



Analýza nájemného v České republice

Ministerstvo pro místní rozvoj
České republiky

27.6.2019

Analýza nájemného v České republice

Manažerské shrnutí

Tento dokument obsahuje model tržního nájemného sestavený na datech o transakčních cenách nemovitostí. Model je založen na rozdílném vztahu mezi transakční cenou bytů a tržní výší nájmu v jednotlivých územích. Model pokrývá celou Českou republiku vyjma 4 vojenských újezdů v měřítku 389 území obcí s pověřeným úřadem.

Výsledné modelované tržní nájemné je vypočteno jako průměr, medián a první tři decily a je prezentováno v podobě map pro porovnání regionálních odlišností, v grafech srovnávajících modelovanou distribuci výše nájemného včetně srovnání s daty o výších nájmu podle realitních portálů. Výsledky jsou rovněž prezentovány v tabulkové příloze.

Nejvyšší nájmy jsou v největších českých městech a jejich aglomeračním zázemí. Nejvyšší průměrné modelované nájemné je v Praze s 266 Kč za metr čtvereční. Specifickým územím jsou Karlovarský a Ústecký kraj, kde je nájemné ve vztahu k transakčním cenám nemovitostí relativně vysoké. Totéž v menší míře platí i pro vnitřní periferie republiky, obvykle na hranicích jednotlivých krajů. Nejnižší průměrné modelované nájemné se pohybuje mezi 73 a 100 Kč za metr čtvereční, obvykle v hraničních oblastech České republiky.

Z hlediska faktorů ovlivňujících cenu bytů byla zkoumána území aglomerací velkých měst (dle vymezení FUA podle OECD). Srovnání mezi aglomeracemi se zaměřilo především na vliv velikosti bytu na cenu bytu za metr čtvereční a vliv vzdálenosti od centra aglomerace. Cena bytu za metr čtvereční typicky klesne o 2%, pokud je výměra bytu o 10% větší. Výjimkou jsou například Ostravsko a Ústecko, kde se cena za metr čtvereční s velikostí bytu nemění.

Cena bytů za metr čtvereční v závislosti od centra aglomerace se napříč republikou také liší. Pokud je byt dále o 10% od centra jádrové aglomerace, tak jeho cena průměrně klesne o 0,2% až 3%. V Praze jsou to 2%.

Zkoumán byl i vliv typu konstrukce domů na cenu bytů. Cena panelových domů a cihlových domů vychází při zohlednění osatních proměnných shodně, developerské novostavby jsou v průměru o 22,5% dražší oproti cihlovým domům a měšťanské historické domy jsou oproti cihlovým domům dražší o 12%.

Obsah

1. Zadání a poskytnutá data	5
1.1. Datové zdroje poskytnuté klientem	5
1.2. Doplněné datové zdroje o trhu nemovitostí	6
1.3. Ostatní socio-ekonomická data	14
1.4. Úpravy vstupních dat oproti Metodice	19
2. Příprava modelu tržního nájemného	21
2.1. Koncept modelu a predikce	21
2.2. Propojení datových zdrojů	23
2.3. Výběr dat pro základní model vztahu transakcí a nájmů	23
2.4. Vzájemné závislosti sledovaných proměnných	26
2.5. Statistický model	27
3. Výsledky modelu tržního nájemného	30
3.1. Model na úrovni území obcí s pověřeným úřadem (POU)	30
3.1. Model na úrovni městských obvodů a městských částí	35
4. Model faktorů ovlivňujících výši tržního nájemného	41
4.1. Popis modelu	41
4.2. Výsledky modelu	41
4.3. Interpretace výsledků modelu	43
4.4. Přehled proměnných	44
5. Komentář	45
5.1. Komentář k modelu z hlediska rozložení příjemců dávek v oblasti bydlení	45
5.2. Komentář k dostupným datovým zdrojům a modelu	47
6. Návrh možného následného postupu	48
6.1. Možnosti rozšíření použitých dat o cenách nemovitostí – použití dat z více let	48
6.2. Rozšíření datové základny o výších tržních nájmů – neagregovaná data ARK ČR	48
6.3. Úprava koncepce analýzy a modelu – modelování nad daty realitních portálů	49
6.4. Analýza stávajících vyplácených dávek	50
6.5. Analýza dopadů změny výše vyplácené podpory na veřejné rozpočty	51
7. Příloha ke statistické analýze	52
7.1. Model M0a	52
7.2. Model M1c	54
7.3. Model M1g	55
7.1. Agregace území s malým počtem transakcí	56
7.2. Kontrola predikce modelu M1g	61
7.1. Komentář k modelové specifikaci regionálních rozdílů v nájmech	62

7.2. Model M2a	67
8. Slovník použitých zkratk	69
9. Přehled ostatních příloh	70

1. Zadání a poskytnutá data

Klientem analýzy je Ministerstvo pro místní rozvoj ČR (dále „**MMR**“) ve spolupráci s Ministerstvem práce a sociálních věcí ČR (dále „**MPSV**“). Analýza by měla být použita jako podklad pro návrh veřejných politik s prostorovým dopadem v gesci MMR a dále jako podklad pro revizi systému podpory bydlení v gesci MPSV.

Cílem analýzy je namodelovat výši tržního nájemného v podrobném geografickém měřítku na území celé České republiky. Hlavními datovými zdroji jsou tržní výše nájemného podle uzavřených nájemních smluv evidované Asociací realitních kanceláří ČR, která byla poskytnuta klientem. Tato data jsou agregovaná do průměrů za obce nad 5000 obyvatel za období jednoho roku.

Hlavní datovou sadou pro modelování tržního nájemného jsou transakční (prodejní) ceny nemovitostí na základě údajů Katastru nemovitostí. Cílem modelu je tedy vysvětlit vztah mezi tržní cenou nemovitosti a ekvivalentní tržní výší nájmu, což je provedeno pomocí vysvětlujících proměnných charakterizujících místní trh nemovitostí a další socio-ekonomické faktory.

S ohledem na výše uvedené požádalo MMR společnost Deloitte Advisory, s.r.o. („**Deloitte**“) o zpracování analýzy získaných dat a sestavení komentářů a doporučení pro budoucí sběr a vyhodnocování dat i pro současné možnosti úpravy systému vyplácení příspěvku na bydlení.

1.1. Datové zdroje poskytnuté klientem

Databáze tržních nájmu dle ARK ČR

Pro potřeby zpracování analýzy poskytlo MMR 2 datové soubory. První soubor „Kopie - obce_nad5000_listopad2018_ARK_pro_MMR (2).xlsx“ (dále „**databáze tržních nájmu**“) obsahuje data o průměrné výši tržního nájemného v obcích nad 5000 obyvatel v období od poloviny roku 2017 do poloviny roku 2018, která byla pořízena od Asociace realitních kanceláří. Kromě výčtu výše tržního nájemného podle jednotlivých obcí jsou v souboru přiloženy i souhrny tržního nájemného podle velikostní kategorie obcí a podle velikostní kategorie obcí a kraje. Data obsahují 274 záznamů obcí.

Data o obecním nájemném

V druhém poskytnutém datovém souboru „Kopie - Kopie - Kopie - Tabulka nájemné k 15.1.2019_SMOCR_JT_2 (2).xlsx“ (dále „**databáze obecních bytů**“) jsou data o obecních bytových fondech a o výši nájemného v obecních bytech. V databázi jsou evidovány obce i městské části statutárních měst, obce jsou identifikované kódem a dále rozdělené podle kraje a velikosti dle kategorizace MMR a dle kategorizace MPSV. Pro každou obec jsou data rozdělena na byty celkem, byty pronajaté ve volné soutěži a na byty administrativně přidělené podle sociálních kritérií. Evidovány jsou počty bytů, celkové vybrané nájemné za měsíc, celková podlahová plocha bytů, nájemné za metr čtvereční podlahové plochy a dále tržní nájemné podle Asociace realitních kanceláří pro obce, pro které je známo. Data obsahují 917 záznamů obcí. Výčet všech sledovaných ukazatelů je zobrazen níže v tabulce.

Přehled sledovaných ukazatelů u databáze obecních bytů

Kód obce	Počet bytů pronajatých ve volné soutěži	Celková podlahová plocha všech obecních bytů v m2
Sloupec1	Počet bytů administrativně přidělených podle sociálních kritérií	Podlahová plocha obecních bytů se smluvním nájemným v m2
Název obce	Celkové vybrané nájemné ze všech obecních bytů v Kč/měsíc	Podlahová plocha bytů se sociálním nájemným v m2
Počet obyvatel	Vybrané nájemné z bytů se smluvním nájemným v Kč/měsíc	Nájemné v Kč za 1m2 podlahové plochy obecního bytu (modrá) K/P
Počet obyvatel podle MPSV	Prostor pro Váš komentář	Nájemné v Kč za 1m2 podlahové plochy bytu se smluvním nájemným (zelená) L/Q
Uvedte kraj	Vybrané nájemné z bytů se sociálním nájemným v Kč/měsíc	Nájemné v Kč za 1m2 podlahové plochy bytu se sociálním nájemným (oranžová) N/R
Celkový počet obecních bytů	Prostor pro Váš komentář2	Nájemné na m2 podlahové plochy dle ARK

Obě dvě databáze byly dále doplněny o soubor „Hodnotové mapy - teze.docx“, ve kterém jsou jednak shrnuta zjištění o obou datových sadách a dále možnosti dalšího postupu při úpravě systému vyplácení příspěvku na bydlení.

Data o počtu obyvatel pobírajících podporu v bydlení

Přehled příjemců příspěvku na bydlení a doplatku na bydlení je rozdělen podle typu dávky a pro každou obec je uveden počet příjemců této dávky. V případě, že je v obci méně než 5 příjemců dávky, pak je u obce uvedeno „méně než 5“.

1.2. Doplněné datové zdroje o trhu nemovitostí

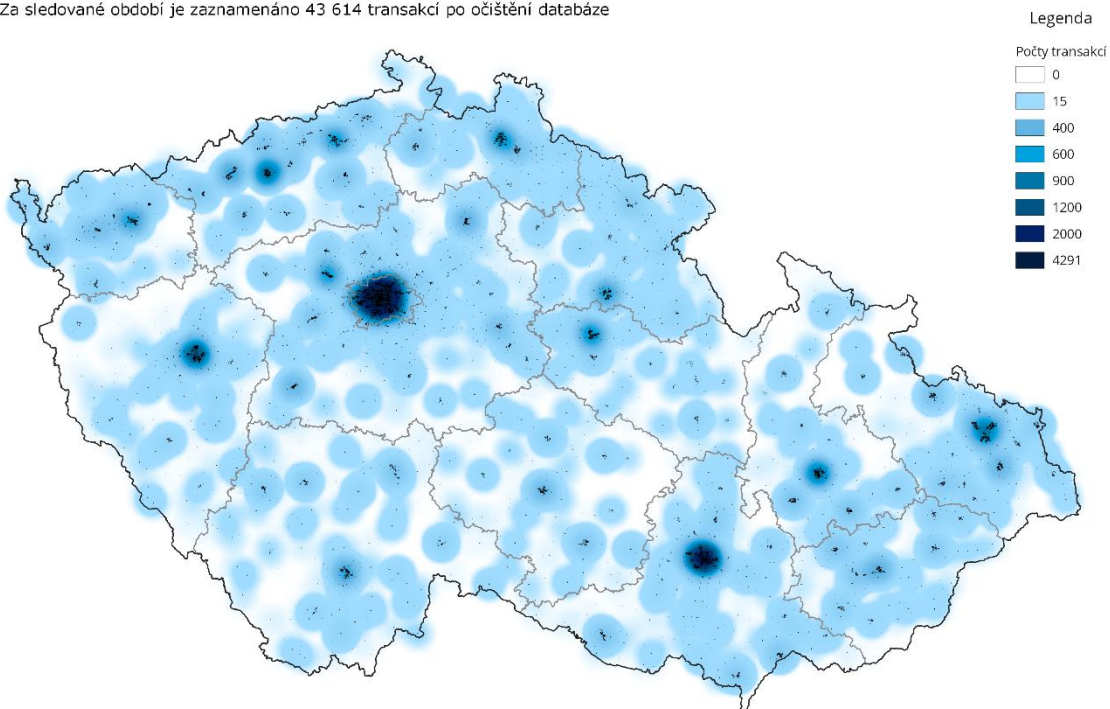
Transakční ceny bytů

Použitá data jsou tržními transakcemi přeprodávaných bytů, tedy bez prvoprodeje od developerů klientům. Výjimku z tohoto pravidla tvoří obce pod 10 tisíc obyvatel, kde data zahrnují i transakce od developerů prvním klientům.

Pokrytí záznamy o transakčních cenách bytů

Heat mapa počtu tržních transakcí bytů

Za sledované období je zaznamenáno 43 614 transakcí po očištění databáze

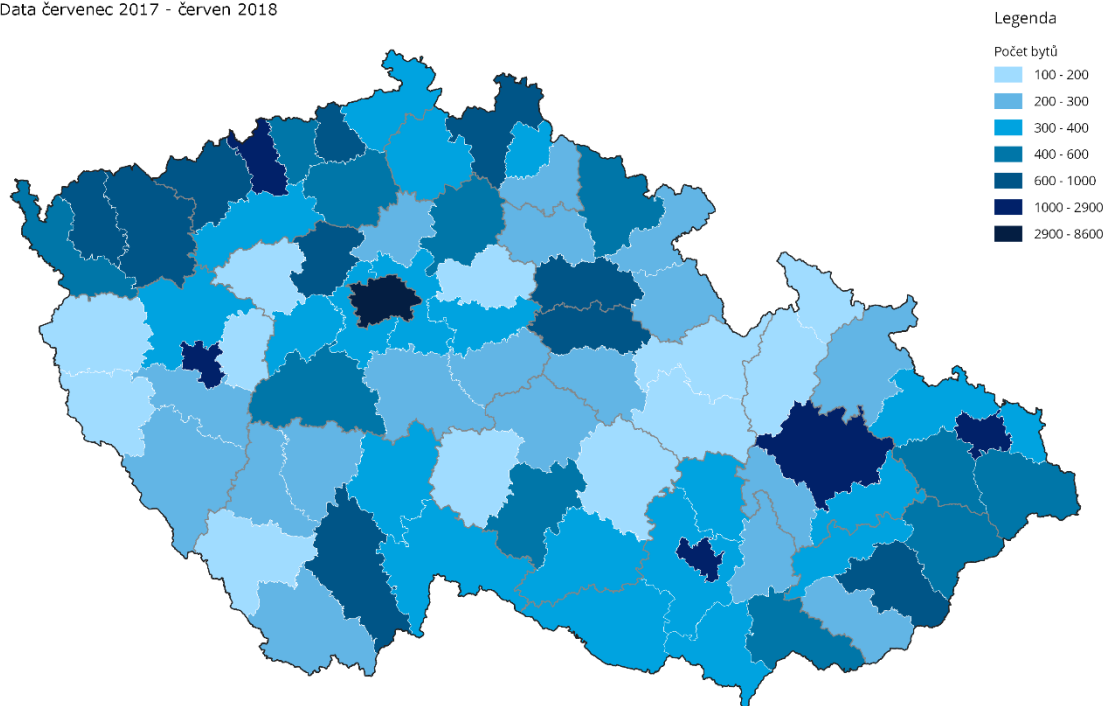


© 2019 Deloitte Česká republika

Počet tržních transakcí podle okresů

Počet transakcí bytů dle okresů

Data červenec 2017 - červen 2018

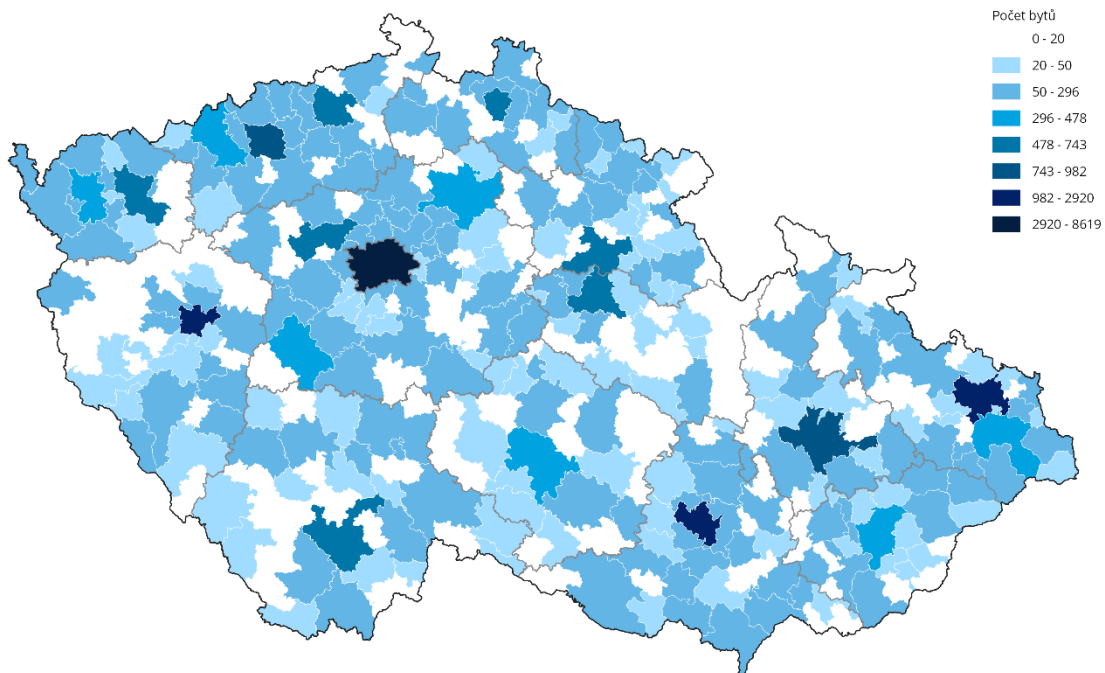


© 2019 Deloitte Česká republika

Počet tržních transakcí bytů podle obcí s pověřeným úřadem (POU)

Počet transakcí bytů dle obcí s pověřeným úřadem

Data červenec 2017 - červen 2018

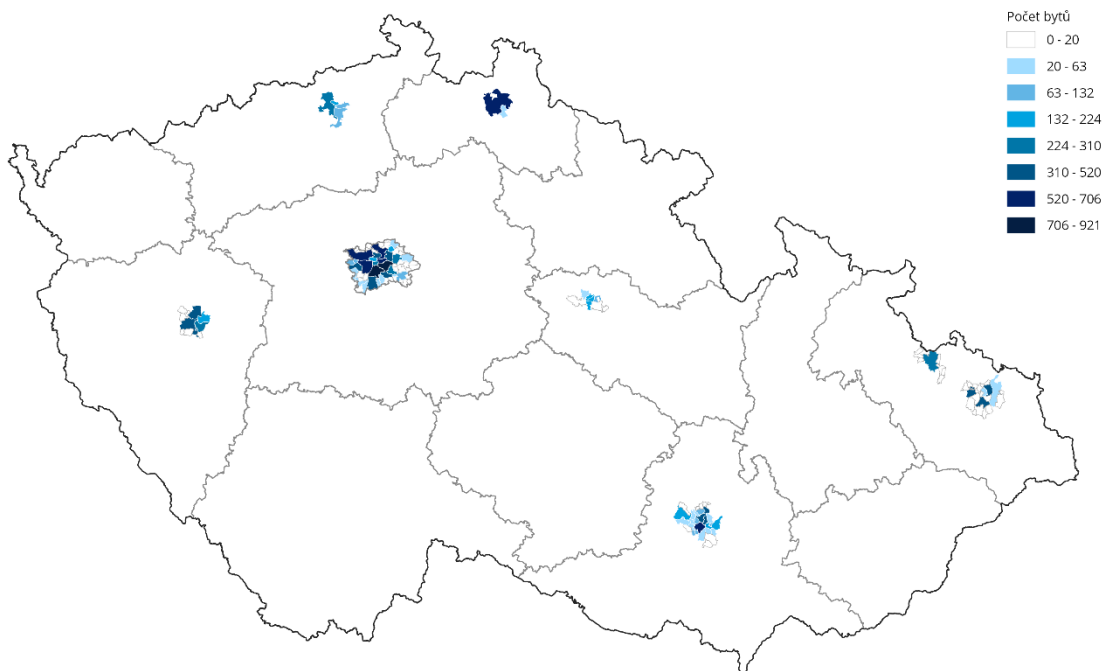


© 2019 Deloitte Česká republika

Počet tržních transakcí bytů podle městských obvodů a městských částí

Počet transakcí bytů dle městských obvodů a městských částí

Data červenec 2017 - červen 2018

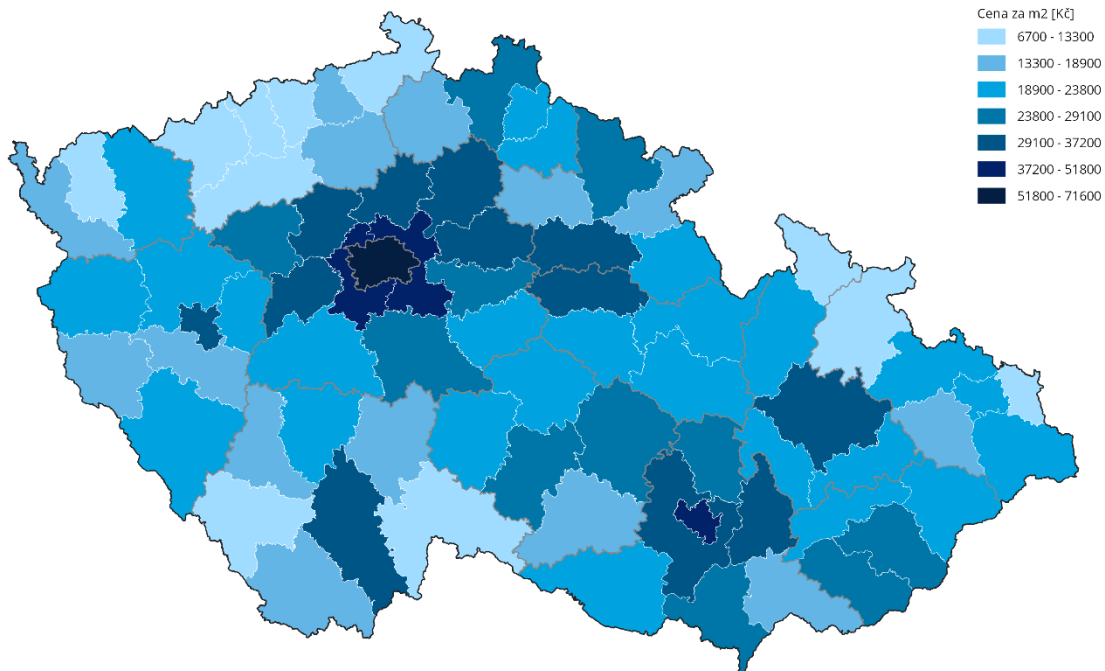


© 2019 Deloitte Česká republika

Transakční ceny bytů podle okresu

Průměrné transakční ceny bytů dle okresů

Data červenec 2017 - červen 2018

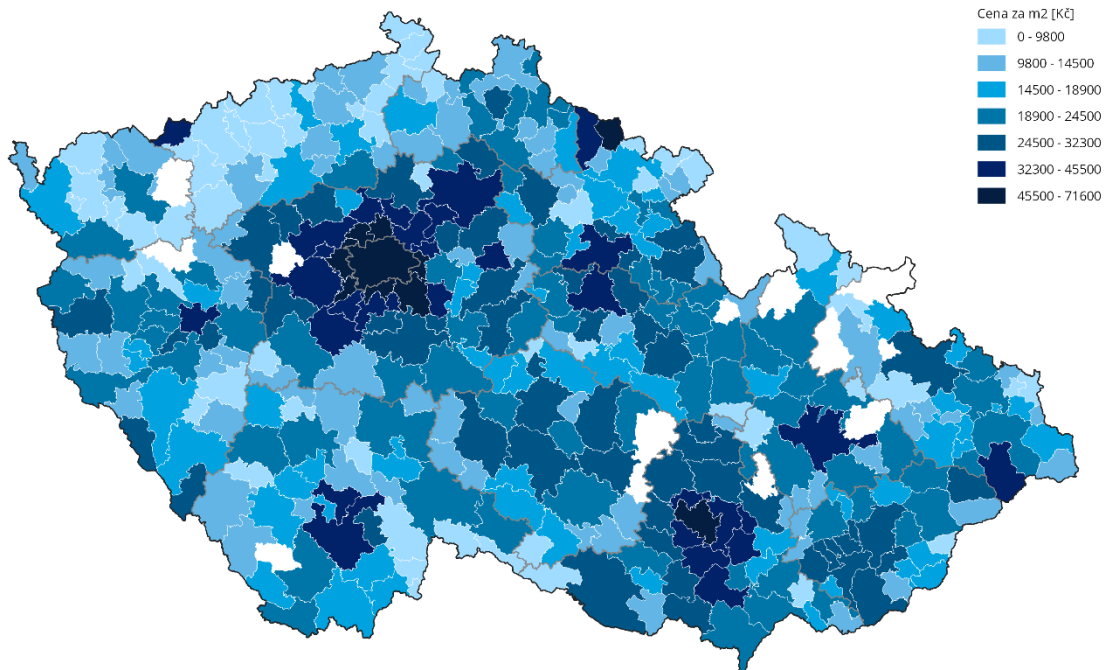


© 2019 Deloitte Česká republika

Transakční ceny nemovitostí podle obcí s pověřeným úřadem (POU)

Průměrné transakční ceny bytů dle obcí s pověřeným úřadem

Data červenec 2017 - červen 2018



© 2019 Deloitte Česká republika

Nabídkové ceny nájmu z webových portálů

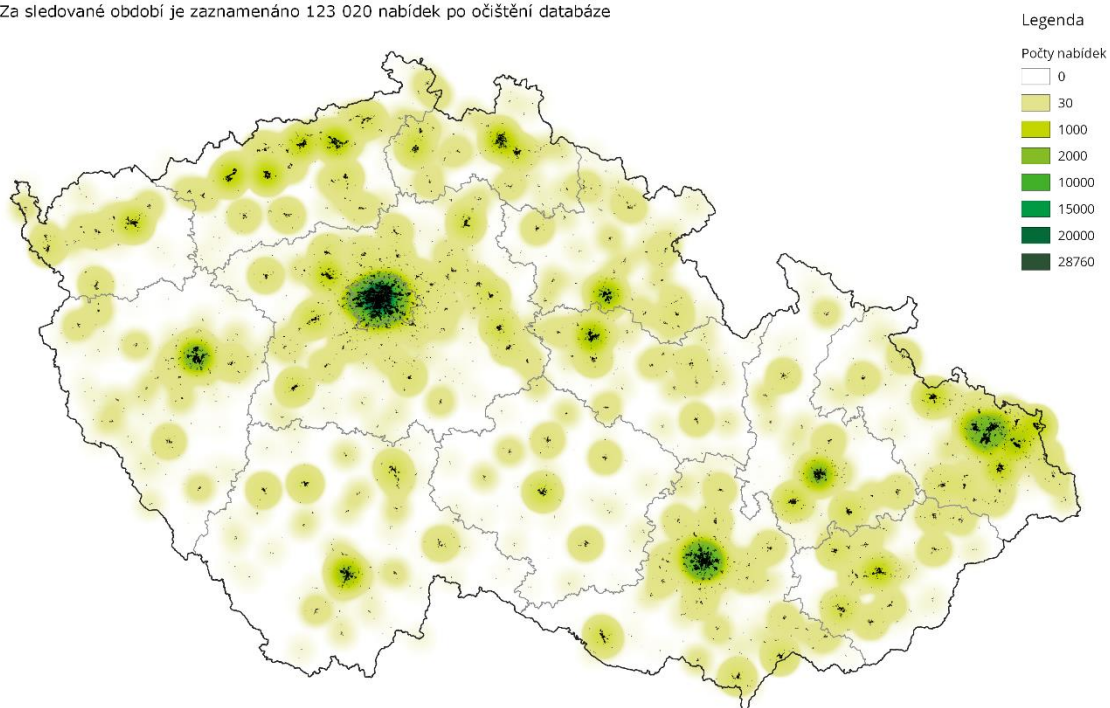
Přehled všech nabídek je v podobě heat mapy zobrazen na mapě níže. Z mapy je patrné, že největší počet nabídek bytů k pronájmu je zaznamenán v regionálních centrech, tedy hlavním městě a krajských městech.

Naopak velmi malý počet nabídek je v oblastech venkovských vnitřních periferií, jako jsou hranice Plzeňského a Jihočeského kraje a kraje Vysočina.

Pokrytí záznamy o nabídkových výších nájmu

Heat mapa počtu nabídek nájmu podle realitních portálů

Za sledované období je zaznamenáno 123 020 nabídek po očištění databáze




© 2019 Deloitte Česká republika

Pro následující analytickou práci je ale výhodnější počet nabídek bilancovat za území dle existujícího administrativního členění a proto jsou níže uvedeny počty nabídek podle okresů a podle obcí s pověřeným úřadem.

Počet nabídek bytů podle okresů

Počet nabídkových inzerátů nájmu bytů dle okresů

Data červenec 2017 - červen 2018, zdroj webové portály

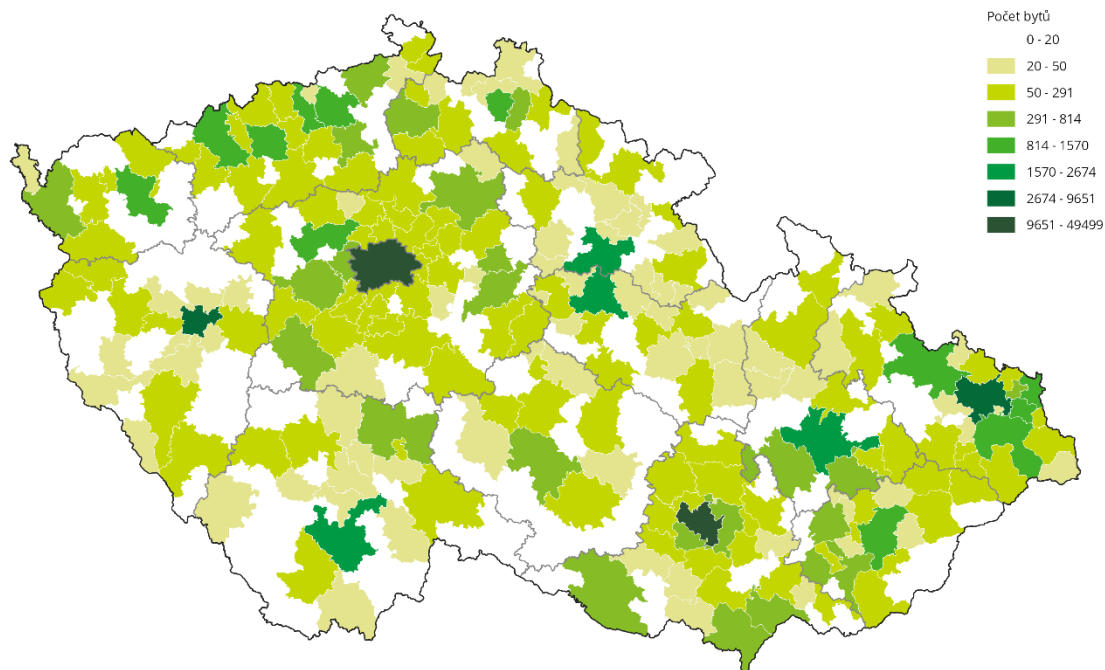


© 2019 Deloitte Česká republika

Počet nabídek bytů podle obcí s pověřeným úřadem (POU)

Počet nabídkových inzerátů nájmu bytů dle obcí s pověřeným úřadem

Data červenec 2017 - červen 2018, zdroj webové portály

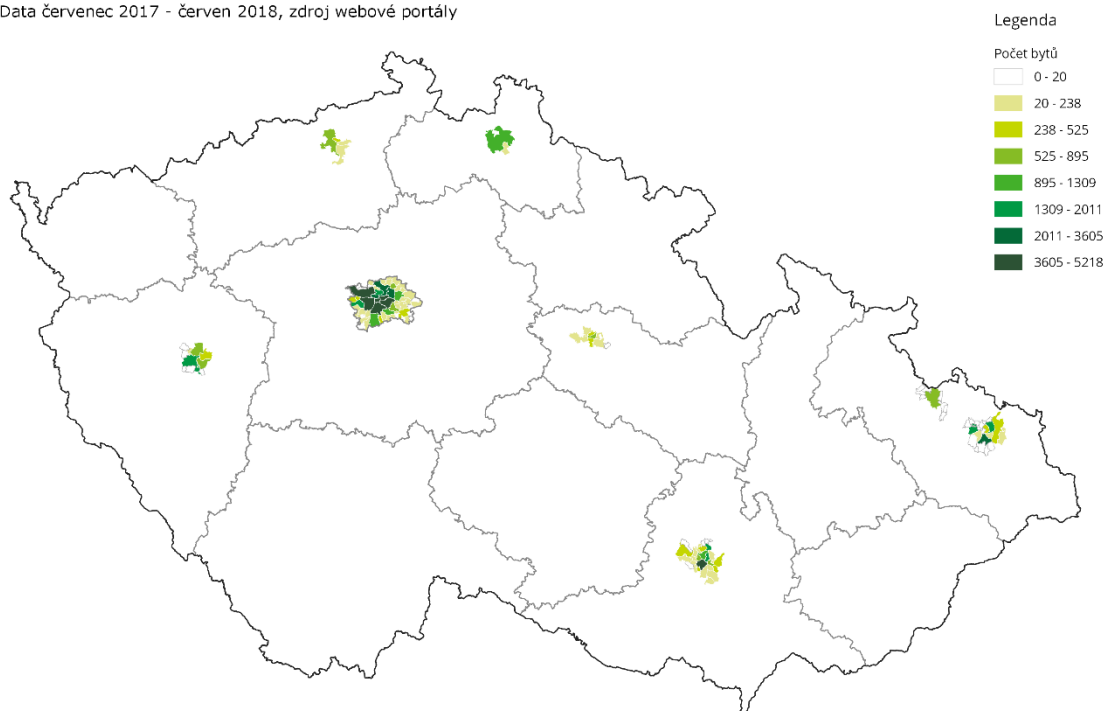


© 2019 Deloitte Česká republika

Počet nabídek bytů podle městských obvodů a městských částí

Počet nabídkových inzerátů nájmu bytů dle městských částí a městských obvodů

Data červenec 2017 - červen 2018, zdroj webové portály

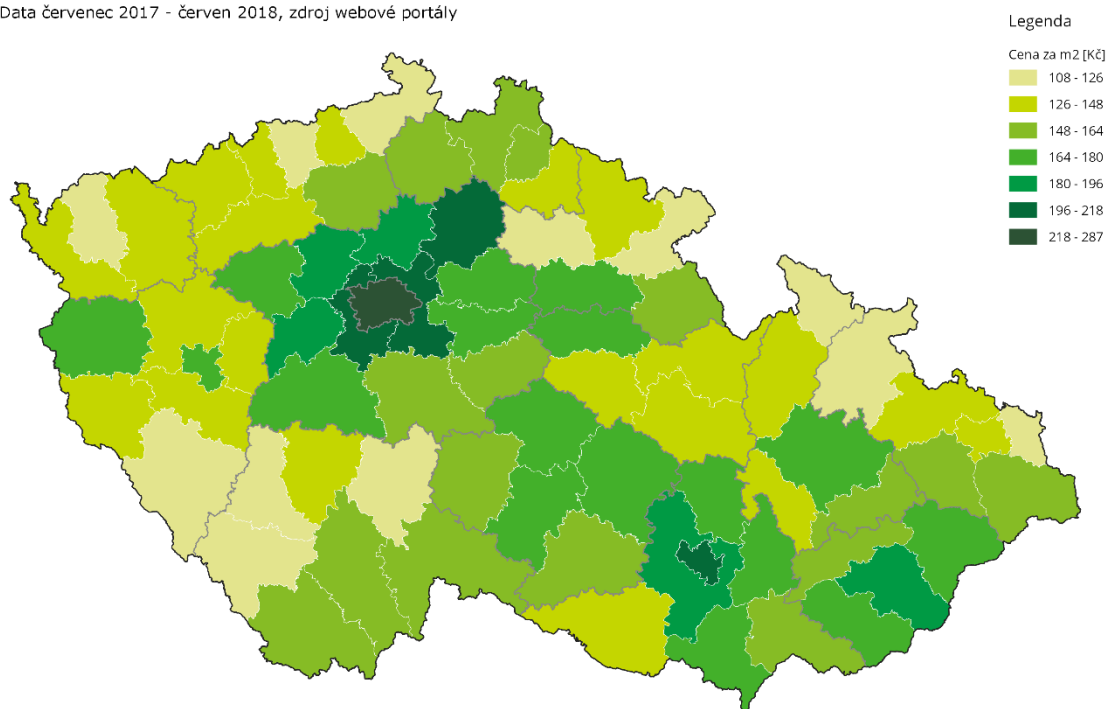


© 2019 Deloitte Česká republika

Nabídkové ceny nájmu podle okresu

Průměrné nabídkové ceny nájmu bytů dle okresů

Data červenec 2017 - červen 2018, zdroj webové portály

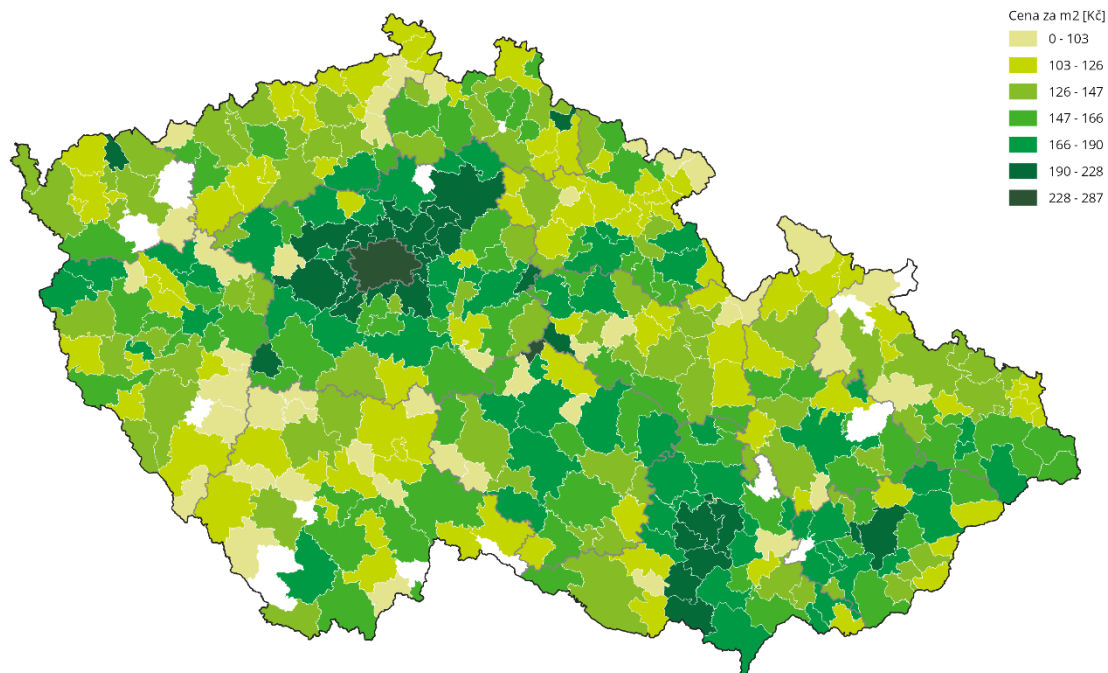


© 2019 Deloitte Česká republika

Nabídkové ceny nájmu podle obcí s pověřeným úřadem (POU)

Průměrné nabídkové ceny nájmu bytů dle obcí s pověřeným úřadem

Data červenec 2017 - červen 2018, zdroj webové portály




© 2019 Deloitte Česká republika

Doba zveřejnění inzerátů

Mediánová doba mezi zveřejněním a stažením inzerátu bytu k pronájmu

Data webové portály




© 2019 Deloitte Česká republika

1.3. Ostatní socio-ekonomická data

Počet obyvatel obcí

Počet obyvatel obcí
Data ČSÚ, prosinec 2017




© 2019 Deloitte Česká republika

Vývoj počtu obyvatel

Vývoj počtu obyvatel obcí

Data ČSÚ, 2011-2017, průměrná roční změna počtu obyvatel




© 2019 Deloitte Česká republika

Model mediánových mezd

Model mediánových mezd

Data ČSÚ, MPSV, model Deloitte

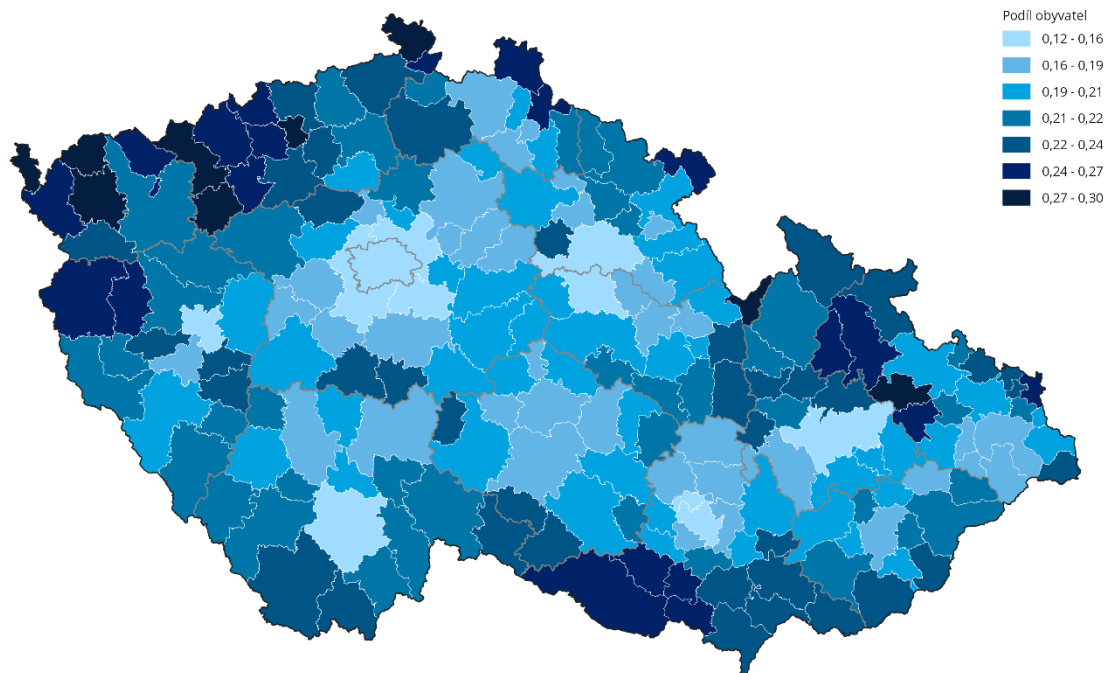


© 2019 Deloitte Česká republika

Podíl obyvatel se základním a bez vzdělání

Podíl obyvatel se základním vzděláním a bez vzdělání

Data ČSÚ, SLDB 2011

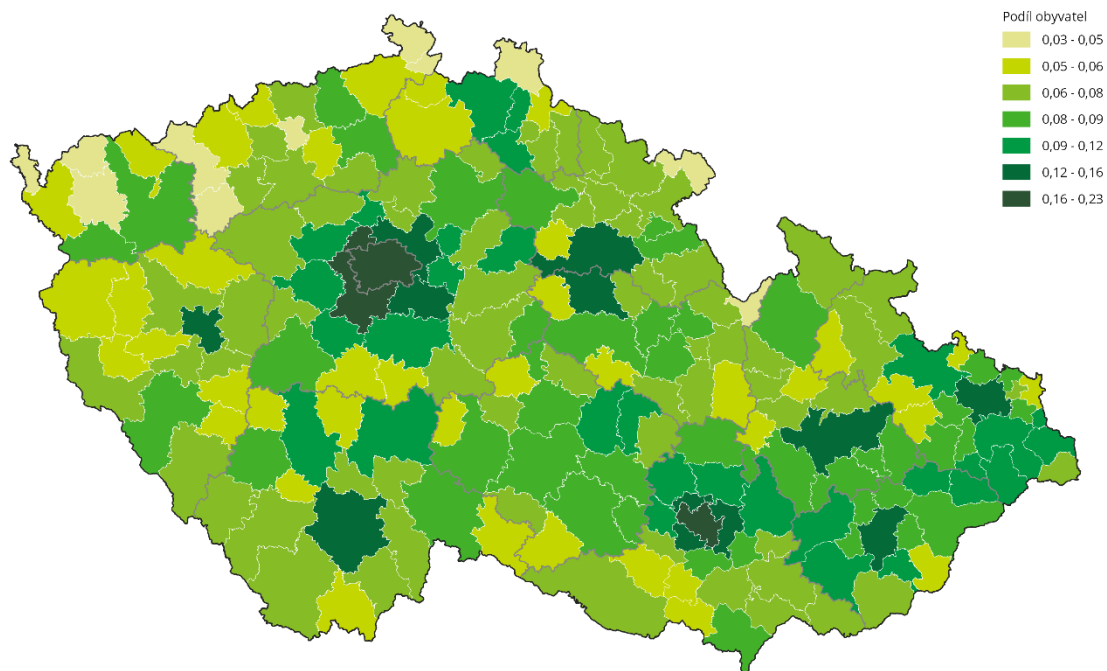


© 2019 Deloitte Česká republika

Podíl obyvatel s ukončeným magisterským vzděláním a vyšším

Podíl obyvatel s ukončeným magisterským vzděláním a vyšším

Data ČSÚ, SLDB 2011




© 2019 Deloitte Česká republika

Míra nezaměstnanosti

Míra nezaměstnanosti

Data ČSÚ




© 2019 Deloitte Česká republika

Intenzita bytové výstavby

Změna velikosti bytového fondu

Data ČSÚ

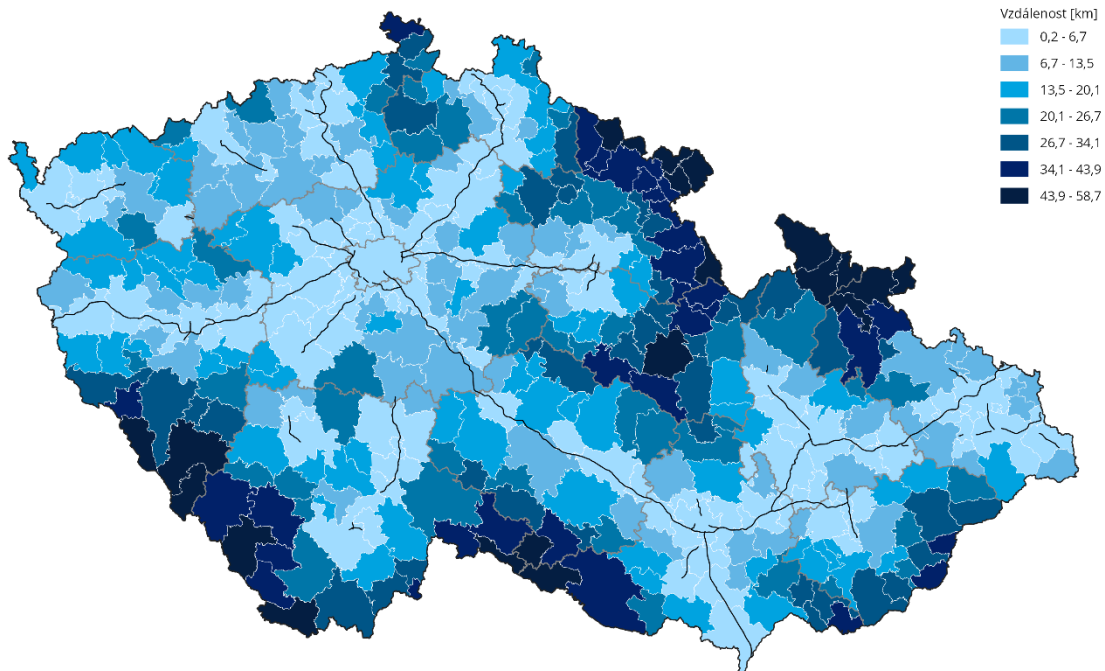


© 2019 Deloitte Česká republika

Vzdálenost k nejbližší dálnici nebo silnici pro motorová vozidla

Vzdálenost k nejbližší dálnici nebo silnici pro motorová vozidla

Data ČÚZK

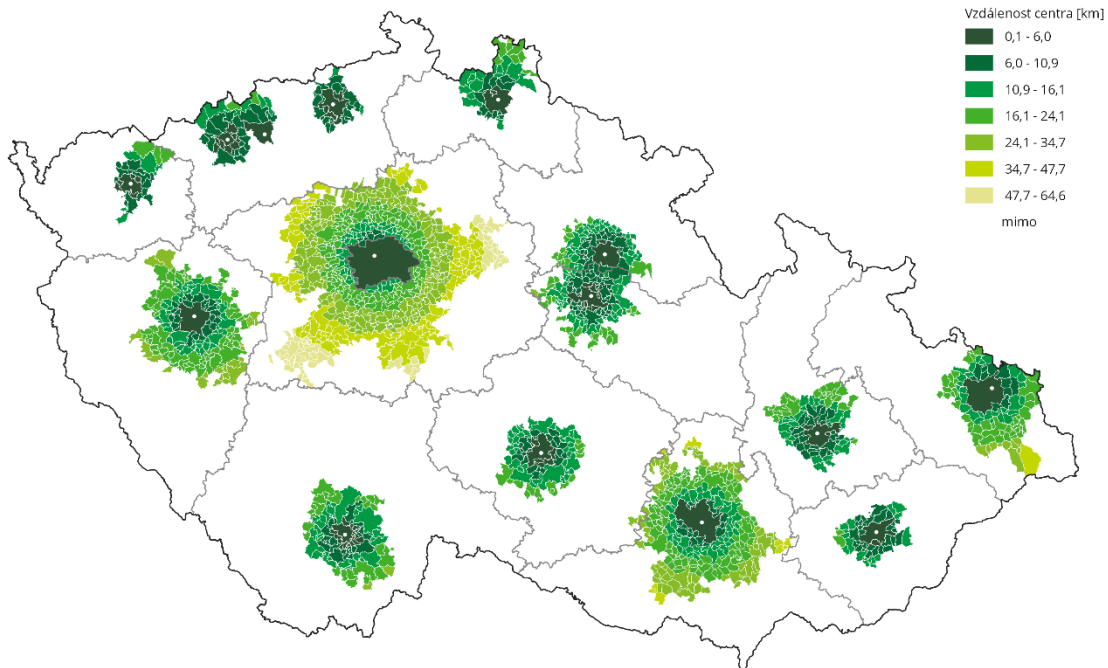


© 2019 Deloitte Česká republika

Umístění v rámci Functional urban area

Lokalizace ve Functional urban area a vzdálenost do jejího centra

Data OECD

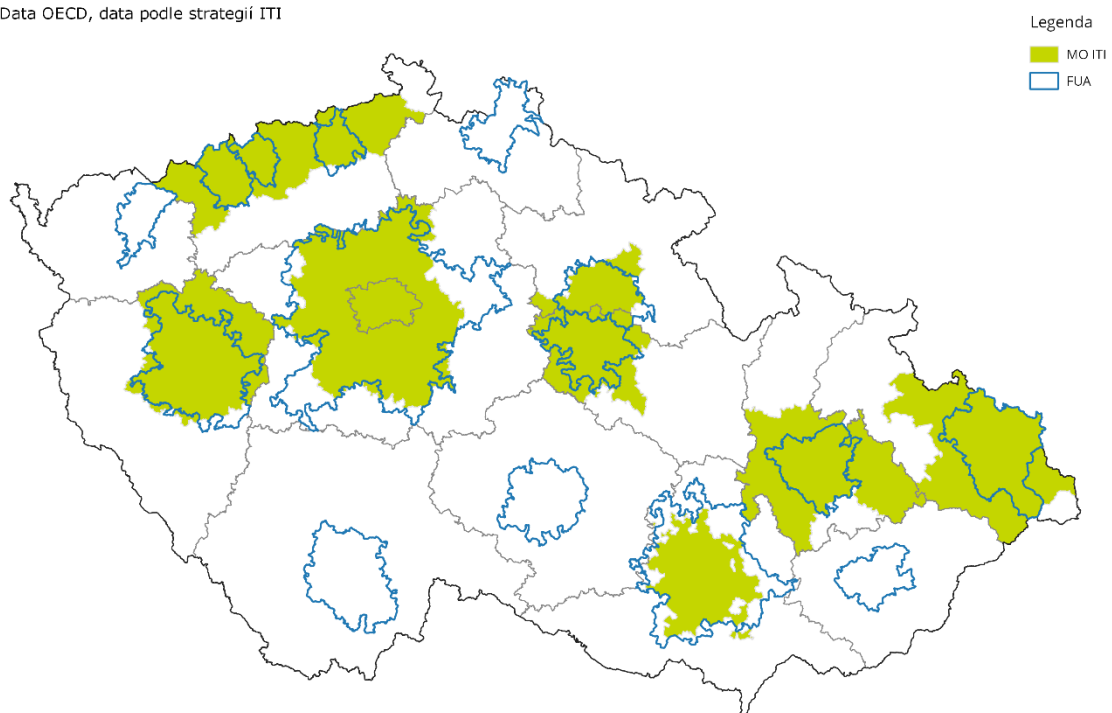


© 2019 Deloitte Česká republika

Vymezení FUA a MO ITI

Vymezení Functional urban areas (FUA) a Metropolitních oblastí pro integrované teritoriální investice (MO ITI)

Data OECD, data podle strategií ITI



© 2019 Deloitte Česká republika

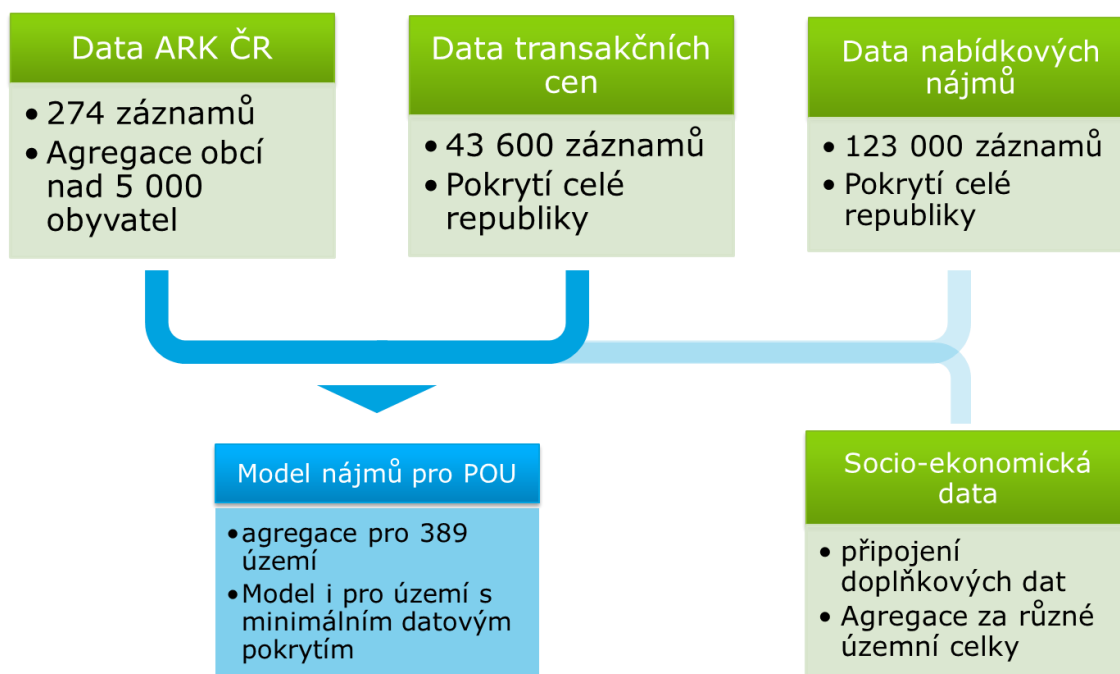
2. Příprava modelu tržního nájemného

2.1. Koncept modelu a predikce

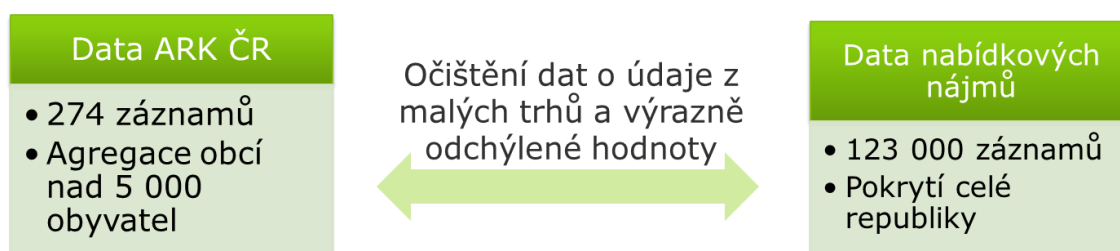
Model nájmu pro území jednotlivých POU je sestaven zejména na základě dvou datových sad: výše tržních nájmu podle ARK ČR pro 274 obcí nad 5000 obyvatel agregovaných z jednoletého období mezi pololetím 2017 a 2018 a z dat o transakčních tržních cenách bytů podle Katastrálního úřadu pro přibližně 43,5 tisíc transakcí po celé České republice ve stejném období.

Pro vysvětlení rozdílného vztahu mezi cenou nemovitostí za metr čtvereční a nájem za metr čtvereční napříč republikou, tedy vysvětlení rozdílné návratnosti investice, jsou použita doplňková socio-ekonomická data z veřejných zdrojů.

Výsledná predikce výše nájmu a její distribuce je porovnána se záznamy o výši nabídkových nájmu podle realitních portálů, opět za stejné jednoleté sledované období. Srovnání s daty realitních portálů je provedeno pouze pro ta území, kde mají realitní portály dostatečné datové pokrytí.

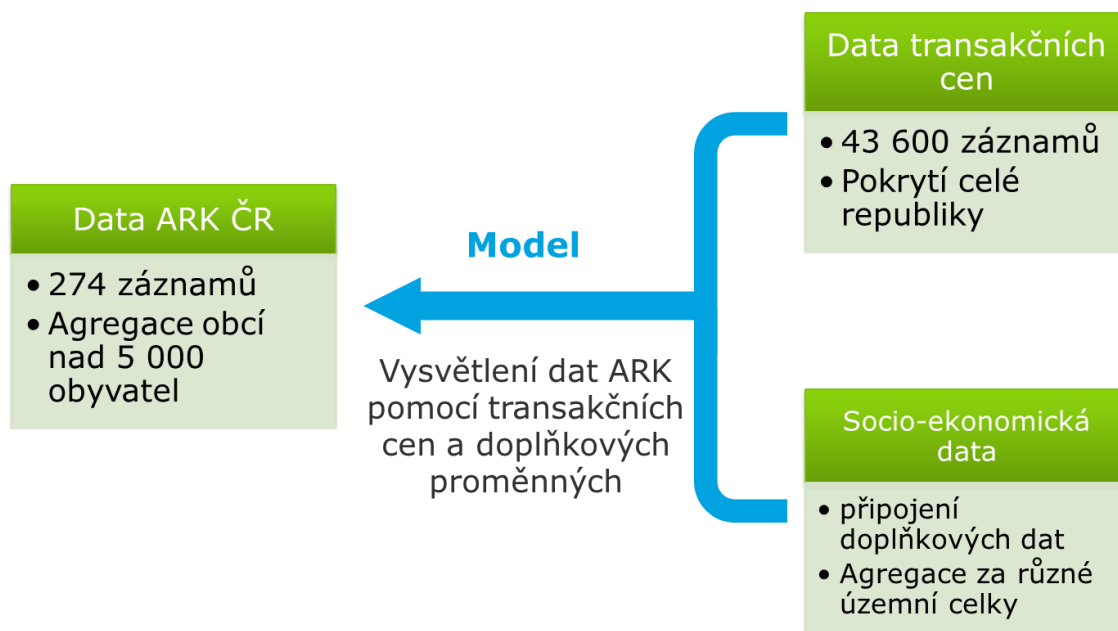


V prvním kroku bylo provedeno očištění vstupních dat o tržních nájmech dle ARK. Pro model byly použity pouze záznamy z obcí, kde bylo během roku inzerováno více než 20 nabídek bytů, což může být považováno za určitou hranici funkčního trhu. Dále byly odebrány záznamy, kde byl rozdíl mezi daty ARK ČR a daty dle realitních portálů větší než 2 standardní odchylky.




Následně byla vytvořena datová sada pro tvorbu modelu. Ta se skládá z obcí, které zůstaly v databázi ARK ČR po jejím očištění, tedy ze 197 obcí. Pro tyto obce byly za jejich administrativní území vypočteny průměrné transakční ceny bytů a dále byly pro tyto obce z dostupných dat


vypočteny další socio-ekonomické proměnné. Tato datová sada byla použita pro lineární regresní analýzu.



Výsledky lineární regresní analýzy, která udává vliv každé ze sledovaných proměnných na výslednou výši tržního nájmu, byly následně promítnuty na území všech 389 POU bez vojenských újezdů a tím byla vytvořena predikce lokální výše tržního nájemného.



Pro možnost srovnání a kontroly výsledků modelu jsou výsledné hodnoty predikce výše nájmu i jejich distribuce srovnány s nabídkovými výšemi nájmu podle realitních portálů. Toto srovnání je provedeno pouze pro území, kde realitní portály evidují více než 20 záznamů ve sledovaném období.



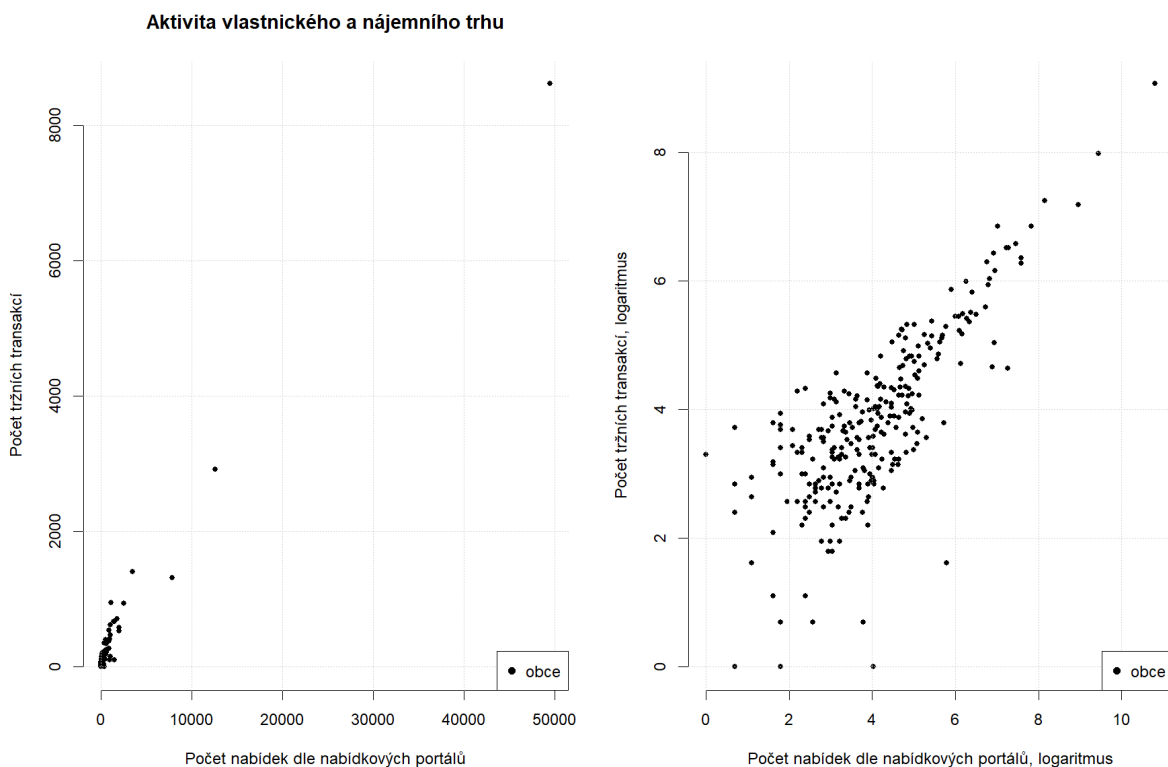
2.2. Propojení datových zdrojů

Při propojování dat o tržních výších nájmného podle ARK ČR, nabídkových výších nájmného bytů z realitních portálů a transakčních cen bytů zůstalo v databázi 267 měst z původních 274. Ztráta 7 pozorování je dána tím, že v připojovaných datových sadách informace za tato města nebyly dostupné a proto byla vyřazena.

V případě připojených datových sad o výších nabídkových cen nájmnů a transakčních cen bytů máme k dispozici neagregovaná data, díky kterým můžeme srovnávat aktivitu na obou trzích – nájmnickém a vlastnickém. V grafu níže je tento vztah zobrazen, kdy na vodorovné ose je počet nabízených bytů a na svislé ose je počet transakcí. Jak je z grafu patrné, mezi oběma proměnnými je těsný vztah. Korelace mezi oběma proměnnými je velmi vysoká: 0,982. Korelace mezi zlogaritmovanými proměnnými je s hodnotou 0,779 sice nižší, ale stále velmi vysoká.

Na základě dat je tedy možné potvrdit, že zde i na úrovni aktivity trhů existuje velmi silná vazba mezi trhem nájmného a vlastnického bydlení.

Vztah trhů vlastnického a nájmného bydlení z hlediska jejich aktivity



2.3. Výběr dat pro základní model vztahu transakcí a nájmnů

Jelikož u dat o tržních výších nájmnů od ARK ČR nemůžeme ověřit, na jakém vzorku byla sestavena a do jaké míry jsou reprezentativní, provedli jsme u této datové sady vícekriteriální hodnocení, podle kterého jsme některé obce z dat vyřadili, aby byla ponechána pouze reprezentativní data.

Z dat byly vyřazeny jednak obce, ve kterých ve sledovaném ročním období nebylo inzerováno více než 20 bytů, což svědčí o velmi malém trhu, kde je pak odhad tržní ceny obtížný a může značně kolísat, a dále byly vyřazeny obce, u kterých se významně rozcházejí údaje o výši nájmného podle databáze ARK ČR a podle nabídkových cen na realitních portálech. V tomto případě byly odebrány ty obce, kde data podle ARK ČR nespádají do intervalu mezi plus minus dvě standardní odchylky od průměru podle dat nabídek z realitních portálů. V tomto posouzení je také zohledněno to, že

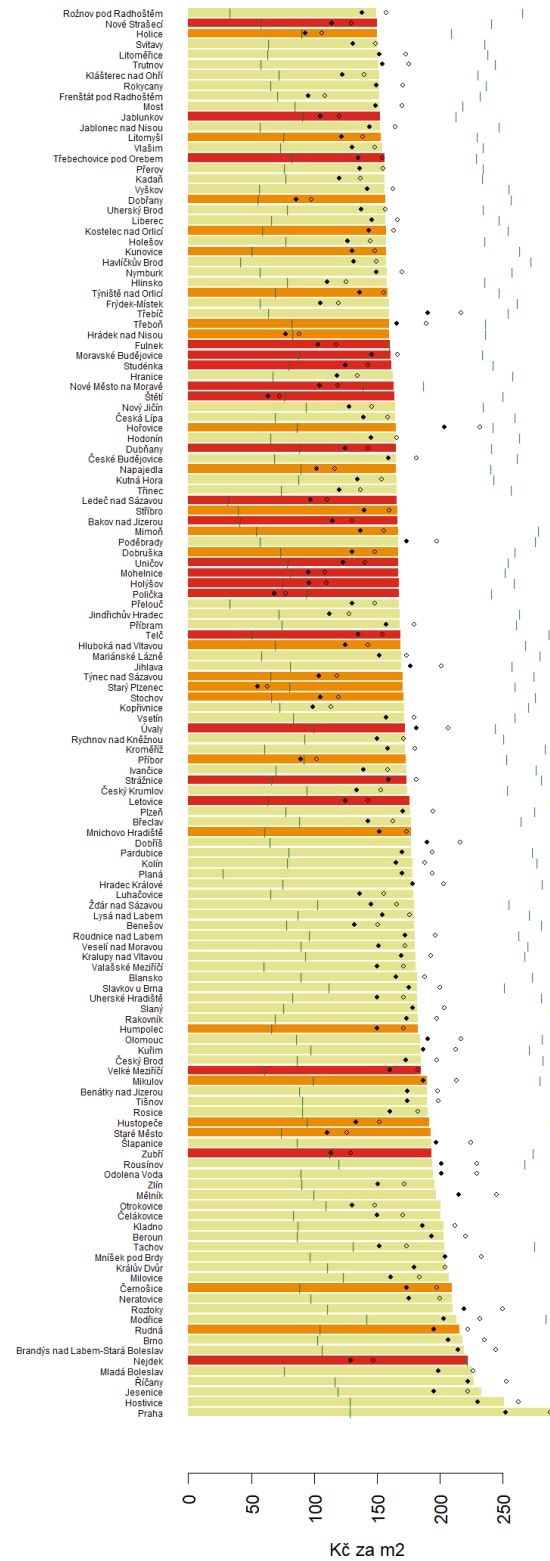

nabídkové ceny jsou v průměru o něco vyšší než výsledné uzavřené výše nájmu, konkrétně zhruba o 14 %, a proto jsou tržní nájmy podle ARK ČR upraveny na cenovou hladinu nabídkových nájmu.

V grafu na následující stránce je zobrazen vztah mezi nabídkovými výšemi nájmu podle realitních serverů a tržními nájmy dle ARK ČR. Barevnými sloupci jsou označeny průměrné nabídkové nájmy pro každou obec a svislé zelené značky ukazují rozptyl jedné standardní odchylky od průměrné výše nabídky nájmu. Sloupce označené červenou barvou zvýrazňují obce, u kterých bylo zaznamenáno 20 a méně nabídek nájmu a oranžově jsou označeny ty, ve kterých bylo inzerováno 50 a méně nabídek nájmu.

Černými kulatými značkami jsou uvedeny výše tržních nájmu podle ARK ČR, přičemž vyplněné značky ukazují tržní nájem v originálních datech a značky s černým obrysem ukazují nájmy zvýšené o 14 % na cenovou hladinu inzerovaných nájmu. Z hlediska výběru reprezentativních dat jsou použity právě tyto upravené výše nájmu znázorněné černým nevyplněným kruhem.

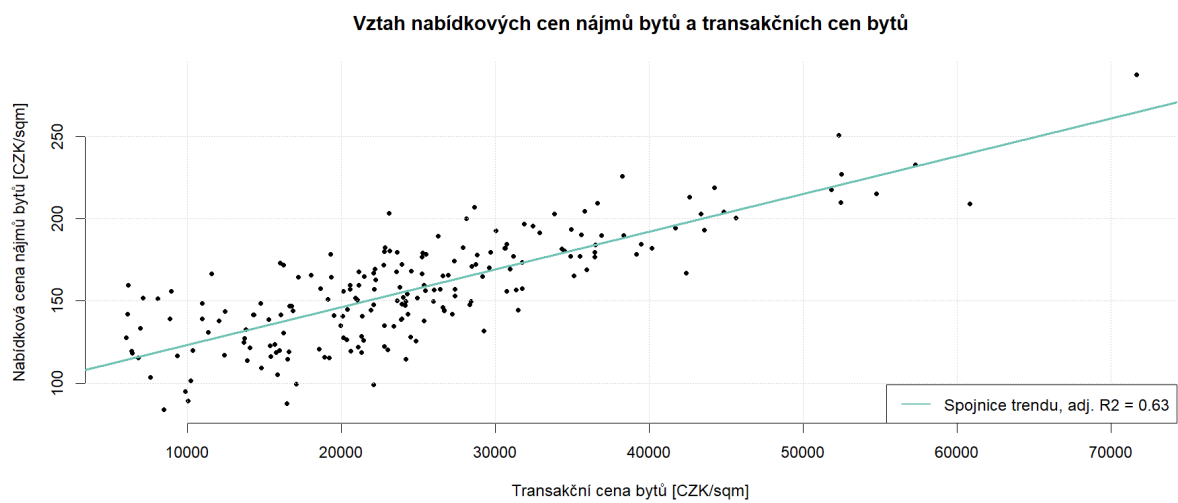


Po uvedeném očištění databáze se snížil rozptyl v datech mezi proměnnými počet nabídek a počet transakcí. Korelace mezi oběma proměnnými nepatrně vzrostla z 0,982 na 0,983, výrazněji pak narostla u proměnných v logaritmické podobě z 0,779 na 0,817. Zároveň se snížil rozdíl mezi průměry cen nabídek a průměry cen uzavřených nájmu, a to z 14 % na 12,3 %.

Vztah nabídkového nájenného a nájenného dle ARK



2.4. Vzájemné závislosti sledovaných proměnných

Graf závislosti hlavních sledovaných proměnných



Podle výše uvedených grafů je patrné, že nejtěsnější vztah je mezi nabídkovými cenami nájmu podle realitních portálů a transakční cenou nemovitostí. Tento vztah vysvětluje 63 % variace

v datech. Dokonce i vztah mezi nabídkovými cenami nájmu podle realitních portálů a údaji o výších uzavřených nájmu podle ARK ČR vysvětluje o jedno procento méně variace v datech.

Toto může mimo jiné znamenat, že data od ARK ČR nemusí být zcela reprezentativní za celé město, za které jsou data agregována. Pro budoucí použití těchto dat by tedy bylo vhodné v datech uvést, z kolika záznamů je údaj agregován, kolik realitních kanceláří se v daném městě na reportování dat podílí a jestli se tyto kanceláře zaměřují na specifický segment trhu, například z hlediska lokality (centrum města, okraj, sídliště) nebo z hlediska typologie nemovitostí (novostavby, činžovní domy, panelové domy).

2.5. Statistický model

Model nájmu pro území obcí s pověřeným úřadem (POU) je založen na cross-section datech (data za jedno období v čase pro jednotlivé územní celky). Modelovací dataset tvoří 197 pozorování obcí nad 5000 obyvatel, který je vytvořen na základě dat o realizovaných nájmech poskytnutých ARK ČR. Původní dataset čítal 267 záznamů, ale byla z něj odebrána města s méně než 20 nabízenými inzeráty bytů za rok, což snížilo počet pozorování na 199. Následně byla odbrána 2 pozorování měst, u kterých se údaje o průměrné ceně nájmeného lišily o více než 2 standardní odchylky na základě dat z realitních portálů.

Model byl zpracován v souladu s představenou metodikou a v obecném zápisu je uveden níže. Vysvětlovanou proměnnou jsou nájmy na metr čtvereční, vysvětlující proměnnou je transakční cena za metr čtvereční a vektor strukturálních proměnných Z_n . Koeficienty α, β, γ_n jsou odhadnuty regresní analýzou a ε je residuum modelu.

$$najem_{sqm} = \alpha + \beta \text{cena}_{sqm} + \gamma_n Z_n + \varepsilon$$

Model byl zpracován lineární regresní analýzou (OLS), na základě předpokladu heteroskedasticity jsou uvedeny robustní standardní odchylky odhadnutých koeficientů. Při výběru výsledné specifikace modelu byly testovány všechny proměnné uvedené v přehledu doplňovaných datových zdrojů a zároveň byly testovány variantní formy těchto proměnných, například logaritmické, nebo interakce s jinými proměnnými. Výsledný vybraný model je dále označován jako model M1g.

Z výsledné specifikace byly vypuštěny některé proměnné, které vzájemně korelovaly – například podíl obyvatel s nejvyšším a nejnižším vzděláním – a ponechány byly ty s větší statistickou významností. Přestože u některých proměnných není splněna podmínka statistické významnosti, tak byly tyto proměnné v modelu ponechány, protože mají ekonomický význam.

Při interpretaci modelu je třeba mít na zřeteli, že je vysvětlován vztah mezi výší nájmeného (závislá proměnná), výší tržních cen nemovitostí a dalšími strukturálními proměnnými. Tato modelová specifikace tedy popisuje regionální specifika ve výnosnosti vložené investice. V případě pozitivních znamének u strukturálních proměnných daná proměnná relativně zvyšuje výnos, zatímco negativní znaménka relativní výnos snižují.

Směr odhadnutých koeficientů odpovídá předpokladům. Negativní koeficienty relativně snižující výnos investice jsou spojené s mírou nezaměstnanosti, podílem inzerovaného počtu bytů na velikosti trhu bydlení, vzdáleností k nejbližší dálnici a silnici pro motorová vozidla, počtu vysokoškolských studentů a vzdáleností k nejbližšímu aglomeračnímu jádru FUA. Pozitivní znaménko mají koeficienty transakční ceny bytů, mediánové mzdy, podílu obyvatel se základním a nedokončeným základním vzděláním, velikosti obce a tempa růstu bytových jednotek.

Dle metodiky bylo předpokládáno, že za relativně přesný bude považován model, který dosáhne upraveného koeficientu determinace (adj. R2) 0.75. Výsledná modelová specifikace dosahuje upraveného koeficientu determinace 0.670 a koeficientu determinace 0.712, tudíž se blíží předpokládaným hodnotám pro přesný model. Vůči výslednému zvolenému modelu M1g byl alternativně zvažován model M1c, který dosahuje upraveného koeficientu determinace 0.801 a

koeficientu determinace 0.828. Diskuze ohledně výběru finální modelové specifikace včetně alternativní modelové specifikace M1c je uvedena v kapitole Komentář.

Model M1g

Vysvětlovaná proměnná: Tržní výše nájmu podle ARK

Residual standard error: 20.01 on 171 degrees of freedom, robust SE

Multiple R-squared: 0.7122, Adjusted R-squared: 0.6701

F-statistic: 16.93 on 25 and 171 DF, p-value: < 2.2e-16

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	-1.7783e+02	5.9731e+01	-2.9773	0.0033305	**
mean	1.8476e-03	3.0902e-04	5.9788	1.276e-08	***
median_wage	5.1113e-03	1.7581e-03	2.9073	0.0041294	**
unemployment_share	-5.3169e-01	1.2564e+00	-0.4232	0.6726997	
primary_share	2.3900e+02	6.9470e+01	3.4403	0.0007301	***
OBEC_LOG_POP	1.0987e+01	3.7452e+00	2.9335	0.0038111	**
ap_gwth_rate	1.0227e+03	9.2508e+02	1.1056	0.2704742	
rent_ap_share	-5.8664e+01	3.1858e+02	-0.1841	0.8541210	
HubDist	-1.9854e-01	1.4816e-01	-1.3400	0.1820165	
log_students	-1.7184e+00	9.2238e-01	-1.8630	0.0641712	.
log_FUA_CENTER	-3.5078e+00	2.2317e+00	-1.5718	0.1178567	
FUA Brno	1.2357e+01	8.4771e+00	1.4576	0.1467734	
FUA České Budějovice	-1.7575e+01	6.5313e+00	-2.6908	0.0078346	**
FUA Hradec Králové	5.9082e+00	6.8264e+00	0.8655	0.3879815	
FUA Chomutov	-1.0221e+01	1.0794e+01	-0.9469	0.3450176	
FUA Jihlava	1.6223e+01	6.5806e+00	2.4652	0.0146800	*
FUA Karlovy Vary	-1.4590e+01	8.1912e+00	-1.7811	0.0766656	.
FUA Liberec	-4.4200e+01	8.5219e+00	-5.1866	6.002e-07	***
FUA Most	9.7510e+00	7.9744e+00	1.2228	0.2230928	
FUA Olomouc	1.8435e+01	7.9826e+00	2.3094	0.0221161	*
FUA Ostrava	-3.5467e+01	6.0151e+00	-5.8963	1.936e-08	***
FUA Pardubice	-2.2560e+00	3.8266e+00	-0.5896	0.5562673	
FUA Plzeň	-2.6948e+01	1.4673e+01	-1.8366	0.0679988	.
FUA Praha	-5.2369e+00	9.5175e+00	-0.5502	0.5828760	
FUA Ústí nad Labem	-9.7549e+00	7.8628e+00	-1.2406	0.2164387	
FUA Zlín	-1.8189e+01	7.6821e+00	-2.3677	0.0190187	*

Signif. codes: '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1

Přehled proměnných v modelu

mean	Průměrná tržní transakční cena bytů za metr čtvereční podle dat Katastrálního úřadu
median_wage	Mediánová mzda modelovaná pro ORP na základě krajských mediánových mezd dle dat MPSV a struktury dosaženého vzdělání obyvatel v území ORP dle dat ČSÚ – SLDB 2011
unemployment_share	Míra nezaměstnanosti podle ORP dle dat ČSÚ
primary_share	Podíl obyvatel se základním vzděláním a neodkončeným základním vzděláním podle ORP dle dat ČSÚ – SLDB 2011
OBEC_LOG_POP	Logaritmus počtu obyvatel obce dle dat ČSÚ
ap_gwth_rate	Tempo růstu dokončených bytů vůči počtu bytů v ORP dle dat ČSÚ

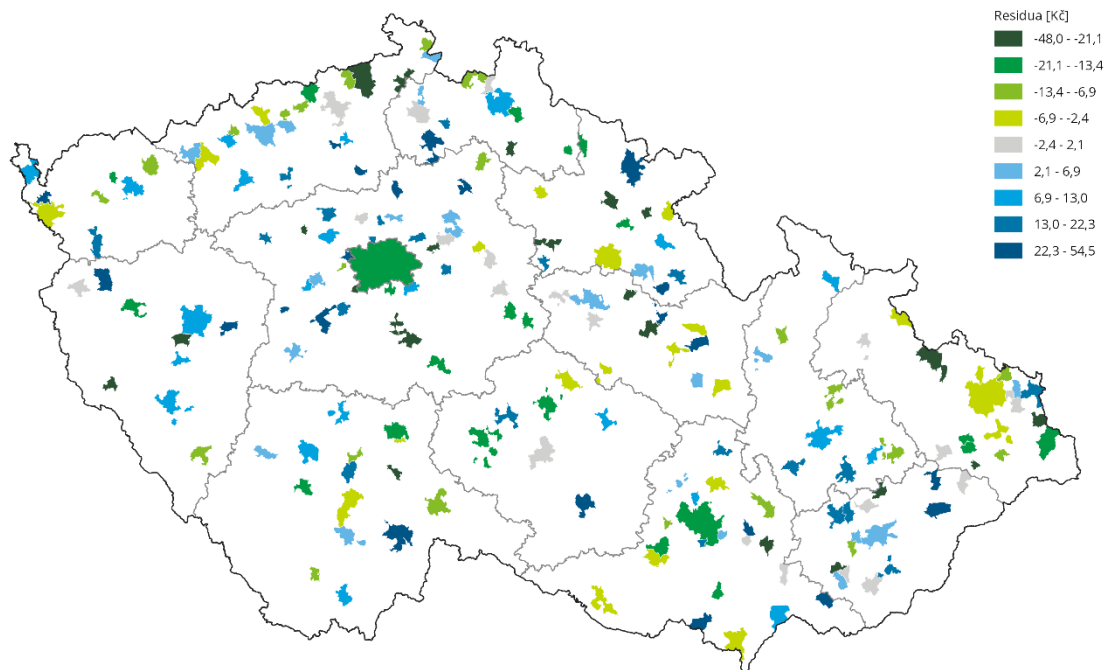
rent_ap_share	Podíl počtu nabízených bytů na realitních portálech a počtu bytů podle ČSÚ
HubDist	Vzdálenost k nejbližší dálnici nebo silnici pro motorová vozidla dle prostorových dat ČÚZK
log_students	Logaritmus počtu vysokoškolských studentů všech vysokých škol v prezenční formě studia zvýšený o 1 v obci podle dat MŠMT
log_FUA_CENTER	Logaritmus vzdálenosti vzdušnou čarou k centru jádrové obce FUA podle prostorových dat ČÚZK a vlastní definice centra města
FUA Město	Binární (dummy) proměnná pro lokalizaci v jedné z vymezených FUA dle dat OECD (OECD používá pro administrativní hranice geometrii neskladebnou s českými obcemi, pro posouzení lokalizace uvnitř FUA byly použity centroidy obcí)

Analýza residuí modelu M1g je uvedena v příloze. Prostorové rozložení residuí je zobrazeno v mapě níže. Z mapy je patrné, že residua nevykazují žádný výrazný prostorový trend.

Prostorové rozložení residuí modelu M1g

Prostorové rozložení residuí modelu M1g

Záporné hodnoty ukazují území, kde model predikuje vyšší nájem, než je pozorovaný v datech



© 2019 Deloitte Česká republika

3. Výsledky modelu tržního nájemného

3.1. Model na úrovni území obcí s pověřeným úřadem (POU)

V mapové podobě jsou výsledky modelu zobrazeny pro 389 území POU, které pokrývají celou Českou republiku. Celkem je v Česku definováno 393 území POU, ale z toho 4 jsou vojenskými újezdy a ty byly z modelu vyřazeny. V mapě jsou vojenské újezdy označeny černou diagonální šrafou na bílém pozadí.

Výsledky modelu ukazují v souladu s předpoklady, že nejvyšší tržní nájem jsou ve dvou největších městech – Praze a Brně – a dále v krajských městech. Směrem od těchto jádrových aglomerací klesá gradient nájmů směrem do aglomeračního zázemí a k vnitřním periferiím.


Relativně nízké nájem jsou predikovány v Moravsko-slezském kraji, ale i v částech Pardubického, Olomouckého a Jihočeského kraje. Výše nájmů v Ústeckém kraji je s ohledem k lokální ceně nemovitostí naopak relativně vysoká.

V následujících mapách jsou v měřítku POU zobrazeny průměry, mediány a 1., 2. a 3. decil modelované výše tržního nájemného.

Model výše nájmů, průměr POU

Model výše tržních nájmů - průměr POU

Model M1g




© 2019 Deloitte Česká republika

Model výše nájmů, medián POU

Model výše tržních nájmů - medián POU

Model M1g




© 2019 Deloitte Česká republika

Model výše nájmů, 1. decil POU

Model výše tržních nájmů - 1. decil POU

Model M1g




© 2019 Deloitte Česká republika

Model výše nájmů, 2. decil POU

Model výše tržních nájmů - 2. decil POU

Model M1g




© 2019 Deloitte Česká republika

Model výše nájmů, 3. decil POU

Model výše tržních nájmů - 3. decil POU

Model M1g



© 2019 Deloitte Česká republika


Výsledek modelu je kromě zobrazení odhadované výše nájemného za metr čtvereční možné zobrazit rovněž návratností investice v konkrétním území. Návratnost investice (Return of Investment – ROI) je měřena jako hrubý součet průměrných ročních nájmu za metr čtvereční dělený průměrnou transakční cenou bytu za metr čtvereční.

V mapě níže je vidět, že návratnost investice je nejnížší ve velkých, zejména krajských městech a jejich zázemí, a naopak vysoká je v hraničních oblastech a vnitřních periferiích. Strukturálně vyšší je také v Ústeckém a Karlovarském kraji.

Návratnost investice podle území

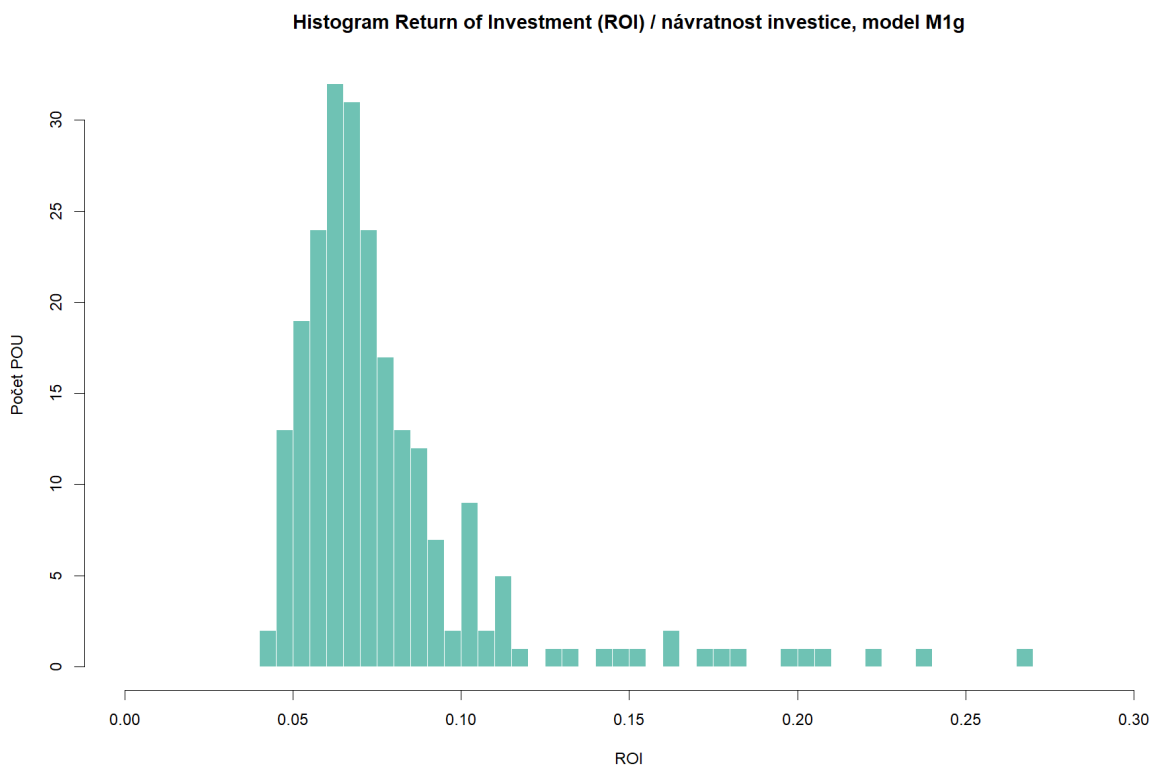
Model Return of Investment (ROI)

Model M1g



© 2019 Deloitte Česká republika

Histogram návratnosti investice podle území POU, model M1G



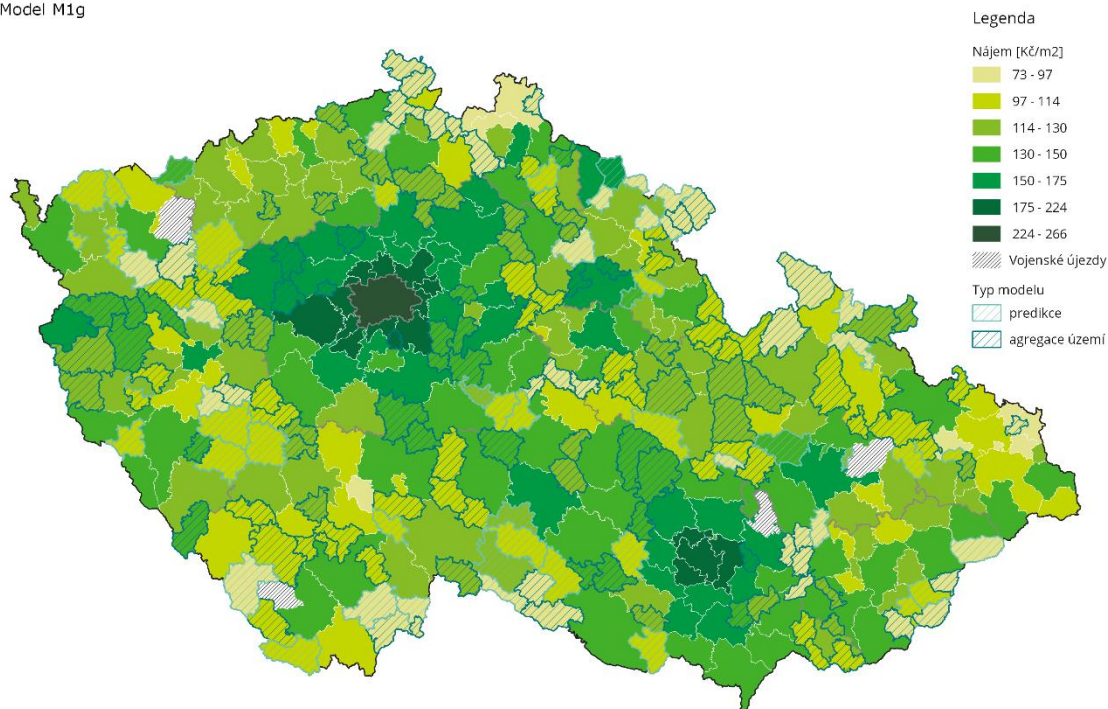
Při interpretaci výsledků je třeba brát v potaz fakt, že některá území mají limitované velikosti trhů a během jednoho sledovaného roku v nich neproběhlo více než 20 transakcí bytů. V těchto případech je pro nedostatek vstupních dat a potřebě slučovat blízká území možnost vyšších odchylek. Území, která musela být pro tvorbu modelu sloučena dohromady vzájemně nebo přiřazena k jinému blízkému území, jsou v mapě níže označena tmavou azurovou šrafovou.

Dále jsou zde světlejší azurovou barvou označena území, u kterých byl splněn požadavek více než 20 transakcí bytů za sledované období, ale kde není možné výsledný model srovnat s daty podle realitních portálů, protože v případě realitních portálů v těchto územích nebylo nabízeno více než 20 bytů během sledovaného období.

Území s nižším datovým pokrytím

Model výše tržních nájmů - průměr POU, území s omezeným počtem záznamů

Model M1g



© 2019 Deloitte Česká republika

3.1. Model na úrovni městských obvodů a městských částí

Model pro úroveň městských obvodů byl sestaven na základě modelovaného ROI (Return of Investment / návratnost investice) pro vnitřně členěná města. Členění na městské obvody a městské části bylo přejato z dat RUIAN.

Podle vypočteného ROI byly z transakčních cen bytů vypočteny ekvivalentní výše nájmů za metr čtvereční bytu a z těchto údajů byly podle příslušnosti k jednotlivým městským obvodům nebo městským částem vypočteny průměr, medián a 1., 2. a 3. decil modelované výše nájmu.

V následujících mapách jsou tyto statistické hodnoty zobrazeny u 8 vnitřně členěných měst pro 69 jejich městských obvodů nebo městských částí, kde bylo ve sledovaném období zaznamenáno více než 20 tržních transakcí bytů.



Výsledky modelu jsou v tabulkové podobě ve verzi v pdf i ve strojově čitelné podobě přílohou této zprávy.

Model výše tržních nájmů - průměr MO a MČ


Model M1g

Legenda


Nájem [Kč/m²]



Praha




Brno



Ostrava



Opava



Pardubice



Plzeň



Ústí nad Labem



Liberec



© 2019 Deloitte Česká republika

Model výše tržních nájmů - medián MO a MČ


Model M1g

Legenda


Nájem [Kč/m²]



Praha




Brno



Ostrava




Opava



Pardubice



Plzeň



Ústí nad Labem



Liberec



© 2019 Deloitte Česká republika

Model výše tržních nájmů - 1. decil MO a MČ


Model M1g

Legenda


Nájem [Kč/m²]



Praha




Brno



Ostrava




Opava



Pardubice



Plzeň



Ústí nad Labem



Liberec



© 2019 Deloitte Česká republika

Model výše tržních nájmů - 2. decil MO a MČ


Model M1g

Legenda


Nájem [Kč/m²]



Praha




Brno



Ostrava



Opava



Pardubice



Plzeň



Ústí nad Labem



Liberec



© 2019 Deloitte Česká republika

Model výše tržních nájmů - 3. decil MO a MČ


Model M1g

Legenda


Nájem [Kč/m²]



Praha




Brno



Ostrava



Opava



Pardubice



Plzeň



Ústí nad Labem



Liberec

© 2019 Deloitte Česká republika

4. Model faktorů ovlivňujících výši tržního nájemného

4.1. Popis modelu

V tomto případě na rozdíl od předešlého modelu jsou použita v modelu mikrodata pro každou jednotlivou transakci, pro kterou nad rámec proměnných uvedených v předchozím modelu známe velikost bytu, datum transakce a dále pro města nad 10 000 obyvatel a okresy Praha-východ, Praha-západ přesné umístění bytu a typ konstrukce budovy (cihlový dům, měšťanský dům v centru města, panelový dům nebo developerská novostavba). Pro ostatní obce známe umístění v podobě centroidu celé obce a neznáme typ konstrukce budovy.

Model je obdobně jako předchozí modely zpracován nad cross-section daty. V tomto případě model využívá jednotlivé záznamy a je zohledněn čas transakce na úrovni měsíce. V období pololetí 2017 až 2018 je předpokládána stabilní změna cenové hladiny na jednotlivých trzích a proto nejsou z důvodu zjednodušení interakce času a území FUA voleny měsíce jako dummy proměnné, ale jako přirozená čísla od 1 do 12, kdy 1 odpovídá červenci 2017, který je 1. měsícem v datech.

Tento model se zaměřuje pouze na území FUA u kterých určuje vliv výše uvedených proměnných na ceny bytů.

Model vysvětluje výši transakčních cen pomocí vektoru proměnných \mathbf{Y}_n , jako jsou dosažené vzdělání, míra nezaměstnanosti, tempo růstu, vzdálenost k infrastruktuře a počet studentů. Dále je v modelu přítomen vektor \mathbf{FUA}_f , který je vektorem dummy proměnných pro jednotlivé FUA. V modelu je dále zahrnuta proměnná *měsíc*, která uvádí pořadí měsíce, kdy byla provedena transakce, od pololetí 2017. Poslední sadou proměnných v modelu je vektor $\mathbf{Y}_n \mathbf{FUA}_f$ interakčních proměnných, kterými jsou měřeny rozdíly mezi jednotlivými FUA.

$$\log \text{cena}_{sqm} = \alpha + \gamma_n \mathbf{Z}_n + \mu_f \mathbf{FUA}_f + \varphi_{fn} \mathbf{FUA}_f \mathbf{Z}_n + \delta \text{měsíc} + \varepsilon$$

V níže uvedených výsledcích modelu je základní kategorií brněnská FUA a interakční proměnné uvádějí rozdíl od odhadů pro tuto základní kategorii.

4.2. Výsledky modelu

Model M2a

Vysvětlovaná proměnná: Transakční cena bytu za metr čtvereční

Residual standard error: 0.3182 on 28148 degrees of freedom, robust SE

Multiple R-squared: 0.8217, Adjusted R-squared: 0.8213

F-statistic: 1965 on 66 and 28148 DF, p-value: < 2.2e-16

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	11.91378951	0.11736802	101.5080	< 2.2e-16	***
growth_rate	0.05415334	0.30716893	0.1763	0.8600609	
unemployment_share	-0.04738820	0.00566941	-8.3586	< 2.2e-16	***
ap_gwth_rate	10.25011381	1.51444794	6.7682	1.329e-11	***
primary_share	-2.60564074	0.42570851	-6.1207	9.439e-10	***
university_share	0.76309240	0.25810456	2.9565	0.0031139	**
log(HubDist)	-0.06962736	0.00490530	-14.1943	< 2.2e-16	***
log(students + 1)	0.01484100	0.00143879	10.3150	< 2.2e-16	***
log(nearest_fua_cen)	-0.04246449	0.00691178	-6.1438	8.166e-10	***
log(Plocha)	-0.21077255	0.01406613	-14.9844	< 2.2e-16	***
MONTH	0.00539322	0.00145964	3.6949	0.0002204	***

České Budějovice:log(nearest_fua_cen)	-0.08567747	0.01694411	-5.0565	4.298e-07	***
Hradec Králové:log(nearest_fua_cen)	-0.05085251	0.01446776	-3.5149	0.0004406	***
Chomutov:log(nearest_fua_cen)	-0.26268520	0.02729569	-9.6237	< 2.2e-16	***
Jihlava:log(nearest_fua_cen)	-0.12905508	0.02172023	-5.9417	2.854e-09	***
Karlovy Vary:log(nearest_fua_cen)	-0.10468970	0.01647971	-6.3526	2.149e-10	***
Liberec:log(nearest_fua_cen)	-0.09967537	0.01767941	-5.6379	1.737e-08	***
Most:log(nearest_fua_cen)	-0.17896694	0.02487504	-7.1946	6.419e-13	***
Olomouc:log(nearest_fua_cen)	-0.05705368	0.01752036	-3.2564	0.0011296	**
Ostrava:log(nearest_fua_cen)	0.02180494	0.00966594	2.2559	0.0240875	*
Pardubice:log(nearest_fua_cen)	0.01996462	0.01297684	1.5385	0.1239422	
Plzeň:log(nearest_fua_cen)	-0.11182573	0.01351922	-8.2716	< 2.2e-16	***
Praha:log(nearest_fua_cen)	-0.16624855	0.00816804	-20.3535	< 2.2e-16	***
Ústí nad Labem:log(nearest_fua_cen)	-0.13031021	0.02450901	-5.3168	1.064e-07	***
Zlín:log(nearest_fua_cen)	-0.02575799	0.01750560	-1.4714	0.1411903	
České Budějovice:log(Plocha)	-0.05377387	0.03200846	-1.6800	0.0929706	.
Hradec Králové:log(Plocha)	-0.06505517	0.03068945	-2.1198	0.0340325	*
Chomutov:log(Plocha)	0.13326581	0.06079480	2.1921	0.0283834	*
Jihlava:log(Plocha)	0.02451077	0.04584724	0.5346	0.5929181	
Karlovy Vary:log(Plocha)	0.14038456	0.05029067	2.7915	0.0052506	**
Liberec:log(Plocha)	-0.10304154	0.04353965	-2.3666	0.0179584	*
Most:log(Plocha)	0.28621791	0.05707006	5.0152	5.330e-07	***
Olomouc:log(Plocha)	-0.03650321	0.03466932	-1.0529	0.2923973	
Ostrava:log(Plocha)	0.19244361	0.02407064	7.9950	1.346e-15	***
Pardubice:log(Plocha)	-0.12168128	0.02882371	-4.2216	2.434e-05	***
Plzeň:log(Plocha)	0.01657636	0.02814510	0.5890	0.5558924	
Praha:log(Plocha)	0.03761245	0.01593933	2.3597	0.0182952	*
Ústí nad Labem:log(Plocha)	0.18082117	0.03920575	4.6121	4.004e-06	***
Zlín:log(Plocha)	0.04345201	0.03980293	1.0917	0.2749838	
České Budějovice:MONTH	-0.00568158	0.00374245	-1.5181	0.1289889	
Hradec Králové:MONTH	-0.00566480	0.00320063	-1.7699	0.0767546	.
Chomutov:MONTH	0.01890765	0.00516227	3.6627	0.0002501	***
Jihlava:MONTH	0.00097617	0.00538931	0.1811	0.8562665	
Karlovy Vary:MONTH	0.00493412	0.00455297	1.0837	0.2784999	
Liberec:MONTH	0.01130212	0.00413491	2.7333	0.0062735	**
Most:MONTH	0.00547885	0.00647176	0.8466	0.3972379	
Olomouc:MONTH	-0.00172566	0.00283914	-0.6078	0.5433182	
Ostrava:MONTH	0.00116055	0.00233328	0.4974	0.6189186	
Pardubice:MONTH	0.00258717	0.00286118	0.9042	0.3658800	
Plzeň:MONTH	-0.00399202	0.00239827	-1.6645	0.0960160	.
Praha:MONTH	0.00329659	0.00162336	2.0307	0.0422921	*
Ústí nad Labem:MONTH	0.01067534	0.00384964	2.7731	0.0055566	**
Zlín:MONTH	-0.00112131	0.00405514	-0.2765	0.7821540	

České Budějovice	-0.03364370	0.13160995	-0.2556	0.7982369	
Hradec Králové	0.11860790	0.12670359	0.9361	0.3492270	
Chomutov	-1.65003426	0.25543932	-6.4596	1.067e-10	***
Jihlava	-0.35155232	0.18874770	-1.8626	0.0625358	.
Karlovy Vary	-0.92845223	0.20164640	-4.6044	4.155e-06	***
Liberec	-0.04349909	0.18011964	-0.2415	0.8091685	
Most	-2.38580344	0.23169765	-10.2971	< 2.2e-16	***
Olomouc	-0.05368450	0.14134331	-0.3798	0.7040846	
Ostrava	-1.37962192	0.09957949	-13.8545	< 2.2e-16	***
Pardubice	0.15989789	0.12222319	1.3082	0.1908009	
Plzeň	-0.22474068	0.11502561	-1.9538	0.0507310	.
Praha	0.30541070	0.06694956	4.5618	5.093e-06	***
Ústí nad Labem	-1.55974067	0.16092650	-9.6923	< 2.2e-16	***
Zlín	-0.37082600	0.15889277	-2.3338	0.0196125	*

Signif. codes: '*' 0.001 '**' 0.01 '*' 0.05 '.' 0.1**

4.3. Interpretace výsledků modelu

Vliv velikosti bytu na cenu za metr čtvereční

U základní kategorie, Brna, v průměru při zvětšení výměry bytu o 10% klesne cena za metr čtvereční o 2,1%. Pokles ceny za metr čtvereční s nárůstem velikosti bytu o 10% je výraznější u Pardubic (3,3%), Liberce (3,1%), Hradce Králové (2,8%) a Českých Budějovic (2,6%). Stejně výsledky jako pro Brno jsou zaznamenány pro Jihlavu, Olomouc, Plzeň a Zlín. Naopak nižší pokles ceny za metr čtvereční při zvětšení velikosti bytu o 10% oproti Brnu je například v Praze (1,8%). V dalších městech, jako je Chomutov, Karlovy Vary, Most, Ostrava a Ústí nad Labem není změna ceny bytu za metr čtvereční při změně velikosti bytu statisticky odlišná od 0.

Vliv vzdálenosti od centra aglomerace na cenu bytů

V případě základní kategorie, Brna, klesne v průměru cena bytu za metr čtvereční o 0,42% při nárůstu vzdálenosti od centra aglomerace o 10%. Vyšší míra poklesu ceny za metr čtvereční se vzdáleností od centra aglomerace je zaznamenána u většiny ostatních FUA. Při nárůstu vzdálenosti od centra aglomerace o 10% v průměru cena bytů za metr čtvereční klesne v Praze o 2%, o 3,1% v Chomutově a 2,2% v Mostě, o 1,7% v Ústí nad Labem a Jihlavě, 1,5% v Karlových Varech a Plzni, 1,3% v Českých Budějovicích, a 0,9% v Hradci Králové. Výsledky pro Zlín a Pardubice se neliší od Brna. U Ostravy je oproti Brnu pokles ceny se vzdáleností s 0,2% zhruba poloviční.

Tempo růstu cen nemovitostí

Přestože cílem této analýzy nebylo identifikovat regionální odlišnosti v tempu růstu bytů, byly tyto proměnné jako kontrolní proměnné zařazeny do modelu. Měsíční tempo růstu cen v Brněnské FUA je 0,54%. Statisticky odlišná tempa růstu cen jsou v Hradci Králové a Plzni, kde ceny ve sledovaném období stagnovaly, výrazně vyšší růst byl v Chomutově a Ústí nad Labem, a to 2,4% a 1,6%. Liberec rostl také vyšším tempem 1,7% a Praha o 0,9%.

Vliv ostatních proměnných

Ostatní proměnné byly vypočteny bez rozdílu pro všechny FUA. Zvýšení míry nezaměstnanosti o jeden procentní bod vede ke snížení cen bytů o 4,7%. Zvýšení tempa výstavby bytů na celkovém počtu bytů o jeden procentní bod by vedlo ke zvýšení cen bytů o 10%. Nárůst podílu osob se základním nebo nedokončeným základním vzděláním o jeden procentní bod by vedl ke snížení cen bytů o 2,6%. Napok zvýšení podílu osob s magisterským nebo doktorským vzděláním o jeden procentní bod by vedl ke zvýšení cen nemovitostí o 0,76%. Dále vyšší vzdálenost od nejbližší dálnice nebo silnice pro motorová vozidla o 10% vede ke snížení ceny bytu o 0,7%. Závěrem 10%

navýšení počtu vysokoškolských studentů v prezenční formě studia na všech typech vysokých škol je asociováno v průměru s o 0,14% nárůstem výše cen bytů za metr čtvereční.

Všechny výše uvedené ostatní proměnné jsou statisticky významné minimálně na 1% hladině statistické významnosti při zohlednění robustních standardních odchylek. Jako statisticky nevýznamná se ukázala proměnná tempa růstu populace obce.

Vliv konstrukce objektu při alternativní specifikaci modelu

Při alterativní specifikaci, kde byla ale použita data pouze pro obce nad 10 000 obyvatel a okresy Praha-východ a Praha-západ (celkem 25 433 pozorování), byl zjišťován i vliv konstrukce domu na cenu bytů. V tomto případě byly základní kategorií cihlové domy. Oproti nim se při zohlednění dalších proměnných, jako je především vzdálenost od centra města, cena panelových domů statisticky neliší. Cena Měšťanských domů je oproti cihlovým domům přibližně o 12% vyšší a cena developerských novostaveb je pak oproti cihlovým domům vyšší o 22,5%.

4.4. Přehled proměnných

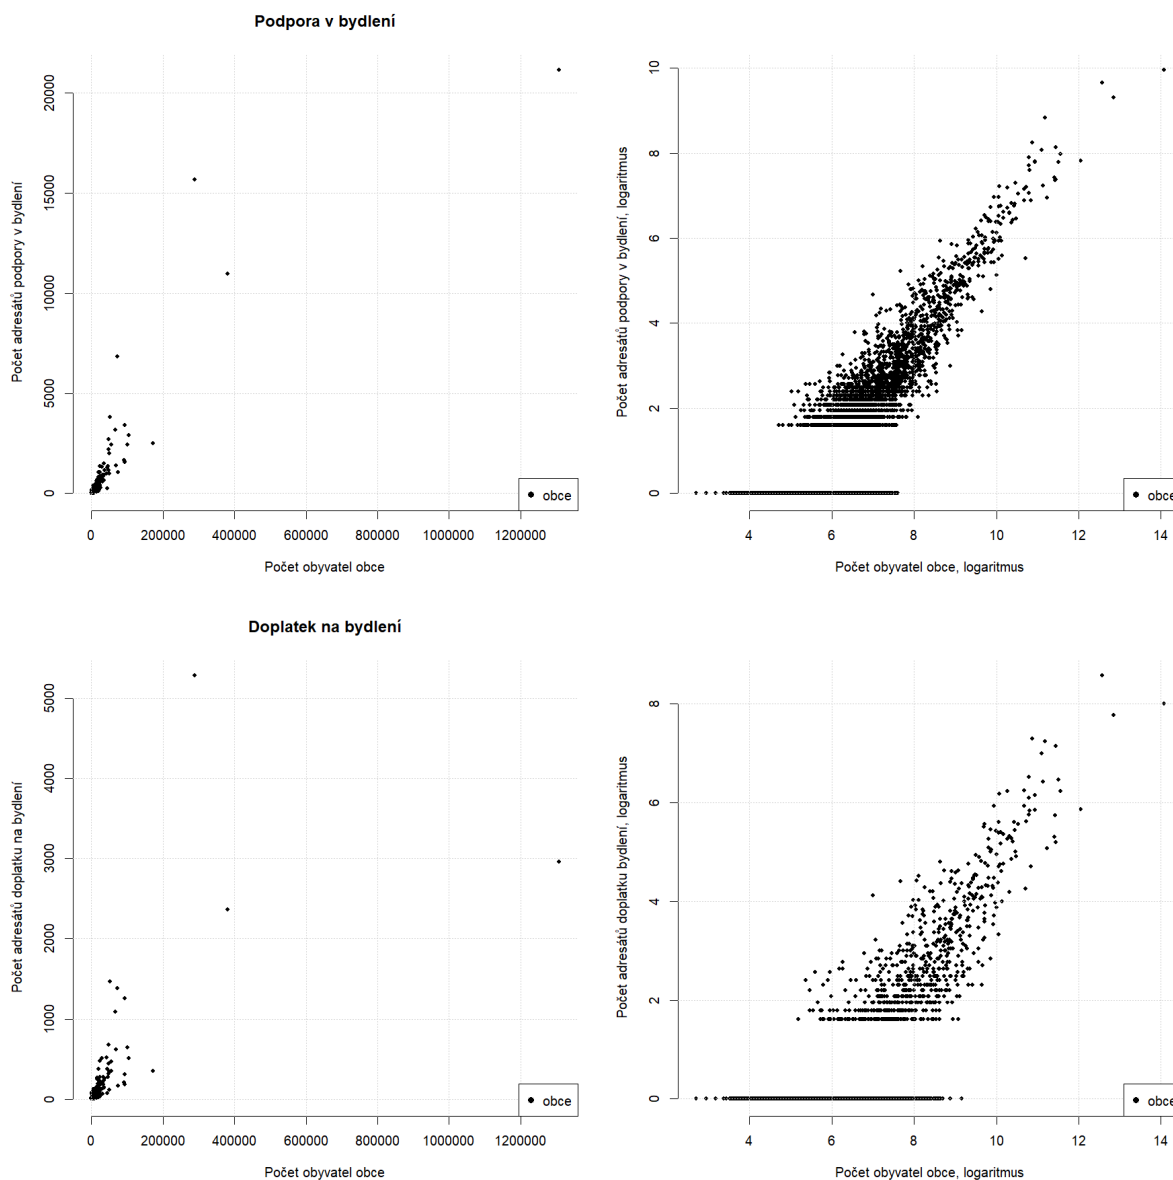
Přehled proměnných v modelu

growth_rate	Tempo růstu počtu obyvatel obce mezi lety 2011 a 2017 dle dat ČSÚ
unemployment_share	Míra nezaměstnanosti podle ORP dle dat ČSÚ. Měřeno v procentech.
ap_gwth_rate	Tempo růstu dokončených bytů vůči počtu bytů v ORP dle dat ČSÚ
primary_share	Podíl obyvatel se základním vzděláním a neodkončeným základním vzděláním podle ORP dle dat ČSÚ – SLDB 2011
university_share	Podíl obyvatel s magisterským nebo doktorským vzděláním podle ORP dle dat ČSÚ – SLDB 2011
log(HubDist)	Logaritmus vzdálenosti k nejbližší dálnici nebo silnici pro motorová vozidla dle prostorových dat ČÚZK
log(students + 1)	Logaritmus počtu vysokoškolských studentů všech vysokých škol v prezenční formě studia zvýšený o 1 v obci podle dat MŠMT
log(nearest_fua_cen)	Logaritmus vzdálenosti vzdušnou čarou k centru jádrové obce FUA podle prostorových dat ČÚZK a vlastní definice centra města
log(Plocha)	Logaritmus plochy bytu
MONTH	Měsíc prodeje bytu
Města	Názvy měst jsou dummy proměnné pro jednotlivé FUA
Interakce	Dvě proměnné oddělené dvojtečkou značí interakční proměnné

5. Komentář

5.1. Komentář k modelu z hlediska rozložení příjemců dávek v oblasti bydlení


Pokud se zaměříme na závislost počtu obyvatel obcí a počtu příjemců dávek podpory v bydlení a doplatku na bydlení, tak u obou dávek, jak je patrné na grafech níže, počet příjemců koreluje s velikostí obce. Konkrétně u dávky podpora v bydlení je korelace velmi vysoká s hodnotou 0.90. U doplatku na bydlení je korelace nižší, 0.69, byť stále relativně vysoká.



V následujících 2 mapách je zobrazen podíl příjemců podpory v bydlení a doplatku na bydlení na celkové populaci pro území POU.

Podíl příjmců podory v bydlení na celkové populaci POU


Data MPSV a MMR ČR



© 2019 Deloitte Česká republika

Podíl příjmců doplatku na bydlení na celkové populaci POU

Data MPSV a MMR ČR



© 2019 Deloitte Česká republika

Z hlediska vztahu vytvořeného modelu k obcím s adresáty dávek je možné konstatovat, že v případě obou dávek bydlí přibližně 90 % adresátů v obcích, pro které je model vytvořen v režimu „predikce a kontrola“, tedy model je založen pouze na transakcích z konkrétních POU a pro tyto POU jsou dostupná taktéž data o nabídkových cenách nájmu podle realitních portálů. V případě doplatku na bydlení je podíl o něco nižší. Vzhledem k tomu, že původní datový zdroj obsahoval kategorii „méně než 5“ příjemců, byla tato kategorie pro možnost součtu nahrazena numerickým průměrem 2.

Přehled počtu adresátů dávek podle pokrytí území modelem

Typ modelu	Medián počtu transakcí v POU	Podpora v bydlení	Doplatek na bydlení
predikce a kontrola	76.0	171728	44835
predikce	35.5	7741	2347
agregace území		17513	5983

5.2. Komentář k dostupným datovým zdrojům a modelu

Data o výších tržního nájemného dle ARK ČR

Datová analýza ukázala, že data o výši nájemného se v závislosti na zdroji liší a z dat samotných není možné jednoduše konstatovat, která data jsou spolehlivější. Na příkladu vztahu mezi výšemi nájmu a transakčními cenami bytů se ale ukázalo, že silnější vztah je mezi nabídkovými cenami bytů podle realitních portálů a transakčními cenami bytů, než mezi nájmy podle ARK ČR a transakčními cenami bytů. Silnější vztah je překvapivě mezi transakčními cenami bytů a nájmy podle realitních portálů, než mezi nájmy podle realitních portálů a nájmy podle ARK ČR.

Dále zohlednění vztahu mezi daty o nájmech podle ARK ČR a podle realitních portálů v statistické analýze, které výrazně zvýšilo prediktivní schopnost modelu a které je komentováno v následující části, naznačuje, že data podle realitních portálů mohou lépe odpovídat skutečnému stavu na nájemním trhu bydlení.

Výsledný model tržních nájmu

Zejména v územích s nízkou cenovou hladinou transakčních cen nemovitostí a malou aktivitou trhu s malým počtem transakcí může model predikovat nerealisticky nízké výše nájmu, zejména ve spodní části distribuce – 1. a 2. decilu. Při malém počtu záznamů mohou být například ve vzorku nadproporčně zastoupeny byty ve velmi špatném stav, které nejsou momentálně způsobilé k pronajímání, ale mohou být předmětem prodeje. Proto v případech, kdy jsou predikované hodnoty nižší než 40 – 50 Kč za metr čtvereční, by měly být tyto výsledky srovnány s dalšími údaji o místním trhu nájemného bydlení.

Výsledky modelu pro městské obvody a městské části

Podle výsledků modelu pro městské obvody a městské části je třeba konstatovat, že zejména u velkých měst se napříč územím města mění ROI (Return of Investment / návratnost investice). To prakticky znamená, že vztah mezi cenou bytu za metr čtvereční a odpovídající výší nájemného za metr čtvereční není v rámci města shodný.

Toto je patrné zejména u Prahy 1, kde by podle modelu měl být průměrný nájem přibližně 500 Kč za metr čtvereční, ale podle upravených dat z nabídkových portálů by výše nájmu měla být mírně nad 300 Kč za metr čtvereční. U dalších centrálních městských částí v Praze a Brně lze tento jev sledovat taktéž, byť v menší míře.

Při použití dat ARK ČR ve stávající agregované podobě za města jako celek ale není možné této situaci předejít, protože pokud máme k dispozici pouze data o nájmu za celé město, pak můžeme ROI odhadnout rovněž jen pro celé město, přestože provedená analýza ukazuje, že ROI je ve středech a atraktivních lokalitách Prahy a Brna nižší než na jejich periferiích.

6. Návrh možného následného postupu

6.1. Možnosti rozšíření použitých dat o cenách nemovitostí – použití dat z více let

Model představený v této analýze vychází z dat o uzavřených nájmem podle Asociace realitních kanceláří ČR za období jednoho roku od pololetí 2017 do pololetí 2018. Z tohoto důvodu byla pro modelování výše tržního nájemného použita data o transakčních cenách nemovitostí a data o inzerovaných výších nájmu za stejné, tedy jednoleté, období.

Při úpravě modelu by ale bylo možné použít data o transakčních cenách bytů a inzerovaných výších nájmu již od roku 2014, čímž by se výrazně zvýšilo datové pokrytí celé republiky. V takovém případě by se opět vypočetl vztah mezi výší tržního nájemného a transakčními cenami nemovitostí za stejné sledované období pro obce, za které jsou dostupná data ARK ČR, ale následně by se model aplikoval na časově upravené záznamy o transakčních cenách nemovitostí zaznamenaných od roku 2014 do současnosti.

Díky většímu časovému období by se zvýšilo datové pokrytí zejména v oblastech s méně aktivním trhem nemovitostí, kde v současném modelu bylo třeba tato území agregovat do územních klastrů.

Zohlednění starších dat by vyžadovalo úpravu historických transakcí na cenovou hladinu shodnou s daty, která v modelu figurují jako vysvětlovaná proměnná. V tomto případě u dat ARK ČR použitých v této analýze by to byl střed sledovaného období, tedy přelom let 2017 a 2018. Úprava dat v čase ale vyžaduje rozdělení území na jednotky, které jsou integrovaným trhem bydlení a v rámci kterých dochází ke shodné změně cen nemovitostí. I na základě modelu M2a v této analýze se ukázalo, že tempo růstu cen nemovitostí ve sledovaném jednoletém období se mezi jednotlivými územími FUA měnilo.

Území integrovaných trhů bydlení by mohla být vymezena tak, že pro velké aglomerace by bylo využito členění na FUA a území mimo FUA by bylo rozděleno například podle okresů. Alternativně by mohla být replikována metodika OECD pro vymezení FUA s jinými parametry. Území FUA jsou vymezena pro města překračující určitý počet obyvatel a do jejich aglomeračních zázemí spadají souvislá území, odkud do centrálního města nebo měst dojíždí určitý podíl obyvatel jednotlivých obcí.

Pro potřebu vymezení území s jednotným trhem bydlení by jako aglomerační jádra mohla být zvolena města s 10 až 15 tisíci obyvateli a jako hranice pro příslušnost obce do aglomeračního území podíl dojíždějících mezi 5 až 15 procenty obyvatel obce. Zde by záleželo na způsobu výpočtu, jestli by byli zohledňováni výhradně dojíždějící za prací, nebo i dojíždějící do škol a dále jestli by byla uvažována celková populace obce, nebo jen podíl z vyjíždějících.

Po vymezení aglomeračních oblastí by zbylá území nepříslušící do aglomeračních zázemí byla rozdělena podle okresů. Vzniklé okresy bez aglomeračních zázemí by byly případně sloučeny do větších celků a dohromady by tvořily periferní oblasti s předpokládanou konzistentní změnou cenové hladiny nemovitostí určených pro bydlení.

Pro sestavní území s předpokládaným stejným vývojem cen bydlení ale může být také využito existující územní členění dle zadání MMR ČR či MPSV ČR.

Alternativním postupem by mohl být využití samotných dat o cenách nemovitostí a vývoj algoritmu na principu shlukové analýzy, který by sdružoval územní jednotky do souvislých území takovým způsobem, aby se minimalizovaly odchylky v tempech růstu cen nemovitostí uvnitř těchto skupin.

6.2. Rozšíření datové základny o výších tržních nájmu – neagregovaná data ARK ČR

Zpracovaná analýza a model tržní výše nájemného je vytvořen nad daty o výších uzavřených nájmu podle dat ARK ČR sestavených jako průměr za metr čtvereční za obce nad 5000 obyvatel. V průběhu zpracování analýzy se potvrdily předpoklady uvedené ve zpracované Metodice, že bez

znalosti původních neagregovaných dat o uzavřených výších nájmu není možné posoudit, jestli průměr za obec je dostatečně reprezentativní. Výše uvedené nemá za cíl nijak snižovat validitu těchto dat, ale poukazuje na fakt, že na základě těchto dat jsou sestavené modely méně přesné, než s využitím jiných datových zdrojů.

Pro další analytickou práci by bylo vhodné sestavit neagregovanou databázi uzavřených nájemních smluv včetně stavu objektu, jeho vybavení, přesného umístění, data uzavření smlouvy a realitní kanceláře, která smlouvu uzavřela.

Na základě znalosti počtu uzavřených nájemních smluv by bylo možné identifikovat málo aktivní trhy, kde kvůli malému počtu uzavřených smluv mohou být průměrné hodnoty zkresleny směrem k extrémním hodnotám. Tato území s malým počtem uzavřených smluv by měla být ošetřena tak, aby neovlivňovala výsledky provedené analýzy, například sloučením s jinými územími nebo vyřazením z analýzy.

Díky znalosti údaje o datu uzavření transakce by bylo možné výsledek očistit o vliv růstu cen v průběhu sledovaného období. Podobný přístup by mohl být zvolen i pro vybavení a stav objektu.

Umístění bytu je důležité ze dvou důvodů: předně na základě znalosti přesného umístění objektu je možné vypočítat cenové hladiny nájemného pro podrobnější územní členění například u velkých měst, ale také umožňuje vyhodnotit reprezentativnost vzorku uzavřených nájemních smluv za územní celek. Například pokud by pro určité město data dodávala pouze jedna realitní kancelář specializující se na byty v panelových domech na sídlišťích, pak by výsledná agregovaná cena byla pravděpodobně zkreslena pro dané město směrem dolů. Z obdobných důvodů by bylo vhodné u každého uzavřeného nájmu identifikovat realitní kancelář, protože zastoupení většího počtu realitních kanceláří pro určitý územní celek by svědčilo o pravděpodobně vyšší reprezentativnosti dat.

Pokud by byla výše zmíněná individuální neagregovaná data získána, pak by nebylo třeba tvořit pro stanovení obvyklé výše tržního nájemného statistický model nad transakčními cenami nemovitostí, ale bylo by možné využít pouze data o výších uzavřených nájmu, kde by se pouze pomocí modelu identifikoval vliv charakteristiky bytu, jako je plocha, stav objektu a vybavení, na výslednou cenu a na základě toho by byla stanovena tržní výše nájemného za metr čtvereční pro standardní byt.

V této variantě by modelování výše nájemného bylo využito pouze pro ta území, kde by byl nedostatek dat o uzavřených výších nájemného.

Na základě jednání s generálním sekretářem ARK ČR panem Borůvkou je ARK ČR připravena dále jednat s MMR o sběru a případném prodeji podrobnějších dat o výších uzavřených tržních nájmu. Podmínky dalšího dodání dat by bylo třeba vyjednat podle možností ARK ČR i MMR a i dle možností implementace těchto podrobnějších dat do představeného modelu tržního nájemného.

6.3. Úprava koncepce analýzy a modelu – modelování nad daty realitních portálů

Otázkou nadále zůstává, do jaké míry mohou být data o tržní výši nájemného podle ARK ČR považována za dostatečně reprezentativní pro jednotlivé územní trhy. Reprezentativnost dat ARK ČR by mohla být posouzena při analýze neagregovaných dat o uzavřených nájemních smlouvách, která momentálně nejsou k dispozici.

V této analýze byla použita data ARK ČR agregovaná za celá města. V rámci analýzy dat bylo v sadě modelů M0 testováno, do jaké míry se vzájemně vysvětlují data ARK ČR a uzavřených výších nájmu, data o nájmech podle internetové inzerce a data o transakčních cenách nemovitostí. Tato analýza ukázala, že mezi daty z internetové inzerce a transakčními cenami nemovitostí je těsnější vazba než mezi daty podle ARK ČR a transakčními cenami. Navíc data o nájmech podle realitních serverů vysvětlují ceny nemovitostí lépe, než data o nájmech podle realitních serverů vysvětlují data o nájmech podle ARK ČR.

Tyto výsledky nasvědčují tomu, že stávající datová sada od ARK ČR je pro provádění modelu výše nájmu méně vhodná, než data o nabídkových výších nájmu z realitních serverů. Výhoda dat z realitních portálů je jejich decentralizovaný charakter, který umožňuje zachytit nabízené nemovitosti jak skrze realitní kanceláře, tak nabídky bez zprostředkování realitními kancelářemi. Díky tomu data z realitních portálů pokrývají větší část trhu nájemního bydlení a tím jsou reprezentativnější.

Nevýhodou nabídkových dat z realitních portálů je ale jejich nadhodnocení nad skutečnou cenou uzavíraných nájemních smluv. Toto nadhodnocení je jednak způsobeno tím, že například není možné rozlišit inzeráty, které byly staženy po úspěšném uzavření nájemní smlouvy, a ty, které byly pro vysokou cenu staženy pro nezájem potenciálních nájemníků. Právě druhá skupina stažených inzerátů bude v průměru nabídkovou cenu zvyšovat oproti ceně skutečně uzavřených nájemních smluv.

Dalším faktorem, který může skutečnou cenu nájmu o něco snížit oproti ceně nabídkové v inzerci na realitních portálech, je smlouvání mezi pronajímajícím a nájemníkem před uzavřením nájemní smlouvy. Oba výše uvedené faktory ale nemusí být stabilní mezi regiony i v čase v závislosti na hospodářském cyklu a stavu trhu bydlení. I v přístupu, kdy by byla jako základní data použita data o nabídkových cenách z realitních portálů, by hrála nezastupitelnou roli data ARK ČR, a to jednak ve stanovení cenové hladiny uzavíraných nájmu oproti cenové hladině nabídkových nájmu a dále pro možnost kontroly výsledků.

Pokud by byla analýza provedena nikoliv nad daty ARK ČR, ale nad nabídkovými výšemi nájmu podle realitních portálů, tak by nájmy byly spíše přímo vypočteny z těchto dat a model by byl aplikován pouze pro území s nedostatečným datovým pokrytím.

Důležitou částí přípravy analýzy by pak byla identifikace toho, o kolik jsou v průměru nabídky nadhodnoceny nad skutečnou cenou uzavíraných nájmu. Toto by bylo nejnázorněji proveditelné regresní analýzou nad neagregovanými daty o uzavřených nájmech a inzerátech bytů. V takové analýze by byl vysvětlovanou proměnnou logaritmus nájmu za metr čtvereční, který by byl vysvětlován sadou proměnných specifikujících byt, jeho okolí a datum uzavření nájmu nebo stažení inzerce a nakonec by byla zařazena binární (dummy) proměnná, jestli se jedná o inzerát nebo uzavřený nájem. Koeficient pro tuto proměnnou by byl hledaným procentním rozdílem mezi výšemi skutečně uzavřených nájmu a inzerčními nabídkami. Obecná specifikace je:

$$\log \text{cena}_{sqm} = \alpha + \beta_f \mathbf{B}_f + \gamma_n \mathbf{Z}_n + \delta \text{měsíc} + \lambda \text{inzerce} + \varepsilon$$

Ve výše uvedené specifikaci je \mathbf{B}_f vektorem specifik bytu, jako jsou výměra, typ konstrukcí, stav nemovitosti a vybavení bytu. Vektor \mathbf{Z}_n udává specifika lokality, jako je vzdálenost od centra aglomerace nebo umístění v konkrétním katastru nebo jiné jednotce administrativní členění. Dále je zohledněna proměnná měsíce od počátku sledovaných dat a nakonec proměnná, zda-li jde o záznam z webové inzerce, nebo jde o uzavřenou nájemní smlouvu. Právě koeficient λ označuje rozdíl mezi nabídkovými cenami nájmu a skutečně uzavřenými nájmy. Výhodou hledání tohoto vztahu metodou regresní analýzy je, že výsledek nebude ovlivňovat, nebo bude ovlivněn výrazně méně, případná nereprezentativnost dat.

6.4. Analýza stávajících vyplácených dávek

Cílem této analýzy by bylo určit, do jaké míry sjednané nájemné adresátů dávek na bydlení odpovídá lokální hladině tržní výše nájemného.

Tato analýza by byla zpracována tak, že pro každý datový záznam o poskytované dávce na bydlení by bylo stanoveno, v jaké části distribuce tržních nájmu v daném území se adresátem dávky sjednané nájemné pohybuje. Například by bylo uvedeno, že u konkrétní adresát dávky má sjednaný nájem na úrovni 30. percentilu v dané lokalitě. Tyto výsledky by se daly následně agregovat za větší územní celky, například obce nebo území POU nebo v případě velkých měst podle podrobnějšího územního členění.

Podle těchto výsledků by se dalo usuzovat, jestli výše nájemného sjednané žadateli o dávky na bydlení odrážejí cenovou hladinu místního trhu.

Pro provedení této analýzy by bylo třeba poskytnout data o jednotlivých žádostech podpory v bydlení, konkrétně výši nájmu za metr čtvereční uzavřenou žadatelem s vlastníkem nemovitosti. Dále by bylo třeba být lokalizovat v rámci obce ideálně adresným bodem, nebo případně v měřítku například základních sídelních jednotek.

Pokud by nebyla dostupná výměra bytu, bylo by možné ve spolupráci tuto výměru zjistit z katastru nemovitostí, ale v takové případě by bylo třeba přesně identifikovat dotčený byt.

6.5. Analýza dopadů změny výše vyplácené podpory na veřejné rozpočty

Nad rámec výše zmíněné analýzy stávajících vyplácených dávek může být zpracován dopad úpravy systému vyplácení dávek na veřejné rozpočty. Díky této analýze by bylo možné odhadnout, jak se případné změny v nastavení systému dávek na bydlení promítnou do nároků na veřejné rozpočty.

Nad rámec individuálních dat adresátů dávek na bydlení by bylo třeba poskytnout přesnou metodiku, podle které jsou dnes dávky vypláceny, případně rovnou uvést u jednotlivých žadatelů výši podpory, kterou z veřejných rozpočtů získává, a dále navrženou novou metodiku, podle které by měly být dávky vypláceny v budoucnu nebo případně více variantních řešení možných nastavení systému, pro které by byly zpracovány variantní odhady dopadů na veřejné rozpočty.

Tato analýza by byla zpracována tak, že u každého kandidáta by byla vypočtena hypotetická výše podpory podle nově navrženého systému, případně podle alternativních variantních systémů.

Je ale třeba dodat, že toto by muselo být provedeno ve 2 krocích, aby výsledky odhadů nebyly zkreslené. Zkreslení by mohlo nastat z toho důvodu, že na základě stávajících adresátů dávek můžeme odhadnout, jestli by pro tyto adresáty došlo ke snížení nebo zvýšení dávky, nedokážeme ale určit, kolik obyvatel by mělo na dávku nárok z těch, kteří doposud tyto dávky nepobírali. Pokud by tito obyvatelé nebyli zohledněni, pak by vždy odhad dopadů na veřejné rozpočty byl systematicky zkreslen směrem k nižším hodnotám, tedy k menším nákladům na straně veřejných rozpočtů. Jedinou výjimkou by byla situace, kdy by nový systém dávek pouze zpříšňoval podmínky a tím pádem by žádní noví adresáti dávek nepřibyli.

Pro zohlednění obyvatel, kteří v současné době dávky nepobírají, by bylo třeba získat data o příjmech domácností a výdajích domácností na bydlení. V dostatečné podrobnosti taková data ale pravděpodobně v současné době nejsou k dispozici, ale pro alespoň nějakou možnost odhadu by bylo možné použít neagregovaná data ze šetření SILC, které je prováděno na vzorku přibližně 11000 domácností. V kombinaci s neagregovanými daty ze SLDB 2011 by pravděpodobně bylo možné sestavit datový model, na základě kterého by bylo možné identifikovat domácnosti, které by nově měly na dávku v podobě bydlení nárok.

Variantně je možné analýzu dále zpracovat včetně výhledu do příštích let. V takovém případě by mohly být dopady na veřejné rozpočty modelovány pro alternativní scénáře růstu cen nemovitostí a s tím spojené růsty nákladů na bydlení.

Další alternativou je zohlednění demografických změn a nárůst počtu domácností seniorů v nadcházejících letech.

7. Příloha ke statistické analýze

7.1. Model M0a

Test normality residuí

Shapiro-Wilk normality test

data: M0\$residuals

W = 0.99319, p-value = 0.4979

Jelikož výsledné p-value testu přesahuje hodnotu 0.05, rozložení residuí se statisticky významně neliší od normálního rozložení a můžeme tedy považovat residua za normálně rozložená.

Test homoskedasticity

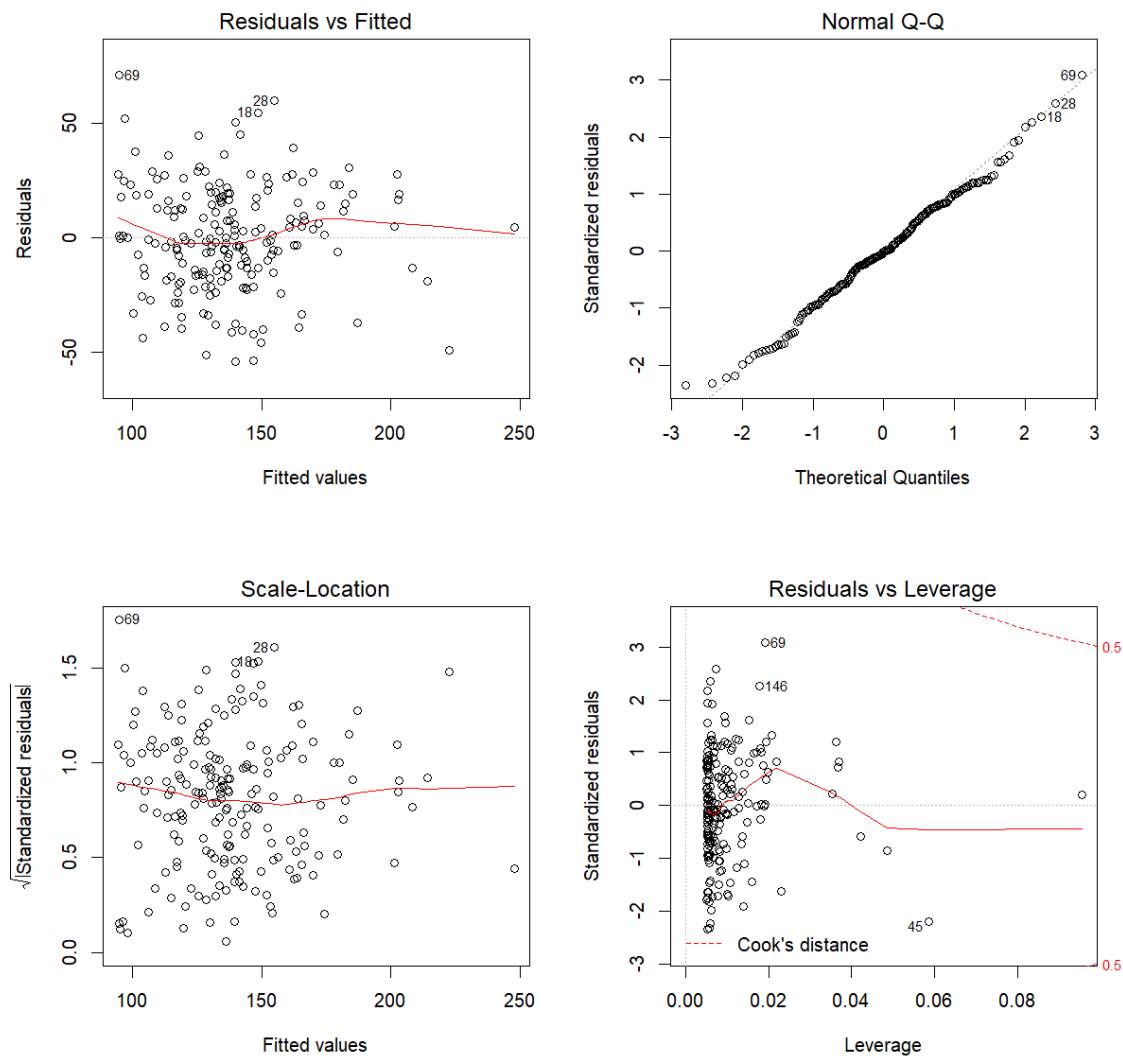
studentized Breusch-Pagan test

data: M0

BP = 0.0046505, df = 1, p-value = 0.9456

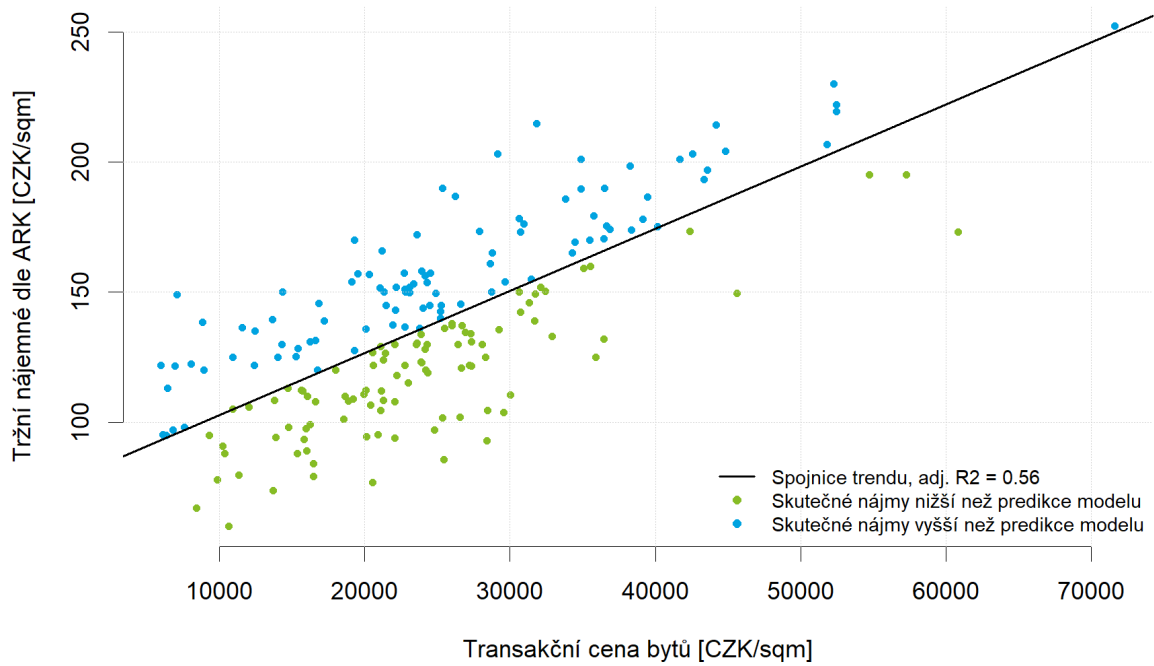
Jelikož výsledné p-value testu přesahuje hodnotu 0.05, můžeme přijmout nulovou hypotézu homoskedasticity.

Analýza residuí modelu M0a



Residua a odhad modelu M0a

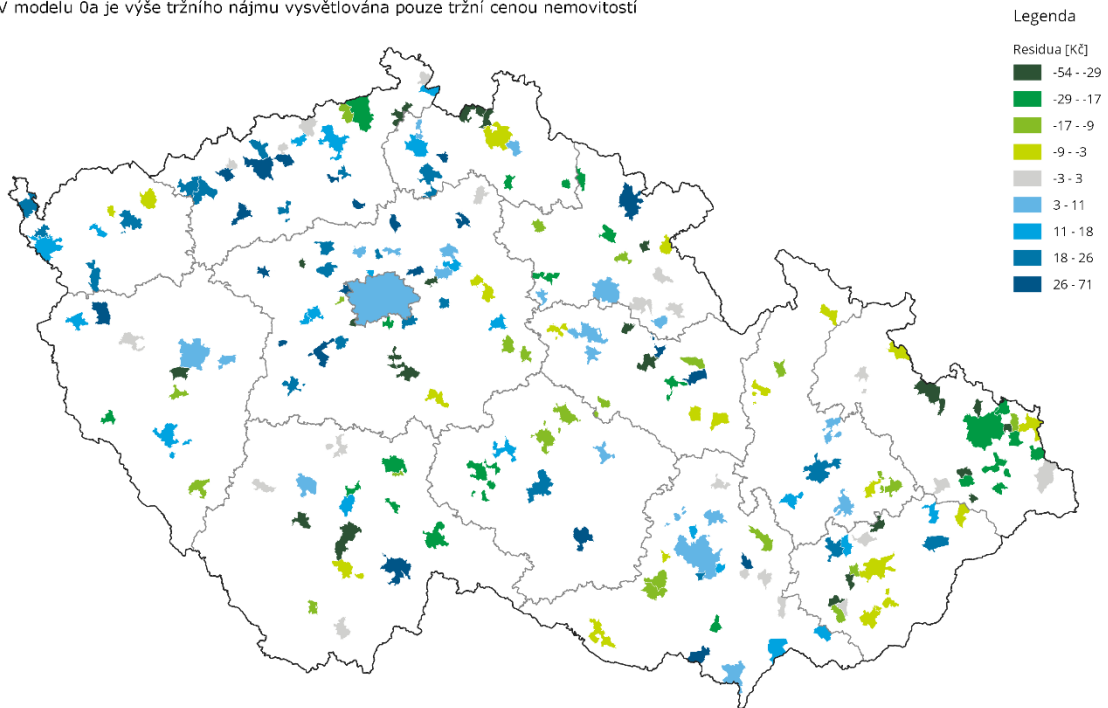
Vztah nájemného dle ARK a transakčních cen bytů



Residua modelu M0a promítnutá v území

Prostorové rozložení residuí modelu 0a

V modelu 0a je výše tržního nájmu vysvětlována pouze tržní cenou nemovitostí



7.2. Model M1c

Test normality residuí

Shapiro-Wilk normality test

data: M1c\$residuals

W = 0.99365, p-value = 0.562

Jelikož výsledné p-value testu přesahuje hodnotu 0.05, rozložení residuí se statisticky významně neliší od normálního rozložení a můžeme tedy považovat residua za normálně rozložená.

Test homoskedasticity





studentized Breusch-Pagan test

data: M1c

BP = 26.08, df = 26, p-value = 0.4587

Jelikož výsledné p-value testu přesahuje hodnotu 0.05, můžeme přijmout nulovou hypotézu homoskedasticity.

Analýza residuí modelu M1c



7.3. Model M1g

Korelační tabulka proměnných v modelu M1g

	mean	median_ wage	unemplo yment_s hare	primary_ share	OBEC_LO G_POP	ap_gwth _rate	rent_ap_ share	HubDist	log_stud ents	log_FUA_ CENTER
mean	1	0,72	-0,5	-0,73	0,1	0,74	0,21	-0,32	0,25	-0,13
median_ wage	0,72	1	-0,42	-0,62	-0,01	0,68	0,09	-0,28	0,1	-0,02
unemplo yment_s hare	-0,5	-0,42	1	0,51	0,23	-0,4	0,21	0,06	0,06	-0,07
primary_ share	-0,73	-0,62	0,51	1	-0,1	-0,57	-0,16	0,27	-0,25	0,15
OBEC_LO G_POP	0,1	-0,01	0,23	-0,1	1	-0,16	0,85	-0,16	0,71	-0,51
ap_gwth _rate	0,74	0,68	-0,4	-0,57	-0,16	1	-0,07	-0,33	-0,03	-0,03
rent_ap_ share	0,21	0,09	0,21	-0,16	0,85	-0,07	1	-0,23	0,73	-0,55
HubDist	-0,32	-0,28	0,06	0,27	-0,16	-0,33	-0,23	1	-0,16	0,37
log_stud ents	0,25	0,1	0,06	-0,25	0,71	-0,03	0,73	-0,16	1	-0,59
log_FUA_ _CENTER	-0,13	-0,02	-0,07	0,15	-0,51	-0,03	-0,55	0,37	-0,59	1

Do modelu nebyly zahrnovány společně proměnné, které jsou vzájemně korelované více než +/- 0,8. Výjimkou jsou proměnné rent_ap_share (podíl ročního počtu nabídek bytů a velikosti bytového fondu) a OBEC_LOG_POP (logaritmus počtu obyvatel), které tuto hranici mírně překračují. Tyto proměnné byly ale ponechány, protože obě mají ekonomický význam a předpokládaný opačný efekt na výši nájemného.

Test normality residuí

Shapiro-Wilk normality test

data: M1g\$residuals

W = 0.99282, p-value = 0.4487

Jelikož výsledné p-value testu přesahuje hodnotu 0.05, rozložení residuí se statisticky významně neliší od normálního rozložení a můžeme tedy považovat residua za normálně rozložená.

Test homoskedasticity

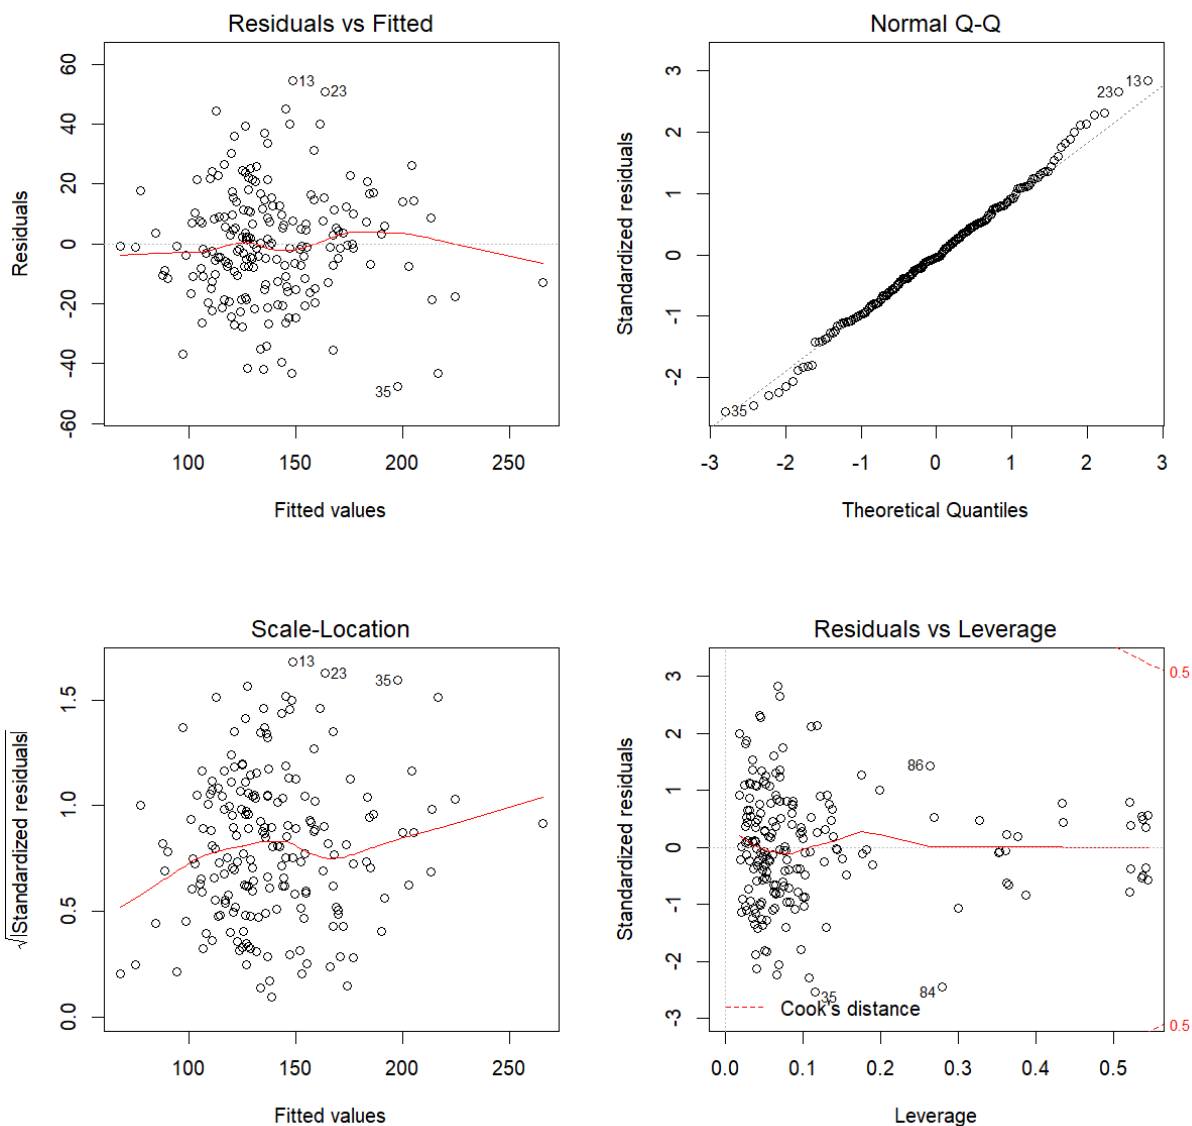
studentized Breusch-Pagan test

data: M1g

BP = 25.177, df = 25, p-value = 0.4525

Jelikož výsledné p-value testu přesahuje hodnotu 0.05, můžeme přijmout nulovou hypotézu homoskedasticity.

Analýza residuí modelu M1g



7.1. Agregace území s malým počtem transakcí

Pro predikci výše nájmu v území byla stanovena hranice více než 20 zaznamenaných tržních transakcí v území, které by byly dostatečně reprezentativní. Jak je vidět z mapy níže, kde jsou tato území označena oranžovou barvou, v České republice je 136 POU, ve kterých nebyl tento požadavek splněn. Jde zhruba o jednu třetinu všech POU bez vojenských újezdů.

Z tohoto důvodu byla území s nedostatečným počtem transakcí sloučena do větších klastrů a pro každé jednotlivé území POU se při výpočtu predikce použily veškeré transakce z klastru. Klustry byly tvořeny podle následujících pravidel: předně byly slučovány sousedící POU s nedostatečným počtem transakcí tak, aby přesáhly hranici 20 záznamů o transakcích. Pokud to bylo možné, tak byla preferována spojení do klastrů bez přecházení hranic ORP a krajů, ale této podmínce vyhovělo relativně málo klastrů. Pokud nebylo možné sloučit POU s nedostatečným počtem záznamů, aby společně překročily hranici 20 záznamů, tak byly sloučeny s územím, které samo o sobě tuto hranici přesahuje. V tomto případě byla opět preferována lokalizace uvnitř shodného ORP, případně kraje. Dále, kde to bylo možné, byly sdružovány POU bez výrazné asymetrie ve velikosti a typologii. I v tomto případě ale existují výjimky, u kterých nebyla lepší možnost agregace


k dispozici. Příkladem je sloučení Smiřic, Nechanic a Hradce Králové do jednoho klastru, který celý leží v rámci jednoho ORP, ale obce jsou vzájemně značně asymetrické.

Přehled vytvořených klastrů je uveden v seznamu níže a dále v mapě níže. Příslušnost ke konkrétnímu klastru je také uvedena v tabulkovém přehledu výsledků modelovaného tržního nájemného.

Rozdělení území podle možností predikce modelu

Rozdělení území podle možností predikce pro POU

Model M1g



Legenda

Možnost predikce

Predikce a kontrola

Predikce

Nedostatek transakcí

Vojenské újezdy

© 2019 Deloitte Česká republika

Klastr 1

Žlutice a Toužim

Klastr 2

Postoloprty, Libochovice a Louny

Klastr 3

Libouchec, Velké Březno a Ústí nad Labem

Klastr 4

Šluknov, Rumburk a Česká Kamenice

Klastr 5

Ústěk a Litoměřice

Klastr 6

Doksy, Bělá pod Bezdězem a Mšeno

Klastr 7

Cvikov, Jablonné v Podještědí, Český Dub a Hodkovice nad Mohelkou

Klastr 8

Frýdlant a Nové Město pod Smrkem

Klastr 9

Jilemnice a Rokytnice nad Jizerou

Klastr 10

Železný Brod a Lomnice nad Popelkou

Klastr 11

Nová Paka, Lázně Bělohrad, Sobotka, Kopidlno a Jičín

Klastr 12

Městec Králové, Týnec nad Labem a Chlumeck nad Cidlinou

Klastr 13

Smiřice, Nechanice a Hradec Králové

Klastr 14

Nové město nad Metují a Červený Kostelec

Klastr 15

Police nad Metují a Broumov

Klastr 16

Rokytnice v Orlických horách, Žamberk, Letohrad, Jablonné nad orlicí a Králíky

Klastr 17

Moravská Třebová, Zábřeh a Lanškroun

Klastr 18

Konice, Jevíčko a Letovice

Klastr 19

Litomyšl a Choceň

Klastr 20

Skuteč a Chrast

Klastr 21

Nasavrky, Třemošnice a Golčův Jeníkov

Klastr 22

Polná a Přebyslav

Klastr 23

Žďár nad Sázavou, Nové Město na Moravě a Bystřice nad Pernštejnem

Klastr 24

Humpolec a Pelhřimov

Klastr 25

Pacov, Kamenice nad Lipou a Počátky

Klastr 26

Velká Bíteš a Velké Meziříčí

Klastr 27

Třebíč, Jaroměřice nad Rokytnou a Hrotovice

Klastr 28

Jemnice a Vranov nad Dyjí

Klastr 29

Moravský Krumlov a Miroslav

Klastr 30

Vyškov a Rousínov

Klastr 31

Koryčany, Morkovice-Slížany, Ivanovice na Hané a Němčice nad Hanou

Klastr 32

Klobouky u Brna a Hustopeče

Klastr 33

Ždánice a Kyjov

Klastr 34

Uherský Ostroh a Staré Město

Klastr 35

Velká nad Veličkou, Strážnice a Bzenec

Klastr 36

Bojkovice, Brumov-Bylnice a Horní Lideč

Klastr 37

Příbor a Kopřivnice

Klastr 38

Orlová a Karviná

Klastr 39

Kravaře a Hlučín

Klastr 40

Vítkov, Fulnek a Moravský Beroun

Klastr 41

Horní Benešov, Bruntál a Rýmařov

Klastr 42

Krnov, Město Albrechtice a Osoblaha

Klastr 43

Javorník, Jeseník a Hanušovice

Klastr 44

Nová Bystřice a Jindřichův Hradec

Klastr 45

Soběslav a Veselí nad Lužnicí

Klastr 46

Zliv, Lišov a Hluboká nad Vltavou

Klastr 47

České Velenice a Nové Hrady

Klastr 48

Horní Planá a Vyšší Brod

Klastr 49

Netolice, Prachatice a Volyně

Klastr 50

Protivín, Písek, Mirovice a Mirovice

Klastr 51

Kašperské Hory a Sušice

Klastr 52

Plánice a Klatovy

Klastr 53

Blovice a Spálené Poříčí

Klastr 54

Stod a Staňkov

Klastr 55

Bor a Poběžovice

Klastr 56

Planá, Stříbro, Bezručice a Všeruby

Klastr 57

Manětín, Kralovice, Jesenice (okres Rakovník)

Klastr 58

Radnice, Zbiroh

Klastr 59

Březnice a Rožmitál pod Třemšínem

Klastr 60

Vlašim, Mladá Vožice a Votice

Klastr 61

Sázava a Uhlířské Janovice

Klastr 62

Kostelec nad Černými lesy a Kouřim

Klastr 63

Nymburk a Sadská

Klastr 64

Kamenice a Říčany

Klastr 65

Křivoklát, Nové Strašecí a Rakovník

Klastr 66

Kladno a Unhošť

Klastr 67

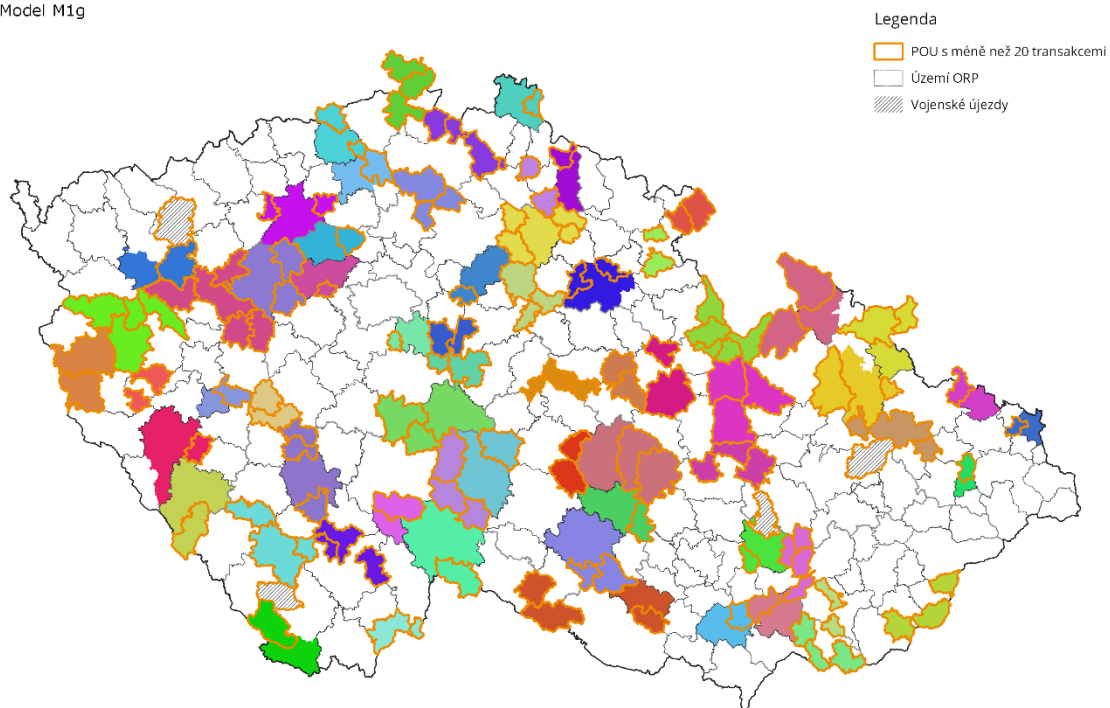
Velvary a Slaný

Výsledné sestavené klastry jsou zobrazeny v mapě níže. Shlukování transakcí do klastrů bude použito pro území označená oranžovým obrysem, kde bylo zaznamenáno 20 nebo méně transakcí za sledovaný rok.

Agregace klastrů

Agregace POU s 20 a méně transakcemi do prostorových klastrů

Model M1g



© 2019 Deloitte Česká republika

7.2. Kontrola predikce modelu M1g

Po provedení predikce výše nájmu – tedy promítnutí statistického modelu na všech 289 území POU – byla provedena kontrola modelovaných výsledků pomocí srovnání průměrné modelové hodnoty nájmného s průměrnou výší nabídkového nájmného podle dat realitních portálů. V tomto případě byla data realitních portálů snížena o 12,3%, aby byla ve stejné cenové hladině jako modelované tržní výše nájmného.

V mapě níže je rozdíl mezi modelem a daty realitních portálů uveden pro všechny POU, kde je počet nabídek za sledovaný rok vyšší než 20. V této mapě je vidět, že se systematicky výsledky

nejvíce rozcházejí ve Zlínském kraji a na Ostravsku, kde model predikuje relativně nižší nájemné, než by zde mělo být podle dat realitních portálů.

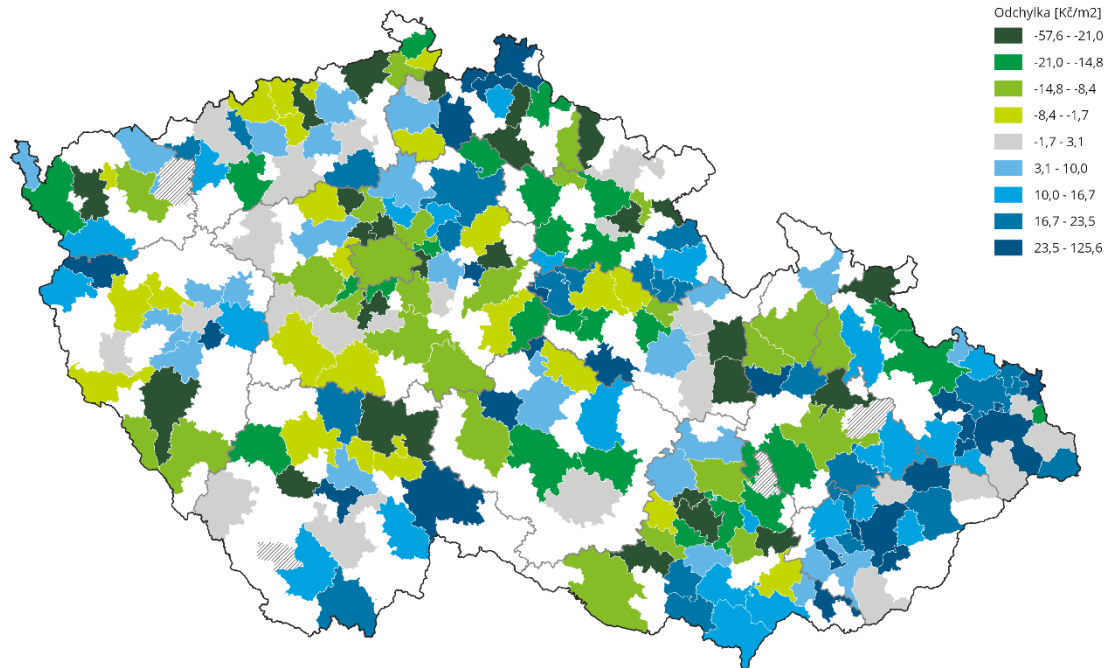
Tento problém ale není dán samotným modelem, protože v mapě prostorového rozložení residuí modelu M1g je vidět, že odchylky modelu vůči vstupním datům zde nejsou vysoké. Například pro město Ostrava je reziduum záporné. Tento systematický rozdíl a odchylka modelu je tedy dána nekonzistentností dat o výších nájmu podle ARK ČR a nabídkových dat nájmu podle realitních portálů.

Toto může být způsobeno různými faktory. Jedním z vysvětlení může být to, že očekávání vlastníků nemovitostí inzerujících byty na realitních portálech na těchto trzích je obecně vyšší a to v datech navyšuje průměrné nabídkové nájemné. Dále může být tato situace způsobena tím, že z těchto trhů poskytuje údaje jen omezené množství realitních kacířů, které se navíc mohou specializovat na levnější segment bytového nájemního bydlení, což by ve výsledku snižovalo odhady průměry výše nájemného z těchto regionů.

Odchylka predikce modelu M1g od údajů podle realitních portálů

Odchylka modelované výše nájmu od dat podle realitních portálů

Model M1g, záporné hodnoty jsou území s vyšší predikcí modelu oproti údajům realitních portálů



© 2019 Deloitte Česká republika

7.1. Komentář k modelové specifikaci regionálních rozdílů v nájmech

Alternativně byl zvažován i model M1c. V této tabulce jsou oba modely vzájemně srovnány. Rozdíl mezi oběma modely je použití proměnné `off_mkt_ratio` v modelu M1c.

V případě obou dvou zvažovaných modelů byly zahrnuty proměnné pro jednotlivé vymezené FUA. Ekonomický význam této proměnné je diskutabilní, protože výnos investice by měl být především ovlivňován zohledněnými strukturálními proměnnými. Statisticky odlišné výsledky pro některá

území FUA ale ukazují, že výsledný výnos může být ovlivňován dalšími místními okolnostmi, které v modelu nejsou zohledněny a nemusí být ani objektivně měřitelné, jako je například pozitivní či negativní sentiment vztahující se k danému regionu.

Model M1g

Vysvětlovaná proměnná: Tržní výše nájmu podle ARK

Residual standard error: 20.01 on 171 degrees of freedom,
Robust SE
Multiple R-squared: 0.7122,
Adjusted R-squared: 0.6701
F-statistic: 16.93 on 25 and 171 DF,
p-value: < 2.2e-16

Model M1c

Vysvětlovaná proměnná: Tržní výše nájmu podle ARK

Residual standard error: 15.54 on 170 degrees of freedom,
Robust SE
Multiple R-squared: 0.8275,
Adjusted R-squared: 0.8011
F-statistic: 31.37 on 26 and 170 DF,
p-value: < 2.2e-16

	Estimate	Std. Error		Estimate	Std. Error	
(Intercept)	-1.7783e+02	5.9731e+01	**	-1.5502e+02	4.9624e+01	**
mean	1.8476e-03	3.0902e-04	***	1.6583e-03	2.4221e-04	***
median_wage	5.1113e-03	1.7581e-03	**	2.7602e-03	1.3492e-03	*
unemployment_share	-5.3169e-01	1.2564e+00		-1.2811e+00	1.0334e+00	
primary_share	2.3900e+02	6.9470e+01	***	1.7945e+02	5.4674e+01	**
OBEC_LOG_POP	1.0987e+01	3.7452e+00	**	6.1753e+00	3.0570e+00	*
ap_gwth_rate	1.0227e+03	9.2508e+02		1.5860e+03	6.7855e+02	*
rent_ap_share	-5.8664e+01	3.1858e+02		1.5897e+02	2.3903e+02	
HubDist	-1.9854e-01	1.4816e-01		-2.4364e-01	1.1806e-01	*
log_students	-1.7184e+00	9.2238e-01	.	-8.2600e-01	9.6091e-01	
log_FUA_CENTR	-3.5078e+00	2.2317e+00		-3.0097e-01	1.9247e+00	
FUA Brno	1.2357e+01	8.4771e+00		4.2629e+00	8.3242e+00	
FUA České Budějovice	-1.7575e+01	6.5313e+00	**	-1.2523e+01	4.9448e+00	*
FUA Hradec Králové	5.9082e+00	6.8264e+00		4.0278e+00	6.2157e+00	
FUA Chomutov	-1.0221e+01	1.0794e+01		6.0889e+00	6.4895e+00	
FUA Jihlava	1.6223e+01	6.5806e+00	*	9.7879e+00	5.3353e+00	.
FUA Karlovy Vary	-1.4590e+01	8.1912e+00	.	-8.8731e+00	4.9918e+00	.
FUA Liberec	-4.4200e+01	8.5219e+00	***	-1.4243e+01	6.1610e+00	*
FUA Most	9.7510e+00	7.9744e+00		1.3909e+01	7.2921e+00	.
FUA Olomouc	1.8435e+01	7.9826e+00	*	-1.7045e+00	1.1454e+01	
FUA Ostrava	-3.5467e+01	6.0151e+00	***	-1.9770e+01	5.5457e+00	***
FUA Pardubice	-2.2560e+00	3.8266e+00		-1.5286e+00	4.7594e+00	
FUA Plzeň	-2.6948e+01	1.4673e+01	.	-1.7289e+01	6.4625e+00	**
FUA Praha	-5.2369e+00	9.5175e+00		-2.3752e+00	6.6208e+00	
FUA Ústí nad Labem	-9.7549e+00	7.8628e+00		-3.2663e-03	6.4046e+00	
FUA Zlín	-1.8189e+01	7.6821e+00	*	6.4125e+00	7.0409e+00	
off_mkt_ratio				9.8117e+01	1.0331e+01	***

Signif. codes: '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1

Proměnná off_mkt_ratio je sestrojena jako výše tržního nájmu podle ARK ČR dělená výší nabídkového nájmu podle realitních portálů. Údaje ARK ČR jsou v průměru o 12,3% nižší než údaje

podle realitních portálů. Výsledek modelu M1c je možné interpretovat tak, že čím vyšší je údaj o tržní výši nájemného podle ARK ČR oproti datům realitních portálů, tím je relativně vyšší nájemné oproti transakční ceně nemovitostí, jinými slovy roste výnos. Je třeba také podotknout, že tento koeficient je statisticky významný na 0,1% hladině a zvyšuje upravený koeficient determinace o 13 procentních bodů na 0.801.

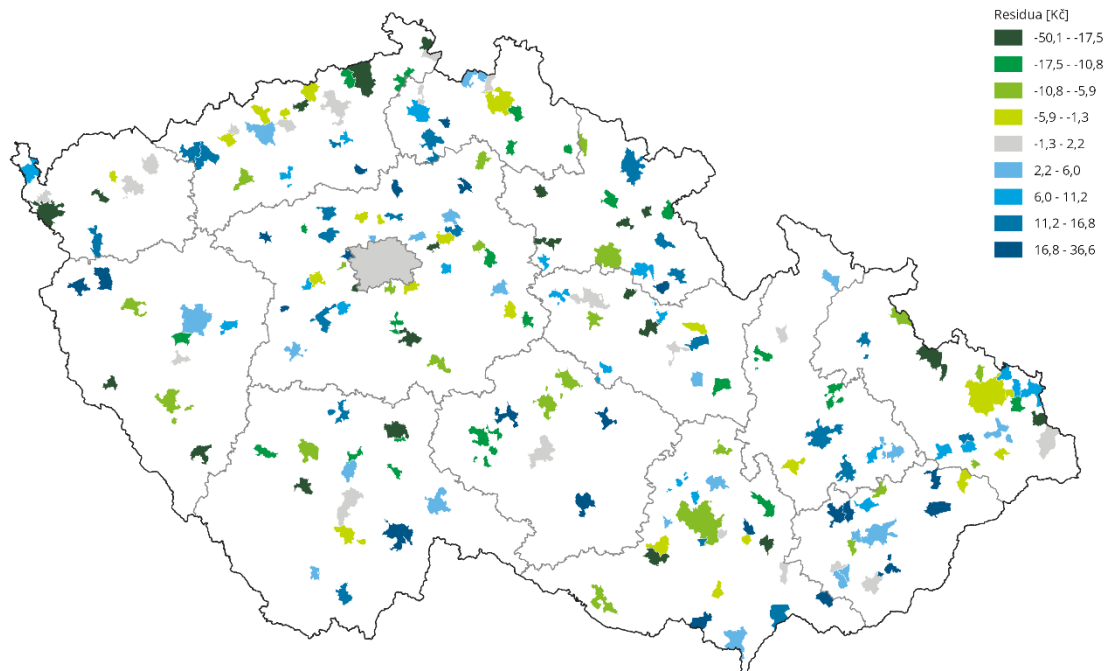
Výsledky modelu M1c ukazují, že data z realitních portálů dokáží dovysvětlit značnou část zývající variace v datech. Přestože má model M1c lepší prediktivní schopnost, použití tohoto modelu s proměnnou `off_mkt_ratio` je komplikované například i z toho důvodu, že tuto proměnnou nepozorujeme pro jednotlivé POU.

Pokud se podíváme na prosotorové rozložení residuí, tak nevykazuje výrazné trendy a zároveň jsou residua relativně malá u velkých měst. U modelu M1c klesla standardní odchylka residuí na 75% residuí modelu M1g, konkrétně z 20 na 15,5 Kč.

Residua modelu M1c

Prostorové rozložení residuí modelu M1c

Záporné hodnoty ukazují území, kde model predikuje vyšší nájem, než je pozorovaný v datech



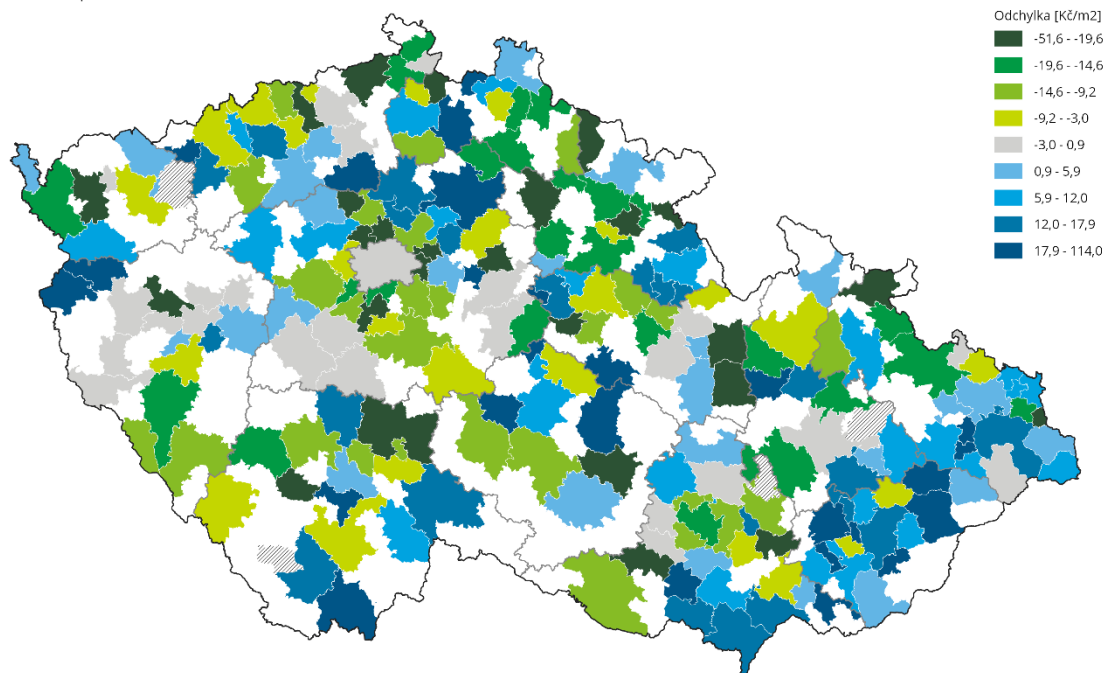
© 2019 Deloitte Česká republika

Při vypočtení predikce pro jednotlivé POU model M1c vykazuje menší odchylky oproti datům z realitních portálů na již zmíněném Ostravsku a Zlínsku, což je ale dáno tím, že data z realitních portálů vsoupila do modelu v rámci proměnné `off_mkt_ratio`.

Odchylka predikce modelu M1c od kontrolních dat realitních portálů

Odchylka modelované výše nájmu od dat podle realitních portálů

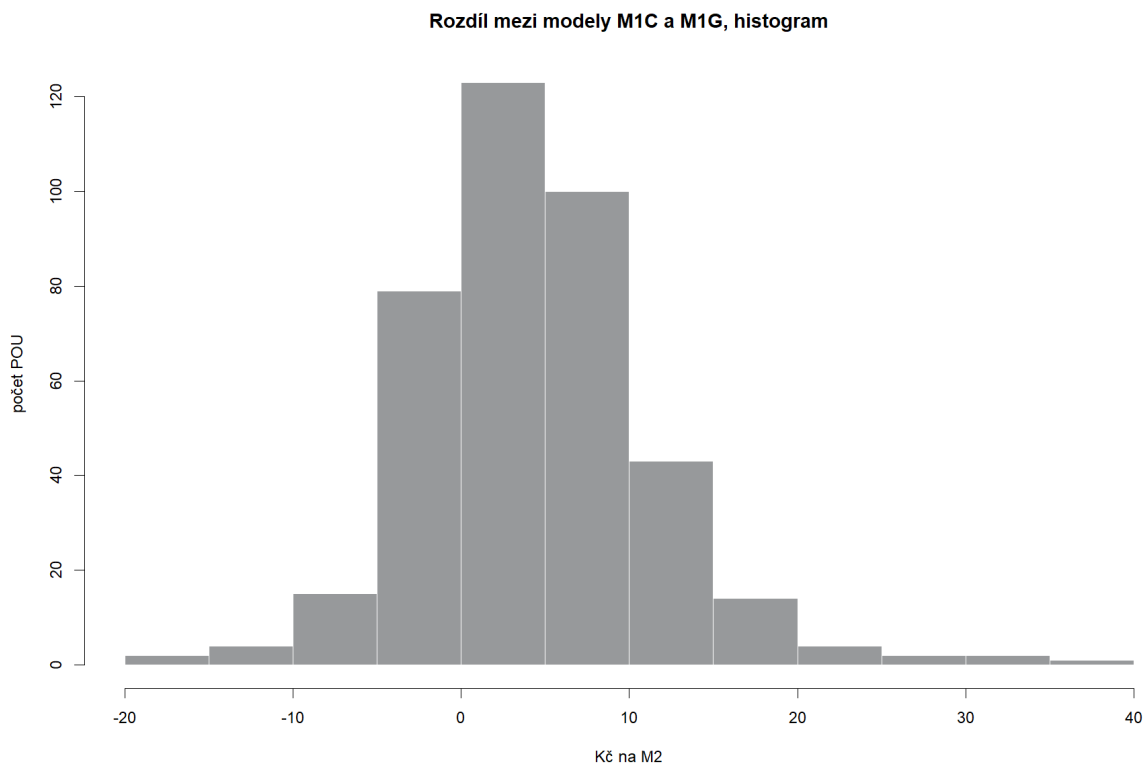
Model M1c, záporné hodnoty jsou území s vyšší predikcí modelu oproti údajům realitních portálů



© 2019 Deloitte Česká republika


Při porovnání predikcí obou modelů M1c a M1g je vidět, že model M1C vykazuje v průměru o něco vyšší nájmné. Největší počet odchylek leží v intervalu 0 až 5 Kč.

Srovnání predikcí modelu M1c a M1g



V případě modelované návratnosti podle území POU je celkový výsledek modelu M1c podobný modelu M1g.

Histogram návratnosti investice podle území POU, model M1C



7.2. Model M2a

V modelu M2a jsou stejně jako v modelech M1 použity proměnné pro identifikaci vlivu jednotlivých území FUA na výši cen nemovitostí. Přestože i zde je ekonomický význam této proměnné diskutabilní, statisticky významné rozdíly mezi jednotlivými regiony ukazují na to, že strukturální proměnné nemohou vysvětlit veškeré odlišnosti mezi jednotlivými trhy, které mají svá lokální specifika.

Test normality residuí

One-sample Kolmogorov-Smirnov test

data: M2a\$residuals

D = 0.28266, p-value < 2.2e-16

alternative hypothesis: two-sided

V případě modelu M2a byl z důvodu většího počtu pozorování než 5000 použit Kolmogorov-Smirnov test normality. Jelikož výsledné p-value je nižší než hodnota 0.05, můžeme vyvrátit nulovou hypotézu odlišnosti distribuce od normální a považovat residua za normálně rozložená.

Test homoskedasticity

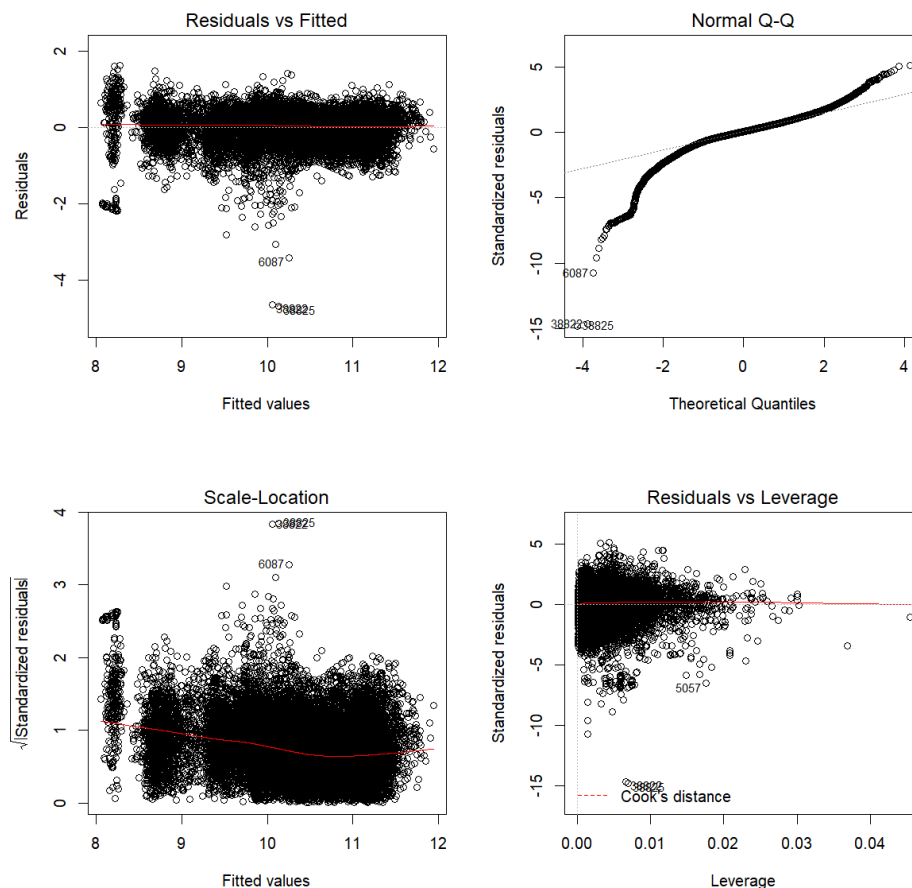
studentized Breusch-Pagan test

data: M2a

BP = 3507.4, df = 66, p-value < 2.2e-16

Jelikož výsledné p-value testu je nižší než hodnota 0.05, můžeme vyvrátit nulovou hypotézu homoskedasticity a předpokládat heteroskedasticitu.

Analýza residuí modelu M2a



Korelační tabulka proměnných v modelu M2a

	growt h_rat e	unemploy ment_shar e	ap_gw th_rat e	primar y_shar e	universi ty_shar e	logH ubDi st	logStud entsplus 1	lognearest _fua_cente r	logP locha
growth_r ate	1	-0,38	0,6	-0,29	0,23	-0,07	-0,06	0,18	0,04
unemploy ment_shar e	-0,38	1	-0,6	0,74	-0,54	-0,15	-0,31	-0,12	-0,04
ap_gwth_r ate	0,6	-0,6	1	-0,56	0,46	-0,09	0,1	0,33	0,04
primary_sh are	-0,29	0,74	-0,56	1	-0,93	0,05	-0,74	0,01	-0,02
university_ share	0,23	-0,54	0,46	-0,93	1	-0,02	0,8	-0,09	0,01
logHubDist	-0,07	-0,15	-0,09	0,05	-0,02	1	-0,13	0,05	-0,01
logStudent splus1	-0,06	-0,31	0,1	-0,74	0,8	-0,13	1	-0,35	-0,02
lognearest _fua_cente r	0,18	-0,12	0,33	0,01	-0,09	0,05	-0,35	1	-0,01
logPlocha	0,04	-0,04	0,04	-0,02	0,01	-0,01	-0,02	-0,01	1

U modelu M2a vidíme vysoké korelace přesahující nebo se těsně blížíící +/- 0.8 mezi proměnnými primary_share (podíl obyvatel se základním nebo nedokončeným základním vzděláním), university_share (podíl obyvatel s magisterským nebo doktorským vzděláním) a logStudentsplus1 (logaritmus z počtu studentů v prezenční formě studia na všech vysokých školách zvýšený o jedna). Jelikož ale všechny výše uvedené korelované proměnné jsou v modelu statisticky významné i při zohlednění robustních standardních odchylek, byly v modelu společně ponechány.

8. Slovník použitých zkratek

ARK ČR	Asociace realitních kanceláří České republiky
ČSÚ	Český statistický úřad
ČÚZK	Český úřad zeměměřičský a katastrální
FUA	Functional urban area / Funkční aglomerační území vymezené OECD na základě dat o dojížděcí obyvatelstva
IPRÚ	Integrované plány rozvoje území
IQR	Inter quartile range, vzdálenost mezi 1. a 3. kvartilem
MMR	Ministerstvo pro místní rozvoj ČR
MO ITI	Metropolitní oblasti pro integrované teritoriální investice
MPSV	Ministerstva práce a sociálních věcí ČR
MŠMT	Ministerstvo školství, mládeže a tělovýchovy ČR
OECD	Organisation for Economic Co-operation and Development / Organizace pro ekonomickou spolupráci a rozvoj
OLS	Ordinary least squares, metoda nejmenších čtverců
POU	Obec s pověřeným úřadem (administrativní členění)
ROI	Return of Investment (návrtnost investice) – Výše ročního nájmu dělená tržní hodnotou
SLDB 2011	Sčítání domů, lidu a bytů 2011
SO ORP	Správní obvod obce s rozšířenou působností (případně jen ORP)
WLS	Weighted least squares, vážená metoda nejmenších čtverců

9. Přehled ostatních příloh

1. Přehled modelovaných tržních nájmů – grafová část
2. Přehled modelovaných tržních nájmů, části obcí – grafová část
3. Přehled modelovaných tržních nájmů – tabulková část
4. Přehled modelovaných tržních nájmů, části obcí – tabulková část
5. Tabulkový přehled rozdílů predikcí modelu M1c a M1g
6. Nabídka na analýzu nájemného v ČR (zpracováno pro MPSV ČR)
7. Objednávka MMR ČR na zpracování analýzy
8. Metodika zpracování Analýzy nájemného v České republice
9. Připomínkový arch s vypořádáním připomínek
10. Tabulka výsledků modelu pro POU (PR10_model_pou.xlsx)
11. Tabulka výsledků modelu pro MO a MČ (PR11_model_momc.xlsx)
12. Tabulka srovnávající predikce modelů M1c a M1g (PR12_komparace_model.xlsx)
13. Zdrojový kód analýzy (PR13_zdrojovy_kod.txt)