

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**MODELIRANJE IN NAPOVEDOVANJE INDEKSA CEN
STANOVANJSKIH NEPREMIČNIN**

Ljubljana, junij 2023

GAŠPER OSTANEK

IZJAVA O AVTORSTVU

Podpisani Gašper Ostanek, študent Ekonomske fakultete Univerze v Ljubljani, avtor predloženega dela z naslovom Modeliranje in napovedovanje indeksa cen stanovanjskih nepremičnin, pripravljene v sodelovanju s svetovalcem red. prof. dr. Miroslavom Verbičem

IZJAVLJAM

1. da sem predloženo delo pripravil samostojno;
2. da je tiskana oblika predloženega dela istovetna njegovi elektronski obliki;
3. da je besedilo predloženega dela jezikovno korektno in tehnično pripravljeno v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani, kar pomeni, da sem poskrbel, da so dela in mnenja drugih avtorjev oziroma avtoric, ki jih uporabljam oziroma navajam v besedilu, citirana oziroma povzeta v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani;
4. da se zavedam, da je plagiatstvo – predstavljanje tujih del (v pisni ali grafični obliki) kot mojih lastnih – kaznivo po Kazenskem zakoniku Republike Slovenije;
5. da se zavedam posledic, ki bi jih na osnovi predloženega dela dokazano plagiatstvo lahko predstavljalo za moj status na Ekonomski fakulteti Univerze v Ljubljani v skladu z relevantnim pravilnikom;
6. da sem pridobil vsa potrebna dovoljenja za uporabo podatkov in avtorskih del v predloženem delu in jih v njem jasno označil;
7. da sem pri pripravi predloženega dela ravnal v skladu z etičnimi načeli in, kjer je to potrebno, za raziskavo pridobil soglasje etične komisije;
8. da soglašam, da se elektronska oblika predloženega dela uporabi za preverjanje podobnosti vsebine z drugimi deli s programsko opremo za preverjanje podobnosti vsebine, ki je povezana s študijskim informacijskim sistemom članice;
9. da na Univerzo v Ljubljani neodplačno, neizključno, prostorsko in časovno neomejeno prenašam pravico shranitve predloženega dela v elektronski obliki, pravico reproduciranja ter pravico dajanja predloženega dela na voljo javnosti na svetovnem spletu preko Repozitorija Univerze v Ljubljani;
10. da hkrati z objavo predloženega dela dovoljujem objavo svojih osebnih podatkov, ki so navedeni v njem in v tej izjavi.
11. da sem preveril verodostojnost informacij, ki izhajajo iz zapisov na podlagi uporabe orodij umetne inteligence.

V Ljubljani, dne _____

Podpis študenta: _____

KAZALO

UVOD	1
1 NEPREMIČNINSKI TRG	2
1.1 Nastanek in pok nepremičninskega balona	4
1.2 Vpliv nepremičninskega trga na gospodarstvo	5
2 MODELIRANJE CEN NEPREMIČNIN.....	7
2.1 Ameriški trg nepremičnin	7
2.2 Evropski trg nepremičnin	9
2.3 Preostali trgi	11
3 SPREMENLJIVKE, VKLJUČENE V NAPOVEDOVANJE CEN STANOVANJSKIH NEPREMIČNIN.....	13
3.1 Pretekle raziskave	13
3.2 Izbrane spremenljivke za modeliranje indeksa cen stanovanjskih nepremičnin v Sloveniji.....	17
3.2.1 Odvisna spremenljivka	17
3.2.2 Pojasnjevalne spremenljivke	18
3.2.2.1 <i>Trg dela</i>	19
3.2.2.2 <i>Gospodarstvo</i>	19
3.2.2.3 <i>Cene</i>	20
3.2.2.4 <i>Monetarna politika</i>	20
3.2.2.5 <i>Delniški trgi</i>	20
3.2.2.6 <i>Gradbeni sektor</i>	21
4 METODOLOGIJA.....	21
4.1 Stacionarnost	21
4.2 Modeli časovnih vrst	23
4.2.1 AR model.....	23
4.2.2 MA model.....	23
4.2.3 ARMA model	24
4.2.4 ARMAX model	25
4.3 Avto-korelacijska funkcija in delna avto-korelacijska funkcija	25
4.4 Box-Jenkins pristop pri izbiri ARMA modela	26

4.5	Box-Pierce oziroma Ljung-Box test	27
4.6	Ocena napovedi modela	27
5	NAPOVEDOVANJE INDEKSA CEN VSEH STANOVANJSKIH NEPREMIČNIN V SLOVENIJI	28
5.1	Stacionarnost spremenljivk	28
5.1.1	Stacionarnost indeksa cen vseh stanovanjskih nepremičnin	28
5.1.2	Stacionarnost pojasnjevalnih spremenljivk	30
5.2	Analiza ARMA modela	31
5.2.1	Diagnostika ARMA modela	35
5.2.2	Napovedovanje zunaj vzorca z ARMA modelom	37
5.3	Analiza ARMAX modela	39
5.3.1	Korelacije napovedovane časovne vrste ter pojasnjevalnih časovnih vrst	39
5.3.2	Izbira optimalnega ARMAX modela	41
5.3.3	Diagnostika ARMAX modela	42
5.3.4	Napovedovanje zunaj vzorca z ARMAX modelom	44
5.4	Primerjava ARMA in ARMAX modela pri napovedovanju	46
5.4.1	Znotraj vzorčno napovedovanje	46
5.4.2	Zunaj vzorčno napovedovanje	47
	SKLEP	48
	LITERATURA IN VIRI	49
	PRILOGE	53

KAZALO TABEL

Tabela 1:	Legenda časovnih vrst	18
Tabela 2:	ADF test z odmikom indeks cen vseh stanovanjskih nepremičnin	29
Tabela 3:	ADF test z odmikom za rast indeksa cen vseh stanovanjskih nepremičnin	30
Tabela 4:	ADF test z zamikom za osnovne časovne vrste	30
Tabela 5:	AIC ARMA modelov opazovane časovne vrste	33
Tabela 6:	SBIC ARMA modelov opazovane časovne vrste	33
Tabela 7:	Model ARMA(2,4)	33
Tabela 8:	Model ARMA(1,1)	34
Tabela 9:	ARMA(1,1) model na podatkih od Q1 2007 do Q4 2021	37
Tabela 10:	MSFE in MAFE zunaj vzorčnega napovedovanja ARMA(1,1) modela	38
Tabela 11:	Korelacijska matrika opazovanih časovnih vrst	39

Tabela 12: MSE in MAE vrednosti ARMAX modelov pri napovedovanju znotraj vzorca	41
Tabela 13: Optimalen ARMAX model	42
Tabela 14: Ocenjen ARMAX model s pojasnjevalnima spremenljivkama SP in LI na podlagi prvih 60 opazovanj	44
Tabela 15: MSFE in MAFE vrednosti zunaj vzorčnega napovedovanja ARMAX modela	45
Tabela 16: Primerjalne vrednosti napovedovanja znotraj vzorca.....	47
Tabela 17: Primerjalne vrednosti napovedovanja zunaj vzorca	48

KAZALO SLIK

Slika 1: Ponudba in povpraševanje na stanovanjskem nepremičninskem trgu	3
Slika 2: Indeks cen vseh stanovanjskih nepremičnin v Sloveniji	17
Slika 3: Rast indeksa cen vseh stanovanjskih nepremičnin v Sloveniji	29
Slika 4: Numerični prikaz ACF in PACF funkcije.....	31
Slika 5: Grafični prikaz ACF	32
Slika 6: Grafični prikaz PACF	32
Slika 7: Primerjava realnih vrednosti in napovednih vrednosti ARMA modela znotraj vzorca	34
Slika 8: Lastne vrednosti ARMA(1,1) modela.....	35
Slika 9: Funkcija impulzivnega odziva	36
Slika 10: Avto-korelacija med ostanki ARMA(1,1) modela.....	36
Slika 11: Primerjava statičnega in dinamičnega napovedovanja zunaj vzorca za ARMA(1,1) model.....	37
Slika 12: Primerjava realnih in napovednih vrednosti ARMAX modela znotraj vzorca	42
Slika 13: Funkcija impulznega odziva ARMAX modela.....	43
Slika 14: Avto-korelacija med ostanki ARMAX modela.....	44
Slika 15: Primerjava statičnega in dinamičnega napovedovanja zunaj vzorca za ARMAX modela	45
Slika 16: Napovedovanja znotraj vzorca ARMA in ARMAX modela	46
Slika 17: Napovedovanja zunaj vzorca ARMA in ARMAX modela.....	47

KAZALO PRILOG

Priloga 1: ARMA (1,1) z dodano pojasnjevalno časovno vrsto LI	1
Priloga 2: ARMA (1,1) z dodano pojasnjevalno časovno vrsto SP	1

SEZNAM KRATIC

angl. – angleško

ACF – (angl. Auto-correlation function); Avto-korelacijska funkcija

ADF – (angl. Augmented Dickey-Fuller test); Razširjeni Dickey-Fullerjev test

AIC – (angl. Akaike information criterion); Akaikiejev informacijski kriterij

AR – (angl. Autoregressive model); Avtoregresijski model

ARDL – (angl. Autoregressive distributed lag model); Avtoregresijski model porazdeljenih odlogov

ARIMA – (angl. Autoregressive integrated moving average model); Avtoregresijski integrirani model drsečega povprečja

ARIMAX – (angl. Autoregressive integrated moving average with exogenous inputs model); Avtoregresijski integrirani model drsečega povprečja z vključenimi pojasnjevalnimi spremenljivkami

ARMA – (angl. Autoregressive moving average model); Avtoregresijski model drsečega povprečja

ARMAX – (angl. Autoregressive moving average with exogenous inputs model); Avtoregresijski model drsečega povprečja z vključenimi pojasnjevalnimi spremenljivkami

BDP – Bruto domači proizvod

BIC – (angl. Bayesian information criterion); Bayesijski informacijski kriterij

BS – Banka Slovenije

BVAR – (angl. Bayesian vector autoregressive model); Bayesijski vektorski avtoregresijski model

EGARCH – (angl. Exponential generalized autoregressive conditional heteroskedasticity model); Eksponentni generalizirani avtoregresijski pogojni heteroskedastični model

FED – (angl. Federal reserve system); Federal reserve sistem

FRED – (angl. Federal reserve economic data); Ekonomski podatki Federal reserve

GARCH – (angl. Generalized autoregressive conditional heteroskedasticity model); Generalizirani avtoregresijski pogojni heteroskedastični model

HICP – (angl. Harmonized index of consumer prices); Harmonizirani indeks cen življenjskih potrebščin

MA – (angl. Moving average model); Model drsečega povprečja

MAE – (angl. Mean absolute error); Povprečna absolutna napaka

MAFE – (angl. Mean absolute forecast error); Povprečna absolutna napaka napovedi

ME – (angl. Mean error); Povprečna napaka

MSE – (angl. Mean square error); Povprečna kvadratna napaka

MSFE – (angl. Mean square forecast errors); Povprečna kvadratna napaka napovedi

OECD – (angl. The organization for economic cooperation and development); Organizacija za gospodarsko sodelovanje in razvoj

PACF – (angl. Partial auto-correlation function); Delna avto-korelacijska funkcija
RMSE – (angl. Root mean square error); Kvadratni koren povprečne kvadratne napake
SBIC - (angl. Schwartz Bayesian information criterion); Schwartz Bayesianski informacijski kriterij
SC - (angl. Schwartz information criterion); Schwartz informacijski kriterij
SURS – Statistični urad Republike Slovenije
VAR – (angl. Vector autoregressive model); Vektorski avtoregresijski model

UVOD

Gibanje cen stanovanjskih nepremičnin je izjemnega pomena, saj lastništvo nepremičnin ohranja bogastvo investorjev in je hkrati ena izmed gonilnih sil gospodarstva skozi gradnje in finančna sredstva, zato je dostop do realnih napovedi cen nepremičnin zelo pomemben tako za lastnike stanovanj kot tudi za vlagatelje in organe finančnega nadzora (Milunovich, 2020). Prav tako daje nepremičninski trg veliko informacij tudi bankam, saj lahko z njimi merijo tveganje neplačil na hipotekarnih kreditih. Na gibanje indeksa se lahko zanašajo tudi centralne banke, saj tako lahko sledijo kreditni sposobnosti gospodinjstev (Finocchiaro & Von Heideken, 2013). Cikli na nepremičninskem trgu imajo velik vpliv na potrošnjo kot tudi na finančne trge in na makroekonomijo kot celoto (Bork & Møller, 2012; Belsky & Prakken, 2004).

Kako velik vpliv ima gibanje cen stanovanjskih nepremičnin na gospodarstvo, smo lahko videli v zadnji gospodarski krizi leta 2008, ko je zaradi prevelike ponudbe in velike zadolženosti gospodinjstev, zaradi nakupov nepremičnin privedla do poka nepremičninskega balona v letu 2007, ki je nato vplival na celotno svetovno gospodarstvo (Baker, 2008). Leamer (2007) je bil celo mnenja, da od zadnjih 10 recesij, ki so se zgodile v Ameriki, jih je kar 8 nastalo zaradi velikih težav na stanovanjskem trgu nepremičnin in trgu trajnih potrošniških dobrin. Gibanje cen stanovanjskih nepremičnin vpliva na bruto domači proizvod (v nadaljevanju BDP) preko gradbenega sektorja, saj če cene stanovanj rastejo hitreje kot stroški gradnje, bodo investitorji pospešili gradnjo novih stanovanj (Jacobsen & Naug, 2005). Prav tako imajo cene stanovanjskih nepremičnin vpliv na potrošnjo gospodinjstev, saj z rastjo cen raste tudi bogastvo gospodinjstev, kar posledično pozitivno vpliva na potrošnjo (Case, Glaeser & Parker, 2000).

Zaradi velikega vpliva gibanja cen nepremičnin na poslovne cikle je že veliko ekonomistov v preteklosti želelo razviti model, s katerim bi lahko napovedovali gibanje cen stanovanjskih nepremičnin. Spekter modelov, ki so jih raziskovalci uporabili v preteklih analizah, je zelo širok. Od najpreprostejših ekonometričnih modelov, kot je univariatna linearna regresija (Case & Shiller, 2003), do bolj zapletenih, kot je na primer Bayesianski vektorski avtoregresijski model (angl. Bayesian vector autoregressive model, v nadaljevanju BVAR) (Stevenson & Young, 2007). Veliko raziskovalcev se je lotilo primerjave točnosti napovedi cen med enostavnimi in kompleksnimi modeli (Chaplin, 1999; Newell, Acheampong & Karantonis, 2002; Stevenson & McGarth, 2003; Jadevicius & Huston, 2015). Ugotovili so, da čeprav kompleksnejše metode vsebujejo več spremenljivk in enačb in boljše napovedujejo znotraj vzorca, še ne pomeni, da se bodo boljše obnesle od preprostejših modelov pri zunaj vzorčnem napovedovanju (Newell, Acheampong & Karantonis, 2002; Jadevicius & Huston, 2015).

Namen magistrske naloge je, da s primerjalno analizo izberem optimalen model časovnih vrst za napovedovanje indeksa cen vseh stanovanjskih nepremičnin v Sloveniji. Med seboj bom primerjal dva modela časovnih vrst, in sicer avtoregresijski model drsečega povprečja (angl. autoregressive moving average model, v nadaljevanju ARMA) in avtoregresijski model drsečega povprečja z vključenimi pojasnjevalnimi spremenljivkami (angl. Autoregressive moving average with exogenous inputs model, v nadaljevanju ARMAX). Magistrska naloga je razdeljena v dva dela. Na teoretični ter aplikativni del. V teoretičnem delu bo predstavljeno:

- definicija nepremičninskega trga,
- nastanek nepremičninskega balona v letu 2007,
- vpliv nepremičninskega trga na gospodarstvo,
- modeliranje cen stanovanjskih nepremičnin,
- vpliv makroekonomskih kazalnikov na cene stanovanjskih nepremičnin,
- pregled izbranih pojasnjevalnih spremenljivk za napovedovanje indeksa cen vseh stanovanjskih nepremičnin in
- metodologija analize.

Aplikativni del magistrske naloge je razdeljen na naslednja poglavja:

- Analiza indeksa cen stanovanjskih nepremičnin,
- Analiza pojasnjevalnih spremenljivk,
- Priprava ARMA modela,
- Diagnostika ARMA modela ter napovedovanje znotraj vzorca,
- Izbira in diagnostika optimalnega ARMAX modela,
- Primerjava zunaj vzorčnih napovedi optimalnega ARMA in ARMAX modela.

V magistrskem delu bom preveril tri temeljne hipoteze:

- Na slovenski indeks cen vseh stanovanjskih nepremičnin vplivajo pretekle vrednosti indeksa cen vseh stanovanjskih nepremičnin, dolgoročna obrestna mera, kratkoročna obrestna mera, stopnja rasti BDP-ja, stopnja brezposelnosti in gibanje delniškega trga.
- Kompleksnejši model (ARMAX) ima večjo pojasnjevalno moč kot enostavnejši model (ARMA).
- Enostavnejši model (ARMA) se izkaže za boljši model pri napovedovanju zunaj vzorca v primerjavi s kompleksnejšim modelom (ARMAX).

1 NEPREMIČNINSKI TRG

V Stvarnopravnem zakoniku (SPZ), UR. l. RS, št. 87/2022 imamo v 18. členu definiran pojem nepremičnina kot: »Nepremičnina je prostorsko odmerjen del zemeljske površine,


skupaj z vsemi sestavinami.« Nepremičnine lahko delimo na več vrst. Če jih delimo po dejanski uporabi, jih lahko razdelimo na (Internet Media, brez datuma):

- stanovanjske nepremičnine,
- kmetijske nepremičnine,
- javne nepremičnine,
- nepremičnine za posebne namene,
- poslovne nepremičnine,
- industrijske nepremičnine.

Sam se bom v nadaljevanju magistrskega dela osredotočil na stanovanjske nepremičnine, ki jih predstavljajo nove in rabljene družinske hiše ter nova in rabljena stanovanja (SURS, brez datuma).

Na trgu nepremičnin se cena stanovanj določi glede na ponudbo in povpraševanje, vendar se vzpostavitev ravnotežne cene na trgu nepremičnin razlikuje od trga dobrin in storitev. Razlika nastane, ker je ponudba nepremičnin na kratek rok neelastična, saj v kratkem roku ne moremo zgraditi novih stanovanj, kar pomeni, da je ponudba takšna, kakršna je zaloga nepremičnin v tistem trenutku na razpolago (Renigier-Biłozor & Wiśniewski, 2012). Na sliki 1 imamo predstavljeno neelastično ponudbo. Predpostavimo, da imamo v času t_0 ravnotežje na trgu stanovanjskih nepremičnin v točki 1. Nato pride do pozitivnega šoka na strani povpraševanja in ker se ponudba na kratek rok ne more prilagoditi, se novo ravnotežje vzpostavi v točki 2 z novo ceno v vrednosti P_2 . Gradbena podjetja in investitorji zaznajo to povečanje cen in pospešijo gradnjo novih stanovanj, kar na dolgi rok premakne premico ponudbe na desno, kjer se ustvari novo ravnotežje v točki 3 s ceno P_3 , ki je nižja od predhodne cene.

Slika 1: Ponudba in povpraševanje na stanovanjskem nepremičninskem trgu



Vir: lastno delo.

Če primerjamo stanovanjski trg s kapitalskim trgom, lahko vidimo, da je kapitalski trg veliko bolj volatilen od stanovanjskega, saj v času krize cene nepremičnin manj padejo v primerjavi z drugimi kapitalskimi trgi. To se zgodi zato, ker njihovi lastniki niso pripravljeni prodati svoje nepremičnine pod svojo določeno ceno. To lahko vidimo tudi pri odzivu cen stanovanjskih nepremičnin na neko informacijo iz gospodarstva, saj se tu cene veliko počasneje odzovejo kakor na kapitalskih trgih. Če pogledamo gibanje cen stanovanj v času gospodarskega razcveta, lahko vidimo, da zaradi pozitivnih pričakovanj lastnikov velikokrat pride do nastajanja nepremičninskih balonov. Velik vpliv na spremembe cen imajo tudi transakcijski stroški, saj nižji stroški vodijo v večje število transakcij, kar pomeni, da se cene hitreje prilagodijo na ravnotežno ceno (Adams & Füss, 2010).

1.1 Nastanek in pok nepremičninskega balona

Veliko raziskovalcev meni, da ima trg nepremičnin zelo velik vpliv na realni sektor ekonomije. To smo lahko videli še posebej v času gospodarske krize 2008, kjer je zlom na nepremičninskem trgu povzročil začetek ene največjih recesij. Od zadnjih 10 recesij v Ameriki, se je kar osem recesij zgodilo zaradi velikih težav na stanovanjskem trgu in trgu trajnih potrošniških dobrin (Leamer, 2007). Prav tako ima stanovanjski trg ključno vlogo pri poslovnih ciklih (Barari, Sarkar, Kundu & Chowdhury, 2014).

Do nepremičninskih balonov pride zaradi pretiranih pričakovanj, da se bodo cene v prihodnosti v nedogled povečevale. Kupci, ki v preteklosti niso bili pripravljeni odšteti tolikšne vsote denarja za stanovanje, zaradi pričakovanj, da bodo v prihodnosti cene nepremičnin zgolj še rasle, kupijo stanovanje, saj se bojijo, da si ga v prihodnosti ne bodo mogli več privoščiti ali bodo primorani zanj odšteti znatno večjo vsoto. Tako pričakovanja potrošnikov oblikujejo cene nepremičnin v prihodnosti. Ko potrošniki na trgu zaznajo hitro povečanje cene, je to zanje informacija, da se bodo cene v prihodnje še dodatno povečale, kar vodi v povečano povpraševanje in še dodatno pospeši rast cen. Poleg tega dodatna pričakovanja investorjev, da jim bo investicija v stanovanje prinesla kapitalske dobičke, še dodatno povečuje povpraševanje, kar vodi v še večjo volatilitnost cen na nepremičninskem trgu (Selim, 2009). Če so pričakovanja o hitri in stabilni rasti prihodnih cen pomemben motivacijski dejavnik pri investitorjih, potem bodo cene same po sebi nestabilne. Cene se na dolgi rok ne morejo zelo hitro povečevati v nedogled, saj ko ljudje zaznajo, da so cene na vrhuncu in v kratkem pričakujejo padec cen, zmanjšajo svoje povpraševanje, kar vodi v hitro znižanje cen in pok nepremičninskega balona (Case & Shiller, 2003).

Zadnji nepremičninski balon v Ameriki je začel nastajati že v sredini 90. let. Na razvoj nepremičninskega balona je imel vpliv predvsem dvig vrednosti delniškega trga, saj so si ljudje z naraščanjem bogastva lahko privoščili večje in boljše domove in s tem del svojega bogastva porazdelili na nepremičninski trg. To je vodilo v povečanje povpraševanja po stanovanjskih nepremičninah in ker je ponudba v kratkem časovnem obdobju neelastična, je to vodilo k povečanju cen. Zaradi stalnega naraščanja cen nepremičnin se je ta rast ugnezdila

v pričakovanja, kar je posledično še dodatno spodbudilo rast cen. Tako so realne cene stanovanjskih nepremičnin narastle med letom 1995 in 2002 za 30 odstotnih točk (FRED, brez datuma b). Zaradi povečanja povpraševanja po stanovanjskih nepremičninah se je posledično povečala izgradnja novih stanovanj (ponudba), ki je bila leta 2002 višja za 25 odstotnih točk kot triletno povprečje novo zgrajenih stanovanj med leti 1993-1995 (FRED, brez datuma c). Posledično se je povečal tudi delež praznih stanovanj iz 7.5 % v sredini 90. let na 9 % leta 2002 (FRED, brez datuma a). Zlom delniškega trga v začetku 2001 je samo še dodatno pospešil vlaganje v nepremičninski trg, saj so ljudje izgubili zaupanje v delniški trg in preusmerili svoje bogastvo na nepremičninski trg, kar je posledično še dodatno dvignilo cene nepremičnin. Dodaten pozitiven vpliv na cene stanovanjskih nepremičnin je imelo še znižanje hipotekarnih obrestnih mer ter spodbuda predsednika odbora Federal reserve sistema (angl. Federal reserve system – FED), da naj ljudje ne zapravljajo svojega denarja s fiksnimi hipotekarnimi krediti in naj se raje zavežejo k variabilnim hipotekarnim kreditom. Vsi ti dogodki so posledično vplivali na to, da so se cene stanovanjskih nepremičnin med letoma 2002 – 2006 povečale za dodatnih 31,6 odstotnih točk, kar je vodilo v to, da je gradbeni sektor še pospešil gradnjo novih stanovanj, ki je bila v letu 2005 za 50 % višja kot v sredini 90. let (FRED, brez datuma c). Leta 2007 je prišlo do poka nepremičninskega balona zaradi presežka ponudbe. V prvem kvartalu leta 2008 je vrednost zaseženih stanovanj znašala kar 60 % celotne vrednosti prodaje stanovanj v tem kvartalu. V določenih območjih je vrednost zaseženih stanovanj celo presegla vrednost prodaje. Zaradi padca cen stanovanjskih nepremičnin je prišlo do tega, da je veliko ljudi imelo višjo vrednost kredita, kakor je bila vrednost nepremičnine, kar je vodilo v neplačilo dolga, poleg tega pa so banke poostrile svoje zahteve z dvigom pologa, kar je posledično zmanjšalo število potencialnih kupcev in še dodatno pospešilo recesijo. Cene stanovanjskih nepremičnin so do konca leta 2007 padle za več kot 15 % glede na najvišjo raven pred začetkom krize (FRED, brez datuma b). Do konca leta 2008 so cene v najbolj prizadetih območjih padle za več kot 30 %. Izguba zaradi poka nepremičninskega balona je znašala 7 trilijonov dolarjev, kar je predstavljalo kar 50 % ameriškega BDP-ja. Zaradi tako velike izgube bogastva se je nato nadaljevala tudi finančna kriza (Baker, 2008).

1.2 Vpliv nepremičninskega trga na gospodarstvo

Agnello in Schuknecht (2011) sta z analiziranjem 18 držav v obdobju, daljšem kot 40 let, ugotovila, da so bili pozitivni trendi rasti cen na trgu nepremičnin med najdaljšimi v zadnjih 40 letih z velikim odstopanjem od dolgoročnega trenda. Vztrajni dolgoročni razcveti naj bi povzročili tudi kasnejše večje zlome na trgu nepremičnin. Ugotovila sta, da je izguba na strani BDP-ja odvisna od tega, kako velik je bil vzpon in kako prijazna je bila v tem obdobju kreditna politika za hipotekarne kredite. Če so v času razcveta pogoji za pridobitev kredita zelo ugodni, je velika verjetnost, da v času krize delu gospodinjestev ne bo uspelo poplačati dolgov, kar nato še dodatno poglobi recesijo in na drugi strani vodi v padec cen nepremičnin. Spremembe cen stanovanjskih nepremičnin vplivajo na BDP skozi dva kanala. Neposreden vpliv ima skozi gradnjo novih stanovanj, saj če cene nepremičnin rastejo hitreje kot stroški

gradnje, potem bo to vodilo v pospešeno investiranje v gradnjo novih stanovanj (Jacobsen & Naug, 2005). Indirektno pa vpliva na bogastvo zasebnih gospodinjstev preko sprememb v potrošnji (Duca, Luttrell & Murphy, 2011).

Glede na to, da ima večina gospodinjstev velik delež svojega premoženja v obliki stanovanjskega premoženja, ni čudno, da je v času finančne krize v letu 2008 velik padec cen stanovanj povzročil najhujšo recesijo po veliki depresiji v 30. letih prejšnjega stoletja. S padcem cen stanovanj se je tako velikemu deležu gospodinjstev močno zmanjšalo skupno bogastvo. Prav tako je recesija povzročila veliko število neodplačanih hipotek in posledično zaseženih stanovanj, kar je privedlo do zaostritve kreditnih pogojev. Pesimizem na hipotekarnem trgu je tako še dodatno poglobil krizo ter podaljšal okrevanje gospodarstva (Bernanke, 2011).

Dvig cen stanovanjskih nepremičnin vodi v povečanje dolgoročne akumulacije zadolževanja, saj si morajo gospodinjstva več denarja izposoditi za nakup stanovanja enake velikosti in kakovosti. Več kot je nepremičnin obremenjenih s hipoteko, večji bo vpliv negativnega šoka na trgu nepremičnin na solventnost bank. V času razcveta lahko dvig cen stanovanjskih nepremičnin vpliva na povpraševanje gospodinjstev po drugih dobrinah, saj se z njim veča tudi bogastvo gospodinjstev. Tako bodo nekatera gospodinjstva povečala svojo potrošnjo z najemom hipotekarnega kredita, saj ga lahko dobijo z zelo ugodno obrestno mero (Jacobsen & Naug, 2005). Do podobnega zaključka so prišli tudi Case, Glaeser in Parker (2000), saj so ugotovili, da se gospodinjstvom z dvigom cen nepremičnin bogastvo poveča, kar jim posledično poveča kreditno sposobnost, ki jo lahko izkoristijo za dodatno potrošnjo, kar nato vodi v večjo odvisnost gospodinjstev od fluktuacije gospodarstva. To lahko v času krize vodi do večjega števila neodplačanih kreditov, kar posledično vodi v zmanjšanje ponudb kreditov, zmanjšanje kapitala bank in dodatno zmanjšanje potrošnje gospodinjstev. Zaradi tega lahko pride do večjih nihanj in daljših obdobij razcvetov in recesij. Ugotovili so tudi, da ima še posebej v Ameriki, kjer kar dve tretjini ljudi živi v lastnem stanovanju, povečanje cen nepremičnin močen vpliv na potrošnjo. V naslednji študiji so Case, Shiller in Quigley (2003) ugotovili celo, da ima povečanje cen stanovanjskih nepremičnin večji pozitiven vpliv na potrošnjo, kakor povečanje vrednosti portfelja na delniškem trgu, saj na delniški trg večinoma investirajo bogata gospodinjstva, ki s povečevanjem bogastva ne bodo še dodatno povečala svoje potrošnje.

V času, ko je trg stanovanjskih nepremičnin, šibek, lastniki niso pripravljeni prodati pod svojo ceno. To vodi v znižanje volumna prodaje, kar posledično pripelje do zmanjšanja novogradenj in kot tudi zaposlitev v gradbenem sektorju. Na drugi strani v času razcveta cene stanovanjskih nepremičnin rastejo, kar pozitivno vpliva tako na število ljudi, zaposlenih v gradbenem sektorju, kot na število novogradenj. Če pogledamo skozi celoten cikel, lahko rečemo, da v času konjunktura pride do čezmerne ponudbe novih stanovanj, kar nato delno vpliva na dolžino naslednje recesije. Zato bi bilo smiselno, da bi monetarna politika spremljala trg nepremičnin in zaznala obdobje, ko bi prišlo do čezmerne gradnje novih stanovanj, in bi tako lahko posredovala že v času konjunktura, da bi s tem skrajšala oziroma

vsaj delno omejila dolžino prihodnjega padca na nepremičninskem trgu. Zaradi tega je zelo pomembno, da bi lahko oblikovalci monetarne politike znali napovedati gibanje cen nepremičnin, saj bi lahko s tem omejili dolžino in globino recesij (Leamer, 2007).

2 MODELIRANJE CEN NEPREMIČNIN

Napovedovanje cen stanovanjskih nepremičnin je bila v razvitih državah že v preteklosti zelo aktualna tema. Manjše, manj razvite države so začele zelo pozno spremljati cene stanovanjskih nepremičnin, kar posledično pomeni, da so to kratke časovne serije, ki jih je zelo težko napovedovati. Velikokrat so cene nepremičnin dokumentirane zgolj vsako četrletje, kar še dodatno skrajša število opazovanj. Poleg tega je analiza še toliko bolj zapletena zaradi asimetričnih ciklov, ki vplivajo na to, da je časovna vrsta nelinearna, saj se cene veliko hitreje vrnejo na ravnotežno raven med razcvetom kot v času recesije (Miles, 2008). Prav tako tudi visoki transakcijski stroški povzročajo nelinearnost časovne serije, kar zgolj dodatno poveča kompleksnost (Muellbauer & Murphy, 1997).

2.1 Ameriški trg nepremičnin

Balcilar, Gupta in Miller (2015) so v svoji raziskavi med seboj primerjali uspešnost linearnih in nelinearnih modelov pri napovedovanju cen stanovanjskih nepremičnin. Na podatkih štirih ameriških podregij so testirali razliko izven vzorčne napovedi med modeli. Prišli so do ugotovitve, da nelinearni model uspešneje napoveduje daljša časovna obdobja, medtem ko krajša obdobja enako dobro napove tudi linearni model, čeprav so bili podatki skladni s specifikacijo nelinearnega modela. Za kratkoročne napovedi je tako boljše uporabiti linearni model, saj po mnenju avtorjev stroški uporabe nelinearnega modela presegajo prednosti le tega.

Case in Shiller (2003) sta v svoji analizi želela preučiti, kako se spreminjajo cene stanovanj glede na letni prihodek na prebivalca v različnih ameriških državah v obdobju od leta 1985 do 2002. Ugotovila sta, da je napovedna moč prihodkov na prebivalca za cene nepremičnin zelo velika predvsem pri državah s stabilnimi cenami nepremičnin. V naslednjem koraku sta v analizo dodala še preostale pojasnjevalne spremenljivke (hipotekarne obrestne mere, stopnja brezposelnost, gradnja novih stanovanj). Z vključitvijo teh spremenljivk sta samo še povečala prilagajanje linearnih modelov. Napovedna moč se je z vključitvijo dodatnih spremenljivk v model veliko bolj povečala pri državah z volatilnimi cenami nepremičnin, saj so imele države s stabilnimi cenami zelo dobre napovedi že zgolj z dohodkom na prebivalca.

Crawford in Fratanoni (2003) sta preučevala tri različne univariatne modele za napovedovanje indeksa cen stanovanj za ponavljajoče se transakcije na državni ravni v obdobju med prvim četrletjem 1979 in četrtem četrletjem 2001. Primerjala sta napovedno moč zunaj in znotraj vzorca za generalizirani avtoregresijski pogojni heteroskedastični

model (angl. generalized autoregressive conditional heteroskedasticity model, v nadaljevanju GARCH), ARMA in model preklopa režima (angl. regime switching model) v petih različnih državah v Ameriki. Model preklopa režima se jima je zdel primeren, saj je trg stanovanjskih nepremičnin nagnjen k velikim spremembam znotraj cikla. Poleg tega sta avtorja menila, da se cene nepremičnin obnašajo drugače v različnih ekonomskih okoljih. Razlika med uporabljenimi modeli je ta, da ima časovna vrsta v ARMA modelu skozi celoten čas konstantno povprečje in varianco, v GARCH modelu konstantno povprečje, medtem ko se varianca spreminja skozi čas, v modelu preklopa režima pa je dovoljeno, da se tako varianca kot tudi povprečna vrednost spreminjata skozi čas. Za vsako državo posebej sta izbrala svoj ARMA model tako, da je imel ta najnižjo vrednost kvadratni koren povprečne kvadratne napake (angl. Root mean square error, v nadaljevanju RMSE) ter najnižjo vrednost Akaikejevega informacijskega kriterija (angl. Akaike information criterion, v nadaljevanju AIC). Z enakim postopkom sta nato izbrala tudi najboljši GARCH model in model preklopa režima za posamezno državo. Nato sta vse modele primerjala v napovedovanju zunaj vzorca za dve, pet in deset let v prihodnost. Ugotovila sta, da se za napovedovanje daljšega obdobja bolje obnesejo modeli preklopa režima zaradi tega, ker je večja možnost, da pride do strukturnega zloma. Medtem ko se je za kratkoročno napovedovanje v dveh državah najboljšo obnesel ARMA model, v drugih dveh državah GARCH model in v eni državi model preklopa režima.

Rapach in Strauss (2007) sta primerjala napovedne moči avtoregresijski modelov porazdeljenih odlogov (angl. autoregressive distributed lag model, v nadaljevanju ARDL) in AR modelov. Modele sta pripravila za osem različnih območij v Ameriki v obdobju od 1975 do 2006. Zanimalo ju je, ali se z dodajanjem neodvisnih spremenljivk v AR model lahko poveča njegova natančnost pri napovedovanju zunaj vzorca. V svojo analizo sta vključila kar 25 različnih neodvisnih spremenljivk, ki so se že v preteklih raziskavah pokazale kot determinante za cene stanovanjskih nepremičnin (Cho, 1996; Abraham & Hendershott, 1996; Johnes & Hyclak, 1999). Odvisna spremenljivka je bila indeks nominalnih cen stanovanj. ARDL modele sta pripravila tako, da sta za vsako okrožje najprej pripravila AR model in mu nato dodala zgolj eno pojasnjevalno spremenljivko. Tako sta lahko primerjala med seboj 25 ARDL modelov in ugotovila, katera spremenljivka najbolj izboljša zunaj vzorčno napovedno moč znotraj okrožja. Pri tem sta ugotavljala tudi, katera spremenljivka izboljša zunaj vzorčno napoved v vseh okrožjih hkrati. Med seboj sta primerjala modele pri napovedovanju štirih in osmih kvartalov v prihodnost. Pri primerjavi napovedi enostavnih ARDL modelov sta ugotovila, da se najboljšo obnese neodvisna spremenljivka indeks cen izdatkov za osebno potrošnjo, saj je bila vrednost povprečne kvadratne napake napovedi (angl. mean square forecast errors, v nadaljevanju MSFE) ARDL modela za kar 13 od 14 napovedi boljša od AR modela. Prav tako so se dobro obnesle tudi spremenljivke: razmerje med ceno in dohodkom, stopnja brezposelnosti in zaupanje potrošnika. Čez čas sta avtorja svojo raziskavo še dodatno razširila s tem, da sta vključila 20 držav in 4 dodatne neodvisne spremenljivke. Pri analizi enostavnih ARDL modelov sta prišla do zaključka, da ne moreta generično določiti, katera individualna spremenljivka izboljša

napoved za vse države, saj so se glede na države te spremenljivke spreminjale. Prišla sta do zaključka, da enostavni ARDL modeli na splošno boljše napovedujejo kakor AR modeli. Poleg tega sta še ugotovila, da se pri državah, ki so imele zelo veliko rast cen v obdobju analize, napovedna moč ARDL modelov in AR modelov ne razlikuje toliko kot pri državah, ki so imele stabilno rast (Rapach & Strauss, 2009).

Barari, Sarkar, Kundu in Chowdhury (2014) so v svoji študiji želeli pripraviti najboljši model za napovedovanje cen stanovanjskih nepremičnin na ameriškem trgu. Ker je imel sektor nepremičnin velik vpliv na začetek recesije 2008, so želeli avtorji preveriti možnosti strukturnih prelomov. V prvem delu so s svojo analizo preverili, koliko strukturnih prelomov se je zgodilo v časovni vrsti S&P/Case-Shiller. Ugotovili so, da znotraj stacionarne časovne vrste ni bilo nobenega strukturnega zloma. V naslednjem koraku so preverili še, ali lahko v originalni časovni vrsti zaznajo kakšen strukturni zlom. Prišli so do zaključka, da so se v času med 1995 in 2010 zgodili štiri strukturni zlomi, in sicer v februarju 2001, oktobru 2003, aprilu 2006 in avgustu 2008. Tako so se odločili, da med svoj nabor modelov vključijo tudi ne-stacionarni model s štirimi prelomi. V naslednji fazi so se lotili priprave različnih modelov, ki so jih nato primerjali med seboj pri zunaj vzorčnem napovedovanju za obdobje od enega do šestih mesecev v prihodnost. Modele so med seboj primerjali glede na RMSE vrednost in vrednost povprečne absolutne napake (angl. mean absolute error, v nadaljevanju MAE). Odločili so se, da bodo v svojo raziskavo vključili šest modelov. To so bili ARMA model, ARMA-eksponentni generalizirani avtoregresijski pogojni heteroskedastični model (angl. exponential generalized autoregressive conditional heteroskedasticity model – EGARCH), model naključnega prehoda, dva modela preklonnega režima in ne-stacionarni model s štirimi prelomi v trendu. Optimalen ARMA model so določili z minimizacijo vrednosti Bayesianski informacijskega kriterija (angl. Bayesian information criterion, v nadaljevanju BIC). Po pripravi vseh modelov in testiranju njihovih zunaj vzorčnih napovedi so prišli do zaključka, da enostavni ARMA model napoveduje zunaj vzorca prav tako dobro kot kompleksnejši modeli, kot so EGARCH in oba modela preklonnega režima. Medtem se je pri napovedovanju znotraj vzorca najboljše obnesel ne-stacionarni model s štirimi prelomi v trendu.

2.2 Evropski trg nepremičnin

Jacobsen in Naug, (2005) sta se v svoji raziskavi vprašala, kaj poganja cene stanovanjskih nepremičnin v nebo, saj so se te na Norveškem od leta 1992 do leta 2004 kar potrojile. Zaradi tega se je tudi zadolženost gospodinjstev od leta 2000 do leta 2004 povečala za kar 11 % na letni ravni in s tem postala še toliko bolj občutljiva na negativne gospodarske šoke. V svoji raziskavi sta se odločila, da bosta razvila ekonometrični model z uporabo makroekonomskih kazalnikov. Z modelom sta nato določila, ali je trg v nepremičninskem balonu ali ne. Če bi njun model napovedal nižje vrednosti, kakor so v realnosti, potem bi lahko sklepali, da se na trgu stanovanjskih nepremičnin kreira nepremičninski balon. S svojim modelom sta ugotovila, da so cene odvisne predvsem od obrestne mere, gradenj novih stanovanj, stopnje

brezposelnosti in dohodka gospodinjstev. Ugotovila sta tudi, da ima sprememba obrestne mere hiter vpliv na spremembo cene. Močan vpliv ima tudi trajna stopnja brezposelnosti, saj če se ta poveča za eno odstotno točko, to povzroči padec dolgoročne cene stanovanjskih nepremičnin za 11 odstotnih točk, vendar je to prilagajanje precej počasno, saj bi cene po enem letu padle za 7 odstotnih točk.

Jadevicius in Huston (2015) sta v svoji raziskavi želela narediti primerjavo med kompleksnimi in enostavnimi modeli ter dokazati, da so kompleksnejši modeli boljši kakor enostavni pri napovedovanju nepremičninskega trga. Napovedati sta želela cene poslovnih nepremičnin v Veliki Britaniji. V svojo analizo sta vključila enostavno linearno regresijo, sestavljeno linearno regresijo, avtoregresijski integrirani model drsečega povprečja (angl. Autoregressive integrated moving average model, v nadaljevanju ARIMA), avtoregresijski integrirani model drsečega povprečja z vključenimi pojasnjevalnimi spremenljivkami (angl. autoregressive integrated moving average with exogenous inputs, v nadaljevanju ARIMAX) in vektorski avtoregresijski model (angl. vector autoregressive model, v nadaljevanju VAR). V raziskavo sta vključila naslednje neodvisne spremenljivke: bančno obrestno mero, stopnjo zaposlenosti, število naročil za gradnje, BDP, izdatke gospodinjstev, inflacijo in angleški borzni indeks FTSE AS. Za odvisno spremenljivko sta izbrala rast vrednosti najemnin. Sestavila sta 169 modelov, med katerimi je bilo 7 enostavnih modelov, en sestavljen regresijski model, en VAR model, dvajset ARMA modelov (do vključno ARMA(4,4)) in 140 ARIMAX modelov, ki so imeli vključeno samo eno neodvisno spremenljivko. Za primerjavo zunaj vzročnega napovedovanja sta uporabila Theil U vrednost. Pri zunaj vzorčni napovedi avtorja nista mogla zagotovo trditi, kateri model se najboljšje izkaže, saj so se najboljše napovedi modelov razlikovale v tem, koliko časa v prihodnost so napovedovali. Prišla pa sta do zaključka, da AIC vrednost in R^2 vrednost modelov še ne pomenita, da bodo modeli dobro napovedovali zunaj vzorca in da s povečevanjem kompleksnosti modela ne pridejo do boljših napovedi. To sta tudi dokazala z VAR modelom, ki je bil najbolj kompleksen izmed vseh in imel tudi najboljšo R^2 vrednost ter zajel vse zlome trga v preteklosti, vendar je veliko slabše napovedoval zunaj vzorca kakor preostali enostavnejši modeli. Tako sta potrdila ugotovitve že preteklih raziskav (Chaplin, 1999; Newell, Acheampong & Karantonis, 2002; Stevenson & McGarth, 2003). Ti so prišli do ugotovitev, da bi morali stremeti k temu, da so modeli za napovedovanje bolj prijazni uporabniku in enostavnejši za razumevanje in da bi morali raziskovalci posvetiti več časa za razvoj in izboljšavo enostavnih napovednih tehnik kot pa povečevati kompleksnost modelov (Jadevicius & Huston, 2015). Newell, Acheampong in Karantonis (2002) so v svoji raziskavi ugotovili, da čeprav kompleksnejše metode vsebujejo več spremenljivk in enačb in boljše napovedujejo znotraj vzorca, še ne pomeni, da se bodo boljše obnesli od enostavnejših modelov pri zunaj vzorčnem napovedovanju. Prav tako sta bila skeptična nad kompleksnimi modeli tudi Pant in Starbuck (1990) v svoji raziskavi, saj sta menila, da lahko kompleksnejše metode res pridobijo več informacij iz podatkov, ampak lahko šum zamenjajo za informacijo, kar nato vodi v večje napake in slabše napovedi zunaj vzorca.

McGough in Tsolacos (1995) sta v svoji raziskavi uporabila ARIMA modele za napovedovanje najemnin treh različnih sektorjev na angleškem trgu. Prišla sta do ugotovitve, da se za napovedovanje stanovanjskih najemnin najboljše odreže ARIMA(1,2,0) model, za pisarniške najemnine ARIMA(0,2,1) in za industrijske najemnine ARIMA(3,2,0). Če pogledamo sestavo modelov, lahko rečemo, da imajo na cene stanovanjskih in industrijskih najemnin vpliv predvsem pretekle vrednosti odvisne spremenljivke, medtem ko na pisarniške najemnine vpliva predvsem pretekla vrednost slučajne spremenljivke.

Stevenson in Young (2007) sta v svoji raziskavi dokazala, da sta tako BVAR model kot tudi sestavljena linearna regresija precenila ponudbo stanovanj na irskem trgu med letom 1998 in 2001, saj se ponudba ne more tako hitro odzvati na dvig povpraševanja, kakor naj bi ta dva modela napovedovala. Težava obeh modelov je, da imata vključene makroekonomske kazalnike, ki se na dvig povpraševanja odzovejo zelo hitro, medtem ko je ponudba stanovanj na kratek rok rigidna. Ponudba na trgu nepremičnin se na povečano povpraševanje odzove zelo počasi, saj povečanje ponudbe na trgu pomeni gradnja novih nepremičnin, kar pa se ne more zgoditi v kratkem času. Med drugim tudi investitorji velikokrat odlašajo z začetkom projekta zaradi potencialno večjih donosov v prihodnosti, saj se nadejajo nenehnega povečevanja vrednosti hiš in zemljišč. Svoj optimalni ARMA model sta določila tako, da sta v prvem delu opravila diferenco in dobila stacionarno časovno vrsto, nato pa sta pripravila vse možne modele od ARMA(1,0) do ARMA(3,3) in izbrala model, ki je imel najnižjo vrednost BIC kriterija. Za pripravo sestavljene linearne regresije in BVAR modela sta avtorja uporabila enake neodvisne spremenljivke. Pri določitvi, kateri model se najboljše obnese pri napovedovanju zunaj vzorca za eno, dve in tri leta v prihodnost, sta uporabila povprečno napako (angl. mean error, v nadaljevanju - ME), MAE, MSFE in varianco napake. Ugotovila sta, da se tako za vse časovne napovedi kot tudi za vse različne kazalnike točnosti napovedovanja izkaže najboljše ARMA(2,1) model.

2.3 Preostali trgi

Pri napovedovanju cen stanovanjskih nepremičnin na Singapurskem trgu sta Chin in Fan (2005) uporabila različne ARIMA modele: navaden ARIMA model, ARIMA model s slamnatimi spremenljivkami ter drugi ARIMA modeli. Ugotovila sta, da se za napovedovanje najboljše odreže ARIMA(1,1,0) model s slamnatimi spremenljivkami .

Za napovedovanje indeksa cen stanovanjskih nepremičnin na trgu v Turčiji sta Yilmaz in Kestel (2020) želela pripraviti model, ki bi se najboljše obnesel pri zunaj vzorčnem napovedovanju. V svoj sklop modelov sta vključila generaliziran linearni model, VAR model, ARMA model in sezonski ARIMA model. Modele sta med seboj primerjala z vrednostjo povprečne kvadratne napake (angl. Mean square error, v nadaljevanju MSE), RMSE in MAE kazalniki pri zunaj vzorčnem napovedovanju. Optimalen ARMA model sta izbrala glede na najnižjo vrednost BIC in AIC, kar je bil ARMA(1,1). Ker sta ugotovila z Webel-Ollech testom, da je časovna vrsta odvisna od sezonskega vpliva, sta v naslednjem

koraku izbrala še najboljši sezonski ARIMA model z najnižjo vrednostjo AIC-ja, in sicer $ARIMA(1,1,3)(0,0,2)_{12}$. Avtorja sta nato pripravila modele na podlagi prvih 102 opazovanj in jih nato testirala na zadnjih 12 opazovanjih. Kot najboljši model z najnižjimi vsemi tremi kazalniki prilagajanja napovedi se je izkazal sezonski ARIMA model.

Tse (1997) je menil, da so ARIMA modeli odlični za napovedovanje kratkoročnih sprememb cen na trgu nepremičnin v Hongkongu, saj se cene nepremičnin na kratki rok počasi spreminjajo. V svoji študiji je avtor želel z ARIMA modeli napovedati dve časovni seriji, in sicer indeks cen pisarniških in industrijskih nepremičnin, saj so bile stanovanjske nepremičnine v času analize pod državno regulacijo. V svojo analizo je vključil četrtnete podatke od leta 1980 do 1995. Določil je najboljša možna ARIMA modela, in sicer za oba indeksa je bil to $ARIMA(2,1,1)$. V zadnjem delu je preizkusil še svoja modela pri napovedovanju. Ugotovil je, da z ARIMA modeli lahko dobro napovedujemo gibanje indeksa cen pisarniških in industrijskih nepremičnin.

Hepšen in Vatansever (2011) sta bila prva raziskovalca, ki sta želela z modeli časovnih vrst napovedati indeks cen stanovanjskih nepremičnin v Dubaju. V svoji raziskavi sta uporabila pristop priprave ARIMA modela po Box-Jenkins postopku. Po pripravi najboljšega ARIMA modela glede na avto-korelacijska funkcijo (angl. auto-correlation function, v nadaljevanju ACF) in delno avto-korelacijsko funkcijo (angl. partial auto-correlation function, v nadaljevanju – PACF), sta pripravila še zunaj vzorčno napoved za naslednjih dvanajst mesecev in jo primerjala z realnimi vrednostmi. Napako napovedi sta merila z RMSE vrednostjo in ugotovila, da se njun ARIMA model zelo dobro obnese.

V raziskavi realnega indeksa cen stanovanjskih nepremičnin v Avstraliji je Milunovich (2020) preizkusil kar sedeminštirideset različnih algoritmov za napovedovanje realnih cen stanovanjskih nepremičnin in stopnje rasti cen stanovanj. Uporabil je tradicionalne modele časovnih vrst, postopke strojnega učenja in nevronske mreže globokega učenja. Po pripravi modelov jih je med seboj primerjal z MSE vrednostjo pri zunaj vzorčnem napovedovanju za en, dva, štiri in osem kvartalov v prihodnost. V raziskavo je avtor vključil poleg odvisne spremenljivke tudi sedem drugih pojasnjevalnih spremenljivk, ki so jih že v preteklosti drugi avtorji vključevali v svoje raziskave. Avtor je prišel do zaključka, da so se pri zunaj vzorčnem napovedovanju boljše odrezali univariatni modeli v primerjavi z multivariatnim v vseh obdobjih. Ugotovil je tudi, da se linearni modeli odrežejo boljše pri napovedovanju enega četrtneta v prihodnost, medtem ko se nelinearni modeli izkažejo bolje pri napovedovanju osmih četrtnetij v prihodnost. Prav tako je avtor ugotovil, da se tako absolutna kot relativna natančnost napovedi z dolžino napovedovanja obzorja slabša in menil, da se za napovedovanje osmih kvartalov v prihodnost lahko zanašamo na napovedi naključnega sprehoda z zamikom.

3 SPREMENLJIVKE, VKLJUČENE V NAPOVEDOVANJE CEN STANOVANJSKIH NEPREMIČNIN

3.1 Pretekle raziskave

Pri raziskavi makroekonomskih determinant na mednarodnem trgu stanovanjskih nepremičnin sta Adams in Fuss (2010) v analizo vključila časovne vrste, dolge 30 let za 15 razvitih držav. Ugotovila sta, da cene povečuje predvsem dvig zaposlenosti, industrijske produktivnosti, povečanje ponudbe denarja in kratkoročne obrestne mere, saj se s tem povečujejo stroški izgradnje novih nepremičnin, kar negativno vpliva na ponudbo stanovanj. To posledično vodi v povečanje najemnin in cen stanovanjskih nepremičnin. Padeč cen nepremičnin pa povzroči dvig dolgoročne obrestne mere, saj postane trg stanovanjskih nepremičnin manj privlačen za investitorje in ti raje investirajo v druge trge s fiksnimi donosi.

Geng (2018) je v svoji raziskavi analiziral, kaj vpliva na dolgoročno ceno stanovanjskih nepremičnin v 20 razvitih OECD državah. Prišel je do zaključka, da so realne cene stanovanjskih nepremičnin pozitivno korelirane z realnim dohodkom na prebivalca, saj večji kot je razpoložljiv dohodek na prebivalca, več denarja je ta pripravljen zapraviti za nakup stanovanja oz. za najem hipotekarnega kredita. Prav tako so cene pozitivno korelirane z realnim neto finančnim premoženjem gospodinjstva, saj se s tem povečuje povpraševanje po stanovanjskih nepremičninah, kar vodi v povišanje cen. Njegove ugotovitve je potrdil tudi Claussen (2013), da je kar 60 % dviga cen stanovanjskih nepremičnin na Švedskem od leta 1990 lahko pojasniti z rastjo realnega razpoložljivega dogodka, nekaj manj kot 10 odstotkov pa z rastjo realnega neto finančnega premoženja. Na rast cen nepremičnin ima pozitiven vpliv tudi nižanje hipotekarne obrestne mere, saj imajo zaradi tega gospodinjstva nižje stroške pri odplačevanju kredita (Geng, 2018). Dodaten vpliv ima tudi znižanje donosnosti na državnih obveznicah, kar investitorje motivira za nakup stanovanja. Pozitiven vpliv na cene ima tudi demografski trend, saj se s priseljevanjem in povečevanjem rodnosti znotraj države na dolgi rok povečuje tudi povpraševanje po stanovanjskih nepremičninah, kar potem vodi v povišanje cen. V drugem delu analize je Geng (2018) preveril še ponudbeno stran in ugotovil, da cene stanovanj rastejo predvsem zaradi slabe politike investiranja v izgradnjo novih stanovanj, kar lahko nato vodi v primanjkljaj ponudbe stanovanj.

Yilmaz in Kestel (2020) sta v svojo analizo na Turškem trgu poleg indeksa cen stanovanjskih nepremičnin vključila še ceno zlata, devizno razmerje med dolarjem in turško liro, devizno razmerje med evrom in turško liro, inflacijo in obrestno mero hipotekarnih kreditov. Devizna razmerja med domačo in tujo valuto sta uporabila, saj je njihovo gospodarstvo zelo odvisno od uvoza. V analizo sta vključila prav tako inflacijo, ker je že veliko preteklih raziskav prikazalo, da naj bi investitorji investirali denar v nepremičnine z namenom, da zaščitijo svoj kapital pred izgubo vrednosti (Yilmaz & Selcuk-Kestel, 2019). Veliko nakupov stanovanj je financiranih s strani hipotekarnih kreditov, zato sta v svojo analizo vključila tudi hipotekarno

obrestno mero. Uporabila sta tudi naslednje makroekonomske kazalnike, kot so indeks življenjskih stroškov, indeks gospodarskega zaupanja ter stopnja zaposlenosti. Odvisnost spremenljivk sta preverila s korelacijsko matriko in z Grangerjevim testom vzročnosti. Ugotovila sta, da stopnja brezposelnosti in indeks življenjskih stroškov ne vplivata na indeks. Na drugi strani pa indeks vpliva na fiksno obrestno mero hipotekarnih kreditov in ne obratno.

Prav tako sta tudi Case in Shiller (2003) v svoji analizi na ameriškem trgu ugotovila, da so z dodajanjem neodvisnih spremenljivk v linearni model, kot so hipotekarna obrestna mera, zaposlitev, stopnja brezposelnosti in novogradnja nepremičnin, samo še povečali prilagajanje linearnih modelov. Analiza linearnih modelov je pokazala, da se z dvigom dohodka na prebivalca cene nepremičnin povečajo, podoben vpliv ima tudi število novogradenj, medtem ko ima dvig brezposelnosti ravno obraten vpliv.

Rapach in Strauss (2009) sta v svoji raziskavi, kjer sta primerjala zunaj vzorčno napovedovanje ARDL modelov z AR modeli, vključila neodvisne spremenljivke, ki so bile že v preteklosti uporabljene v podobnih analizah (Abraham & Hendershott, 1996; Cho, 1996; Johnes & Hyclak, 1999). Vključila sta razmerje med ceno nepremičnin in osebnim prihodkom na prebivalca, saj je veliko avtorjev že v preteklosti menilo, da to razmerje signalizira, ali so cene stanovanj precenjene ali podcenjene. Dodatne spremenljivke so bile še: realni dohodek na prebivalca, populacija, zaposlenost, stopnja delovno sposobnih, stopnja brezposelnosti, število novih stanovanj, število gradbenih dovoljenj, število nepremičnin naprodaj, število prodanih nepremičnin, stopnja prostih stanovanj, povprečno število ur na teden v proizvodnji, S&P 500 indeks, realna denarna ponudba M2, 10-letna donosnost državne obveznice prilagojena za obrestno mero (ang. »federal funds rate«), indeks zaupanja potrošnikov, inflacija, proizvodna industrije in realna efektivna hipotekarna obrestna mera.

Vpliv ekonomskih faktorjev na indeks cen stanovanjskih nepremičnin v Evropi sta raziskovala tudi Renigier-Biłozor in Wiśniewski (2012). V analizo sta vključila četrletne podatke in pripravila modele, ki so pokazali, da tako finančna kot ekonomska stanja v Evropski uniji vplivajo na trge nepremičnin. Ugotovila sta, da so trgi nepremičnin v Evropi med seboj povezani, čeprav so v različnih državah. V analizo sta vključila indeks cen stanovanjskih nepremičnin ter 14 drugih finančnih in ekonomskih neodvisnih spremenljivk za Poljsko in Italijo. Te spremenljivke so bile BDP, stopnja brezposelnosti, dolgoročna obrestna mera, indeks cen življenjskih potrebščin, harmoniziran indeks cen življenjskih potrebščin, HICP dejanskih najemnin za stanovanje, HICP vzdrževanja in popravila stanovanj, HICP stanovanjskih storitev, prilagojen neto nacionalni dohodek, izdatki za končno potrošnjo, izdatki za končno potrošnjo gospodinjstev, rast prebivalstva, javnofinančni dolg države in dolgoročne kredite. Za oceno vpliva kazalnikov na indeks cen stanovanjskih nepremičnin sta uporabila umetno nevronska mrežo. Prišla sta do ugotovitve, da za razvijajočo se državo Poljsko ima vpliv predvsem stopnja brezposelnosti in rast prebivalstva zaradi pritoka tujega kapitala in povečanja privlačnosti Poljske znotraj EU. Ti

dve spremenljivki prikazujeta predvsem vpliv mladih družin, ki si že z vstopom na trg dela privoščijo nakup lastne nepremičnine in s tem generirajo povpraševanje. Za razvito državo, kot je Italija, se nabor statistično značilnih spremenljivk razlikuje, saj si je že večina prebivalcev privoščila stanovanje in se povpraševanje generira predvsem z namenom višjega življenjskega standarda in naložb. Na indeks cen v Italiji tako vplivajo predvsem izdatki za potrošnjo, izdatki za potrošnjo gospodinjstev in stanovanjski stroški. V obeh državah javnofinančni dolg države in število dolgoročnih kreditov ni imelo nobenega oz. zelo majhen vpliv na indeks cen stanovanjskih nepremičnin.

V razvitih državah ima vpliv na cene predvsem BDP, stopnja brezposelnosti, obrestna mera in kreditni pogoji (Adams & Füss, 2010; Agnello & Schuknecht, 2011; Jacobsen & Naug, 2005). Agnello in Schuknecht (2011) sta ugotovila, da kratkoročna obrestna mera, razvoj lokalne in svetovne denarne ter kreditne politike in deregulacija hipotekarnega trga močno vplivajo na cikličnost nepremičninskega trga. Ali so cene stanovanjskih nepremičnin odvisne od obrestne mere, je odvisno predvsem od tega, koliko stanovanj je financiranih s strani hipotekarnih kreditov. Če je večina stanovanj financiranih s strani kreditov, potem ima sprememba obrestne mere velik vpliv na gibanje cen (Adams & Fuss, 2010). Pozitivna rast realnega BDP-ja na prebivalca prav tako pozitivno vpliva na ceno stanovanjskih nepremičnin, saj se zaradi rasti BDP-ja poveča tudi dohodek gospodinjstva, kar posledično vpliva na to, da je posameznik pripravljen porabiti večji delež svojega dohodka za nakup nepremičnine (Agnello & Schuknecht, 2011). Cohen in Karpavičiute (2017) sta želeli preveriti, katere makroekonomske determinante vplivajo na cene stanovanjskih nepremičnin v manj razvitih državah. Zanimalo ju je, ali bosta prišli do enakih ugotovitev kot drugi raziskovalci. Za analizo sta si izbrali Litvo, saj je ena izmed držav, ki spada med manj razvite države. Neodvisne spremenljivke, za katere sta želeli preučiti vpliv na cene, so bile BDP, stopnja brezposelnosti, inflacija, kratkoročna obrestna mera, priseljevanje in vpeljava makro bonitetne politike. Odvisnost spremenljivk sta preverili z Grangerjevim testom vzročnosti. S testom sta ugotovili, da samo BDP in brezposelnost vplivata na cene stanovanjskih nepremičnin in da na drugi strani cene nepremičnin vplivajo na inflacijo. Za obrestno mero sta ugotovili, da nima nobene povezave s cenami, saj je samo 25 % stanovanj v Litvi financiranih s hipotekarnim kreditom. Nato sta sestavili linearno regresijo, v katero sta vključili BDP, brezposelnost in slamnato spremenljivko za makro bonitetno politiko (to je politika za zavarovanje gospodarstva pred nastankom krize, ki so jo sprejeli v Litvi po letu 2011), in en odlog odvisne spremenljivke, saj sta v modelu brez odvisne spremenljivke zaznali avto-korelacijo med ostanki modela. Za zaključek sta ugotovili, da če se BDP poveča za 1 odstotno točko, se bodo cene na kvadratni meter povečale za 0,46 odstotne točke, ceteris paribus. Če se stopnja brezposelnosti poveča za eno odstotno točko, bodo cene padle za 0,14 odstotne točke. Prav tako tudi vpeljava makro bonitetne politike povzroči padec cen nepremičnin.

Pri analizi avstralskega trga nepremičnin je Milunovich (2020) vključil v svojo raziskavo poleg realnih cen stanovanjskih nepremičnin še realni bruto dohodek na osebo, saj so že

drugi raziskovalci dokazali v svojih raziskavah, da ima dohodek velik vpliv na napovedovanje indeksa cen nepremičnin (Case & Shiller, 1990; Favilukis, Ludvigson & Van Nieuwerburgh 2017; Malpezzi, 1999). Druga uporabljena spremenljivka je bila cena najemnin, ki je bila prav tako že vključena v preteklih analizah drugih raziskovalcev (DiPasquale & Wheaton William, 1994; Plazzi, Torous & Valkanov, 2010). Vključil je prav tako tudi realno hipotekarno obrestno mero, ki sta jo uporabila že Muellbauer in Murphy (1997), ter zaposlenost, za katero sta pokazala Abraham in Hendershott (1996), da je relevantna pri napovedovanju cen stanovanjskih nepremičnin. Med drugim je vključil tudi indeks cen življenjskih potrebščin in gibanje delniškega trga, za katera so Abelson, Joveux, Milunovich in Chung (2005) v svoji raziskavi ugotovili, da imata močen vpliv na cene nepremičnin v Avstraliji.

Égert in Mihaljek (2007) sta sistematično raziskala, katere determinante vplivajo na cene stanovanjskih nepremičnin v centralni in vzhodni Evropi. V opazovanje sta vključila 8 držav v tranziciji in 19 držav organizacija za gospodarsko sodelovanje in razvoj (angl. The organization for economic cooperation and development, v nadaljevanju OECD). Pri raziskovanju determinant sta ugotovila, da je BDP na prebivalca statistično značilna spremenljivka s pozitivnim predznakom, kar pomeni, da so spremembe v dohodku močno pozitivno povezane s spremembo cen stanovanjskih nepremičnin. Realna obrestna mera je prav tako v večini primerov statistično značilna z negativnim predznakom, kar pomeni, da zniževanje obrestnih mer vodi v povečanje cen stanovanjskih nepremičnin. Prav tako sta ugotovila, da ima razmerje med krediti privatnega sektorja in BDP-jem, kar močno pozitivno povezuje s cenami, saj manj kot je omejena hipotekarna politika v državi, lažje gospodinjstva pridejo do kreditov, kar vodi v povečanje povpraševanja po stanovanjskih nepremičninah. Spremenljivki število prebivalstva in delovna sila sta prav tako statistično značilni spremenljivki s pozitivnim predznakom, saj večje število prebivalstva in večje število delovne sile povečuje povpraševanje. Prav tako znižanje stopnje brezposelnosti vodi v zvišanje cen, kar potrjuje ekonomsko teorijo. Časovna vrsta cene delnic ima znotraj OECD držav negativen predznak, vendar znotraj vseh držav osrednje in vzhodne Evrope ima pozitiven predznak, ki nakazuje možne učinke bogastva.

Grum in Govekar (2015) sta analizirala vpliv makroekonomskih faktorjev na cene stanovanjskih nepremičnin v Sloveniji, Grčiji, Franciji, Poljski in na Norveškem. V svoji raziskavi sta ugotovila, da so stopnja brezposelnosti, delniški indeks, tekoči račun države, BDP in proizvodnja industrije spremenljivke, povezane s cenami stanovanjskih nepremičnin. Z multiplo regresijo sta ugotovila, da je v vseh državah razen v Sloveniji statistično značilna spremenljivka z negativnim predznakom stopnja brezposelnosti. Za Slovenijo sta ugotovila, da je delniški indeks edina statistično značilna spremenljivka. Koeficient borznega indeksa je znašal 0,96, kar pomeni, da višji kot je indeks, višje bodo cene stanovanj na kvadratni meter.


3.2 Izbrane spremenljivke za modeliranje indeksa cen stanovanjskih nepremičnin v Sloveniji

V analizo sem vključil 15 časovnih vrst v časovnem okviru od leta 2007 do vključno tretjega kvartala 2022. Podatki so bili zbrani iz različnih javno dostopnih baz, kot je Statistični urad Republike Slovenije, Banka Slovenije, OECD, FRED in drugi. Časovne vrste, vključene v analizo, sem razdelili v različne skupine. To so cene, trg dela, gospodarstvo, delniški trg, monetarna politika in gradbeni sektor.

3.2.1 Odvisna spremenljivka

Časovna vrsta, ki jo bom napovedoval v magistrski nalogi, je indeks cen vseh stanovanjskih nepremičnin v Sloveniji. V indeks spadajo tako nove stanovanjske nepremičnine kot tudi rabljene. Podatki so bili pridobljeni iz statističnega urada republike Slovenije. Časovna vrsta vsebuje 63 opazovanj, od prvega četrletja 2007 do tretjega četrletja 2022. Na sliki 2 lahko vidimo gibanje indeksa cen vseh stanovanjskih nepremičnin in predstavlja spremembe cen v tekočem četrletju glede na povprečje v letu 2015.

Slika 2: Indeks cen vseh stanovanjskih nepremičnin v Sloveniji



Vir: SURS (brez datuma).

3.2.2 Pojasnjevalne spremenljivke

V analizo sem vključil še 14 pojasnjevalnih spremenljivk, uporabljene že v preteklih raziskavah, za katere so različni raziskovalci menili, da so pomembne za napovedovanje indeksa cen vseh stanovanjskih nepremičnin. Ime in vir spremenljivke lahko vidimo v tabeli 1.

Tabela 1: Legenda časovnih vrst

Spremenljivka	Baza	Vir
Indeks cen vseh stanovanjskih nepremičnin	SURS	https://pxweb.stat.si/SiStatData/pxweb/sl/Data/-/0419001S.px
Stopnja brezposelnosti: Starost 15-64: Vse osebe v Sloveniji	FRED	https://fred.stlouisfed.org/series/LRUN64TTSIQ156S
Dolgoročna obrestna mera (10 letna obrestna mera državnih obveznic – Slovenija)	OECD	https://data.oecd.org/interest/long-term-interest-rates.htm#indicator-chart
Kratkoročna obrestna mera (3 mesečna obrestna mera, po katerih poteka kratkoročno izposojanje med finančnimi institucijami)	OECD	https://data.oecd.org/interest/short-term-interest-rates.htm
Hipotekarna obrestna mera za gospodinjstva za nakup nepremičnine z vsaj 10-letno fiksno obrestno mero	BS	https://px.bsi.si/pxweb/en/serije_ang/serije_ang__20_obrestne_mere__20_OBR_MERE_MFI/I2_4_3AE.px/?rxid=12d934b3-61d9-4a1d-82d9-7e43b14eba0c
SBITOP	Trading Economics	https://tradingeconomics.com/sbitop:ind
Rast skupne cene delnic za vse delnice v Sloveniji	FRED	https://fred.stlouisfed.org/series/SPASTT01SIQ657N
Indeks cen življenjskih potrebščin: Skupaj vse postavke za Slovenijo	FRED	https://fred.stlouisfed.org/series/CPALTT01SIQ659N
Rast skupne proizvodnje predelovalnih dejavnosti za Slovenijo	FRED	https://fred.stlouisfed.org/series/PRMNT001SIQ657S
Ponudba denarja M2 (Prispevek Slovenije k agregatom ekonomski in monetarni uniji)	BS	https://px.bsi.si/pxweb/en/serije_ang/serije_ang__10_denar_mfi__10_denarni_agregati/I1_1E.px/?rxid=7b89edce-2592-4302-a0f2-f7f4b34913a8
Indeks novogradenj stanovanjskih stavb po številu stanovanj	SURS	https://pxweb.stat.si/SiStatData/pxweb/sl/Data/-/1970714S.px
Zaposleno prebivalstvo: Starost 15-74 let: Vse osebe v Sloveniji	FRED	https://fred.stlouisfed.org/series/LFEM74TTSIQ647S
Indeks cen dejanskih najemnin, ki jih plačuje najemnik	SURS	https://pxweb.stat.si/SiStatData/pxweb/sl/Data/-/0400600S.px
BDP po izdatkih, Slovenija	SURS	https://pxweb.stat.si/SiStatData/pxweb/en/Data/-/0300230S.px
Povprečna mesečna neto plača za vse SKD dejavnosti skupaj	SURS	https://pxweb.stat.si/SiStatData/pxweb/sl/Data/-/0701011S.px

Vir: lastno delo.

3.2.2.1 *Trg dela*

Spremenljivke, vključene v analizo, opisujejo trg dela, to so stopnja brezposelnosti, zaposlenost in neto plače. Stopnja brezposelnosti ima negativen vpliv na cene stanovanjskih nepremičnin, saj visoka stopnja brezposelnosti znižuje kupno moč gospodinjstev, kar vodi v znižanje števila potencialnih kupcev in posledično znižuje povpraševanje po stanovanjskih nepremičninah (Abelson, Chung & drugi 2005; Grum & Govekar, 2016; Lee, 2009; Leung & drugi, 2006).

Spremenljivko neto plača sem vključil v analizo kot pokazatelj razpoložljivega dohodka gospodinjstva, saj je veliko raziskovalcev mnenja, da povečevanje razpoložljivega dohodka prebivalstva vodi v višanje cen stanovanjskih nepremičnin, ker si lahko ljudje več privoščijo (Case & Shiller, 2003; Geng, 2018; Milunovich, 2020; Rapach & Strauss, 2009).

Prav tako sem v analizo vključil tudi zaposlenost. Ta naj bi pozitivno vplivala na cene stanovanjskih nepremičnin, saj povečuje kupno moč prebivalstva (Égert & Mihaljek, 2007). Prav tako so jo tudi drugi raziskovalci vključili v svoje raziskave (Abraham & Hendershott, 1996; Adams & Füss, 2010; Case & Shiller, 2003; Jadevicius & Huston, 2015; Milunovich, 2020; Rapach & Strauss, 2009).

3.2.2.2 *Gospodarstvo*

Spremenljivki, ki bosta v analizi predstavljali gospodarstvo, sta BDP s stalnimi cenami v letu 2010 in celotna proizvodnja industrije v Sloveniji. BDP sem vključil v analizo, ker nam prikazuje rast gospodarstva znotraj države in tako posledično vpliva na razpoložljiv dohodek gospodinjstev, saj je Baker (2008) v svoji raziskavi ugotovil, da ko je v Ameriki prišlo do recesije v zadnji finančni krizi, je to ohlajanje vodilo v negotovost služb, kar je nato vplivalo na zmanjšanje povpraševanj po stanovanjskih nepremičninah in vodilo do znižanja cen stanovanjskih nepremičnin. Do enake ugotovitve so prišli tudi pri analizi na trgu nepremičnin v Indiji (Mahalik & Mallick, 2011). Prav tako so menili tudi drugi raziskovalci, da so cene stanovanjskih nepremičnin odvisne od BDP-ja in ga zato vključili v svoje raziskave (Cohen & Karpavičiūtė, 2017; Grum & Govekar, 2015; Jadevicius & Huston, 2015; Renigier-Biłozor & Wiśniewski, 2012).

Druga spremenljivka, ki sem jo vključil v analizo in nam prikazuje delovanje gospodarstva, je proizvodnja celotne industrije, za katero so tako Rapach in Strauss (2009) kot tudi Grum in Govekar (2015) menili, da je pomembna spremenljivka pri analizi cen stanovanj, saj nam tako kot BDP opisuje stanje v gospodarstvu.

3.2.2.3 Cene

Pojasnjevalni spremenljivki, ki sta bili že v preteklosti uporabljeni pri analizi preučevanja trga stanovanjskih nepremičnin in vplivata na cene stanovanjskih nepremičnin, sta sprememba indeksa cen življenjskih potrebščin (Cohen & Karpavičiūtė, 2017; Rapach & Strauss, 2009; Renigier-Biłozor & Wiśniewski, 2012; Yilmaz & Kestel, 2019) in indeks cen dejanskih najemnin za stanovanja (Milunovich, 2020; Renigier-Biłozor & Wiśniewski, 2012).

3.2.2.4 Monetarna politika

Spremenljivke, ki predstavljajo vpliv monetarne politike in so bile uporabljene že v preteklih analizah trga stanovanjskih nepremičnin kot pojasnjevalne spremenljivke ter sem jih tudi jaz uporabil v nadaljnji analizi, so dolgoročna in kratkoročna obrestna mera ter ponudba denarja M2 in hipotekarna obrestna mera.

Nižanje hipotekarne obrestne mere ima pozitiven vpliv na rast cen stanovanjskih nepremičnin, saj imajo zaradi tega gospodinjstva nižje stroške pri odplačevanju kredita (Geng, 2018). Zaradi velikega vpliva na trg nepremičnin so to spremenljivko vključili v svoje raziskave Kastel in Yilmaz (2020), Case in Shiller (2003), Rapach in Strauss (2009), Milunovich (2020) ter Muellbauer in Murphy (1997).

Padec dolgoročne obrestne mere vpliva na cene stanovanjskih nepremičnin pozitivno, saj zaradi znižanja donosnosti državnih obveznic pride do premika kapitala investitorjev z obvezniškega trga na nepremičninski, kar vodi v povečanje povpraševanja po stanovanjskih nepremičninah in posledično dvig cen stanovanjskih nepremičnin (Geng, 2018). Dolgoročno obrestno mero so v pretekle analize prav tako vključili tudi Rapach in Strauss (2009), Renigier-Biłozor in Wiśniewski (2012), Cohen in Karpavičiūtė (2017) ter Égert in Mihaljek (2007).

Ponudbo denarja sta vključila v svoji raziskavi tako Adam in Füss (2010) kot tudi Rapach in Strauss (2009), saj so menili, da ekspanzivna denarna politika s povečevanjem ponudbe denarja v obtoku vodi v zvišanje cen stanovanjskih nepremičnin.

Prav tako sta Adam in Füss (2010) v svojo raziskavo vključila tudi kratkoročno obrestno mero, saj sta menila, da se z zviševanjem obrestne mere zvišujejo tudi stroški izgradnje novih nepremičnin, kar negativno vpliva na ponudbo stanovanj.

3.2.2.5 Delniški trgi

Grum in Govekar (2016) sta v svoji raziskavi, kjer sta analizirala vpliv makroekonomskih faktorjev na cene stanovanjskih nepremičnin v različnih evropskih državah, med katerimi je bila tudi Slovenija, ugotovila, da ima na slovenski trg stanovanjskih nepremičnin največji

vpliv borzni indeks, zato sem v svojo analizo vključil indeks SBITOP in rast skupne cene vseh delnic v Sloveniji. Prav tako so tudi drugi raziskovalci, kot so Egert in Mihaljek (2007), Milunovich (2020), Rapach in Strauss (2009) ter Jadevicius in Huston (2015), vključili v svoje raziskave borzni indeks.

3.2.2.6 Gradbeni sektor

V analizo sem vključil še spremenljivko indeks stanovanjskih novogradenj, saj nam ta spremenljivka predstavlja ponudbeno stran trga stanovanjskih nepremičnin (Geng, 2018; Rapach & Strauss, 2009; Case & Shiller, 2003).

4 METODOLOGIJA

Holden, Peel in Thompson (1990) so v svoji knjigi predpostavili, da je za uporabo ARIMA modela potrebnih vsaj 50 časovnih vrst, saj mora biti znotraj časovne vrste vključenih vsaj nekaj ciklov. Prav tako so enakega mnenja tudi drugi raziskovalci, kot so Tse (1997), Yaffee in McGee (2000) ter Brooks in Tsolacos (2010).

4.1 Stacionarnost

Obvezen pogoj za pripravo ARIMA modela je zagotoviti stacionarnost časovne vrste. Stacionarnost lahko definiramo kot neodvisnost od časa, kar pomeni, da se tako povprečje kot tudi varianca ne smeta spreminjati skozi čas (Brooks & Tsolacos, 2010).

S tem ko impliciramo šok na časovno vrsto, lahko preverimo, ali je časovna vrsta stacionarna ali ne. Če je serija stacionarna, potem bo šok sčasoma zamrl, kar pomeni, da bo vpliv šoka v $t+1$ manjši kot v t . Če serija ni stacionarna, potem bo obstojnost šoka neskončna, kar pomeni, da bo učinek šoka na časovno vrsto enak v t , $t+1$ in tako naprej (Brooks & Tsolacos, 2010).

V analizi časovnih vrst poznamo dve vrsti stacionarnosti. To je strog in šibek stacionarni proces. Časovna vrsta je strogo stacionarna takrat, kadar so vse porazdelitve y_t, \dots, y_{t-s} časovno neodvisne za vsak s . Če povzamemo z drugimi besedami, je časovna vrsta strogo stacionarna, če porazdelitev vrednosti skozi čas ostane enaka. Časovna vrsta je šibko stacionarna takrat, kadar ima konstantno povprečje, varianco in avto-kovariančno strukturo, kar pomeni, da mora biti kovarianca med y_t in y_{t-1} enaka kot med y_{t-5} in y_{t-6} (Brooks & Tsolacos, 2010). Predstavljeni so vsi trije pogoji v enačbah (1), (2) in (3):

$$E(y_t) = \mu \quad (1)$$

$$E(y_t - \mu)(y_t - \mu) = \sigma^2 < \infty \quad (2)$$

$$E(y_{t_1} - \mu)(y_{t_2} - \mu) = \gamma_{t_2-t_1}, \forall t_1, t_2 \quad (3)$$

V nadaljevanju analize bom za testiranje stacionarnosti uporabil Dickey-Fullerjev test. Osnovni cilj testa je preveriti ničelno hipotezo $H_0: \rho = 1$ proti enostranski alternativni $\rho < 1$ v enačbi (4):

$$y_t = \rho y_{t-1} + v_t. \quad (4)$$

V praksi se zaradi lažjega računanja in razlage uporabi naslednjo enačbo (5):

$$\Delta y_t = \gamma y_{t-1} + v_t, \quad (5)$$

kjer predstavlja $\Delta y_t = (y_t - y_{t-1})$ in $\gamma = (\rho - 1)$. V novi enačbi (5) testiramo $H_0: \gamma = 0$, kar pomeni, da je časovna vrsta nestacionarna in alternativo $H_1: \gamma < 0$ (Brooks & Tsolacos, 2010).

Nato so raziskovalci razvili še razširjeni Dickey-Fullerjev test (angl. Augmented Dickey-Fuller test, v nadaljevanju ADF), v katerega ni vključen samo en odlog opazovane spremenljivke ampak m število odlogov, s čimer dosežemo, da v_t ni avto-koreliran. V novih enačbah (6), (7) in (8) prav tako testiramo γ (Brooks & Tsolacos, 2010).

$$\text{brez konstante in trenda: } \Delta y_t = \gamma y_{t-1} + \sum_{s=1}^m a_s \Delta y_{t-s} + v_t, \quad (6)$$

$$\text{s konstanto: } \Delta y_t = \alpha + \gamma y_{t-1} + \sum_{s=1}^m a_s \Delta y_{t-s} + v_t, \quad (7)$$

$$\text{s konstanto in trendom: } \Delta y_t = \alpha + \gamma y_{t-1} + \lambda t + \sum_{s=1}^m a_s \Delta y_{t-s} + v_t. \quad (8)$$

Težava nastane pri določanju, koliko odlogov m vključiti v testiranje. Načeloma veljajo tri pravila. Prvo pravilo je to, da se vključi toliko odlogov, kot je frekvenca podatkov, torej če imamo mesečne podatke, vključimo dvanajst odlogov, če imamo kvartalne podatke, se vključi štiri odloge. Drugo pravilo je, da se lahko za odločanje uporabi informacijski kriterij. Če uporabimo to pravilo, določimo takšno število odlogov, ki nam minimizirajo vrednost informacijskega kriterija. Če imamo velik vzorec, je najboljšo izbrati Schwartz informacijski kriterij (angl. Schwartz information criterion – SC). Z manjšim vzorcem izberemo število odlogov, ki nam minimizira AIC (Brooks & Tsolacos, 2010).

Najbolj pogost pristop za odpravo nestacionarnosti časovne vrste je uporaba prvih diferenc. Poleg diference se lahko v analizi časovnih vrst za odpravo nestacionarnosti uporabi tudi odprava trenda s transformacijo časovne vrste v stopnjo rasti (diferenca logaritemske vrednosti časovne vrste) ali z uporabo filtra časovne vrste, kot je na primer Hodrick-Prescott filter, katerega se uporabi za odpravo ciklične komponente v časovni vrsti. Po transformaciji časovne vrste je zmeraj treba še enkrat preveriti ADF test stacionarnosti, da potrdimo, ali je časovna vrste res stacionarna (Brooks & Tsolacos, 2010).

4.2 Modeli časovnih vrst

ARMA model je univariatni model časovnih vrst. Odvisna spremenljivka je v ARMA modelu pojasnjena z informacijami lastnih preteklih vrednosti in trenutnimi ter preteklimi vrednostnimi slučajne spremenljivke. Ta vrsta modelov je ateoretična, kar pomeni, da sestava ter uporaba teh modelov ne temelji na nobenem osnovnem teoretičnem modelu obnašanja spremenljivke. Modele časovnih vrst se uporablja v primeru, ko so strukturni modeli neprimerni.

4.2.1 AR model

Enačba (9) predstavlja AR model:

$$y_t = \mu + \phi_1 y_{t-1} + \dots + \phi_{t-p} y_{t-p} + u_t, \quad (9)$$

kjer y predstavlja odvisno spremenljivko. Ta model lahko predstavimo tudi z operatorjem odloga ($L^i y_t = y_{t-i}$) (Brooks & Tsolacos, 2010). Če v enačbo (9) vključimo operator odloga, dobimo naslednje enačbo (10):

$$y_t = \mu + \sum_{i=1}^p \phi_i L^i y_t + u_t, \quad (10)$$

oziroma (11):

$$\phi(L)y_t = \mu + u_t, \text{ kjer } \phi(L) = 1 - (\phi_1 L + \phi_2 L^2 + \dots + \phi_p L^p). \quad (11)$$

Pogoj stacionarnosti AR(p) modela je ta, da vsi koreni karakteristične enačbe ležijo zunaj enotskega kroga, kar je predstavljeno v enačbi (12) (Brooks & Tsolacos, 2010):

$$1 - \phi_1 z - \phi_2 z^2 - \dots - \phi_p z^p = 0. \quad (12)$$

Poleg tega velja tudi, da stacionaren AR(p) model lahko zapišemo s procesom drsečega povprečja (angl. Moving average, v nadaljevanju MA)(∞). S tem da bodo koeficienti v MA procesu s časom izzveneli, če je proces stacionaren. Če proces ni stacionaren, potem koeficienti MA procesa ne bodo konvergirali proti 0 s povečevanjem odlogov. Zaradi tega je zelo pomembno, da vsi koreni karakteristične enačbe ležijo zunaj enotskega kroga. Prav tako velja tudi, da če je AR model stacionaren, potem bo avto-korelacijska funkcija osnovne časovne vrste z večanjem odlogov konvergirala k 0 (Brooks & Tsolacos, 2010).

4.2.2 MA model

Naj bo μ_t ($t = 1, 2, 3 \dots$) zaporedje neodvisnih in identično porazdeljenih slučajnih spremenljivk z $E(\mu_t) = 0$ in $\text{Var}(\mu_t) = \sigma^2$. Potem je enačba (13) (Brooks & Tsolacos, 2010):

$$y_t = \mu + \theta_1 u_{t-1} + \dots + \theta_{t-q} u_{t-q} + u_t \quad (13)$$

model drsečega povprečja s q odlogi (MA(q)).

Lastnosti MA modela morejo biti naslednje (14), (15) in (16) (Brooks & Tsolacos, 2010):

$$E(y_t) = \mu \quad (14)$$

$$Var(y_t) = \gamma_0 = (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2)\sigma^2, \quad (15)$$

kovariance:

$$\gamma_s = \begin{cases} (\theta_s + \theta_{s+1}\theta_1 + \dots + \theta_q\theta_{q+s})\sigma^2 & \text{za } s = 1, 2, \dots, q \\ 0 & \text{za } s > q \end{cases}. \quad (16)$$

4.2.3 ARMA model

ARMA proces je kombinacija AR(p) in MA(q) modelov. Ko združimo te dve vrsti modelov, dobimo ARMA(p, q) model. P vrednost nam predstavlja linearno odvisnost od lastnih preteklih vrednosti in nam pove, koliko odlogov pretekle vrednosti odvisne spremenljivke bomo vključili v model. Q vrednost nam predstavi linearno odvisnost od kombinacije trenutnih in preteklih vrednosti slučajne spremenljivke in nam predstavlja, koliko slučajnih spremenljivk iz preteklosti bo vključenih v model (Brooks & Tsolacos, 2010).

Generalno je ARMA(p, q) model predstavljen z naslednjo enačbo (17) in (18) (Brooks & Tsolacos, 2010):

$$\phi(L)y_t = \mu + \theta(L)u_t, \quad (17)$$

$$\text{kjer je } \phi(L) = 1 - \phi_1L - \phi_2L^2 - \dots - \phi_pL^p \text{ in } \theta(L) = 1 - \theta_1L - \theta_2L^2 - \dots - \theta_qL^q \quad (18)$$

Z združitvijo enačbe (17) in (18) ter preureditvijo pridemo do naslednjega izraza (19) (Brooks & Tsolacos, 2010):

$$y_t = \mu + \phi_1y_{t-1} + \dots + \phi_{t-p}y_{t-p} + \theta_1u_{t-1} + \dots + \theta_{t-q}u_{t-q} + u_t. \quad (19)$$

Lastnosti ARMA modela so naslednje (20), (21) in (22) (Brooks & Tsolacos, 2010):

$$E(u_t) = 0, \quad (20)$$

$$E(u_t^2) = \sigma^2, \quad (21)$$

$$E(u_t u_s) = 0, t \neq s. \quad (22)$$

4.2.4 ARMAX model

ARMA modele lahko razširimo tako, da poleg preteklih vrednosti in preteklih slučajnih spremenljivk napovedovane spremenljivke vključimo v model še eksogene pojasnjevalne časovne vrste. Za oblikovanje ARMAX modela obstajata dva načina. Prvi način je ta, da preprosto v ARMA proces vključimo še eksogeno pojasnjevalno spremenljivko (Edbrooke, 2016). V tem primeru bi ARMAX model z eno eksogeno pojasnjevalno spremenljivko izgledal bil predstavljen z naslednjo enačbo (23) in (24):

$$\phi(L)y_t = \beta x_t + \theta(L)u_t, \quad (23)$$

oziroma:

$$y_t = \frac{\beta}{\phi(L)} x_t + \frac{\theta(L)}{\phi(L)} u_t. \quad (24)$$

Kar bi nato zakompliciralo interpretacijo koeficienta pojasnjevalne spremenljivke, saj ta ne prikazuje več, za koliko se spremeni y_t vrednost, če se x_t poveča za eno enoto, saj bi ga bilo potrebno interpretirati v povezavi z odlogi y_t spremenljivke (Edbrooke, 2016).

Drugi način, kako lahko pripravimo ARMAX model, je ta, da se v prvem delu pripravi navaden regresivni model z eksogenimi pojasnjevalnimi spremenljivkami in se nato slučajno spremenljivko modela modelira kot ARMA proces (Hyndman, 2010). V tem primeru bi enačba ARMAX model (25) izgledal tako:

$$y_t = \sum_{k=1}^b \beta_k x_{kt} + \varepsilon_t, \quad \varepsilon_t = \sum_{i=1}^p \phi_i \varepsilon_{t-i} + u_t + \sum_{j=1}^q \theta_j u_{t-j}, \quad (25)$$

kjer β_k predstavlja koeficiente pojasnjevalnih spremenljivk in ε_t predstavlja ARMA proces. S tem načinom priprave ARMAX modela je interpretacija koeficienta pojasnjevalnih spremenljivk veliko enostavnejša, saj če enačbo (25) preuredimo pridemo do naslednje enačbe (26) (Hyndman, 2010):

$$y_t = \beta x_t + \frac{\theta(L)}{\phi(L)} u_t. \quad (26)$$

4.3 Avto-korelacijska funkcija in delna avto-korelacijska funkcija

Kot je bilo že predstavljeno v točki 4.1, potrebujemo za šibko stacionarnost pogoj, da se varianca skozi čas ne spreminja in da so vse kovariance odvisne od razlike med t_1 in t_2 . Kar pomeni, da mora biti kovarianca med y_t in y_{t-1} enaka kot med y_{t-9} in y_{t-10} . Enačba (27) je znana kot avto-kovariančna funkcija (Brooks & Tsolacos, 2010):

$$E(y_t - E(y_t))(y_{t+s} - E(y_{t+s})) = \gamma_s, \quad s = 0, 1, 2, \dots \quad (27)$$

Vrednosti kovariančne funkcije so odvisne od merske enote y_t , zato je bolj priročno, da uporabimo avto-korelacije, ki predstavljajo avto-kovariance deljene z varianco (28) (Brooks & Tsolacos, 2010):

$$\zeta_s = \frac{\gamma_s}{\gamma_0}, s = 0, 1, 2 \dots \quad (28)$$

Če prikažemo ζ_s na grafu s $s=0, 1, 2 \dots$, dobimo ACF. Z ACF grafom lahko preverimo tudi, če je naša opazovana vrsta stacionarna, saj se mora z večanjem odlogov avto-korelacija časovne vrste zmanjševati oz. konvergirati k 0 (Brooks & Tsolacos, 2010).

PACF označena z ζ_{kk} , predstavlja korelacijo med spremenljivko, odloženo za k obdobj, in neodloženo spremenljivko z odstranjenimi vsemi vplivi vmesnih opazovanj (za vse odloge do k). Na primer ζ_{kk} predstavlja korelacijo med y_t in y_{t-k} po odpravi vseh vplivov od y_{t-k-1} , $y_{t-k-2} \dots$, y_{t-1} . V prvem odlogu sta PACF in ACF vrednosti enaki, saj ni nobenega odloga, za katerega je treba odpraviti vmesni vpliv, torej velja $\zeta_{11} = \zeta_1$ (Brooks & Tsolacos, 2010).

4.4 Box-Jenkins pristop pri izbiri ARMA modela

Box in Jenkins sta leta 1970 razvila svoj pristop, kako izbrati najboljši ARMA model za opazovano časovno vrsto. Pristop je sestavljen iz 3 korakov.

Prvi korak je identifikacija modela. V tem koraku določimo, koliko odlogov AR in MA modela bomo uporabili v svojem modelu, da bomo zajeli celotno dinamiko podatkov. To se je v preteklosti določalo z ACF in PACF grafi. Danes se raziskovalci opirajo predvsem na informacijska merila, kot sta AIC (29) in Schwartz Bayesianski informacijski kriterij (angl. Schwartz Bayesian information criterion, v nadaljevanju SBIC) (30). Model se izbere na podlagi minimizacije enega ali drugega kriterija (Brooks & Tsolacos, 2010). Izračun kriterijev je naslednji:

$$AIC = \ln(\sigma^2) + \frac{2k}{T}, \quad (29)$$

$$SBIC = \ln(\sigma^2) + \frac{k}{T} \ln T, \quad (30)$$

kjer σ^2 predstavlja varianco nepojasnjenege dela (varianco ostankov), $k = p + q + 1$ in T je število opazovanj.

SBIC kriterij uporablja strožjo kazen pri izbiri večjega modela, kar pomeni, da v večini primerov AIC kriterij predlaga večji model kakor SBIC kriterij (Brooks & Tsolacos, 2010).

V drugem koraku ocenimo parametre izbranega modela iz prvega koraka. To lahko naredimo s cenilko najmanjših kvadratov ali s cenilko največjega verjetja (Brooks & Tsolacos, 2010).

V zadnjem koraku se model preveri. Box in Jenkins sta predlagala dve metodi. Prva je presežno prilaganje modela, kar se preveri tako, da modelu, ki smo ga izbrali v prvem koraku, dodamo še dodatne odloge opazovane spremenljivke in preverimo, ali so vse dodane spremenljivke statistično neznačilne. Tako potrdimo, da smo izbrali pravilen model. Druga metoda je preverjanje linearne odvisnosti ostankov modela. Če zaznamo linearno odvisnost ostankov modela, potem je bil model napačno specificiran in se moremo vrniti na prvi korak. To lahko preverimo z ACF, PACF grafoma ter z Ljung-Box testom (Brooks & Tsolacos, 2010; Tse, 1997).

4.5 Box-Pierce oziroma Ljung-Box test

Z Box-Pierce oziroma Ljung-Box testom preverimo, ali so ostanki modela statistično neodvisni med seboj. S testom preverimo hipotezo, da so vsi korelacijski koeficienti skupaj enaki 0 (Brooks & Tsolacos, 2010). Enačba (31) za Box-Pierce Q statistiko je naslednja:

$$Q = T \sum_{k=1}^m \tau_k^2, \quad (31)$$

kjer τ_k predstavlja korelacijski koeficient, T velikost vzorca in m maksimalno število odlogov (Brooks & Tsolacos, 2010).

Težava Box-Pierce testa je ta, da če testiramo avto-korelacijo znotraj majhnega vzorca, nas lahko njegov rezultat vodi do napačne odločitve. Zato sta Ljung in Box kasneje razvila statistični test, ki deluje dobro tudi na manjšem vzorcu (Brooks & Tsolacos, 2010). Enačba (32) za Ljung-Box test je naslednja:

$$Q^* = T(T+2) \sum_{k=1}^m \frac{\tau_k^2}{T-k}, \quad (32)$$

kjer prav tako τ_k predstavlja korelacijski koeficient, T velikost vzorca in m maksimalno število odlogov (Brooks & Tsolacos, 2010).

S povečevanjem vzorca v neskončnost je iz enačbe razvidno, da se člena $(T+2)$ in $(T-k)$ izničita in dobimo Box-Pierce test (Brooks & Tsolacos, 2010).

4.6 Ocena napovedi modela

Ko izberemo optimalne modele in opravimo vse statistične teste, ki nam potrdijo, da smo izbrali pravilne modele, lahko preverimo še, kako natančno izbrani model napoveduje. Ocena napovedi modela nam lahko pomaga pri izbiri optimalnega modela. Napaka napovedi se za vsako opazovanje posebej izračuna tako, da se dejansko vrednost odšteje od napovedne vrednosti (33) (Brooks & Tsolacos, 2010):

$$e_i = y_i - y_p, \quad (33)$$

kjer y_i predstavlja realno vrednost v času i , y_p napovedno vrednost v času i in e_i napako napovedi.

Da ugotovimo, kako dobro se napovedi modela prilagajajo dejanskim vrednostim, izračunamo MAE vrednost z enačbo (34), ki predstavlja absolutno razliko med realnimi in napovednimi vrednostmi. Poleg MAE vrednosti lahko izračunamo tudi MSE vrednost z enačbo (35), ki predstavlja kvadrate razlik med realnimi in napovednimi vrednostmi. Bližje kot je MAE ali MSE vrednosti 0, boljša je napoved modela, saj če je MAE oziroma MSE vrednost enaka 0, potem so vse napovedne vrednosti enake realnim vrednostim. MSE vrednost bolj kaznuje večje napake napovedi, saj razliko med realno in napovedno vrednostjo kvadrira. To pomeni, da če napovedujemo časovno vrsto, ki ima zelo velike odmike v določenem času oz. osamelce, in želimo izbrati model, ki se čim bolj približa tem odkikom, je bolje izbrati model z najnižjo MSE vrednostjo v primerjavi z MAE vrednostjo (Brooks & Tsolacos, 2010).

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i|, \quad (34)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2. \quad (35)$$

5 NAPOVEDOVANJE INDEKSA CEN VSEH STANOVANJSKIH NEPREMIČNIN V SLOVENIJI

V svoji analizi bom predstavil pripravo dveh modelov časovnih vrst na slovenskih podatkih. Najprej bom preveril stacionarnost napovedovane spremenljivke ter preostalih pojasnjevalnih spremenljivk. Nato bom pripravil ARMA, kjer napovemo prihodnjo vrednost napovedovane spremenljivke s preteklimi vrednostnimi napovedovane spremenljivke in sedanji in preteklimi vrednostnimi slučajne spremenljivke. Po izbiri optimalnega ARMA modela bom v drugem delu pripravil ARMAX model, ki bo vseboval enako odlogov AR in MA dela kakor ARMA modela, ter dodal še preostale pojasnjevalne spremenljivke, za katere so raziskovalci v svojih preteklih delih menili, da imajo vpliv na cene vseh stanovanjskih nepremičnin.

5.1 Stacionarnost spremenljivk

5.1.1 Stacionarnost indeksa cen vseh stanovanjskih nepremičnin

Če pogledamo časovno vrsto na sliki 2, lahko vidimo, da časovna vrsta ni stacionarna, saj nima ne konstantnega povprečja in prav tako tudi nima konstantne variance. Stacionarnost časovne vrste sem preveril z ADF testom. Če je testna statistika po absolutni vrednosti višja od kritične vrednosti, potem lahko zavrnilo ničelno hipotezo o nestacionarnosti in lahko trdimo, da je časovna vrsta stacionarna. V prvem koraku sem moral izbrati število odlogov,

ki bodo upoštevani pri ADF testu. Z minimizacijo AIC sem ugotovil, da moram uporabiti 3 odloge vrednosti za testiranje stacionarnosti časovne vrste. Z ADF testom sem preveril stacionarnost indeksa cen vseh stanovanjskih nepremičnin in ugotovil, da časovna vrsta ni stacionarna, saj je testna statistika po absolutni vrednosti nižja od kritične vrednosti. Prikazano je v tabeli 2.


Tabela 2: ADF test z odmikom indeks cen vseh stanovanjskih nepremičnin

Spremenljivka	ADF testna statistika	Kritična vrednost			Stacionarnost
		1 %	5 %	10 %	
Indeksa cen vseh stanovanjskih nepremičnin	0,507	-2,397	-1,674	-1,297	Ne

Vir: lastno delo.

Ker osnovna časovna vrsta ni zagotovila stacionarnosti, sem v nadaljnji analizi uporabili rast indeksa cen vseh stanovanjskih nepremičnin, ki prav tako vsebuje 63 opazovanj od prvega kvartala 2007 do tretjega kvartala 2022. Gibanje časovne vrste lahko vidimo na sliki 3.

Slika 3: Rast indeksa cen vseh stanovanjskih nepremičnin v Sloveniji



Vir: lastno delo.

V tabeli 3 lahko vidimo, da testna statistika ADF testa znaša -2,485 in je po absolutni vrednosti višja od kritične vrednosti, kar pomeni, da zavrnem ničelno hipotezo in lahko trdim, da je opazovana časovna vrsta stacionarna.

Tabela 3: ADF test z odmikom za rast indeksa cen vseh stanovanjskih nepremičnin

Spremenljivka	ADF testna statistika	Kritična vrednost			Stacionarnost	Okrajšava
		1 %	5 %	10 %		
Rast indeksa cen vseh stanovanjskih nepremičnin	-2,485	-2,397	-1,674	-1,297	Da	Y

Vir: lastno delo.

5.1.2 Stacionarnost pojasnjevalnih spremenljivk

Za vključitev pojasnjevalnih spremenljivk v ARMAX model morajo te najprej zagotoviti pogoj stacionarnosti. Prvi pogoj šibke stacionarnosti se glasi, da mora biti povprečna vrednost časovne vrste konstantna. Da sem zagotovil ta pogoj, sem vse časovne vrste, ki so bile odvisne od časa, preoblikoval v prve diference. Rezultate lahko vidimo v tabeli 4.

Tabela 4: ADF test z zamikom za osnovne časovne vrste

Spremenljivka	ADF testna statistika	Kritična vrednost			Stacionarnost	Okrajšava
		1%	5%	10%		
Rast indeksa cen vseh stanovanjskih nepremičnin	-2,485	-2,397	-1,674	-1,297	Da	Y
Stopnjo brezposelnosti: Starost 15-64: Vse osebe v Sloveniji	-1,715	-2,397	-1,674	-1,297	Da	UN
Dolgoročna obrestna mera	-1,450	-2,397	-1,674	-1,297	Da	LI
Kratkoročna obrestna mera	-3,233	-2,397	-1,674	-1,297	Da	SI
Hipotekarna obrestna mera za gospodinjstva za nakup nepremičnine z vsaj 10-letno fiksno obrestno mero	-1,541	-2,397	-1,674	-1,297	Da	HI
Sprememba SBITOP	-3,730	-2,397	-1,674	-1,297	Da	SBI
Rast skupne cene delnic za vse delnice v Sloveniji	-4,287	-2,397	-1,674	-1,297	Da	SP
Indeks cen življenjskih potrebščin: Skupaj vse postavke za Slovenijo	-2,618	-2,397	-1,674	-1,297	Da	CPI
Rast skupne proizvodnje predelovalnih dejavnosti za Slovenijo	-4,059	-2,397	-1,674	-1,297	Da	PT

se nadaljuje

Tabela 4: ADF test z zamikom za osnovne časovne vrste (nad.)

Spremenljivka	ADF testna statistika	Kritična vrednost			Stacionarnost	Okrajšava
		1%	5%	10%		
Sprememba ponudbe denarja M2	-1,410	-2,397	-1,674	-1,297	Da	MS
Sprememba zaposlenega prebivalstva: Starost 15-74 let: Vse osebe v Sloveniji	-3,529	-2,397	-1,674	-1,297	Da	ER
Sprememba indeksa cen dejanskih najemnin, ki jih plačuje najemnik	-1,946	-2,397	-1,674	-1,297	Da	ICN
Sprememba BDP po izdatkih, Slovenija	-3,499	-2,397	-1,674	-1,297	Da	BDP
Sprememba indeks novogradenj stanovanjskih stavb po število stanovanj	-6,116	-2,397	-1,674	-1,297	Da	IN
Sprememba povprečne mesečne neto plače za vse SKD dejavnosti skupaj	-2,752	-2,397	-1,674	-1,297	Da	NP

Vir: lastno delo.

Kot lahko vidimo v tabeli 4, so vse testne statistike po absolutni vrednosti višje od kritične vrednosti, kar pomeni, da zavrnem ničelno hipotezo in lahko trdim, da so opazovane časovne vrste stacionarne.

5.2 Analiza ARMA modela


Za pripravo ARMA modela sem najprej preveril avto-korelacijo znotraj časovne vrste z avto-korelacijsko in delno avto-korelacijsko funkcijo. S pomočjo ACF in PACF funkcije lahko določim, kakšen ARMA model bi se najbolj prilegal časovni vrsti. Slika 4 prikazuje numerične vrednosti ACF in PACF, slika 5 in 6 pa grafični prikaz ACF in PACF.

Slika 4: Numerični prikaz ACF in PACF funkcije

Odlog	AC	PAC	Q statistik	Verjetnost > Q	-1	0	1	-1	0	1
					Avto-korelacija			Delna avto-korelacija		
1	0.4026	0.4043	10.703	0.0011						
2	0.3091	0.1650	17.117	0.0002						
3	0.3713	0.2676	26.528	0.0000						
4	0.1874	-0.0474	28.967	0.0000						
5	0.1050	-0.0549	29.745	0.0000						
6	0.1428	0.0295	31.21	0.0000						
7	-0.0816	-0.2498	31.697	0.0000						
8	0.0120	0.0611	31.708	0.0001						
9	0.0484	-0.0554	31.886	0.0002						
10	0.0542	0.1034	32.113	0.0004						
11	0.1286	0.0863	33.416	0.0005						
12	0.1578	0.1579	35.416	0.0004						


Vir: lastno delo.

Slika 5: Grafični prikaz ACF



Vir: lastno delo.

Slika 6: Grafični prikaz PACF



Vir: lastno delo.

S slik 5 in 6 je razvidno, da ACF s časom znižuje in je v četrtem odlogu avto-korelacija že statistično enaka 0, medtem ko je vrednost delne avto-korelacije samo v prvem odlogu statistično različna od 0. Na podlagi gibanja ACF in PACF bi lahko sklepal, da se bo najbolje odrezal AR(1) model. Alternativa AR procesu je ARMA model. Zato sem v naslednjem koraku iskal optimalen ARMA model glede na minimizacijo kriterijev. Pripravil sem vse modele od ARMA(0,0) do ARMA(4,4) in izračunal njihove vrednosti AIC in SBIC kriterija. Rezultate kriterijev lahko vidimo v tabelah 5 in 6.

Tabela 5: AIC ARMA modelov opazovane časovne vrste

AR/MA	0	1	2	3	4
0	304.879	296.820	298.152	294.900	293.313
1	293.487	291.066	292.954	291.412	292.835
2	293.425	293.025	290.857	292.301	286.725
3	289.905	291.839	293.727	289.185	289.635
4	291.813	291.760	291.603	289.341	288.684

Vir: lastno delo.

Tabela 6: SBIC ARMA modelov opazovane časovne vrste

AR/MA	0	1	2	3	4
0	309.165	303.250	306.724	305.616	306.172
1	299.917	299.638	303.670	304.271	307.837
2	301.998	303.741	301.573	307.303	301.727
3	300.621	304.698	308.728	304.187	306.781
4	304.672	306.762	308.748	306.486	307.972

Vir: lastno delo.

Ker ima časovna vrsta samo 63 opazovanj, sem uporabil AIC vrednost za izbiro optimalnega modela. Model z najnižjo AIC vrednostjo ARMA(2,4) je predstavljen v spodnji tabeli 7.

Tabela 7: Model ARMA(2,4)

Spremenljivka	Koeficient	Standardni odklon	z vrednost	p-vrednost
μ	1,192	0,751	1,59	0,112
y_{t-1}	-0,255	0,138	-1,85	0,064
y_{t-2}	0,65	0,142	4,58	0,000
u_{t-1}	0,828	0,242	3,43	0,001
u_{t-2}	-0,522	0,240	-2,17	0,030
u_{t-3}	0,142	0,180	0,79	0,430
u_{t-4}	0,647	0,214	3,02	0,002

Vir: lastno delo.

V tabeli 7 lahko vidimo, da ima koeficient u_{t-3} p-vrednost višjo od 10 %, kar pomeni, da ni statistično značilen. Zaradi tega sem preveril še model z najnižjo SBIC vrednostjo, in sicer ARMA(1,1). V tabeli 8 lahko vidimo, da so vse p-vrednosti koeficientov nižje od 10 %, kar pomeni, da so vsi koeficienti statistično značilni. Zato sem za nadaljnjo analizo obdržali ARMA(1,1) model.


Tabela 8: Model ARMA(1,1)

Spremenljivka	Koeficient	Standardni odklon	z vrednost	p-vrednost
μ	1,356	0,778	1,74	0,081
y_{t-1}	0,863	0,094	9,17	0,000
u_{t-1}	-0,520	0,154	-3,36	0,001

Vir: lastno delo.

Na sliki 7 je predstavljeno prilagajanje napovednih vrednosti znotraj vzorca glede na realne vrednosti rasti indeksa cen vseh stanovanjskih nepremičnin. Na sliki lahko lepo vidimo, da ARMA model ne napove tako velikih sprememb v indeksu cen in da zamudi eno obdobje pri napovedi padca ali rasti. Prilagajanje ARMA(1,1) modela realnim vrednostim sem preverili tudi z izračunom MAE in MSE vrednosti. Vrednost MSE je znašala 5,517, vrednost MAE pa 1,683.

Slika 7: Primerjava realnih vrednosti in napovednih vrednosti ARMA modela znotraj vzorca

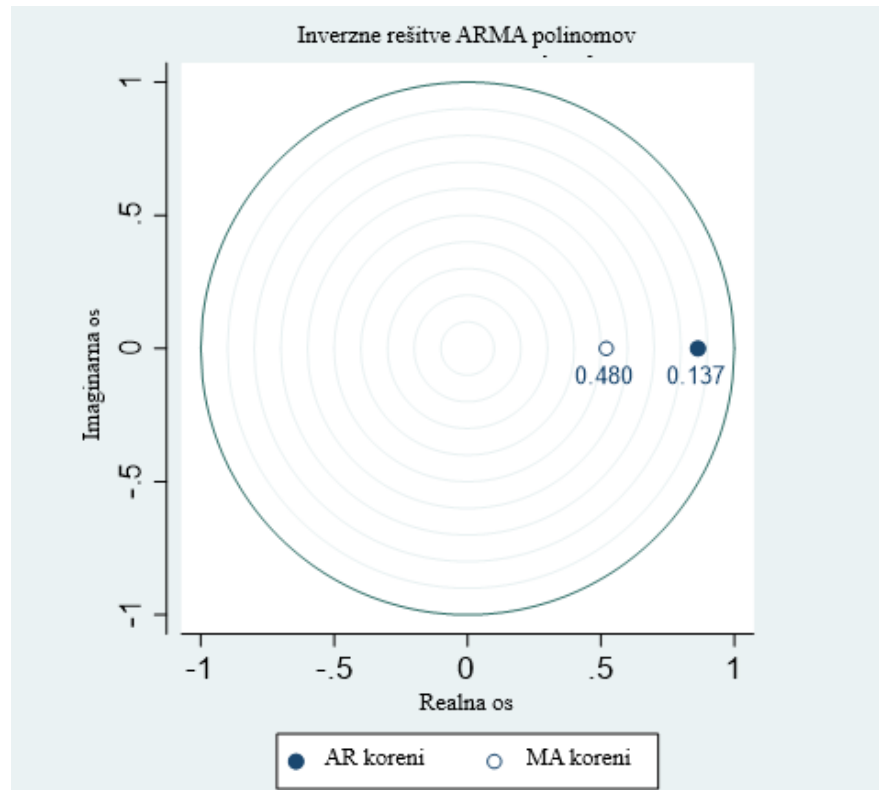


Vir: lastno delo.

5.2.1 Diagnostika ARMA modela

Stabilnost ARMA procesa sem preveril s pogojem stabilnosti lastnih vrednosti. Na sliki 8 lahko vidimo, da vse lastne vrednosti ležijo znotraj enotskega kroga, kar pomeni, da je ARMA(1,1) proces stacionaren.

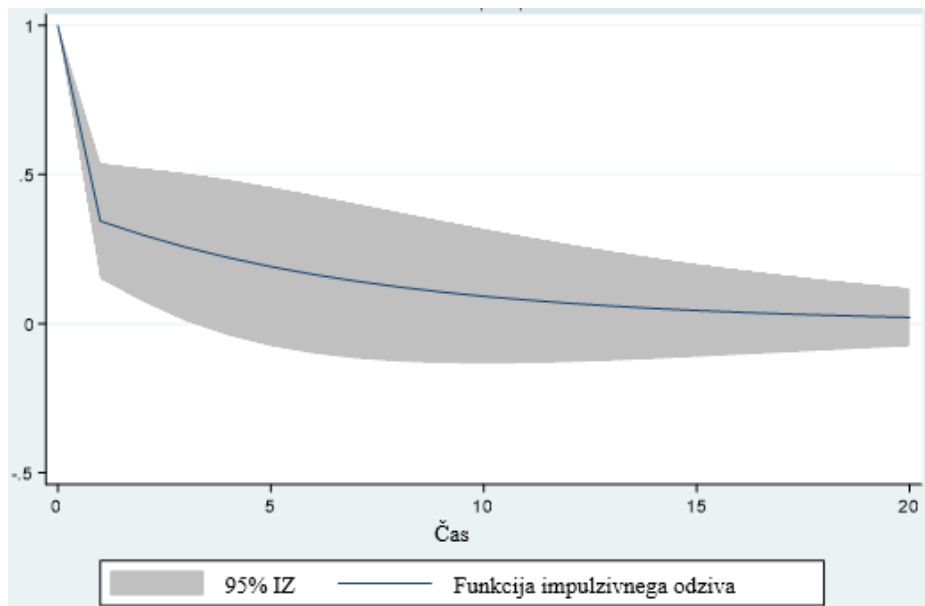
Slika 8: Lastne vrednosti ARMA(1,1) modela



Vir: lastno delo.

V naslednjem koraku sem preveril, kako šok vpliva na časovno serijo skozi model. Ta odziv, merjen skozi čas, sem preveril s funkcijo impulznega odziva. Funkcija impulznega odziva nam prikazuje, da šok na rast indeksa cen stanovanjskih nepremičnin v višini ene odstotne točke vpliva na povečanje v naslednjem kvartalu zgolj le za 0,35 odstotne točke. Ta šok s časom limitira nazaj na začetno vrednost in znaša po 4 letih zgolj 0,037 odstotne točke. To lahko vidimo na sliki 9.


Slika 9: Funkcija impulzivnega odziva



Vir: lastno delo.

Ali sem izbral dober ARMA model, lahko preverim tudi s testom za preverjanje avto-korelacije med ostanki. Če pogledamo spodnjo sliko 10, lahko vidimo, da so vse vrednosti avto-korelacije med ostanki znotraj intervala zaupanja, kar pomeni, da med ostanki ni korelacije. Avto-korelacijo med ostanki sem še dodatno preverili z Ljung-Box testom. Testna statistika je znašala 16,809 in p-vrednost 0,665, kar pomeni, da ne morem zavrniti ničelne hipoteze in lahko rečem, da so ostanki neodvisni med seboj.

Slika 10: Avto-korelacija med ostanki ARMA(1,1) modela



Vir: lastno delo.

5.2.2 Napovedovanje zunaj vzorca z ARMA modelom

V zadnjem delu sem preveril še napovedovanje modela zunaj vzorca. Najprej sem razdelil podatke na vzorec, na katerem bom testiral model, in na vzorec, na katerem bom ocenil model. Model sem ocenil iz podatkov od prvega kvartala 2007 do četrtega kvartala 2021, nato pa sem ta model testiral na podatkih od prvega kvartala 2022 do tretjega kvartala 2022 (skupaj 3 kvartale). Na teh podatkih sem pripravili ARMA(1,1) model, ki je predstavljen v tabeli 9.


Tabela 9: ARMA(1,1) model na podatkih od Q1 2007 do Q4 2021

Spremenljivka	Koeficient	Standardni odklon	z vrednost	p-vrednost
μ	1,297	0,787	1,65	0,100
y_{t-1}	0,859	0,102	8,41	0,000
u_{t-1}	-0,522	0,164	-3,19	0,001

Vir: lastno delo.

Za napovedovanje podatkov od prvega kvartala 2022 do tretjega kvartala 2022 sem pripravil tako statično kot tudi dinamično napovedovanje zunaj vzorca. Statično napovedovanje zunaj vzorca je izračunano tako, da je napovedana vrednost za $t+1$ izračunana iz realnih vrednosti opazovane spremenljivke in tako se ponovi za vsako prihodno napovedno obdobje. Pri dinamičnem napovedovanju zunaj vzorca pa gre za to, da so vse napovedane vrednosti odvisne od predhodnih napovedanih vrednosti. Grafični prikaz statičnega in dinamičnega napovedovanja zunaj vzorca je predstavljen na spodnji sliki 11.

Slika 11: Primerjava statičnega in dinamičnega napovedovanja zunaj vzorca za ARMA(1,1) model



Vir: lastno delo.

Če pogledamo sliko 11, lahko vidimo, da dinamična napoved zelo hitro konvergira k dolgoročni brezpogojni srednji vrednosti, ko se horizont poveča. Medtem ko pri statičnem napovedovanju lahko vidimo, da se to ne zgodi in so napovedne vrednosti veliko bolj podobne realnim vrednostim. V tabeli 10 je predstavljena primerjava MSFE vrednostjo in vrednostjo povprečne absolutne napake napovedi (angl. mean absolute forecaste error, v nadaljevanju MAFE) za napovedane vrednosti od prvega kvartala 2022 do tretjega kvartala 2022.

Tabela 10: MSFE in MAFE zunaj vzorčnega napovedovanja ARMA(1,1) modela

ARMA model	MSFE vrednost	MAFE vrednost
ARMA(1,1) statične zunaj vzorčne napovedi	0,548	0,678
ARMA(1,1) dinamične zunaj vzorčne napovedi	0,566	0,654

Vir: lastno delo.

5.3 Analiza ARMAX modela

V nadaljevanju sem želel razširiti osnovni model ARMA(1,1) z dodajanjem pojasnjevalnih spremenljivk, katere so že preteklosti znani avtorji vključili pri modeliranju cen stanovanjskih nepremičnin. Podroben opis vsake spremenljivke je predstavljen v poglavju 3.2.2.

5.3.1 Korelacije napovedovane časovne vrste ter pojasnjevalnih časovnih vrst

V tabeli 11 sem pripravil korelacijsko matriko, ki prikazuje odvisnosti ene spremenljivke od druge. Kot lahko vidimo, sta visoko korelirani časovni vrsti sprememba BDP po izdatkih (BDP) in rast skupne proizvodnje predelovalnih dejavnosti za Slovenijo (PT), ki imata korelacijsko vrednost 0,87, ter dolgoročna obrestna mera (LI) in hipotekarna obrestna mera za gospodinjstva za nakup nepremičnine z vsaj 10-letno fiksno obrestno mero (HI), ki imata korelacijsko vrednost 0,90. Zaradi te informacije sem moral v prihodnje pri sestavi modela paziti, da nisem vključil obeh spremenljivk v model.

Tabela 11: Korelacijska matrika opazovanih časovnih vrst

Spremenljivka	Y	CPI	PT	SP	MS	HI	NP	SBI	UN	LI	SI	BDP	ER	ICN	IN
Y	1,00														
CPI	0,20	1,00													
PT	0,23	-0,07	1,00												
SP	0,31	-0,21	0,38	1,00											
MS	0,39	0,04	0,00	0,24	1,00										
HI	-0,50	0,18	-0,28	-0,27	-0,52	1,00									
NP	0,22	0,10	-0,45	-0,14	0,33	-0,11	1,00								

se nadaljuje

Tabela 11: Korelacijska matrika opazovanih časovnih vrst (nad.)

Spremenljivka	Y	CPI	PT	SP	MS	HI	NP	SBI	UN	LI	SI	BDP	ER	ICN	IN
SBI	-0,01	-0,39	0,09	0,55	0,12	-0,28	0,01	1,00							
UN	-0,43	-0,45	0,06	0,05	-0,57	0,26	-0,34	0,12	1,00						
LI	-0,55	0,22	-0,23	-0,21	-0,62	0,90	-0,18	-0,15	0,47	1,00					
SI	-0,12	0,47	-0,21	-0,26	-0,13	0,78	0,06	-0,37	-0,21	0,59	1,00				
BDP	0,24	0,01	0,87	0,31	0,02	-0,23	-0,50	0,11	-0,04	-0,20	-0,12	1,00			
ER	0,10	0,09	0,33	0,32	-0,02	-0,16	-0,15	0,05	-0,12	-0,17	0,00	0,27	1,00		
ICN	0,38	0,47	0,17	0,02	0,12	-0,37	0,01	-0,08	-0,35	-0,31	-0,09	0,30	0,12	1,00	
IN	0,08	-0,08	0,13	0,26	-0,02	-0,11	-0,19	0,21	-0,02	-0,09	-0,03	0,08	0,35	0,00	1,00

Vir: lastno delo.

5.3.2 Izbira optimalnega ARMAX modela

Priprave optimalnega ARMAX modela sem se lotil tako, da sem za osnovo vzel optimalen ARMA(1,1) model s konstanto, in mu nato dodajal nove pojasnjevalne časovne vrste. V prvem koraku sem vključil vseh 14 pojasnjevalnih časovnih vrst, eno po eno posamično v ARMA(1,1) modelu s konstanto, in ugotovil, da sta statistično značilni pojasnjevalni časovni vrsti s pravilnim predznakom samo dolgoročna obrestna mera in rast skupne cene delnic za vse delnice v Sloveniji. Modela lahko vidite v prilogi 1 in 2. V naslednjem koraku sem obema modeloma dodajal eno po eno posamično spremenljivko izmed preostalih 13 spremenljivk in ugotovil, da se ARMA(1,1) modelu z dolgoročno obrestno mero (LI) najboljše prilega časovna vrsta rast skupne cene delnic za vse delnice v Sloveniji (SP), saj je bila statistično značilna spremenljivka s pravilnim predznakom koeficienta. Do enakega zaključka sem prišel tudi pri ARMA(1,1) modelu z rastjo skupne cene delnic za vse delnice v Sloveniji (SP), saj je bila edina statistično značilna spremenljivka s pravilnim predznakom dolgoročna obrestna mera (LI). Po enakem postopku sem dobil še tretjo časovno vrsto s statistično značilnim koeficientom. To je bila sprememba ponudbe denarja M2 (MS), vendar je ta imela negativen predznak, kar se ne sklada z ekonomsko logiko. S povečevanjem količine denarja v obtoku bi se morale cene stanovanjskih nepremičnin povečevati. Preostale pojasnjevalne spremenljivke niso bile statistično značilne, zato sem zaključil s testiranjem vpliva pojasnjevalnih spremenljivk na rast indeksa cen vseh stanovanjskih nepremičnin. Nato sem za vse izbrane modele preveril znotraj vzorčno napovedovanje s primerjavo povprečja kvadratne napake in povprečja absolutne napake. Vrednosti MSE in MAE lahko vidimo v tabeli 12.

Tabela 12: MSE in MAE vrednosti ARMAX modelov pri napovedovanju znotraj vzorca

ARMAX model	MSE vrednost	MAE vrednost
ARMA(1,1) s SP spremenljivko	5,111	1,725
ARMA(1,1) z LI spremenljivko	5,090	1,614
ARMA(1,1) z LI in SP spremenljivko	4,698	1,604

Vir: lastno delo.

Kot optimalen ARMAX model se je izkazal ARMA(1,1) model s pojasnjevalnima spremenljivkama dolgoročna obrestna mera in rast skupne cene delnic v Sloveniji, saj ima najnižjo vrednost MSE in MAE. Vrednosti koeficientov in p-vrednosti optimalnega modela so predstavljene v tabeli 13.

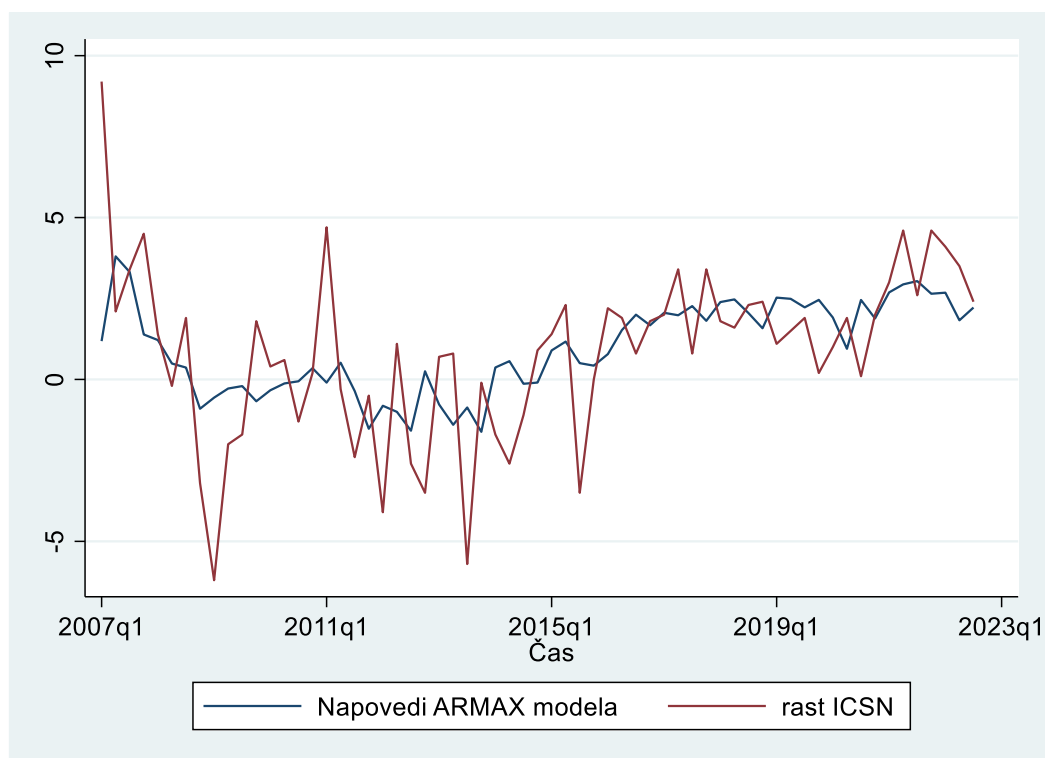
Tabela 13: Optimalen ARMAX model

Spremenljivka	Koeficient	Standardni odklon	z vrednost	p-vrednost
μ	2,708	1,337	2,03	0,043
LI_t	-0,576	0,313	-1,84	0,066
SP_t	0,063	0,032	1,98	0,048
y_{t-1}	0,828	0,156	5,32	0,000
u_{t-1}	-0,609	0,217	-2,80	0,005

Vir: lastno delo.

V nadaljevanju sem pripravil še grafični prikaz napovedovanja znotraj vzorca optimalnega ARMAX modela glede na realne vrednosti rasti indeksa cen vseh stanovanjskih nepremičnin. Kot lahko vidimo na sliki 12, model relativno dobro napove, ali bodo cene zrastle ali padle, vendar ne uspe ujeti velikih sprememb v cenah.

Slika 12: Primerjava realnih in napovednih vrednosti ARMAX modela znotraj vzorca




Vir: lastno delo.

5.3.3 Diagnostika ARMAX modela

S funkcijo impulznih odzivov sem preveril, kako vpliva šok na časovno serijo skozi model. Impulzni odziv nam prikazuje, da šok na rast indeksa cen vseh stanovanjskih nepremičnin v višini ene odstotne točke vpliva na povečanje v naslednjem kvartalu za 0,22 odstotne točke,

nato se v drugem kvartalu zmanjša vrednost na 0,18 odstotne točke nato pa počasi konvergira k 0. Graf funkcije impulznega odziva lahko vidimo na sliki 13.


Slika 13: Funkcija impulznega odziva ARMAX modela



Vir: lastno delo.

Po izbiri optimalnega modela je zelo pomembno, da se preveri, če so ostanki med seboj neodvisni. To sem preveril Ljung-Box testom. Če je p-vrednost testa višja od 10 %, potem ne morem zavrniti ničelne hipoteze in lahko trdimo, da so ostanki med seboj neodvisni. Testna statistika Ljung-Box testa za 20 odlogov za izbrani model znaša 21,994 s p-vrednostjo 0,341, kar pomeni, da so ostanki med seboj neodvisni. Prav tako sem preveril tudi avto-korelacijo med ostanki z avto-korelacijsko funkcijo. Če so vse vrednosti znotraj intervalov zaupanja, potem lahko trdimo, da med ostanki ni prisotne avto-korelacije, torej so med seboj neodvisni. Slika 14 nam prikazuje, da so vse vrednosti avto-korelacije znotraj intervala zaupanja, razen sedmega odloga, ki je na sami meji intervala. Kljub temu lahko potrdim, da ostanki med seboj niso odvisni.

Slika 14: Avto-korelacija med ostanki ARMAX modela



Vir: lastno delo.

5.3.4 Napovedovanje zunaj vzorca z ARMAX modelom

Testiranja, kako dobro model napoveduje zunaj vzorca, sem se pri ARMAX modelu lotil na enak način kot pri osnovnem ARMA modelu. V prvem delu sem razdelil vse časovne vrste na vzorec, na katerem bom ocenil model, in na vzorec, na katerem bom testiral zunaj vzorčno napoved. Vzorec, na katerem bom ocenil model, zajema 60 opazovanj (od prvega kvartala 2007 do četrtega kvartala 2020). V testni vzorec, na katerem bom testiral, kako dobro se obnese zunaj vzorčno napovedovanje, sem zajel zadnja 3 opazovanja. V tabeli 14 je predstavljen ocenjen ARMAX model z dolgoročno obrestno mero (LI) in z rastjo skupne cene delnic v Sloveniji (SP) za prvih 60 opazovanj.


Tabela 14: Ocenjen ARMAX model s pojasnjevalnima spremenljivkama SP in LI na podlagi prvih 60 opazovanj

Spremenljivka	Koeficient	Standardni odklon	z vrednost	p-vrednost
μ	2.460	1.279	1.92	0.054
LI_t	-0.548	0.302	-1.81	0.070
SP_t	0.07	0.034	2.04	0.042
y_{t-1}	0.816	0.191	4.27	0,000
u_{t-1}	-0.635	0.260	-2.44	0.015

Vir: lastno delo.

Nato sem pripravil statično in dinamično zunaj vzorčno napoved za zadnja tri opazovana obdobja, kjer lahko vidimo, da je statična napoved boljša, saj je bližje realnim vrednostim. Grafični prikaz napovedovanja zunaj vzorca lahko vidimo na sliki 15.

Slika 15: Primerjava statičnega in dinamičnega napovedovanja zunaj vzorca za ARMAX modela



Vir: lastno delo.

V tabeli 15 je predstavljena primerjava med MSFE in MAFE vrednostjo za statično in dinamično napovedovanje zunaj vzorca od prvega kvartala 2022 do tretjega kvartala 2022.

Tabela 15: MSFE in MAFE vrednosti zunaj vzorčnega napovedovanja ARMAX modela

ARMAX model	MSFE vrednost	MAFE vrednost
Statične zunaj vzorčne napovedi ARMA(1,1) z LI in SP spremenljivkama	2,143	1,317
Dinamična zunaj vzorčne napovedi ARMA(1,1) z LI in SP spremenljivkama	2,823	1,608

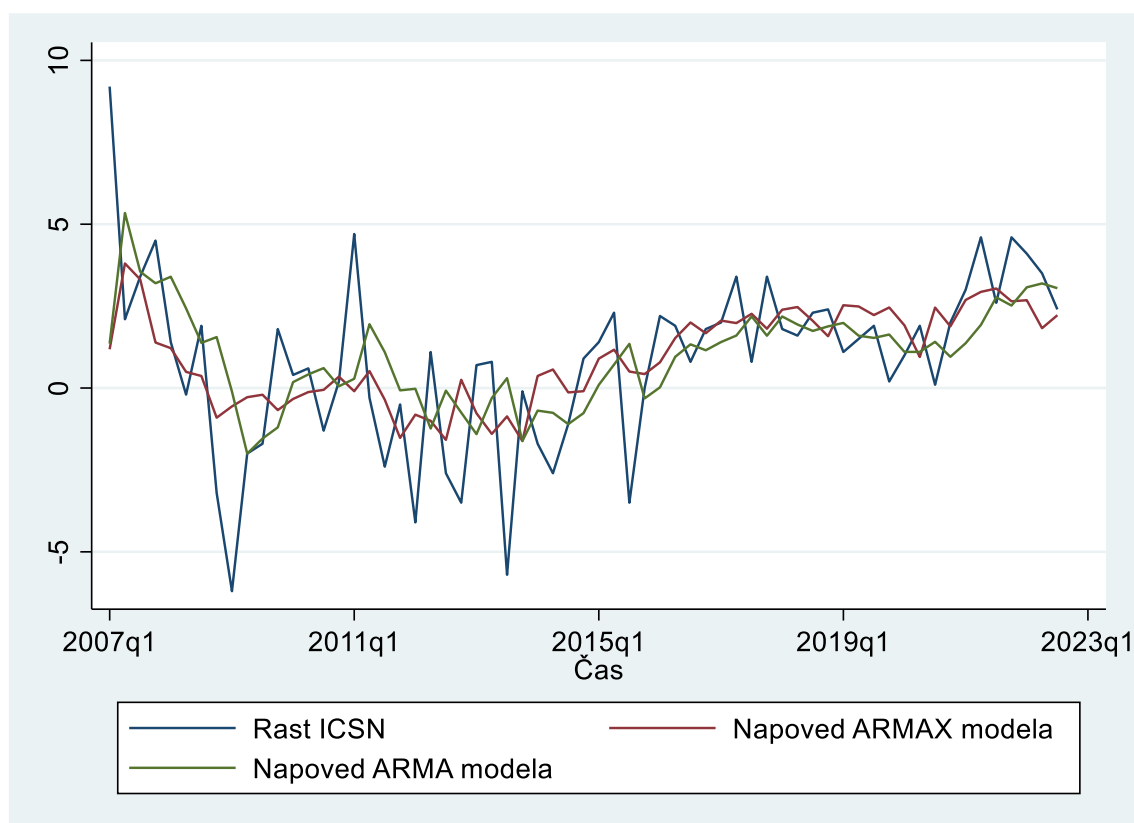
Vir: lastno delo.

5.4 Primerjava ARMA in ARMAX modela pri napovedovanju

5.4.1 Znotraj vzorčno napovedovanje

Med seboj sem primerjal ARMA(1,1) in izbrani ARMAX model. Modela sem ocenil na celotnem vzorcu (63 opazovanj) in ju nato primerjal z realnimi vrednostmi rasti indeksa cen vseh stanovanjskih nepremičnin. Na sliki 16 je predstavljena grafična primerjava napovedovanja znotraj vzorca obeh modelov.

Slika 16: Napovedovanja znotraj vzorca ARMA in ARMAX modela



Vir: lastno delo.

Znotraj vzorčne napovedi modelov sem nato primerjal med seboj z MAE in MSE vrednostjo. Prav tako sem primerjal med seboj tudi, koliko pravih predznakov napovedi sta modela napovedala pravilno. Izračun vseh treh vrednosti lahko vidimo v spodnji tabeli 16. Kot lahko vidimo, ima ARMAX model tako MSE kot tudi MAE vrednost nižjo kot ARMA model, kar pomeni, da se boljše odreže pri napovedovanju znotraj vzorca. Če primerjamo napovedane predznake glede na realne predznake, lahko vidimo, da ARMA model napove 81 % pravih predznakov, medtem ko ARMAX model samo 76 %.

Tabela 16: Primerjalne vrednosti napovedovanja znotraj vzorca


Model	MSE	MAE	Primerjava predznakov napovedi
ARMA	5,516	1,683	81 % pravih napovedi
ARMAX	4,698	1,604	76 % pravih napovedi

Vir: lastno delo.

5.4.2 Zunaj vzorčno napovedovanje

Pri preverjanju, kateri model se boljše obnese pri zunaj vzorčnem napovedovanju, sem najprej ocenil oba modela na prvih 60 opazovanjih in ju nato primerjal z dinamičnim napovedovanjem zunaj vzorca za 3 obdobja v prihodnost, saj statično napovedovanje ni možno, če ne poznamo realnih vrednosti v prejšnjem obdobju. Na sliki 17 je predstavljen grafični prikaz napovedovanja zunaj vzorca.

Slika 17: Napovedovanja zunaj vzorca ARMA in ARMAX modela



Vir: lastno delo.

Prilagajanje zunaj vzorčnega napovedovanja sem preveril z izračunom MSFE in MAFE vrednosti. Izračun obeh vrednosti za oba modela lahko vidimo v tabeli 17. Kot lahko vidimo v tabeli, je zunaj vzorčna napoved ARMA modela za 3 kvartale v prihodnost veliko boljše kakor napoved ARMAX modela, saj je tako MSFE kot tudi MAFE vrednost veliko nižja.

Če primerjamo predznake napovedi z realnimi vrednostmi, lahko vidimo, da sta oba modela pravilno napovedala predznak za vsa tri obdobja.

Tabela 17: Primerjalne vrednosti napovedovanja zunaj vzorca

Model	MSFE	MAFE	Primerjava predznakov napovedi
ARMA	0,566	0,654	100 % pravilnih napovedi
ARMAX	2,823	1,608	100 % pravilnih napovedi

Vir: lastno delo.

SKLEP

Z dobrim modelom za napovedovanje indeksa cen stanovanjskih nepremičnin bi lahko države in centralne banke že v času konjunktore zaznale povečano verjetnost, da se bo v prihodnosti zgodila kriza oziroma recesija na trgu nepremičnin, ki jo bi lahko potem s pravilno fiskalno in monetarno politiko omilili. Prav tako bi dober model za napovedovanje cen indeksa prišel prav tudi investitorjem, saj bi s tem lahko zaščitili svoje premoženje.

V magistrski nalogi sem želel preučiti, ali se pri napovedovanju indeksa cen stanovanjskih nepremičnin kompleksnejši model časovnih vrst ARMAX izkaže bolje kakor enostavnejši model ARMA. Optimalen ARMA model sem izbral na podlagi minimizacije vrednosti AIC in SBIC. V nadaljnji analizi sem želel ugotoviti, ali imajo na cene poleg preteklih vrednosti odvisne spremenljivke vpliv tudi makroekonomski kazalniki. Izbor makroekonomskih kazalnikov sem se lotil glede na preteklo literaturo. V analizo sem vključil 14 različnih pojasnjevalnih spremenljivk, ki prikazujejo stanje na trgu dela, v gospodarstvu, cenah, monetarni politiki, delniškem trgu in v gradbenem sektorju. Sestave ARMAX modela sem se lotil na način, da sem postopoma dodajal eno po eno pojasnjevalno spremenljivko ter preverjal, ali je koeficient statistično značilen in ali vrednost koeficienta potrjuje ekonomsko logiko. S tem načinom sem prišel do ARMAX modela, ki poleg pretekle vrednosti odvisne spremenljivke ter pretekle vrednosti slučajne spremenljivke vsebuje še pojasnjevalni spremenljivki:

- dolgoročna obrestna mera z negativnim koeficientom, saj povišanje dolgoročne obrestne mere vodi v povišanje stroškov kreditov ter premik kapitala z nepremičninskega trga na obvezniški trg, kar zmanjša ceno nepremičnin;
- rast skupne cene vseh delnic v Sloveniji s pozitivnim koeficientom, saj rast cene delnic nakazuje razcvet gospodarstva, kar vodi v povečanje povpraševanja po nepremičninah.

Torej lahko samo delno potrdim hipotezo 1, ki se glasi: »Na slovenski indeks cen stanovanjskih nepremičnin vplivajo pretekle vrednosti indeksa cen stanovanjskih nepremičnin, dolgoročna obrestna mera, kratkoročna obrestna mera, stopnja rasti BDP-ja,

stopnja brezposelnosti in gibanje delniškega trga«, saj sem v svojem ARMAX modelu potrdil zgolj spremenljivki dolgoročna obrestna mera in gibanje delniškega trga.

Hipoteza 2, ki sem jo potrdil v analizi, se glasi: »Kompleksnejši model (ARMAX) ima večjo pojasnjevalno moč kot enostavnejši model (ARMA).« To sem preveril z izračunom MSE in MAE vrednosti. ARMAX model je imel tako MSE kot tudi MAE vrednost nižjo od ARMA modela.

Prav tako sem v svoji analizi potrdil tudi hipotezo 3, saj se je enostavnejši model ARMA izkazal za boljši model pri napovedovanju zunaj vzorca za 3 kvartale v prihodnost v primerjavi s kompleksnejšim modelom ARMAX. Napovedovanje zunaj vzorca sem preveril z izračunom MSFE in MAFE vrednosti. Tako MSFE kot tudi MAFE vrednosti ARMA modela sta bili nižji kakor vrednosti ARMAX modela.

Omejitev raziskave je ta, da je časovno obdobje analizirane časovne vrste zelo kratko, saj smo jo v Sloveniji začeli spremljati šele v začetku leta 2007. To pomeni, da imamo znotraj opazovane časovne vrste samo recesijo, ki se je zgodila leta 2008, in nato razcvet stanovanjskega nepremičninskega trga do konca leta 2022. V prihodnosti bi bilo dobro še enkrat pripraviti podobno analizo, v kateri bi lahko prišli do drugačnih zaključkov, saj bi časovna vrsta vsebovala več ciklov.

LITERATURA IN VIRI

1. Abelson, P., Joyeux, R., Milunovich, G. & Chung, D. (2005). Explaining House Prices in Australia: 1970–2003. *Economic Record*, 81(s1), S96–S103.
2. Abraham, J. M. & Hendershott, P. H. (1996). Bubbles in Metropolitan Housing Markets. *Journal of Housing Research*, 7(2), 191–207.
3. Adams, Z. & Füss, R. (2010). Macroeconomic determinants of international housing markets. *Journal of Housing Economics*, 19(1), 38–50.
4. Agnello, L. & Schuknecht, L. (2011). Booms and busts in housing markets: Determinants and implications. *Journal of Housing Economics*, 20(3), 171–190.
5. Baker, D. (2008). The housing bubble and the financial crisis. *Real-World Economics Review*, 46, 73–81.
6. Balcilar, M., Gupta, R. & Miller, S. M. (2015). The out-of-sample forecasting performance of nonlinear models of regional housing prices in the US. *Applied Economics*, 47(22), 2259–2277.
7. Barari, M., Sarkar, N., Kundu, S. & Chowdhury, K. B. (2014). Forecasting House Prices in the United States with Multiple Structural Breaks. *International Econometric Review (IER)*, 6(1), 1–23.
8. Belsky, E. & Prakken, J. (2004). *Housing Wealth Effects: Housing's Impact on Wealth Accumulation, Wealth Distribution and Consumer Spending*. Joint Center for Housing Studies Harvard University.

9. Bernanke, B. S. (2011). Opening remarks: The near and longer-term prospects for the U.S. economy. *Proceedings - Economic Policy Symposium - Jackson Hole*, 1–12.
10. Bork, L. & Møller, S. V. (2018). Housing Price Forecastability: A Factor Analysis. *Real Estate Economics*, 46(3), 582–611.
11. Brooks, C. & Tsolacos, S. (2010). *Real Estate Modelling and Forecasting* (1. izd.). New York: Cambridge University Press.
12. Case, K. E. & Shiller, R. J. (1990). Forecasting Prices and Excess Returns in the Housing Market (*Working Paper Št. 3368*). National Bureau of Economic Research.
13. Case, K. E. & Shiller, R. J. (2003). Is There a Bubble in the Housing Market? *Brookings Papers on Economic Activity*, (2), 299–362.
14. Case, K. E., Glaeser, E. L. & Parker, J. A. (2000). Real Estate and the Macroeconomy. *Brookings Papers on Economic Activity*, (2), 119–162.
15. Case, K. E., Shiller, R. J. & Quigley, J. M. (2001). *Comparing Wealth Effects: The Stock Market Versus the Housing Market (Working Paper Št. 8606)*. National Bureau of Economic Research.
16. Chaplin, R. (1999). The predictability of real office rents. *Journal of Property Research*, 16(1), 21–49.
17. Chatfield, C. (2000). *Time-Series Forecasting*. Chapman and Hall/CRC.
18. Chin, L. & Fan, G. (2005). Autoregressive analysis of Singapore's private residential prices. *Property Management*, 23(4), 257–270.
19. Cho, M. (1996). House Price Dynamics: A Survey of Theoretical and Empirical Issues. *Journal of Housing Research*, 7(2), 145–172.
20. Claussen, C. A. (2013). Are Swedish houses overpriced? *International Journal of Housing Markets and Analysis*, 6(2), 180–196.
21. Cohen, V. & Karpavičiūtė, L. (2017). The analysis of the determinants of housing prices. *Independent journal of management & production*, 8(1), 049-063.
22. Crawford, G. W. & Fratantoni, M. C. (2003). Assessing the Forecasting Performance of Regime-Switching, ARIMA and GARCH Models of House Prices. *Real Estate Economics*, 31(2), 223–243.
23. DiPasquale, D. & Wheaton W. C. (1994). Housing Market Dynamics and the Future of Housing Prices. *Journal of Urban Economics*, 35(1), 1–27.
24. Duca, J. V., Luttrell, D. & Murphy, A. (2011). When will the U.S. housing market stabilize? *Economic Letter*, 6.
25. Edbrooke, J. (2016). *Time Series Modelling Technique Analysis for Enterprise Stress Testing* (magistrsko delo). United Kingdom: Imperial College London.
26. Égert, B. & Mihaljek, D. (2007). *Determinants of house prices in central and eastern Europe (BIS Working Paper Št. 236)*. Bank for International Settlements.
27. Favilukis, J., Ludvigson, S. C. & Van Nieuwerburgh, S. (2017). The Macroeconomic Effects of Housing Wealth, Housing Finance, and Limited Risk Sharing in General Equilibrium. *Journal of Political Economy*, 125(1), 140–223.
28. Finocchiaro, D. & Von Heideken, V. Q. (2013). Do Central Banks React to House Prices? *Journal of Money, Credit and Banking*, 45(8), 1659–1683.

29. FRED. (brez datuma a). *Rental Vacancy Rate in the United States*. Pridobljeno 23. aprila 2023 iz <https://fred.stlouisfed.org/series/RRVRUSQ156N>
30. FRED. (brez datuma b). *S&P/Case-Shiller U.S. National Home Price Index*. Pridobljeno 23. aprila 2023 iz <https://fred.stlouisfed.org/series/CSUSHPISA>
31. FRED. (brez datuma c). *New Privately-Owned Housing Units Started: Total Units*. Pridobljeno 23. aprila 2023 iz <https://fred.stlouisfed.org/series/HOUST>
32. Geng, N. (2018). Fundamental Drivers of House Prices in Advanced Economies. *IMF Working Papers*, 164.
33. Grum, B. & Govekar, D. K. (2015). Influence of Macroeconomic Factors on Prices of Real Estate in Various Cultural Environments: Case of Slovenia, Greece, France, Poland and Norway. *Procedia Economics and Finance*, 39, 597–604.
34. Hepşen, A. & Vatansever, M. (2011). Forecasting future trends in Dubai housing market by using Box-Jenkins autoregressive integrated moving average. *International Journal of Housing Markets and Analysis*, 4(3), 210–223.
35. Holden, K., Peel, D. A. & Thompson, J. L. (1990). *Economic Forecasting: An Introduction*. Cambridge University Press.
36. Hyndman, R. (2010). *The ARIMAX model muddle*. Pridobljeno 15. marca 2023 iz <https://robjhyndman.com/hyndsight/arimax/>
37. INTERNET MEDIA d. o. o. (brez datuma). *Kaj so nepremičnine*. Pridobljeno 12. aprila 2023 iz <https://www.slonep.net:443/info/nepremicninski-trg/nepremicnine>
38. Jacobsen, D. H. & Naug, B. E. (2005). *What Drives House Prices?* Pridobljeno 9. decembra 2022 iz <https://norges-bank.brage.unit.no/norges-bank-xmlui/handle/11250/2504379>
39. Jadevicius, A. & Huston, S. (2015). Property market modelling and forecasting: Simple vs complex models. *Journal of Property Investment & Finance*, 33(4), 337–361.
40. Johnes, G. & Hyclak, T. (1999). House prices and regional labor markets. *The Annals of Regional Science*, 33(1), 33–49.
41. Kestel, A. S. S. & Yilmaz, B. (2020). Forecasting house prices in Turkey: GLM, VAR and time series approaches. *Pressacademia*, 9(4), 274–291.
42. Leamer, E. E. (2007). Housing IS the Business Cycle. *NBER*, 13428.
43. Lee, C. L. (2009). Housing price volatility and its determinants. *International Journal of Housing Markets and Analysis*, 293–308
44. Leung, C. K. Y., Leong, Y. C. F. & Wong, S. K. (2006). Housing Price Dispersion: An Empirical Investigation. *The Journal of Real Estate Finance and Economics*, 32(3), 357–385.
45. Mahalik, M. K. & Mallick, H. (2011). What Causes Asset Price Bubble in an Emerging Economy? Some Empirical Evidence in the Housing Sector of India. *International Economic Journal*, 25(2), 215–237.
46. Malpezzi, S. (1999). A Simple Error Correction Model of House Prices. *Journal of Housing Economics*, 8(1), 27–62.
47. McAllister, P. & Nase, I. (2020). The accuracy of consensus real estate forecasts revisited. *Journal of Property Research*, 37(2), 147–170.

48. McGough, T. & Tsolacos, S. (1995). Forecasting commercial rental values using ARIMA models. *Journal of Property Valuation and Investment*, 13(5), 6–22.
49. Miles, W. (2008). Boom–Bust Cycles and the Forecasting Performance of Linear and Non-Linear Models of House Prices. *The Journal of Real Estate Finance and Economics*, 36(3), 249–264.
50. Milunovich, G. (2020). Forecasting Australia’s real house price index: A comparison of time series and machine learning methods. *Journal of Forecasting*, 39(7), 1098–1118.
51. Muellbauer, J. & Murphy, A. (1997). Booms and Busts in the UK Housing Market. *The Economic Journal*, 107(445), 1701–1727.
52. Newell, G., Acheampong, P. & Karantonis, A. (2002). *The accuracy of property forecasting*. Pridobljeno 10. februarja 2023 iz http://www.prres.net/Papers/Newell_The_accuracy_of_property_forecasting.pdf
53. Pant, P. N. & Starbuck, W. H. (1990). Innocents in the Forest: Forecasting and Research Methods. *Journal of Management*, 16(2), 433–460.
54. Plazzi, A., Torous, W. & Valkanov, R. (2010). Expected Returns and Expected Growth in Rents of Commercial Real Estate. *Review of Financial Studies*, 23, 3469–3519.
55. Rapach, D. E. & Strauss, J. K. (2007). Forecasting real housing price growth in the Eighth District states. *Regional Economic Development*, 33–42.
56. Rapach, D. E. & Strauss, J. K. (2009). Differences in housing price forecastability across US states. *International Journal of Forecasting*, 25(2), 351–372.
57. Renigier-Biłozor, M. & Wiśniewski, R. (2012). The impact of macroeconomic factors on residential property prices indices in Europe. *Aestimum*, 149–166.
58. Selim, H. (2009). Determinants of house prices in Turkey: Hedonic regression versus artificial neural network. *Expert Systems with Applications*, 36(2, Part 2), 2843–2852.
59. Stevenson, S. & McGarth, O. (2003). A comparison of alternative rental forecasting models: Empirical tests on the London office market. *Journal of Property Research*, 20(3), 235–260.
60. Stevenson, S. & Young, J. (2007). Forecasting Housing Supply: Empirical Evidence from the Irish Market. *European Journal of Housing Policy*, 7(1), 1–17.
61. Tse, R. Y. C. (1997). An application of the ARIMA model to real-estate prices in Hong Kong. *Journal of Property Finance*, 8(2), 152–163.
62. Yilmaz, B. & Selcuk-Kestel, A. S. (2019). Computation of Hedging Coefficients for Mortgage Default and Prepayment Options: Malliavin Calculus Approach. *The Journal of Real Estate Finance and Economics*, 59(4), 673–697.

PRILOGE

Priloga 1: ARMA (1,1) z dodano pojasnjevalno časovno vrsto LI

Spremenljivka	Koeficient	Standardni odklon	z vrednost	p-vrednost
μ	3,016	1,608	1,88	0,061
LI_t	-0,657	0,369	-1,78	0,075
y_{t-1}	0,815	0,140	5,80	0,000
u_{t-1}	-0,518	0,201	-2,58	0,010

Vir: lastno delo.

Priloga 2: ARMA (1,1) z dodano pojasnjevalno časovno vrsto SP

Spremenljivka	Koeficient	Standardni odklon	z vrednost	p-vrednost
μ	1,301	0,746	1,75	0,081
SP_t	0,065	0,293	2,22	0,027
y_{t-1}	0,883	0,088	10,03	0,000
u_{t-1}	-0,612	0,152	-4,03	0,000

Vir: lastno delo.