je zmena daného koeficientu za

podmienok *ceteris paribus*, čo znamená za inak rovnakých okolností avšak v skutočnosti môže dochádzať k zmene aj u ostatných premenných.

Záver

Cieľom diplomovej práce „Analýza faktorov pôsobiacich na hypotekárny trh v ČR“ bolo odhadnúť vplyv každého z vybraných faktorov na objem novoposkytnutých hypotekárnych úverov.

Práca pozostáva z troch kapitol. V prvej (teoretickej) kapitole je pozornosť venovaná histórii hypotekárneho úveru, jeho základným charakteristikám a špecifikám, vplyvu centrálnej banky a situácií v priebehu finančnej krízy.

Druhá kapitola poukazuje na dominantné faktory, ktoré vedú k zmene záujmu domácnosti o hypotéky, čo ovplyvňuje objem novoposkytnutých hypotekárnych úverov. Trh je celý previazaný, ovplyvnený mnohými faktormi avšak medzi základné som zaradila hrubý domáci produkt, nezamestnanosť, priemernú mzdu, cenu nehnuteľností, úrokovú sadzbu a infláciu. Každý zo zvolených faktorov je analyzovaný zvlášť. Pri modelovaní som sa snažila na základe priebehu grafu odhadnúť či sa jedná o stacionárnu alebo nestacionárnu časovú radu. Na 95% hladine spoľahlivosti som pomocou testu jednotkových koreňov potvrdila alebo poprela svoj subjektívny názor z predchádzajúceho kroku. Pokiaľ bola pôvodná časová rada nestacionárna, analyzovala som jej prvú diferenciu. Ak aj časová rada prvých diferencií bola nestacionárna, analyzovala som časovú radu druhých diferencií. Následne pomocou tvaru výberovej autokorelačnej a parciálnej autokorelačnej funkcie som určila aký typ modelu by bol vhodný pre stacionárnu časovú radu a prostredníctvom EViews 10 doplnila jeho parametre. Rozhodujúcu rolu tu hrá intuícia keďže niekedy je náročné určiť správny typ modelu. Po výbere vhodného modelu nasledovala jeho kontrola, spočívajúca v analýze rezíduí (museli byť bielym šumom) pomocou grafu rezíduí a reziduálnej autokorelačnej a parciálnej autokorelačnej funkcie. Ak som pri analýze usúdila, že existuje viac vhodných modelov tak Akaikeho dodatočné hodnotiace kritérium rozhodlo, ktorý z nich je pre nás najviac vyhovujúci. Takýmto postupom (na základe dát od roku 2005 do druhého kvartálu roku 2019) bola prostredníctvom štatistického softvéru EViews 10 zistená závislosť na minulých pozorovaniach a identifikovaný model, ktorý by tieto vzťahy popísal. Súčasťou druhej kapitoly je taktiež zhodnotenie vzťahu medzi skúmaným faktorom a objemom hypoték. Pri jednotlivom posudzovaní vzťahov som narazila na

problém. Existencia vzťahov je veľmi diskutabilná, keďže sledovaný faktor predstavuje len jednu z mnohých príčin, ktoré môžu viesť k zmene poskytnutých hypoték. Na základe grafu nebolo teda možné odvodiť vplyv na úvery – vzťahy sa niekoľkokrát v priebehu sledovaného obdobia menili.

V tretej časti bola využitá viacnásobná lineárna regresia. Ide o model pozostávajúci z viacerých nezávislých premenných. V mojom prípade závislou premennou je objem novoposkytnutých hypotekárnych úverov a za nezávislé premenné boli zvolené analyzované faktory z predchádzajúcej časti práce. Konštrukcia modelu bola opäť realizovaná prostredníctvom štatistického softvéru EViews 10. Hneď na začiatku som časové rady očistila o sezónnosť metódou STL Decomposition. Následne došlo k overeniu vlastností náhodnej zložky, zostaveniu rovnice modelu a interpretácii výsledkov. V poslednom kroku som zhodnotila model ako celok. Vo vytvorenom modeli máme len jeden pozitívny vzťah a to medzi objemom hypoték a infláciou. Ostatné faktory: HDP, nezamestnanosť, mzda, cena a priemerná úroková sadzba majú nepriamu závislosť so závislou premennou. Významnosť modelu ako celku overujeme koeficientom determinácie. Model tejto práce vysvetlil 90,83% variability, zvyšné percentá predstavujú ostatné faktory, ktoré som v rámci modelu nebrala v úvahu.

Na záver by som zdôraznila, že som si vedomá slabín modelu na rôznych úrovniach. Jedným z problémov modelu môže byť nezahrnutie dôležitých premenných, otázkou však je, ktoré faktory sú relevantné a ktoré by v modeli nemali byť. Trh je celý previazaný a preto sa jedná o vytipovanie faktorov. Ďalším problémom môže byť slabá sila diagnostických testov pri malom množstve dostupných dát alebo reakcie premennej s určitým oneskorením. Model je založený na predpoklade, že nezávislé premenné sú striktne exogénne, to však v praxi môže byť porušené spätnou väzbou objemu novoposkytnutých hypoték k ostatným faktorom. Druhým predpokladom je zmena daného koeficientu za podmienok ceteris paribus, čo znamená za inak rovnakých okolností avšak v skutočnosti môže dochádzať k zmene aj u ostatných premenných.

Po dopísaní práce hodnotím cieľ práce za splnený. Téma je veľmi zaujímavá a obohatila ma o mnohé nové poznatky. Za prínos hodnotím ucelený text, ktorý sa zaoberá danou problematikou.

Zoznam použitej literatúry a prameňov

1. ARLT, Josef, Markéta ARLTOVÁ a Eva RUBLÍKOVÁ, 2002. *Analýza ekonomických časových řad s příklady* [online]. Praha, [cit. 2020-01-17]. Dostupné z: <http://nb.vse.cz/~arltova/vyuka/crsbir02.pdf>. Skripta. Vysoká škola ekonomická v Praze.
2. ARLT, Josef a Markéta ARLTOVÁ, 2009. *Ekonomické časové řady*. Praha: Professional Publishing. ISBN 978-80-86946-85-6.
3. BARDOVÁ, Dagmar, Radka OPLTOVÁ a František PAVELKA, 1997. *Jak správně na hypotéky*. Praha: Consultinvest. ISBN 80-901486-5-4.
4. BAŠTA, Milan, 2015. *ARMA modely (úvod)*. Praha.
5. HOLMAN, Robert, 2010. Makroekonomie: středně pokročilý kurz. 2. vyd. Praha: C.H. Beck. Beckovy ekonomické učebnice. ISBN 978-80-7179-861-3.
6. HOLMAN, Robert, 2011. *Ekonomie*. 5. vyd. V Praze: C.H. Beck. Beckovy ekonomické učebnice. ISBN 978-80-7400-006-5.
7. MUSÍLEK, Petr, 2011. *Trhy cenných papírů*. 2. Aktualiz. a rozš. vyd. Praha: Ekopress, s. 139-145. ISBN 978-80-86929-70-5.
8. RADOVÁ, Jarmila, Petr DVOŘÁK a Jiří MÁLEK, 2013. *Finanční matematika pro každého*. 8., rozš. vyd. Praha: Grada. Finance (Grada). ISBN 978-80-247-4831-3
9. REVENDA, Zbyněk, 2011. *Centrální bankovníctví*. 3., aktualiz. vyd. Praha: Management Press. ISBN 978-80-7261-230-7.
10. 257/2016 Sb. Zákon o spotřebitelském úvěru

Elektronické zdroje

1. ChytryHonza.cz, ©2010-2019 : *Vývoj úrokových sazeb hypoték* [online]. Praha: Chytrý Honza, [cit. 2020-01-17]. Dostupné z: <https://www.chytryhonza.cz/vyvoj-urokovych-sazeb-hypotek>

2. ČECHLOVSKÁ, Šárka, 2005. *Zdroje financování bytové výstavby v České republice: Se zaměřením na hypoteční úvěr v kontextu evropského vývoje*. Liberec, 2005. Disertační práce. TECHNICKÁ UNIVERZITA V LIBERCI. Vedoucí práce Prof. Ing. Anděla Landorová, CSc.
3. Česká národní banka, ©2003-2018: *Ekonomický vývoj na území České republiky* [online]. Praha: Česká národní banka, [cit. 2020-01-17]. Dostupné z:
https://www.historie.cnb.cz/cs/menova_politika/prurezova_temata_menova_politika/1_ekonomicky_vyvoj_na_uzemi_ceske_republiky.html
4. Česká národní banka, ©2003-2020. *ARAD systém časových řad* [online]. Praha: Česká národní banka, [cit. 2020-01-17]. Dostupné z:
https://www.cnb.cz/cnb/STAT.ARADY_PKG.STROM_DRILL?p_strid=AC_HA&p_lang=CS
5. Český statistický úřad, 2005-2019. *Ceny bytů* [online]. Praha: Český statistický úřad, 2019 [cit. 2020-01-18]. Dostupné z:
https://www.czso.cz/csu/czso/ceny_bytu
6. Český statistický úřad, 2019. *Inflace, spotřebitelské ceny* [online]. Praha: Český statistický úřad, 2019 [cit. 2020-01-17]. Dostupné z:
https://www.czso.cz/csu/czso/inflace_spotrebitelske
7. *Finance v praxi*, ©2017-2019. *Hrubý domácí produkt v České republice* [online]. Praha: Finance v praxi, [cit. 2020-01-17]. Dostupné z:
<http://www.financevpraxi.cz/makroekonomie-ekonomicka-vykonnost>
8. HÁJEK, Ladislav a Lukáš REŽNÝ, 2014. 20 LET VÝVOJE ČESKÉ EKONOMIKY - SROVNÁNÍ SE SLOVENSKEM. *Economics* [online]. 2014(XVII), s. 20-31 [cit. 2020-01-17]. Dostupné z:
https://otik.uk.zcu.cz/bitstream/11025/17535/1/02_20%20Let%20Vyvoje%20Cesk_%20Ekonomiky.pdf
9. Hypio, 2018. *ČNB zavádí přísnější limity na hypotéky* [online]. Praha: Hypio, 2018 [cit. 2020-01-17]. Dostupné z: <https://www.hypio.cz/clanek/cnb-zavadi-prisnejsi-limity-na-hypoteky>

10. Hypoindex.cz, 2019. *Fincentrum Hypoindex – vývoj* [online]. Praha: Fincentrum & Swiss Life Select, [cit. 2020-01-19]. Dostupné z: <https://www.hypoindex.cz/hypoindex-vyvoj>
11. *Hypoteční kalkulačka*, 2018. *Jak na hypotéku po velkém říjnu 2018?* [online]. Praha: Hypoteční kalkulačka, [cit. 2020-01-17]. Dostupné z: <https://www.hypotecnikalkulacka.cz/hypotecni-zpravy/jak-na-hypoteku-po-velkem-rijnu-2018>
12. KALABIS, Zbyněk, 2013. ZLATÁ KORUNA: Z historie poskytování hypotečních úvěrů u nás. *ZLATÁ KORUNA: Z historie poskytování hypotečních úvěrů u nás* [online]. Praha: pdMEDIA, 13.11.2013 [cit. 2020-01-22]. Dostupné z: <http://www.zlatakoruna.info/zpravy/hypoteky/z-historie-poskytovani-hypotecnich-uveru-u-nas>
13. KRČEK, T. a D. SMETANKOVÁ, 2019. *Trh práce* [online]. Praha: Kancelář Poslanecké snemovny, 2019(9) [cit. 2020-01-17]. ISSN 2533-4158. Dostupné z: <http://www.psp.cz/sqw/ppi.sqw?d=12>
14. Kurzy.cz, ©2000-2020. *HDP 2020, vývoj hdp v ČR. Kurzy.cz: HDP 2020, vývoj hdp v ČR* [online]. Praha: Kurzy.cz, spol. s r.o., [cit. 2020-01-17]. Dostupné z: <https://www.kurzy.cz/makroekonomika/hdp/?G=3&A=2&page=1>
15. Kurzy.cz, ©2000-2020. *Průměrná mzda - vývoj průměrné mzdy, 2020* [online]. Praha: Kurzy.cz, spol. s r.o., [cit. 2020-01-17]. Dostupné z: <https://www.kurzy.cz/makroekonomika/mzdy/?G=1&A=1&page=1>
16. Kurzy.cz, 2020. *Typy hypoték (hypotečních úvěrů)* [online]. Praha: Kurzy.cz, [cit. 2020-01-22]. Dostupné z: <https://www.kurzy.cz/hypoteky/typy-hypotek/>
17. Ministerstvo pro místní rozvoj ČR, ©2019. *Hypoteční úvěry pro občany, podnikatele a obce* [online]. Praha: Ministerstvo pro místní rozvoj ČR, [cit. 2020-01-17]. Dostupné z: https://www.mmr.cz/getmedia/9fc70713-a7e8-43ef-8ce1-307f078fa7bf/Hypotecni-uvery-poskytnute-od-pocatku-cinnosti-hypotecnich-bank,-k-30-9-19-s-logem_1.pdf.aspx?ext=.pdf
18. Musílek, P., 2008. Příčiny globální finanční krize a selhání regulace. *Český finanční a účetní časopis*, 2008(4), 6-20. doi: 10.18267/j.cfuc.285.

19. NOVOTNÝ, Josef, 2009. Faktory ovlivňující spotřebitele při poskytování hypotečních úvěrů. *Scientific Papers of the University of Pardubice. Series D. Faculty of Economics and Administration*, , 100-104 Dostupné z: <https://search-proquest-com.zdroje.vse.cz/docview/2265544348?accountid=17203>
20. OSTATEK, Libor, 2010. Hypoindex.cz: Hypotéky nebyly hlavní příčinou globální krize. *Hypoindex.cz: Hypotéky nebyly hlavní příčinou globální krize* [online]. Praha: Fincentrum & Swiss Life Select a.s, 9.12.2010 [cit. 2020-01-22]. Dostupné z: <https://www.hypoindex.cz/clanky/hypoteky-nebyly-hlavni-pricinou-globalni-krize/>
21. Partners Finanční poradenství jinak, ©2012. *Historie hypotečních úvěrů* [online]. Praha: Partners Finanční poradenství jinak, [cit. 2020-01-17]. Dostupné z: <http://www.partners.cz/cs/produkty/hypoteky/historie-hypotecnich-uveru/>
22. PELLEŠOVÁ, Pavlína, 2009. Trendy ekonomického růstu v České republice. In: *Nierówności społeczne a wzrost gospodarczy w kontekście uwarunkowań instytucjonalnych* [online]. Uniwersytet Rzeszowski, s. 221-232 [cit. 2020-01-17]. ISBN 978-83-7338-463-7. ISSN 1898-5085. Dostupné z: <http://ur.edu.pl/pliki/Zeszyt14/17.pdf>
23. POKORNÁ, Tereza, 2018. Rekordní jízdu českého hypotečního trhu zarazí změny pravidel. *Peak.cz* [online]. Praha: PEAK NEWS MEDIA, [cit. 2020-01-17]. Dostupné z: <https://www.peak.cz/rekordni-jizdu-ceskeho-hypotecniho-trhu-zarazi-zmeny-pravidel/1663/>
24. RABUŠIC, Ladislav, 2004. Mnohonásobná lineární regrese. In: *Informační systém Masarykovy univerzity* [online]. Praha: Masarykova univerzita, [cit. 2020-01-17]. Dostupné z: https://is.muni.cz/el/1423/podzim2004/SOC418/multipl_regres_1.pdf
25. SOMOGYI, Tomáš, 2019. Česká bankovní asociace: Analýza vývoje cen nemovitostí v ČR [online]. Praha: Česká bankovní asociace, 28.8.2019 [cit. 2020-01-17]. Dostupné z: <https://cbaonline.cz/upload/371-studie-cba-2019.pdf>

26. Top-hypoteky.cz, ©2018: *Zvolit variabilní, nebo fixní úrokovou sazbu?* [online]. Praha: Top-Hypoteky.cz, [cit. 2020-01-17]. Dostupné z: <https://www.top-hypoteky.cz/hypotecni-novinky/zvolit-variabilni-nebo-fixni-urokovou-sazbu-4>
27. URBÁNEK, Vladimír, © 2000 - 2020. Předběžný odhad HDP - 4. čtvrtletí 2008. In: Kurzycz [online]. Praha: kurzy.cz, [cit. 2020-01-17]. Dostupné z: <https://www.kurzy.cz/zpravy/161636-cr-hdp-ve-4-ctvtletí-vzrostl-o-1-0--v-roce-2008-o-3-5/>

Zoznam obrázkov a grafov

Zoznam obrázkov

Obrázok 1: Transmisný mechanizmus menovej politiky v tržnej ekonomike	17
Obrázok 2: Úrokový transmisný mechanizmus	18
Obrázok 3: Nástroje centrálnej banky a ich vplyv na tržnú krátkodobú úrokovú mieru	18
Obrázok 4: Časová rada HDP	26
Obrázok 5: ADF test časovej rady HDP	27
Obrázok 6: Diferencovaná časová rada HDP	27
Obrázok 7: ADF test diferencovanej časovej rady HDP	28
Obrázok 8: Korelogram prvej diferencie časovej rady HDP	28
Obrázok 9: Diagnostika rezíduí modelov AR(4) a ARMA(3,2)	29
Obrázok 10: Reziduálna ACF a PACF modelov AR(4) a ARMA(3,2)	29
Obrázok 11: Výstup modelov AR(4) a ARMA(3,2)	30
Obrázok 12: Časová rada všeobecnej miery nezamestnanosti	33
Obrázok 13: ADF test časovej rady všeobecnej miery nezamestnanosti	33
Obrázok 14: Diferencovaná časová rada všeobecnej miery nezamestnanosti	34
Obrázok 15: ADF test diferencovanej časovej rady všeobecnej miery nezamestnanosti	34
Obrázok 16: Časová rada všeobecnej miery nezamestnanosti po druhej diferencii	35
Obrázok 17: ADF test dvakrát diferencovanej časovej rady všeobecnej miery nezamestnanosti	35
Obrázok 18: Korelogram dvakrát diferencovanej časovej rady všeobecnej miery nezamestnanosti	35
Obrázok 19: Diagnostika rezíduí modelov AR(5) a ARMA(1,1)	36
Obrázok 20: Reziduálna ACF a PACF modelov AR(5) a ARMA(1,1)	36
Obrázok 21: Výstup modelov AR(5) a ARMA(1,1)	37
Obrázok 22: Časová rada priemernej hrubej mzdy	39
Obrázok 23: ADF test časovej rady priemernej hrubej mzdy	40
Obrázok 24: Diferencovaná časová rada priemernej hrubej mzdy	40
Obrázok 25: ADF test diferencovanej časovej rady priemernej hrubej mzdy	40
Obrázok 26: Korelogram prvej diferenciácie časovej rady priemernej hrubej mzdy	41
Obrázok 27: Diagnostika rezíduí modelu AR(12)	41
Obrázok 28: Reziduálna ACF a PACF modelu AR(12)	42
Obrázok 29: Výstup modelu AR(12)	42
Obrázok 30: Časová rada indexu cien nehnuteľností (2010=100)	45
Obrázok 31: ADF test časovej rady indexu cien nehnuteľností	45
Obrázok 32: Diferencovaná časová rada indexu cien nehnuteľností	46

Obrázok 33: Korelogram prvej diferencie časovej rady indexu cien nehnuteľností	46
Obrázok 34: Diagnostika rezíduí modelov AR(1) a ARMA(1,1)	47
Obrázok 35: Reziduálna ACF a PACF modelov AR(1) a ARMA(1,1)	47
Obrázok 36: Výstup modelov AR(1) a ARMA(1,1)	48
Obrázok 37: Časová rada váženej priemernej úrokovej sadzby	50
Obrázok 38: ADF test časovej rady váženej priemernej úrokovej sadzby	51
Obrázok 39: Diferencovaná časová rada váženej priemernej úrokovej sadzby	51
Obrázok 40: ADF test diferencovanej časovej rady váženej priemernej úrokovej sadzby	52
Obrázok 41: Korelogram prvej diferencie časovej rady váženej priemernej úrokovej sadzby	52
Obrázok 42: Diagnostika rezíduí modelov AR(6) a ARMA(3,3)	53
Obrázok 43: Reziduálna ACF a PACF modelov AR(6) a ARMA(3,3)	53
Obrázok 44: Výstup modelov AR(6) a ARMA(3,3)	54
Obrázok 45: Časová rada indexu inflácie (2015=100)	56
Obrázok 46: ADF test časovej rady indexu inflácie (2015=100)	57
Obrázok 47: Diferencovaná časová rada indexu inflácie (2015=100)	57
Obrázok 48: Korelogram prvej diferencie časovej rady indexu cien nehnuteľností	58
Obrázok 49: Diagnostika rezíduí modelov AR(8) a ARMA(4,3)	58
Obrázok 50: Reziduálna ACF a PACF modelov AR(8) a ARMA(3,2)	59
Obrázok 51: Výstup modelu ARMA(3,2)	59
Obrázok 52: Sezónne očistené časové rady	61
Obrázok 53: Výstup viacnásobnej lineárnej regresie	61
Obrázok 54: Diagnostika rezíduí	62

Zoznam grafov

Graf 1: Objem novoposkytnutých úverov (tis. Kč)	12
Graf 2: Zmena HDP oproti rovnakému obdobiu minulého roku, vychádzame zo stálych cien roku 1995	23
Graf 3: Vývoj HDP a objemu novoposkytnutých hypotekárnych úverov (v mld. Kč)	25
Graf 4: Percentuálna zmena HDP a objemu novoposkytnutých hypotekárnych úverov oproti rovnakému obdobiu minulého roku	26
Graf 5: Vývoj všeobecnej miery nezamestnanosti	31
Graf 6: Vývoj objemu novoposkytnutých hypotekárnych úverov (v mld. Kč) a všeobecnej miery nezamestnanosti	32
Graf 7: Percentuálna zmena všeobecnej miery nezamestnanosti a objemu novoposkytnutých hypotekárnych úverov oproti rovnakému obdobiu minulého roku	32
Graf 8: Vývoj priemernej mzdy v Kč.	38

Graf 9: Vývoj objemu novoposkytnutých hypotekárnych úverov (v mld. Kč) a priemernej hrubej mzdy (v Kč)	38
Graf 10: Percentuálna zmena objemu hypoték a priemernej hrubej mzdy oproti rovnakému obdobiu minulého roka	39
Graf 11: Vývoj indexu cien nehnuteľností (2010=100)	43
Graf 12: Percentuálna zmena objemu hypoték a rozdiel indexu cien nehnuteľností oproti rovnakému obdobiu minulého roka	44
Graf 13: Vývoj priemernej úrokovej sadzby	49
Graf 14: Vývoj objemu novoposkytnutých hypotekárnych úverov (v mld. Kč) a váženej priemernej úrokovej sadzby	49
Graf 15: Percentuálna zmena objemu hypoték a priemernej úrokovej sadzby oproti rovnakému obdobiu minulého roka	50
Graf 16: Vývoj inflácie	55
Graf 17: Vývoj miery inflácie vyjadrenej prírastkom indexu spotrebiteľských cien k základnému obdobiu (2015=100)	55
Graf 18: Percentuálna zmena objemu hypoték a cenovej hladiny oproti rovnakému obdobiu minulého roka	56

Zoznam príloh

Příloha A – Dáta použité pre spracovanie modelu viacnásobnej lineárnej regresie

obdobie	Objem novoposkytnutých hypotekárnych úverov (mld. Kč)	Hrubý domáci produkt (mld.Kč)	Všeobecná miera nezamestnanosti (%)	Vážená priemerná úroková sadzba (%)	Index cien nehnuteľnosti (2010=100)	Index miery inflácie (2015=100)	Priemerná hrubá mzda (Kč)
2005Q1	13,12	695,20	8,10	4,45	66,30	80,30	17067,00
2005Q2	18,21	759,40	8,00	3,97	65,80	80,60	18112,00
2005Q3	18,68	753,50	7,80	3,63	66,50	81,10	18203,00
2005Q4	22,06	775,80	7,90	3,80	67,50	81,50	19963,00
2006Q1	18,89	749,70	7,70	4,12	69,00	82,60	18270,00
2006Q2	27,03	812,20	7,30	4,02	70,70	82,90	19300,00
2006Q3	26,27	819,70	7,10	4,19	73,30	83,50	19305,00
2006Q4	28,65	840,80	6,70	4,37	76,50	82,70	21269,00
2007Q1	28,17	832,50	5,90	4,27	80,30	83,80	19687,00
2007Q2	46,35	890,10	5,50	4,32	84,90	85,00	20740,00
2007Q3	32,23	895,60	5,20	4,90	89,70	85,70	20721,00
2007Q4	35,54	917,30	4,90	5,29	93,90	86,80	22641,00
2008Q1	25,76	876,90	4,60	5,54	99,10	89,90	21647,00
2008Q2	33,79	935,90	4,40	5,52	106,10	90,70	22370,00
2008Q3	30,81	935,10	4,30	5,73	111,80	91,40	22282,00
2008Q4	29,73	941,00	4,50	5,67	111,90	90,80	24484,00
2009Q1	17,81	875,90	5,70	5,66	108,80	92,00	22263,00
2009Q2	21,84	918,10	6,60	5,53	103,00	92,00	22971,00
2009Q3	16,81	908,80	7,30	5,65	103,30	91,50	23192,00
2009Q4	17,39	925,30	7,50	5,60	102,10	91,20	25565,00
2010Q1	15,97	905,00	7,90	5,43	100,80	92,60	22748,00
2010Q2	22,62	914,70	7,40	5,11	100,40	93,20	23513,00
2010Q3	21,07	925,40	7,20	4,73	99,90	93,20	23665,00
2010Q4	25,11	921,70	7,00	4,33	98,90	93,10	25803,00
2011Q1	23,37	924,50	7,00	4,24	97,10	94,20	23144,00
2011Q2	33,02	932,70	6,90	4,22	95,10	94,80	23984,00
2011Q3	28,48	957,80	6,70	4,04	94,50	94,90	24089,00
2011Q4	34,21	961,10	6,60	3,66	93,70	95,30	26067,00
2012Q1	28,55	957,00	6,90	3,62	94,90	97,60	24126,00
2012Q2	31,38	951,70	7,00	3,66	96,80	98,00	24626,00
2012Q3	27,66	956,40	7,10	3,53	96,00	98,00	24514,00
2012Q4	34,01	957,40	7,30	3,26	96,60	98,00	27170,00
2013Q1	27,85	953,90	7,30	3,20	96,40	99,40	24061,00
2013Q2	43,93	964,20	7,00	3,00	96,60	99,50	24449,00
2013Q3	38,10	962,30	7,00	3,00	97,40	99,20	24836,00
2013Q4	39,44	993,00	6,90	3,07	98,50	99,20	22288,00
2014Q1	28,93	987,20	6,60	3,00	99,30	99,60	24806,00
2014Q2	38,94	1061,20	6,30	2,82	100,60	99,70	25500,00
2014Q3	37,29	1072,40	6,00	2,64	101,90	99,80	25219,00
2014Q4	38,20	1077,70	5,90	2,44	101,20	99,60	27200,00
2015Q1	37,02	1104,20	5,90	2,26	102,90	99,70	25306,00
2015Q2	50,99	1115,90	5,20	2,07	105,60	100,30	26287,00
2015Q3	47,41	1125,20	4,90	2,10	108,10	100,20	26072,00
2015Q4	48,87	1153,60	4,60	2,09	110,90	99,70	28152,00
2016Q1	41,99	1167,00	4,30	2,02	113,40	101,30	26480,00
2016Q2	60,02	1176,30	4,10	1,90	116,50	100,60	27297,00
2016Q3	51,77	1183,10	4,00	1,85	118,80	100,70	27220,00
2016Q4	64,52	1185,90	3,70	1,78	121,90	101,20	25061,00
2017Q1	53,51	1211,90	3,40	1,88	124,20	102,60	27889,00
2017Q2	59,60	1259,50	3,10	2,03	127,60	102,80	29346,00
2017Q3	48,82	1276,70	2,80	2,02	133,70	103,30	29050,00
2017Q4	54,77	1291,20	2,50	2,15	137,10	103,80	31646,00
2018Q1	48,93	1305,60	2,40	2,37	140,10	104,50	30265,00
2018Q2	51,87	1314,60	2,30	2,50	143,20	105,20	31851,00
2018Q3	53,94	1334,70	2,30	2,53	146,40	105,80	31516,00
2018Q4	55,86	1355,30	2,10	2,78	148,70	106,00	33840,00
2019Q1	34,90	1405,50	2,00	2,96	150,50	107,30	32466,00
2019Q2	45,87	1381,40	2,10	2,80	151,40	108,10	34105,00