

POLOHA BYTU A JEHO CENA: PRIESTOROVÝ HEDONICKÝ MODEL

Štefan Rehák*

* Národohospodárska fakulta Ekonomickej univerzity v Bratislave, Katedra verejnej správy a regionálneho rozvoja, Dolnozemska cesta 1, 852 35 Bratislava, stefan.rehak@euba.sk

The location of an apartment and its price: a spatial hedonic model

House prices are determined by the characteristics of the particular apartment or house and its location in the town. The location of an apartment in the town may be represented in several ways. First, the position relative to the town centre represents the costs related to the transportation to the city centre. Second, as the amenities and public services vary in the town, location in the town district could be used in the model. Finally, prices of other neighbouring apartments may also influence the price and the role of spatially clustered positive or negative externalities. This paper analyses the significance of the location of an apartment for the apartment price using spatial hedonic models. The empirical part is based on the example of residential apartment prices in the town of Šaľa. Our analysis suggests that the location influences the apartment's price. Distance to the city centre, local amenities and also prices of neighbouring apartments have a significant impact on price.

Key words: apartment location, hedonic model, real estate, spatial econometrics, town of Šaľa

ÚVOD

Diskusia o cenách bytov sa zvyčajne odvíja od vývoja dopytu po nehnuteľnosťach a ich ponuky. Dopyt je determinovaný skupinou faktorov (prehľad napr. Cár 2009), medzi hlavné z nich patria demografické faktory (vývoj počtu obyvateľov, resp. jednotlivých vekových skupín), ekonomické faktory (vývoj príjmov domácností, resp. celkový vývoj ekonomiky), politické faktory (štátna bytová politika, dotácie na bytovú výstavbu) a finančné faktory (napr. úverové podmienky a výška úrokových mier). Ceny nehnuteľností ovplyvňuje aj ich ponuka. Tá sa odvíja od regulácie bytovej výstavby, napr. prostredníctvom územného plánovania obcí, ale aj od dispozície kapitálu na obnovu, prípadne výstavbu bytov. Zmeny v dopyte po bytoch ovplyvňuje najmä pohyb cien na národnej, prípadne regionálnej úrovni, zmeny v ponuke bytov vysvetľujú rozdiely v cenách bytov medzi mestami.

Príznačnou črtou nehnuteľností sú však pomerne veľké rozdiely v cenách bytov v jednotlivých lokalitách v rámci mesta. Cieľom článku je preskúmať, akým spôsobom ovplyvňuje poloha bytu v meste výslednú cenu nehnuteľnosti. Špecifikum tohto článku je, že oproti tradičnému výskumu cien nehnuteľností v SR, ktorý sa zvyčajne zameriava na vplyv dopytu a ponuky na ceny, bude našim hlavným cieľom analyzovať vplyv polohy bytu. Nezaoberáme sa teda celým spektrom faktorov vplývajúcich na cenu bytov, ale sa úzko zameriavame na vplyv lokálnych faktorov na úrovni mesta. Okrem toho je naším zámerom aj preskúmanie a uplatnenie metód, ktoré je možné použiť na hodnotenie vplyvu polohy na cenu bytov.

Používame hedonický model cien, ktorý umožňuje skúmať vplyv jednotlivých charakteristík bytu, bytového domu a jeho polohy na výslednú cenu bytu. Hedonický model umožňuje zakomponovať vplyv polohy bytu do jeho ceny viacerými spô-

sobmi. Prvý spôsob je zahrnúť do modelu kategorickú (dummy) premennú pre časť mesta. Tento spôsob poukazuje na význam okolia bytu, teda význam lokálnych špecifik. Druhou možnosťou je preskúmať relatívnu polohu bytu vzhľadom na centrum mesta. Tento spôsob analyzuje význam dopravných nákladov na výslednú cenu. Nakoniec tretí spôsob vychádza z priestorových ekonometrických modelov, ktoré umožňujú testovať význam vplyvu cien vzájomne susediacich bytov, resp. testovať význam lokálnych faktorov, ktoré nie sú zahrnuté v modeli.

PRIESTOROVÉ HEDONICKÉ MODELÝ CIEN NEHNUTEĽNOSTÍ

Existujú rôzne prístupy modelovania cien nehnuteľností v meste. Modelovanie vplyvu polohy na ceny nehnuteľností vychádzajú najčastejšie z konceptu hedonických cien. Rosen (1974) integroval hedonický model cien do štandardnej ekonomickej teórie. Metóda hedonickej ceny vychádza z tézy, že dopyt spotrebiteľov nie je reprezentovaný všeobecným statkom, ale spotrebiteľia oceňujú jednotlivé atribúty statku a tie sa prejavujú vo výslednej cene (Rosen 1974). Nehnuteľnosti na bývanie predstavujú statok, ktorý má špecifické charakteristiky, akými sú heterogenita (rozmanitosť veľkosti, veku, štýlu a pod.), trvácnosť (dlhodobá spotreba) a nakoniec priestorová stabilita (viazanosť spotreby na určitú lokalitu a existencia nákladov spojených so zmenou spotreby – O'Sullivan 2009).

Cena bytu v hedonickom modeli je determinovaná charakteristikami bytu (rozloha, počet izieb, dispozícia, vybavenie, dizajn a poschodie), charakteristikami bytového domu (konštrukcia, počet poschodí, stav, vek a možnosti parkovania) a charakteristikami okolia a polohy bytu (vzdialenosť od centra, občianska vybavenosť, sociálna skladba obyvateľstva, znečistenie a pod.). V tomto článku budeme porovnávať rôzne hedonické modely cien nehnuteľností, pričom budeme skúmať kvalitu modelu v závislosti od rôzneho spôsobu zakomponovania vplyvu polohy bytu do výslednej ceny bytu.

Tradičné prístupy definovali polohu bytu v hedonickom modeli na základe jeho vzdialenosti od centra. Tento prístup vychádza z modelov urbánnej ekonómie (Burgess 1925 a Alonso 1964), ktoré považujú mesto za monocentrické. Centrum mesta predstavuje miesto, kde sa odohrávajú ekonomické transakcie (tzv. central business district – CBD). Keďže doprava do centra je spojená s transakčnými nákladmi (finančnými alebo nákladmi obetovaných príležitostí), domácnosti budú ponúkať vyššiu sumu za byty v blízkosti centra a táto cena bude klesať smerom od centra (negatívny cenový gradient).

Druhou skupinou modelov sú modely zahrňajúce rôzne lokálne charakteristiky, ktoré pozitívne alebo negatívne ovplyvňujú užitočnosť domácností, akými sú napríklad kriminalita, znečistenie, pracovné príležitosti, nákupné možnosti, možnosti zábavy a rekreácie alebo sociálna skladba obyvateľov. Podľa Heratha a Maiera (2010), ktorí uskutočnili prehľad 321 empirických štúdií, sa viac ako polovica venovala analýze charakteristík okolia nehnuteľnosti. Z nich sa väčšina zamerala na hodnotenie environmentálnych faktorov (znečistenie a zelené plochy) alebo infraštruktúry (verejné statky a služby). Práve výskum vplyvu environmentálnych faktorov na ceny nehnuteľností podporil rozvoj hedonických modelov (Ridker a Henning 1967 a Freeman 1979). Podstatne menej je preskúmaný vplyv sociálnych faktorov prostredia (rasová segregácia, kriminalita a iné – Thaler 1978 a Lynch a Rasmussen 2001).

Hedonické modelovanie čelí viacerým metodickým problémom ekonometrického modelovania prierezných údajov, akými sú napr. heteroskedasticita, kolinearita a priestorová autokorelácia. Najmä pokrok v priestorovej ekonometrii (Anselin 1988 a Lesage a Pace 2009) umožnil novým spôsobom zahrnúť vplyv susediacich nehnuteľností na ich cenu. Množstvo autorov v poslednom období využíva priestorové ekonometrické modely na zníženie vplyvu priestorovej autokorelácie, resp. na identifikovanie chýbajúcich vysvetľujúcich premenných (Watkins 2001, McMillen 2003 a Osland 2010). Existencia priestorovej autokorelácie znamená, že jednotlivé pozorovania nie sú nezávislé a hodnoty jedného pozorovania ovplyvňujú hodnoty pozorovaní v jeho blízkosti, prípadne, že v modeli nie sú zahrnuté niektoré priestorovo koncentrované faktory. Preto sa aplikujú SAR (spatial autoregressive lag model) alebo SEM (spatial autoregressive error model) modely.

Model s priestorovo oneskorenou závislou premennou (SAR – spatial autoregressive lag model) vysvetľuje, že priestorová autokorelácia cien nehnuteľností (závislej premennej) je výsledkom tzv. efektu susedstva, kde ide o napodobňovanie cien susediacich nehnuteľností (Farber a Yeates 2006). Všeobecný hedonický model s priestorovým oneskorením (spatial lag) môžeme zapísať ako:

$$P = \rho WP + X\beta + u,$$

kde P je vektor cien nehnuteľností, X je matica nezávislých premenných, β je vektor regresných koeficientov, u je vektor rezíduí a nakoniec W je priestorová matica váh, ktorá reprezentuje maticu susedstva. WP je priestorovo oneskorená závislá premenná, kde parameter ρ označuje priestorovú závislosť. Ak $\rho = 0$, tak ide o štandardnú lineárnu regresiu. Ak priestorová štruktúra nereprezentuje reálnu priestorovú závislosť, bude hodnota ρ nízka alebo štatisticky nevýznamná.

Druhou možnosťou je, že existuje priestorová autokorelácia v rezíduách (SEM – spatial autoregressive error model). Tento model ukazuje, že existujú ďalšie faktory, ktoré ovplyvňujú výšku ceny nehnuteľností a neboli zahrnuté v pôvodnom modeli. Tieto faktory sú koncentrované v priestore a ich efekt sa stráca s rastúcou vzdialenosťou. Medzi vynechané, resp. nepozorované premenné patrí napr. lokálne špecifická infraštruktúra (napr. detské ihriská, zelené plochy, neprispôsobiví susedia a pod. – Osland 2010). Všeobecný model môžeme zapísať nasledovne (Anselin 2003):

$$P = X\beta + \varepsilon, \text{ kde } \varepsilon = \lambda W\varepsilon + u.$$

Podobne ako v prvom modeli, $W\varepsilon$ vyjadruje priestorovú maticu. Parameter λ vyjadruje priestorovú závislosť, pričom analyzujeme jeho veľkosť a štatistickú významnosť. Dôležitou súčasťou modelovania priestorovej závislosti je určenie matice priestorových váh. Znamená to určenie počtu najbližších susedov alebo vzdialenosti, pri ktorej sa pozorovania považujú za susediace. Prítomnosť autokorelácie sa zvyčajne testuje prostredníctvom Moranovho I a Lagrange multiplier (LM)¹, resp. robustného LM.

¹ Výpočet Moranovo I sa používa na zisťovanie prítomnosti priestorovej autokorelácie, teda korelácie hodnôt priestorovo blízkych pozorovaní. Moranove I nadobúda hodnoty od -1 po +1, pričom negatívne hodnoty ukazujú na negatívnu priestorovú autokoreláciu a pozitívne hodnoty znamenajú pozitívnu priestorovú autokoreláciu. Hodnota nula predstavuje náhodné rozmiestnenie hodnôt v priestore. Prostredníctvom výpočtu Moranovho I vieme zistiť prítomnosť priestorovej autokorelácie, ale nie je možné na jeho základe určiť vhodný model. Pre výber modelu sa používajú Lagrange multiplier testy, ktoré poskytujú testovaciu štatistiku na rozhodnutie, či ide o model model s priestorovo oneskorenou závislou premennou alebo o model s priestorovými chybami.

ZDROJE ÚDAJOV

Ceny nehnuteľností nie sú predmetom formálneho štatistického zisťovania. Jediným oficiálnym zdrojom cien nehnuteľností je Národná banka Slovenska, ktorá analyzuje vývoj cien na základe údajov poskytovaných Národnou asociáciou realitných kancelárií. Ceny sú však vykazované len na regionálnej úrovni. Pre výskum na úrovni miest sú preto jediným možným zdrojom cien inzeráty o nehnuteľnostiach na predaj. Hoci cenu bytu uvedenú v inzeráte nemôžeme považovať za transakčnú cenu, mnohí autori ju používajú ako proxy ukazovateľ skutočnej ceny (Cheshire a Sheppard 1989, Henneberry 1998 a Herath a Maier 2013). Pre náš výskum však je možné považovať údaj o ponúkanej cene za vhodný ukazovateľ, pretože cena je prevažne určená po obhliadke nehnuteľností realitným maklérom, takže odráža skutočný stav nehnuteľnosti. Zároveň predpokladáme že neexistujú systematické skreslenia medzi ponukovou a transakčnou cenou v priestore, preto cena bytu teda odráža hodnotu jeho polohy.


Získanie a spracovanie údajov z inzerátov je manuálna a časovo náročná úloha, rozhodli sme sa preto pre menšie mesto. Modely, ktoré aplikujú cenový gradient, zvyčajne vychádzajú z konceptu monocentrického mesta. Najmä väčšie mestá sú typické existenciou viacerých mestských centier. Malé mestá, ako je napr. Šaľa, sú naopak typické monocentrickosťou, čo vyhovuje nášmu modelu. Keďže budeme skúmať vplyv lokálnych charakteristík na cenu bytov, na interpretáciu je potrebné mať dostatok informácií, resp. poznať charakteristiky jednotlivých lokalít v meste. Na Slovensku sú len veľmi obmedzené informácie o mestských častiach, tieto nahradzujeme osobnou znalosťou mesta a terénnym pozorovaním.

Podľa údajov zo Sčítania obyvateľov, domov a bytov 2011 je v meste Šaľa 8 139 bytov v domoch, v čom je 1 497 bytov v budovách s jedným bytom, 67 v budovách s dvoma bytmi a 6 574 bytov v budovách s tromi a viac bytmi a jeden byt je v nebytovej budove. Podiel bytov v budovách s tromi a viac bytmi je približne 81 percent. Naša analýza cien nehnuteľností sa zaoberá len cenami bytov v bytových domoch, ktoré tvoria hlavnú časť transakcií na trhu nehnuteľností v meste. Analýza iba jedného typu statku, teda v našom prípade bytov v bytových domoch, je v súlade s literatúrou, ktorá zdôrazňuje, že analýza by mala zamerať na niektorý z čiastkových trhov, ktoré sa zvyčajne definujú na základe typu nehnuteľností. Štruktúra bytov v bytových budovách je nasledujúca. Bytov s jednou obytnou miestnosťou je 674 (10 %), dve obytné miestnosti má 1 364 bytov (21 %), tri obytné miestnosti má 3 763 bytov (57 %), štyri obytné miestnosti má 593 bytov (9 %), 5 obytných miestností má 51 bytov (1 %), ostatných 129 bytov (2 %) má 6 a viac miestností, prípadne má nezistený počet miestností.

Zdroj údajov pre náš výskum bolo 98 inzerátov o predaji bytu v meste Šaľa zverejnených na portáli *www.reality.sme.sk* v období december 2014 – január 2015. Krátke časové obdobie umožňuje minimalizovať riziko vplyvu zmeny cien nehnuteľností v dôsledku zmien v ekonomike, a teda dáva možnosť použiť analýzy vhodné pre prierezové dáta. Celková vzorka bytov v našom výskume predstavuje približne 1,4 % bytov v meste. Štruktúra vzorky je nasledujúca. Počet 1-izbových bytov je 14 (14,4 %), 2-izbových bytov je 24 (24,7 %), 3-izbových bytov je 52 (53,6 %) a 4-izbových bytov je 7 (7,2 %). Štruktúra vzorky je podobná celkovej štruktúre bytov v Šali s mierne vyšším zastúpením 1- a 2-izbových bytov.

Okrem ceny nehnuteľnosti obsahovali inzeráty štrukturálne charakteristiky bytu (počet izieb, rozlohu bytu, stav bytu, poschodie a informáciu, či má byt balkón,

pivnicu a komoru) a charakteristiky domu (počet poschodí, výťah, stav a konštrukcia domu). Niektoré inzeráty obsahovali aj priamo GPS súradnice predávaného bytu. Tie inzeráty, ktoré uvádzali len adresu, na ktorej sa byt nachádza, sme manuálne geokodovali. Jeden inzerát neobsahoval žiadny údaj o polohe bytu, preto bol z ďalšej analýzy vylúčený. Nie všetky inzeráty však mali rovnakú štruktúru údajov, niektoré z nich nemali údaje v štruktúrovanej forme, boli uvedené len popisne, resp. neobsahovali ich vôbec. Preto sme všetky inzeráty manuálne prekontrolovali za pomoci fotografií interiéru. Tento problém sa týkal hlavne informácií o stave rekonštrukcie bytu. Preto sme sa rozhodli zostaviť škálový ukazovateľ stavu bytu. Ten nadobúda hodnoty od 0, čo predstavuje byt v pôvodnom stave, až po 9, čo predstavovalo kompletnú rekonštrukciu (vrátane novej kuchynskej linky, elektroinštalácie a pod.). Na analýzu používame 8 ukazovateľov: cena bytu, rozloha bytu, stav bytu, informáciu, či má byt balkón, pivnicu, či ide o panelový bytový dom, o malý dom (tri poschodia a menej), či je zateplený a či ide o novostavbu (po roku 2000). Tieto premenné sú štandardnými kontrolnými premennými, ktoré vyjadrujú kvalitatívne charakteristiky bytu a bytového domu (veľkosť, stav, vek, príslušnosť a pod.) a majú vplyv na cenu. Navyše sme použili dve premenné vyjadrujúce polohu bytu. Prvou bola vzdialenosť od centra mesta a informácia o tom, či sa byt nachádza v mestskej časti Veča, ktorá je oddelená od ostatnej časti mesta riekou. Premenné – cena bytu, rozloha bytu, stav bytu a vzdialenosť od centra – sú v modeli transformované do logaritmickej podoby.



Obr. 1. Byty na predaj v meste Šaľa

Zdroj: Vlastné spracovanie v programe QGIS (2015).

Tab. 1. Popis premenných a popisná štatistika

Premenná	Popis	Priemer	Medián	Min	Max
Cena	Cena za byt (v eurách)	46 132	45 500	21 490	83 500
Rozloha	Rozloha bytu (m ²)	63	68	19	89
Izby	Počet izieb v byte (1 = 14 %, 2 = 25 %, 3 = 54 %, 4 = 7 %)	2,5	3	1	4
Balkon	Byt má balkón nie (0) = 47 %, áno (1) = 53 %	0,5	1	0	1
Pivnica	Byt má pivnicu, resp. komoru nie (0) = 38 %, áno (1) = 62 %	0,6	1	0	1
Stav_bytu	Stav rekonštrukcie bytu	4,0	4	0	9
Byt_posch	Poschodie bytu	3,0	2	0	12
Novy	Dom je nový nie (0) = 94 %, áno (1) = 6 %	0,1	0	0	1
Konstru	Konštrukcia domu je panelová nie (0) = 20 %, áno (1) = 80 %	0,8	1	0	1
Zateplenie	Dom je zateplený nie (0) = 23 %, áno (1) = 77 %	0,8	1	0	1
Dom_posch	Počet poschodí domu	5,7	7	0	12
Vytah	Dom má výťah nie (0) = 36 %, áno (1) = 64 %	0,6	1	0	1
Vzdialenost	Vzdialenosť od centra mesta (km)	0,90	0,65	0,07	1,95
Veca	Nachádza sa byt v štvrti Veča? nie (0) = 70 % áno (1) = 30 %	0,30	0	0	1

Zdroj: Vlastné spracovanie.

EMPIRICKÝ MODEL

Zvyčajne sa na určenie hedonického modelu používa klasická OLS regresia. Môžeme definovať tri modely, ktoré sa líšia spôsobom zakomponovania polohy bytu do modelu. Model 1 je bez priestorových špecifikácií polohy bytu.

$$\ln \text{Cena}_i = b_0 + b_1 \ln \text{Rozloha}_i + b_2 \ln \text{Stav_bytu}_i + b_3 \text{Balkon}_i + b_4 \text{Pivnica}_i + b_5 \text{Kostruk}_i + b_6 \text{Zateplenie}_i + b_7 \text{Novy}_i + b_8 \text{Dom_maly}_i + \varepsilon_i$$

Model 2 definuje polohu bytu na základe kategorickej premennej lokalizácie bytu v mestskej časti Veča. Keďže vybavenosť občianskou infraštruktúrou, nákupnými možnosťami a verejnými službami je odlišná oproti ostatným častiam mesta, skúmame do akej miery má táto skutočnosť vplyv na cenu bytu.

$$\ln \text{Cena}_i = b_0 + b_1 \ln \text{Rozloha}_i + b_2 \ln \text{Stav_bytu}_i + b_3 \text{Balkon}_i + b_4 \text{Pivnica}_i + b_5 \text{Kostruk}_i + b_6 \text{Zateplenie}_i + b_7 \text{Novy}_i + b_8 \text{Dom_maly}_i + \text{Veca}_i + \varepsilon_i$$

Model 3 definuje polohu bytu na základe vzdialenosti bytu od centra mesta. Keďže, ako sme spomínali v úvodných častiach článku, musia vzdialenejšie domácnosti vynakladať vyššie transakčné náklady na dopravu za prácou a zábavou v centre mesta, tak skúmame, či sa to prejaví aj vo výslednej cene bytu.

$$\ln C_{eni} = b_0 + b_1 \ln R_{ozloha_i} + b_2 \ln S_{tav_bytu_i} + b_3 B_{alkon_i} + b_4 P_{ivnica_i} + b_5 K_{onstruk_i} + b_6 Z_{ateplenie_i} + b_7 N_{ovy_i} + b_8 D_{om_maly_i} + b_9 \ln V_{zdial_i} + \varepsilon_i$$

Výsledky ukazujú, že rozloha a stav bytu významne pozitívne ovplyvňujú jeho výslednú cenu. Vybavenie bytu pivnicou ani balkónom nie sú v modeloch štatisticky významnými faktormi. Zateplenie domu pozitívne a významne zvyšuje cenu bytu. Byty v nižších domoch sú podľa modelu lacnejšie, ale tento faktor nie je štatisticky významný v žiadnom modeli. Panelová konštrukcia domu znižuje cenu bytu, tento faktor nie je významný v modeli 3. Byty v nových domoch sú drahšie, ale ani tento faktor nie je v modeli 1 štatisticky významný.

Tab. 2. Výsledky regresie vplyvu hedonických charakteristík na cenu bytu (ln)

Vysvetľujúce premenné	Model 1	Model 2	Model 3
b_0	8,03*** (0,17)	8,01*** (0,16)	7,95*** (0,17)
$\ln R_{ozloha}$	0,60*** (0,04)	0,61*** (0,04)	0,61*** (0,04)
$\ln S_{tav_bytu}$	0,14*** (0,03)	0,11*** (0,03)	0,11*** (0,03)
<i>Balkon</i>	0,01 (0,03)	0,01 (0,03)	0,01 (0,03)
<i>Pivnica</i>	-0,01 (0,03)	-0,01 (0,03)	-0,01 (0,03)
<i>Dom_maly</i>	-0,02 (0,04)	-0,04 (0,04)	-0,03 (0,04)
<i>Konstruk</i>	-0,12** (0,04)	-0,10* (0,04)	-0,05 (0,04)
<i>Zateplenie</i>	0,21*** (0,03)	0,20*** (0,03)	0,20*** (0,03)
<i>Novy</i>	0,09 (0,07)	0,14* (0,07)	0,15* (0,07)
$\ln V_{zdial}$			-0,06** (0,02)
<i>Veca</i>		-0,10** (0,03)	
R2	0,81	0,83	0,83
R2adj	0,80	0,81	0,81
F statistics	48,2906***	47,9461***	46,7844***
AIC	-117,735	-125,484	-123,508
Log likelihood	67,867	72,742	71,754
Počet pozorovaní	97	97	97

Zdroj: Vlastné spracovanie v programe GeoDa (Anselin et al. 2005).

Poznámky:

– Závislá premenná $\ln C_{ena}$

– V zátvorke sú uvedené štandardné chyby.

* $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$

Zaujímali nás hlavne tie premenné, ktoré sa týkali polohy bytu v meste. Oba modely 2 a 3 s priestorovou premennou sú vo všeobecnosti lepšie z hľadiska vypovedacej schopnosti modelu. Hodnota koeficientu determinácie v modeloch 2 a 3 je vyššia ako v modeli 1 (0,83 oproti 0,81). Hodnoty Akaike information criteria (AIC) sú nižšie v modeloch 2 a 3 (-125,484, resp. -123,508) ako v modeli 1 (-117,735) a aj hodnoty log likelihood v modeli 2 a 3 (72,742, resp. 71,754) sú vyššie ako v modeli 1 (67,867), teda modely 2 a 3 sú spoľahlivejšie². Premenná Veča v modeli 2 je záporná a štatisticky významná ($p < 0,01$). Byty v mestskej časti Veča sú významne lacnejšie ako byty v Šali. Podobne aj premenná vzdialenosť od centra mesta je záporná a štatisticky významná ($p < 0,01$). Vzdialenejšie byty sú lacnejšie ako byty v blízkosti centra mesta.


Vidíme teda, že poloha bytu je významným determinantom jeho ceny. Viacerí autori ukázali, že keďže OLS regresia v hedonických modeloch prináša problémy s priestorovou autokoreláciou reziduí, na analýzu cien nehnuteľností navrhujú používať priestorový model (Osland 2010 a Herath a Maier 2013). V nasledujúcej časti budeme preto testovať modely na prítomnosť priestorovej autokorelácie a postavíme priestorový ekonometrický model.

PRIESTOROVÝ EKONOMETRICKÝ MODEL CIEN BYTOV

Analýza priestorovej autokorelácie vychádza zo stanovenia priestorovej matice váh. V našom prípade definujeme priestorovú maticu na základe metódy piatich najbližších susedov. Reziduá vo všetkých troch modeloch vykazovali významnú mieru priestorovej autokorelácie, teda prítomnosť priestorovej nestacionarity modelu. Hodnoty Moranovho I sú kladné, ide teda o pozitívnu priestorovú autokoreláciu a pohybujú medzi 0,19 v modeli 1 po 0,22 v modeli 2. To znamená, že v určitých častiach mesta sa model pravidelne „mýli“ v predikcii, pričom dochádza ku priestorovej koncentrácii vysokých alebo nízkych hodnôt reziduí. Obrázok 2 dokumentuje tieto zistenia. Vo všetkých troch modeloch je v juhozápadnej časti mesta priestorová koncentrácia nízkych hodnôt reziduí (nízke – nízke). V tejto časti mesta model predpovedal vysokú cenu nehnuteľností, ale v skutočnosti bola hodnota nižšia ako predikovaná (záporné reziduá). Rovnako vidíme, že v centre mesta je priestorová koncentrácia vysokých hodnôt reziduí (vysoké – vysoké), teda v tejto časti mesta boli skutočné ceny vyššie ako predpovedal model.

V predchádzajúcej časti sme videli, že model 2 môžeme považovať za najlepší (najvyššia vypovedacia schopnosť) a budeme z neho vychádzať v ďalšej analýze. Priestorový ekonometrický model je dôležité testovať, aby sa špecifikovalo, o ktorý druh priestorovej závislosti ide. Podľa Anselina a Reya (1991) v prípade, ak sú oba testy štatisticky významné, určuje vhodnú formu priestorovej závislosti test s nižšou hodnotou p . Výsledky jednoduchých Lagrange multiplier (LM) testov ukazujú, že obe priestorové závislosti sú vhodné, ale podľa robustného LM testu vidíme, že najvhodnejším modelom je autoregresný priestorový model s priestorovo oneskorenou závislou premennou.

² Obe štatistiky sa používajú pri hodnotení rozdielov v kvalite v prípade tzv. vnorených modelov, keď jeden model je podskupinou druhého modelu. Obe štatistiky sú založené na pravdepodobnosti modelov. *Akaike information criteria* (AIC) je relatívny odhad informačnej straty modelu. Model s nižším AIC je považovaný za lepší. Prostredníctvom AIC sa porovnáva kvalita modelu (*goodness of fit*) s komplexnosťou modelu (počet premenných). Podobne aj hodnota *log likelihood* sa používa na výber vhodného modelu z viacerých alternatív. Cieľom modelu je nájsť také hodnoty koeficientov, ktoré maximalizujú pravdepodobnosť vygenerovania údajov, ktoré používame. Model s vyššou hodnotou log likelihood je považovaný za lepší.



Obr. 2. Mapa priestorovej autokorelácie rezíduí modelov 1 až 3

Zdroj: Vlastné spracovanie v programe GeoDa (Anselin et al. 2005).

Tab. 3. Výsledky LM testov

Test	MI/DF	VALUE	PROB
Moran's I (error)	0,2183	4,809	0,0000
Lagrange multiplier (lag)	1	15,974	0,0001
Robust LM (lag)	1	5,173	0,0229
Lagrange multiplier (error)	1	13,462	0,0002
Robust LM (error)	1	2,661	0,1028
Lagrange multiplier (SARMA)	2	18,635	0,0001

Zdroj: Vlastné spracovanie v programe GeoDa (Anselin et al. 2005).

Môžeme preto postaviť model 4, ktorý vychádza z modelu 2 s priestorovo oneskorenou závislou premennou.

$$\ln C_{eni} = b_0 + \rho \sum_j W_{ij} \ln C_{en_j} + b_1 \ln Rozloha_i + b_2 \ln Stav_bytu_i + b_3 Balkon_i + b_4 Pivnica_i + b_5 Kostruk_i + b_6 Zateplenie_i + b_7 Novy_i + b_8 Dom_maly_i + b_7 \ln Vzdial_i + \varepsilon_i$$

Výsledky oboch modelov porovnáme v tab. 4. Model 4 môžeme považovať za model s lepšou vypovedacou schopnosťou v porovnaní s modelom 2. Hodnota AIC v modeli 4 je nižšia (-136,872) oproti modelu 2 (-125,484) a hodnota log likelihood modelu 4 (79,436) je vyššia oproti modelu 2 (72,742). Spomedzi všetkých modelov model 4 najlepšie vystihuje ekonomické procesy v pozadí tvorby ceny bytov v Šali. Hodnota priestorovo oneskorenej závislej premennej je pozitívna (0,32) a štatisticky významná ($p < 0,001$), to znamená, že cena bytu priamoúmerne závisí od ceny okolitých bytov. Hodnota ostatných ukazovateľov sa zmenila iba minimálne. Celkove vidíme mierny pokles hodnôt koeficientov v prípade ukazovateľov Dom_maly, Konstruk, Zateplenie, Novy a Veka. Minimálny nárast hodnôt koeficientov nastal v premenných lnStav_byt a Pivnica. Najvýznamnejšou zmenou

v modeli 4 oproti modelu 2 je zmena štatistickej významnosti ukazovateľa Dom_maly, ktorý sa stal štatisticky významným ($p < 0,05$).

Tab. 4. Porovnanie modelu 2 a modelu 2 s priestorovo oneskorenou premennou (model 4)

Vysvetľujúce premenné	Model 2	Model 4
b_0	8,01*** (0,16)	4,61*** (0,89)
lnRozloha	0,61*** (0,04)	0,61*** (0,04)
lnStav_byt	0,11*** (0,03)	0,12*** (0,02)
Balkon	0,01 (0,03)	0,01 (0,03)
Pivnica	-0,01 (0,03)	-0,00 (0,03)
Dom_maly	-0,04 (0,04)	-0,07* (0,03)
Konstruk	-0,10* (0,04)	-0,07* (0,03)
Zateplenie	0,20*** (0,03)	0,17*** (0,04)
Novy	0,14* (0,07)	0,12* (0,06)
Veca	-0,10** (0,03)	-0,08** (0,03)
W_lnCena		0,32*** (0,08)
R2	0,83	0,86 (pseudo)
R2adj	0,81	0,83 (pseudo)
F statistics	47,9461***	
AIC	-125,484	-136, 872
Log likelihood	72,742	79, 436
Počet pozorovaní	97	97

Zdroj: Vlastné spracovanie v programe GeoDa Space.

Poznámky:

– Závislá premenná lnCena

– V zátvorke sú uvedené štandardné chyby.

* $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$

DISKUSIA K VÝSLEDKOM

Ako sme ukázali, poloha nehnuteľnosti v meste je dôležitým determinantom jej výslednej ceny. Cenu bytu tak určujú nielen vzdialenosť od centra, lokalizácia v mestskej časti, charakteristickej určitým mixom občianskej vybavenosti, ale aj ceny susediacich bytov. Ako ukázal náš model, byty, ktoré sú vzdialenejšie od centra, sú lacnejšie. Nárast vzdialenosti od centra mesta o jedno percento znižuje ponukovú cenu bytu o 0,06 percent (model 3). Analýza zároveň ukázala, že byty v samostatnej mestskej časti Veča sú významne lacnejšie, v priemere o 10 percent

(model 2). Nižšie ceny bytov v mestskej časti Veča sú výsledkom kombinácie lokálnych charakteristík a súčasne väčšej vzdialenosti od centra mesta. Táto mestská časť je charakteristická nižšou kvalitou občianskej vybavenosti a vyššou hustotou zástavby s horšími možnosťami parkovania. V našej analýze nie je možné odlišiť, ktorý faktor je významnejší, pretože kombináciou oboch faktorov v jednom modeli sa oba faktory stanú štatisticky nevýznamnými, čo je výsledok vzájomnej kolinearít premenných.

Podstatná časť našej analýzy sa zamerala na modelovanie vzťahu cien susediacich nehnuteľností. Ukázali sme, že v našom prípade je vhodný model s priestorovo oneskorenou závislou premennou. Model s priestorovým oneskorením popisuje závislosť medzi cenami susediacich nehnuteľností, pričom sa táto závislosť môže interpretovať z pohľadu viacerých ekonomických procesov. Na jednej strane môže byť výsledkom informačného efektu. Ak si predávajúci nie je istý hodnotou nehnuteľnosti, z hľadiska jej charakteristík alebo hodnoty samotnej lokality, stanovuje cenu na základe ceny podobnej blízkej nehnuteľnosti, ktorá je v predaji, resp., ktorá sa nedávno predala. Osland (2010) uvádza, že efekt vzájomného ovplyvňovania cien susediacich nehnuteľností môže byť tiež výsledkom tzv. snobskej hodnoty lokality. Investície do renovácie nehnuteľnosti majú vplyv aj na susediace nehnuteľnosti. Investície bohatších domácností do rekonštrukcie nehnuteľnosti zvyšujú hodnotu ostatných nehnuteľností, čím vytlačujú menej majetných potenciálnych kupcov a menia sociálnu skladbu obyvateľstva v lokalite. Opačný proces prebieha v prípade, keď dochádza k devastácii niektorých bytov v bytových domoch. Tá znižuje aj cenu okolitých bytov, čím sa stávajú výhodnejšie pre domácnosti s nižšími príjmami. V našom prípade sme pozorovali priestorovú koncentráciu negatívnych rezíduí v určitej časti mesta, ktorá je charakteristická koncentráciou sociálne slabších skupín obyvateľstva s nižším štandardom bývania. Napriek tomu, že rozloha, vybavenosť a ostatné charakteristiky bytu boli porovnateľné s bytmi v inej časti mesta, skutočná cena bola nižšia pre spomínané negatívne externality. S využitím priestorového ekonometrického modelu s priestorovo oneskorenou premennou sme tento efekt odhadli. Jednopercentné zvýšenie priemernej ceny piatich susediacich bytov zvyšuje cenu bytu približne o 0,3 percenta.

Druhá oblasť diskusie smeruje k robustnosti výsledkov. Voľba priestorovej štruktúry modelu je subjektívnym rozhodnutím. Voľba vyjadruje našu predstavu o tom, akým spôsobom prebiehajú ekonomické efekty a aké údaje máme k dispozícii. Ako upozorňuje Lesage (2014), je chybné sa domnievať, že malé zmeny v špecifikácii váh priestorovej matice budú mať za výsledok veľké zmeny v modeli. Lesage (2014) odporúča preferovať tzv. riedke matice susedstva, t. j. matice, kde je veľká časť hodnôt nulová. Matice susedstva sa často definujú na základe funkcie klesajúcej vzdialenosti, ktorej výsledkom je, že predpokladáme určitú formu interakcie aj pre veľmi vzdialených susedov. Preto je skôr vhodné určiť tzv. bod zlomu, alebo definovať susedstvo na základe metódy najbližších susedov. V tabuľke 5 môžeme ukázať, do akej miery sú výsledky našej analýzy citlivé na spôsob definovania priestorovej štruktúry modelu. Porovnávame štyri rôzne definované priestorové matice: jeden sused, dvaja susedia, piati susedia a definovanie susedstva na základe vzdialenosti. Vzdialenosť 159 metrov predstavuje takú vzdialenosť, keď má každé pozorovanie aspoň jedného suseda.

Hodnota Moranovho I je síce stále pozitívna, ale v prípade jedného suseda štatisticky nevýznamná. Testy Lagrange multiplier overujú nulovú hypotézu neexistencie priestorovej autokorelácie. V prípade robustnej verzie LM testu je nulová

Tab. 5. Vplyv rôzne definovaných matíc susedstva na priestorovú autokoreláciu v modeli 2

	1 sused			3 susedia			5 susedia			159 metrov		
	MI/DF	Value	Prob	MI/DF	Value	Prob	MI/DF	Value	Prob	MI/DF	Value	Prob
Moran's I (error)	0,1512	1,591	0,1116	0,2470	3,961	0,0001	0,2183	4,809	0,0000	0,0976	2,287	0,0222
Lagrange multiplier (lag)	1	4,614	0,0317	1	11,586	0,0007	1	15,974	0,0001	1	3,116	0,0775
Robust LM (lag)	1	3,203	0,0735	1	3,752	0,0527	1	5,173	0,0229	1	1,217	0,2700
Lagrange multiplier (error)	1	1,424	0,2327	1	10,315	0,0013	1	13,462	0,0002	1	2,183	0,1396
Robust LM (error)	1	0,013	0,9108	1	2,481	0,1152	1	2,661	0,1028	1	0,283	0,5944
Lagrange multiplier (SARMA)	2	4,627	0,0989	2	14,067	0,0009	2	18,635	0,0001	2	3,399	0,1827

Zdroj: Vlastné spracovanie v programe GeoDa Space.

hypotéza, že sa hodnota p rovná 0 a ide teda o SAM lag model, resp. že $\lambda = 0$ a ide o SAR model. Tak ako navrhuje Anselin (1988), v prípade, ak nie je ani jeden zo štandardných LM testov štatisticky významný, tak nie je potrebné uskutočniť priestorovú regresiu. Ak niektorý zo štandardných testov je štatisticky významný a druhý nie, realizuje sa model, ktorý zamietá nulovú hypotézu. V prípade, ak sú oba štandardné testy štatisticky významné, tak sa uskutočňujú robustné LM testy. Ak je významný iba jeden z nich, uskutočníme zodpovedajúci model, ak sú významné oba robustné LM testy, potom uskutočníme model s vyššou hodnotou testovacej štatistiky. V našom prípade vidíme, že napriek tomu, že hodnoty testovacích štatistik sa vo všetkých modeloch líšia, v modeloch založených na susedstve všetky testy navrhujú priestorový SAM model. Jedinou výnimkou je posledná matica, v ktorej nie sú testy štatisticky významné. Ako sme už uviedli, je vhodnejšie definovať takú maticu, ktorá je tzv. riedka. Matica zostavená na základe hraničnej vzdialenosti je významne hustejšia, v našom prípade je najčastejší počet susedov pozorovania 12. Aj vzhľadom na túto skutočnosť sme navrhli model 4, kde je matica susedstva definovaná na základe päť najbližších susedov. Aj ekonomická intuícia nám naznačuje, že predávajúci skôr porovnávajú cenu s niekoľkými najbližšími ponukami, ako by skúmali všetky ponuky v určitom okruhu.

ZÁVER

Cieľom článku bolo preskúmať vplyv polohy bytu v meste na jeho výslednú cenu. S využitím hedonických modelov cien sme zostrojili štyri modely, ktoré popisujú vplyv polohy bytu na jeho výslednú cenu rôznym spôsobom. Vzhľadom na problémy štandardnej OLS regresie sme v prípade hedonických modelov zostrojili priestorový ekonometrický model, ktorý umožnil preskúmať aj význam lokálnych charakteristík, resp. vzájomný vplyv susediacich nehnuteľností na ich cenu. Naš výskum ukázal, že modely, ktoré obsahovali priestorovú informáciu ako nezávislú premennú, majú vo všeobecnosti vyššiu vypovedaciu hodnotu. Vzdialenosť od centra, ako aj lokalizácia bytu v samostatnej mestskej časti boli štatisticky významnými faktormi ceny bytu. Zahŕnutie týchto premenných nemalo významný vplyv na ostatné premenné v modeli. Pomocou testov založených na priestorovej autokorelácii sme zostavili priestorový ekonometrický model s priestorovo oneskorenou závislou premennou. Tento model bol na základe testov vyhodnotený ako najvhodnejší. Ukázali sme, že cena bytov v našom modeli ovplyvňuje cenu ostatných bytov v ich okolí. Na základe priestorovej autokorelácie rezíduí môžeme zároveň odhadnúť lokálne špecifiká cien nehnuteľností v meste. Ďalší výskum by sa mohol zamerať na analýzu dlhšieho časového obdobia, pričom hedonické modely by sa dali využiť na skúmanie zmien cien nehnuteľností v jednotlivých lokalitách v meste v závislosti napr. od investícií do mestskej regenerácie (parky, doprava a pod.).

LITERATÚRA

- ALONSO, W. (1964). *Location and land use*. Cambridge (Harvard University Press).
 ANSELIN, L. (1988). *Spatial econometrics: methods and models*. Dordrecht (Kluwer Academic Publishers).
 ANSELIN, L. (2003). Spatial externalities, spatial multipliers, and spatial econometrics. *International Regional Science Review*, 26, 153-166.
 ANSELIN, L., REY, S. (1991). Properties of tests for spatial dependence in linear regression models. *Geographical Analysis*, 23, 112-131.

- ANSELIN, L., SYABRI, I., KHO, Y. (2005). GeoDa: an introduction to spatial data analysis. *Geographical Analysis*, 38, 5-22.
- BURGESS, E. W. (1925). The growth of the city. In Park, R. E., Burgess, E. W., McKenzie, R. D., eds. *The city*. Chicago (University of Chicago Press).
- CÁR, M. (2009). Výber faktorov ovplyvňujúcich cenu nehnuteľností na bývanie na Slovensku. *Biatec*, 17(3), 2-8.
- FARBER, S., YEATES, M. (2006). A comparison of localized regression models in a hedonic house price context. *Canadian Journal of Regional Science*, 29, 405-420.
- FREEMAN, A. (1979). Hedonic prices, property values and measuring environmental benefits: a survey of the issues. *Scandinavian Journal of Economics*, 81, 154-173.
- HENNEBERRY, J. (1998). Transport investment and house prices. *Journal of Property Investment & Finance*, 16, 144-158.
- HERATH, S., MAIER, G. (2010). *The hedonic price method in real estate and housing market research. A review of the literature*, [Online]. Dostupné na: < <http://epub.wu.ac.at/588/> [cit. 05-02-2015].
- HERATH, S., MAIER, G. (2013). Local particularities or distance gradient: what matters most in the case of the Viennese apartment market? *Journal of European Real Estate Research*, 6, 163-185.
- CHESHIRE, P., SHEPPARD, S. (1989). British planning policy and access to housing: some empirical estimates. *Urban Studies*, 26, 469-485.
- LESAGE, J. (2014). What regional scientists need to know about spatial econometrics. *The Review of Regional Studies*, 44, 13-32.
- LESAGE, J., PACE, R. (2009). *Introduction to spatial econometrics*. Boca Raton (CRC press).
- LYNCH, A. K., RASMUSSEN, D. W. (2001). Measuring the impact of crime on house prices. *Applied Economics*, 33, 1981-1989.
- McMILLEN, D. (2003). Spatial autocorrelation or model misspecification? *International Regional Science Review*, 26, 208-217.
- OSLAND, L. (2010). An application of spatial econometrics in relation to hedonic house price modeling. *Journal of Real Estate Research*, 32, 289-320.
- O'SULLIVAN, A. (2009). *Urban economics*. New York (McGraw-Hill Europe).
- RIDKER, R. G., HENNING, J. A. (1967). The determinants of residential property values with special reference to air pollution. *The Review of Economics and Statistics*, 49, 246-257.
- ROSEN, S. (1974). Hedonic prices and implicit markets: product differentiation in pure competition. *Journal of Political Economy*, 82, 34-55.
- THALER, R. (1978). A note on the value of crime control: evidence from the property market. *Journal of Urban Economics*, 5, 137-145.
- WATKINS, C. A. (2001). The definition and identification of housing submarket. *Environment and Planning A*, 33, 2235-2253.

Štefan Reháč

THE LOCATION OF AN APARTMENT AND ITS PRICE: A SPATIAL HEDONIC MODEL

The aim of the paper is to examine the relationship between the location of an apartment and its price. Hedonic models of apartment prices, which allow exploration of the effect of attributes of apartments, apartment buildings and their location on the market price, were used. The analysis uses the data from 97 apartments for sale in the town of Šaľa published on line on the website (www.reality.sme.sk) during December 2014 – January 2015. Although the price of the apartment listed in the advertisement cannot be treated as a transaction price, for the purpose of our research it is an appropriate proxy. The information listed in the advertisement includes price and all attributes of the apartment including its position.

Following indicators were used in the hedonic model: information on the apartment – price, apartment area, condition of the apartment, availability of balcony and basement; information on the building – type of construction, number of floors, insulation and age. In the first part of the article the apartment's location in terms of distance from the city centre and the location of the apartment in the town district are defined. Four models that analyse the location impact of the apartment in the city have been constructed. Our research has shown that models that contain information on the location as independent variable have a higher information value. As shown by our models, apartments that are more distant from the town centre are cheaper. An increase in distance from the centre by 1 km reduces the offering price of the apartment by 0.06 percent. The analysis also showed that apartments in separate district Veča are cheaper by an average of 11 percent. A substantial part of our analysis has focused on modelling the relationship of adjacent apartment prices. Based on the spatial autocorrelation analysis of residuals a spatial econometric model with spatially lagged dependent variable has been designed. The results showed that the price of an apartment in proportion depends on the price of the neighbouring apartments. Investments in renovation of apartments but also apartment depreciation can affect the prices of apartments in their neighbourhood. One percent increase/decrease of the mean value of five neighbouring apartments led to 0.3 percent increase/decrease of the apartment's price.

