

Andrzej Muczyński, Magdalena Kołek

Modelowanie czynszu najmu lokali użytkowych gminy z zastosowaniem sztucznych sieci neuronowych

Acta Scientiarum Polonorum. Administratio Locorum 6/2, 55-67

2007

Artykuł został opracowany do udostępnienia w internecie przez Muzeum Historii Polski w ramach prac podejmowanych na rzecz zapewnienia otwartego, powszechnego i trwałego dostępu do polskiego dorobku naukowego i kulturalnego. Artykuł jest umieszczony w kolekcji cyfrowej bazhum.muzhp.pl, gromadzącej zawartość polskich czasopism humanistycznych i społecznych.

Tekst jest udostępniony do wykorzystania w ramach dozwolonego użytku.

MODELOWANIE CZYNSZU NAJMU LOKALI UŻYTKOWYCH GMINY Z ZASTOSOWANIEM SZTUCZNYCH SIECI NEURONOWYCH

Andrzej Muczyński, Magdalena Kołek

Uniwersytet Warmińsko-Mazurski w Olsztynie

Streszczenie. W pracy przedstawiono wyniki badań własnych w zakresie zastosowania sztucznych sieci neuronowych do określenia modeli rynkowych stawek czynszu najmu lokali użytkowych z zasobu wybranej gminy miejskiej. Procedura badawcza polega na wytrenowaniu wybranych sieci na danych z lokalnego rynku nieruchomości i przetransformowaniu wykrytych zależności – za pośrednictwem ustalonych modeli – do oszacowania potencjalnych stawek rynkowego czynszu najmu lokali komunalnych. Na tej podstawie dokonano oceny stopnia adekwatności rynkowej rzeczywistych stawek czynszu najmu lokali gminnych o funkcjach handlowych, usługowych, magazynowych i użyteczności publicznej. Badania empiryczne przeprowadzono na obszarze lokalnego rynku nieruchomości miasta Olsztyna. Do opisu zjawiska kształtowania się rynkowego czynszu najmu lokali użytkowych wytypowano jednokierunkowe sieci trzywarstwowe oraz sieci o radialnych funkcjach bazowych. Analizy wykazały relatywnie niski stopień zbieżności rzeczywistych czynszów najmu lokali komunalnych z odpowiednimi czynszami wyznaczonymi potencjalnie przez rynek. Stopień ten był mocno zróżnicowany w zależności od rodzaju prowadzonej działalności w lokalu i oceny jej wpływu na społeczeństwo i gospodarkę miejską. Zastosowana metodyka badań i uzyskane wyniki mogą być wykorzystane do racjonalizacji gospodarki gminnymi zasobami lokalowymi, w tym do aktywizacji polityki czynszowej.

Słowa kluczowe: gospodarowanie nieruchomościami gminnymi, rynek, sieci neuronowe

WPROWADZENIE

W obecnych warunkach racjonalne gospodarowanie gminnymi zasobami nieruchomości stanowi problem o złożonym charakterze. Dotyczy to zwłaszcza komunalnych zasobów lokali użytkowych, gdyż duże zróżnicowanie lokalizacyjne i funkcjonalne tych obiektów wymaga elastycznego podejścia w procesie ich wynajmowania opartego na

Adres do korespondencji – Corresponding author: Andrzej Muczyński, Katedra Gospodarki Nieruchomościami i Rozwoju Regionalnego, Uniwersytet Warmińsko-Mazurski w Olsztynie, ul. Prawocheńskiego 15, 10-724 Olsztyn, e-mail: amucz@uwm.edu.pl

właściwym wyważeniu interesu społecznego i ekonomicznego gminy jako właściciela. Część z tych zasobów służy bowiem do realizacji zadań własnych gminy z zakresu użyteczności publicznej. Przykładem tego typu obiektów są lokale wykorzystywane na cele kulturalno-oświatowe (szkoły, przedszkola, ośrodki kultury), opieki społecznej, czy też służby zdrowia (jak np.: przychodnie zdrowia, gabinety lekarskie). W zasobach komunalnych znajdują się ponadto lokale, które są wynajmowane na cele prowadzenia działalności wykraczającej poza sferę użyteczności publicznej – tzn. działalności strictly komercyjnej (jak np. handel czy usługi). Lokale takie spełniają funkcje typowych obiektów komercyjnych, a dochody z ich wynajmu stanowią znaczące uzupełnienie wpływów budżetowych. W tym kontekście, jeden z głównych problemów gospodarowania gminnymi zasobami lokali użytkowych stanowi kreowanie właściwego poziomu czynszu najmu. Wybór właściwej stawki czynszu winien uwzględniać – z jednej strony – rodzaj działalności, jaka będzie prowadzona w obiekcie oraz walory położenia i cechy techniczno-użytkowe lokalu. Z drugiej strony, proces kształtowania odpowiednich stawek czynszu najmu znacznej części lokali użytkowych gminy musi być powiązany z wynikami analizy stanu i tendencji panujących na lokalnym rynku nieruchomości.

Celem głównym pracy jest zastosowanie metod sztucznej inteligencji do określenia modeli rynkowych stawek czynszu najmu lokali użytkowych z zasobu wybranej gminy miejskiej. Przyjęto hipotezę, że sztuczne sieci neuronowe stanowią użyteczne narzędzie opisu (modelowania) lokalnego rynku najmu nieruchomości lokalowych. Wynika to z ich możliwości wykrywania zależności rynkowych, uczenia się tych zależności i zapamiętywania, a następnie wykorzystywania poznanych związków do poprawnego rozwiązywania zadań. W pierwszym etapie badań wybrane typy sieci neuronowych posłużą do zokodowania związków i zależności determinujących kształtowanie się rynkowych stawek czynszu najmu lokali użytkowych stanowiących własność prywatną. Następnie, tak określone prawidłowości zostaną przeniesione – za pośrednictwem wyuczonych sieci – do określenia modelowanych stawek rynkowego czynszu najmu lokali użytkowych gminy. Porównanie rzeczywistych stawek czynszu najmu z ich modelami rynkowymi pozwoli na ocenę stopnia rynkowej adekwatności czynszu najmu w wybranych grupach lokali komunalnych.

METODYKA I PRZEBIEG BADAŃ

Sieci neuronowe powstały w efekcie badań prowadzonych w dziedzinie sztucznej inteligencji. Istotne znaczenie przypisuje się pracom dotyczącym budowy modeli struktur występujących w mózgu. Miały one na celu naśladowanie tych cech biologicznych systemów nerwowych, które mogą być technicznie użyteczne. Do katalogu takich cech zalicza się przede wszystkim odporność systemów biologicznych na uszkodzenia oraz ich nadzwyczajną zdolność do uczenia się [StatSoft... 2001]. Sztuczne sieci neuronowe, jako jedna z metod sztucznej inteligencji, posiadają możliwości analizowania dużych ilości informacji w sposób szybki i równoległy, z czego każda zmienna może być prezentowana z wykorzystaniem wielu poziomów wartości. Wykazują one zdolność odtwarzania zachowań z ciągu uczącego, potrafią generować na tej podstawie wnioski, zapamiętywać je

i wykorzystywać oraz posiadają umiejętność generalizacji. Te właściwości sieci sprawiają, że mogą one być stosowane do analizy procesów zachodzących na rynku nieruchomości [Wiśniewski 1999].

Metodykę badań oparto na założeniu, że procedura modelowania rynkowych stawek czynszu najmu zostanie zrealizowana na wybranym obszarze lokalnego rynku najmu nieruchomości lokalowych o funkcjach użytkowych. Obszar ten winien charakteryzować się współwystępowaniem lokali użytkowych stanowiących własność gminy (wynajmowanych według stawek „komunalnych”) i podobnych do nich – pod względem istotnych cech wartości użytkowej i położenia – lokali użytkowych z zasobów prywatnych (wynajmowanych według stawek rynkowych). Istota zastosowania sieci neuronowych polega na wykorzystaniu danych o transakcjach najmu ze zbioru nieruchomości prywatnych do wykrycia i nauczenia sieci empirycznych prawidłowości zachodzących na lokalnym rynku najmu, a następnie na podaniu na wejście tak wytrenowanych sieci odpowiednich atrybutów lokali użytkowych gminy. W ten sposób sieci neuronowe estymują modelowane stawki rynkowego czynszu najmu lokali komunalnych, czyli takie stawki, jakie można byłoby potencjalnie osiągnąć, gdyby lokale te wynajmowali prywatni właściciele.

Badania empiryczne przeprowadzono na obszarze lokalnego rynku najmu miasta Olsztyna. Materiał obserwacyjny opisujący poszczególne umowy najmu dotyczył stawek obowiązujących w 2005 roku. Na początku przeanalizowano cechy położenia i dane dotyczące stanu techniczno-funkcjonalnego lokali komunalnych, a także dostępne bazy informacji o najmie lokali prywatnych. Po wstępnym rozpoznaniu przedmiotu analiz dalsze etapy badawcze przebiegały zgodnie z niżej przedstawioną procedurą.

Przygotowanie danych do analiz

Po zgromadzeniu danych surowych charakteryzujących obiekty i stawki czynszu najmu w obu zbiorach badanych lokali pierwszym problemem metodycznym było wytypowanie zestawu zmiennych, które powinny uczestniczyć w procesie trenowania sieci, a także określenie niezbędnej liczby obserwacji. Dokonując wyboru zestawu atrybutów opisujących rynkowy poziom czynszu najmu nieruchomości lokalowych kierowano się wskazaniem literatury przedmiotu [Masters 1996], wynikami wcześniejszych badań, a także dostępnością i wiarygodnością pozyskania danych. Wstępnie wytypowany zestaw zmiennych mogących potencjalnie tworzyć wektor wejść sieci neuronowej został następnie zweryfikowany metodami analizującymi wpływ poszczególnych zmiennych na zmienną objaśnianą, którą stanowiła jednostkowa stawka rynkowego czynszu najmu netto miesięcznie. Praktycznie wykorzystano metodę regresji kroczącej, algorytmy genetyczne i metodę analizy wrażliwości. Obliczenia przeprowadzono programem STATISTICA Neural Networks firmy StatSoft Polska. Ustalony zbiór zmiennych wejściowych i ich kwantyfikację zawarto w tabeli 1.

Tabela 1. Wykaz zmiennych objaśniających przyjętych do analizy oraz ich kwantyfikacja
 Table 1. List of independent variables selected to the analysis and registration

Lp.	Rodzaj zmiennej objaśniającej Type of independent variable	Sposób kwantyfikacji Means of registration
1	Oddalenie lokalu od centrum miasta Distance of the premises from the downtown	Odległość w km, mierzona w linii prostej od przedmiotowej nieruchomości do centrum miasta
2	Powierzchnia użytkowa lokalu Permitted usable floor space	Wyrażona liczbą m ²
3	Strefa lokalizacyjna miasta City locational zone	Podział miasta na dwie strefy lokalizacyjne wg właściwej uchwały Rady Miasta Olsztyna: 1 – strefa pierwsza, 2 – strefa druga

Zmienne te wyznaczono niezależnie w podzbiorach lokali handlowych, usługowych, magazynowych i użyteczności publicznej. Ostatnim krokiem na etapie przygotowania danych było podzielenie zbioru danych na podzbiory: uczący, walidacyjny i testowy [Tadeusiewicz 1993]. Do tego celu wykorzystano automatycznego projektanta wskazanego programu, który dokonał losowego zaszerzegowania obserwacji do każdego z wymienionych podzbiorów odpowiednio w proporcjach 2:1:1.

Zaprojektowanie i wybór odpowiedniej struktury sztucznych sieci neuronowych

Projektowanie sieci, po ustaleniu zbioru zmiennych wejściowych, wymaga realizacji sekwencji kilku dalszych kroków. Najpierw należy dokonać wyboru początkowej struktury sieci, po czym iteracyjnie przeprowadza się szereg eksperymentów z każdą konfiguracją sieci zachowując konfigurację najlepszą z punktu widzenia błędu walidacyjnego [StatSoft... 2001]. Eksperymentów potrzebnych do znalezienia najlepszej sieci trzeba wykonać relatywnie dużo. Aby uniknąć pomyłek wskutek zatrzymywania się algorytmu w minimum lokalnym zaleca się, aby z każdą możliwą strukturą sieci przeprowadzić kilka eksperymentów. Jeśli wyniki eksperymentu świadczą o niedouczeniu sieci, wówczas należy dodać nowe neurony ukryte lub całą nową warstwę ukrytą. Natomiast w sytuacji, gdy pojawi się zjawisko przeuczenia sieci (błąd walidacyjny zacznie znacząco wzrastać przed osiągnięciem zadowalającego poziomu wytrenowania sieci), należy usunąć pewną liczbę neuronów ukrytych (lub całych ich warstw). Po znalezieniu zadowalającej konfiguracji sieci należy dokonać takiego próbkowania, aby otrzymać nowe sieci o ustalonej konfiguracji.

W pierwszej fazie badań trenowaniu poddano modele sieci jednokierunkowych trzy- i czterowarstwowych, sieci liniowych, a także sieci o radialnych funkcjach bazowych. Zbiory wag wyjściowych inicjowano losowo z zakresu od -1 do 1. Parametry uczenia dobierano wykorzystując przybliżenia iteracyjne. Do optymalizacji wykorzystano algorytmy wstecznej propagacji błędów oraz gradientów sprzężonych, a także metodę Levenberga-Marquardta. Po przetestowaniu kilkudziesięciu różnych modeli, stwierdzono, że badane zjawisko najlepiej odwzorowują modele perceptronu trzywarstwowego (MLP) i modele

o radialnych funkcjach bazowych (RBF) oraz niektóre zbiory tych sieci. Wybrane typy sieci charakteryzowały się najlepszą architekturą spośród analizowanych, a ponadto proces ich uczenia i testowania był umiarkowanie krótki. Szczegółowe złożenia, na podstawie których wybrano konkretne sieci opisujące modelowane stawki rynkowego czynszu najmu lokali użytkowych miasta Olsztyna przedstawiono w pracy [Kolek 2006].

Ocena uzyskanych wyników

Do wyboru najlepszej struktury estymowanych sieci można wykorzystać standardowe mierniki, jakie są dostępne w programie STATISTICA Neural Networks, a mianowicie: błąd dopasowania modelu dla zbioru uczącego i walidacyjnego (eliminacja przetrenowania sieci), a także iloraz odchyień i współczynnik dopasowania modelu (kryterium korelacji).

Po wyznaczeniu modelowanych stawek rynkowego czynszu najmu w badanym zbiorze lokali użytkowych gminy za pomocą poprawnie wytrenowanych sieci neuronowych możliwe było przejście do ostatniego etapu badań, jaki stanowiła ocena rynkowej adekwatności czynszu najmu lokali komunalnych. Ocenę oparto na pomiarze stopnia zgodności rzeczywistych stawek czynszu najmu lokali gminy z modelowanymi stawkami rynkowego czynszu najmu tych lokali – wyznaczonymi przy pomocy sieci neuronowych. Jako miernik zgodności przyjęto wskaźnik rynkowej adekwatności czynszu najmu A_2 , wyrażony wzorem [Muczyński 2006]:

$$A_2 = \left(1 - \frac{R(Ck) - Ck}{R(Ck)}\right) \cdot 100\%,$$

gdzie:

- A_2 – wskaźnik adekwatności rynkowej czynszu najmu lokalu użytkowego gminy (w %);
- Ck – rzeczywista stawka czynszu najmu lokalu użytkowego gminy (w zł·m⁻²);
- $R(Ck)$ – modelowana stawka rynkowego czynszu najmu lokalu użytkowego gminy (w zł·m⁻²);

Wskaźnik A_2 zdefiniowano w taki sposób, aby wyrażał on względny stopień zgodności rzeczywistego czynszu najmu lokalu komunalnego z jego rynkowym modelem $R(Ck)$. Stawka modelowana czynszu najmu wybranego lokalu określana jest w wyniku podania atrybutów lokalu (z tabeli 1) na wejście wytrenowanych modeli sieci neuronowych. Zakres zmienności wskaźnika A_2 mieści się w przedziale od 0 do 100%. Wartość maksimum przyjmuje on przypadku, gdy rzeczywisty czynsz najmu danego lokalu komunalnego osiągnie poziom potencjalnego czynszu rynkowego dla tego lokalu odwzorowanego modelem sieci. Z kolei dolna granica wartości tego wskaźnika (na poziomie 0%) ma charakter czysto teoretyczny, gdyż może wystąpić w sytuacji spadku czynszu najmu lokalu gminy do poziomu zerowego.

Tabela 2. Podstawowe charakterystyki uzyskanych modeli sieci neuronowych
Table 2. Basic characteristics of achieved neural network models

Typ sieci Net type	Jakość uczenia Training quality	Jakość walidacji Quality of validation	Jakość testowania Testing quality	Błąd uczenia Training error	Błąd walidacji Validation error	Błąd testowania Testing error	Uczenie/ składniki Training/components
MLP 4:7-15-1:1	0,75754	0,88585	0,72776	0,20018	0,22191	0,18257	BP100,CG24b
MLP 4:6-6-1:1	0,75376	0,80462	0,76822	0,14344	0,17121	0,14758	BP100,CG22b
MLP 4:6-20-1:1	0,77267	0,74244	0,82738	0,11885	0,10624	0,11602	BP621b
MLP 4:6-8-1:1	0,73994	0,75846	0,82506	0,18550	0,18090	0,20073	BP100,CG20,CG9b
Wyj. 3:[5]:1	0,75963	0,81813	0,79541	0,12222	0,14535	0,13461	1-5


WYNIKI BADAŃ

W efekcie realizacji procedury modelowania ze zbioru powstałego w trakcie uczenia wybrano pięć najlepszych modeli sieci. W tabeli 2 przedstawiono podstawowe charakterystyki tych modeli.

Typ sieci przedstawia charakterystykę struktury uzyskanego modelu. Format zapisu jest następujący: $\langle typ \rangle \langle wejść \rangle : \langle warstwa1 \rangle - \langle warstwa2 \rangle - \langle warstwa3 \rangle : \langle wyjść \rangle$. Przykładowo, kod MLP4:6-6-1:1 oznacza perceptron wielowarstwowy z czterema zmiennymi wejściowymi i jedną wyjściową, o trzech warstwach – odpowiednio: z sześcioma neuronami w dwóch pierwszych warstwach i jednym neuronem w ostatniej. Jak wynika z tabeli, zadanie predykcji rynkowego czynszu najmu najlepiej wypełniły cztery sieci jednokierunkowe wielowarstwowe (typu MLP). Zakwalifikowany do zbioru piąty model (oznaczony jako: „Wyj.”) reprezentuje zespół sieci składający się z kombinacji sieci liniowej, dwóch sieci typu MLP i dwóch sieci typu RBF. Każda z wybranych sieci posiada jedną warstwę ukrytą, w której znajdują się neurony ukryte w liczbie odpowiednio: od 2 do 20 (sieci typu MLP) i od 11 do 38 (sieci typu RBF). W kolumnach 2–4 tabeli 2 przedstawiono mierniki jakości sieci wyznaczone w trakcie procesu jej uczenia dla zbioru uczącego, walidacyjnego i testowego. Mierniki zbioru walidacyjnego posłużyły za podstawę selekcji i wyboru najlepszej sieci. W przypadku zmiennych ciągłych (sieci regresyjne) właściwą miarę jakości sieci stanowi iloraz odchyleń standardowych. Iloraz ten jest miarą poprawy jakości modelu i jego wartość winna być mniejsza od 1. Im lepsza sieć tym iloraz odchyleń jest bliższy zeru. Wytypowane sieci prezentowały najniższe ilorazy odchyleń jakie udało się uzyskać w procesie uczenia. Następne kolumny tabeli 2 prezentują błędy sieci uzyskane w trakcie uczenia w podzbiorach danych. Są to błędy wyznaczone na podstawie wartości błędów jednostkowych obliczonych za pomocą przyjętej funkcji błędu, którą stanowiła suma kwadratów różnic między otrzymaną i rzeczywistą wartością wyjścia. Odpowiadające sobie wielkości błędów w podzbiorach walidacyjnych i testowych są porównywalne i jednocześnie relatywnie niskie. Oznacza to, że wybrane sieci dobrze generalizują wiedzę zawartą w przypadkach uczących. W ostatniej kolumnie tabeli 2 przedstawiono symboliczne opisy strategii uczenia poszczególnych sieci (algorytmów uczących). Podano tu kody algorytmów i liczby epok algorytmów iteracyjnych, a także, opcjonalnie kod sposobu wybrania najlepszej sieci. Przykładowo, kod CG24b oznacza, że używany był algorytm gradientów sprzężonych (CG), po czym wybrano najlepszą sieć (b), a otrzymano ją w 24 epoce. Z kolei symbol BP100CG24b oznacza: 100 epok uczenia wsteczną propagacją (BP), po których nastąpiły 24 epoki uczenia metodą gradientów sprzężonych, kiedy to sieć zaczęła się przeuczać.

Ustalone modele sieci neuronowych eksploatowane mogą być dla dowolnych wartości wejściowych. W rozpatrywanych badaniach na wejścia sieci podano dane charakteryzujące lokale użytkowe miasta Olsztyna. Zbiór zaprezentowany na wejścia objął ostatecznie 426 lokali komunalnych. Pewna liczba przypadków (lokalii) została wyeliminowana z obliczeń ze względu na luki informacyjne. Ponadto, w sytuacji braku danych dotyczących rzeczywistych stawek czynszu najmu niektórych lokali (w przeliczeniu na $1m^2$ p.u. miesięcznie) przyjęto wielkości ze środka przedziału oznaczającego czynsz minimalny i czynsz maksymalny.

Przed uruchomieniem sieci dla nowych danych badany zbiór lokali komunalnych podzielono na cztery typy według rodzaju działalności prowadzonej przez najemcę (handel, usługi, magazyny i użyteczność publiczna). Podział taki miał na celu poprawę przejrzystości badanego zjawiska oraz ułatwienie interpretacji wyników. W następstwie powyższego modelowane stawki rynkowego czynszu najmu lokali komunalnych wyznaczono odrębnie w każdej z wyróżnionych grup lokali. W trakcie obliczeń grupom tym przypisano po dwa lub trzy modele sieci (z pięciu wykazanych w tabeli 2) relatywnie najlepiej odwzorowujące tendencje panujące w danym sektorze rynku. Empiryczne wyniki modelowania rynkowych stawek czynszu najmu lokali gminy o funkcjach handlowych i użyteczności publicznej przedstawiono na rysunkach 1 i 2. Wynika z nich, że w obu grupach lokali rzeczywiste stawki czynszu najmu znacząco różnią się od potencjalnych stawek rynkowych, modelowanych przy pomocy sieci neuronowych. Prawidłowość ta dotyczy również lokali usługowych i magazynowych. Analizując wszystkie cztery grupy lokali, można stwierdzić, że najmniejsze rozbieżności między czynszem rzeczywistym i rynkowym wystąpiły w grupie lokali handlowych. Trzy sieci jednokierunkowe wielowarstwowe ustaliły dla tej grupy lokali średnią stawkę czynszu modelowanego na poziomie $23,43 \text{ zł} \cdot \text{m}^{-2}$. Jeśli uwzględnimy średnią stawkę rzeczywistego czynszu najmu na poziomie $14,84 \text{ zł} \cdot \text{m}^{-2}$, wynika z tego, że czynsze modelowane są przeciętnie 1,5-krotnie wyższe od rzeczywistych. Ustalona relacja wielkości przeciętnych stanowi jednak duże uproszczenie analizy. Należy zauważyć, że w konkretnych przypadkach najmu lokali handlowych każda z trzech sieci „przypisała” określonemu obiektowi różny poziom czynszu rynkowego. Niekiedy czynsz rzeczywisty okazał się nawet wyższy od uzyskanego z modelu.



Rys. 1. Rzeczywiste i modelowane stawki czynszu najmu lokali handlowych z zasobu miasta Olsztyna ustalone z zastosowaniem wybranych sieci neuronowych


Fig. 1. Actual and model rates of commercial premises rentals from the city of Olsztyn resources established with the aid of selected neural networks

Relatywnie najniższą średnią stawką czynszu rzeczywistego – na poziomie $3,69 \text{ zł} \cdot \text{m}^{-2}$ charakteryzowała się grupa lokali użytkowych gminy o funkcjach użyteczności publicznej (rys. 2). Zastosowanie sieci typu MLP o czterech zmiennych oraz zespołu sieci o trzech zmiennych doprowadziło do uzyskania średniej stawki modelowanego czynszu rynkowego na poziomie – $27,32 \text{ zł} \cdot \text{m}^{-2}$. Uzyskane wyniki pokazują, że w lokalach użyteczności publicznej występują największe rozbieżności między rzeczywistym i rynkowym czynszem najmu. W zasobie olsztyńskim były one bowiem wynajmowane ponad 7-krotnie taniej od stawek, jakie potencjalnie kreował rynek nieruchomości. Zauważono ponadto, że oba modele sieci przypisały konkretnym lokalom tego typu bardzo zbliżone stawki potencjalnego czynszu rynkowego. Może to wynikać z faktu, że większość lokali użyteczności publicznej posiada bardzo zbliżone walory lokalizacyjne.

Tabela 3. Ocena rynkowej adekwatności czynszu najmu w poszczególnych typach lokali użytkowych z zasobu miasta Olsztyna

Table 3. Evaluation of market rental adequacy for the certain types of business premises from the city of Olsztyn resources

Typ lokalu The premises type	Charakterystyki rozkładu wartości wskaźnika adekwatności A_2 , % Characteristics of value adequacy rate distribution A_2 , %					
	średnia arytmetyczna arithmetic average	min min	max max	rozstęp spread	odchylenie standardowe standard deviation	współczynnik zmienności coefficient of variation
Usługowe Service	36,3	3,2	162,8	159,6	0,24	0,67
	36,1	3,0	154,7	151,7	0,24	0,66
Handlowe Commercial	78,6	7,3	245,7	238,4	0,50	0,63
	55,9	4,7	242,7	239,0	0,39	0,70
	67,9	5,5	247,4	231,9	0,46	0,68
Magazynowe Storage	24,3	3,2	77,3	74,1	0,14	0,56
	36,8	5,6	93,3	87,7	0,18	0,56
	26,0	4,1	75,5	71,4	0,14	0,52
Użyteczności publicznej Public functions	15,1	1,7	89,0	87,3	0,13	0,83
	14,8	1,8	84,0	82,2	0,12	0,82



Rys. 2. Rzeczywiste i modelowane stawki czynszu najmu lokali użyteczności publicznej z zasobu miasta Olsztyna ustalone z zastosowaniem wybranych sieci neuronowych

Fig. 2. Actual and model rates of public premises rentals from the city of Olsztyn resources established with aid of selected neural networks

W ostatniej fazie badań dokonano względnej oceny rynkowej adekwatności czynszu najmu w wyróżnionych typach funkcjonalnych lokali gminy. Do tego celu wykorzystano wskaźnik A_2 . Uzyskane wartości tego wskaźnika przedstawiono w tabeli 3. Uznano, że obiektywna ocena rynkowej adekwatności czynszu najmu lokali w badanych grupach wymaga szczegółowej analizy parametrów rozkładów wartości wskaźnika A_2 w postaci miar położenia i rozproszenia. Miary położenia obrazują poziomy i wzajemne relacje między wartościami przeciętnymi rozpatrywanego wskaźnika, natomiast miary rozproszenia wyrażają skalę bezwzględnego lub względnego zróżnicowania jego wartości w grupach lokali.

Dane zestawione w tabeli 3 potwierdzają tezę, że rzeczywisty czynsz najmu w badanych typach lokali wykazuje zróżnicowany stopień adekwatności rynkowej. Pokazuje to wyraźnie główna miara położenia, za którą przyjęto średnią arytmetyczną ustalonych wartości wskaźnika A_2 w wyróżnionych typach lokali. Najwyższy stopień zbieżności z czynszami rynkowymi wykazały czynsze najmu lokali handlowych, dla których średnia adekwatność rynkowa – zależnie od modelu sieci – wyniosła od 55,9 do 78,6%. Wyrażnie niższy poziom adekwatności charakteryzował czynsze najmu lokali usługowych (od 36,1 do 36,3%) oraz magazynowych (od 24,3 do 36,8%). Zdecydowanie najniższy stopień adekwatności rynkowej wykazały czynsze najmu lokali użyteczności publicznej, gdzie wartości przeciętne wskaźnika A_2 zastosowane modele sieci wyznaczyły na poziomie odpowiednio 14,8 i 15,1%. Poziomy uzyskanych miar położenia wartości A_2 pokazują, że wskaźnik ten jest zdeterminowany rodzajem (charakterem) działalności gospodarczej prowadzonej przez najemców lokali.

Biorąc pod uwagę miary rozproszenia wartości A_2 , należy zauważyć, że zakres zróżnicowania wartości tego wskaźnika jest bardzo szeroki we wszystkich typach lokali.

Informują o tym wielkości ekstremalne i ich różnice określone mianem rozstępu. Bardzo dużą dyspersją – wyrażoną rozstępem – charakteryzują się wskaźniki adekwatności czynszów najmu lokali handlowych (231,9–238,4%) i usługowych (151,7–159,6%). Wskazuje to na fakt, że przy dużej zmienności niektóre czynsze najmu lokali handlowych i usługowych przewyższały ich potencjalny poziom rynkowy. W przypadku najmu lokali magazynowych i użyteczności publicznej wielkości rozstępu A_2 były mniejsze i nie przekroczyły 88%. Wzajemne relacje bezwzględnego stopnia rozproszenia wartości wskaźnika adekwatności w badanych typach lokali potwierdzone zostały wielkościami odchylenia standardowego. Z kolei dyspersja względna, mierzona współczynnikiem zmienności, wykazała relatywnie niewielką skalę zróżnicowania stopnia rozproszenia wskaźników rynkowej adekwatności czynszu najmu w badanych grupach lokali.

WNIOSKI

Przeprowadzone analizy i badania pozwoliły na sformułowanie następujących wniosków:

1. Rezultaty zastosowania sztucznych sieci neuronowych do modelowania rynkowych stawek czynszu najmu lokali komunalnych potwierdziły hipotezę, że metody sztucznej inteligencji stanowić mogą użyteczne narzędzie wspomagania polityki czynszowej gminy. Przy ograniczonej wiedzy teoretycznej badacza potrafiły one wykreować racjonalne modele czynszowe uwzględniające uwarunkowania lokalnego rynku najmu. Stopień dokładności określenia potencjalnych stawek czynszu rynkowego uzyskany przez sieci był zadowalający, zaś procedury ich modelowania i eksploatacji – dzięki zastosowaniu programu STATISTICA Neural Networks – przyjazne dla użytkownika.

2. W wyniku testowania stwierdzono, że zjawisko kształtowania się rynkowego czynszu najmu lokali użytkowych w warunkach wybranego rynku najlepiej opisywały sieci jednokierunkowe trzywarstwowe oraz sieci o radialnych funkcjach bazowych. Struktury te wykazały najniższe błędy dopasowania, a ponadto czas ich trenowania był relatywnie krótki. Przy określaniu zbioru zmiennych wejściowych uwzględniono rzeczywiste cechy brane pod uwagę podczas wynajmowania lokali użytkowych z zasobu miasta Olsztyna. Wybrane sieci wykazały wysoką zdolność do uogólniania i uzupełniania informacji w przypadkach braku dostatecznej ilości danych rynkowych, pomimo nieskomplikowanej architektury.

3. Z punktu widzenia aktywnej polityki czynszowej miasta zasób lokali użytkowych nie może być traktowany jako zbiór jednorodny. Wyniki badań potwierdziły celowość podziału tego zasobu na cztery grupy funkcjonalne. Najwyższy przedział oczynszowania wykazały lokale handlowe, najniższy lokale użyteczności publicznej, natomiast obiekty usługowe i magazynowe zajęły pozycje środkowe. W odwrotnej kolejności ukształtowały się wielkości rozbieżności między czynszami rzeczywistymi a czynszami potencjalnie wyznaczonymi przez rynek najmu. Relacje te wynikają ze zróżnicowania rodzajów prowadzonej działalności przez najemców i oceny jej wpływu na społeczeństwo i gospodarkę miejską. Lokale użyteczności publicznej służą głównie realizacji zadań własnych gminy, natomiast lokale handlowe, usługowe i magazynowe wykorzystywane są w przeważającej mierze na cele komercyjne.

4. Modele sieci neuronowych przypisały poszczególnym lokalom użytkowym gminy zróżnicowane stawki modelowanego czynszu najmu. Wskazuje to na występowanie pewnej „naturalnej” niedoskonałości rynku nieruchomości objawiającej się zjawiskiem „rozmywania się” potencjalnego czynszu rynkowego w tych samych obiektach. Z tego punktu widzenia punktową estymację czynszu najmu winno się zastąpić estymacją przedziałową. Takie efekty pozwala osiągnąć metodyka badań oparta na wykorzystaniu sztucznej inteligencji.

5. Obliczone wskaźniki adekwatności rynkowej czynszu najmu lokali komunalnych potwierdziły tezę o relatywnie niskim stopniu zbieżności rzeczywistych czynszów najmu lokali komunalnych o funkcjach komercyjnych z odpowiednimi czynszami wyznaczonymi potencjalnie przez rynek. Świadczy to o pasywnej polityce czynszowej miasta Olsztyna. Zbyt niskie czynsze rzutują negatywnie na możliwości utrzymania równowagi ekonomicznej w gospodarce zasobem lokalowym gminy skutkując brakiem środków na właściwe zarządzanie i utrzymanie techniczne zasobu, w tym szczególnie na remonty i inwestycje.

PIŚMIENNICTWO

- Kolek M., 2006. Ocena rynkowej adekwatności czynszu najmu w gminnych zasobach lokali użytkowych miasta Olsztyna. Praca magisterska wykonana pod kierunkiem dr inż. Andrzeja Muczyńskiego. Wydział Geodezji i Gospodarki Przestrzennej. Uniwersytet Warmińsko-Mazurski Olsztyn (maszynopis).
- Masters T., 1996. Sieci neuronowe w praktyce. Programowanie w języku C++. Wydawnictwo Naukowo-Techniczne Warszawa.
- Muczyński A., 2006. Ocena rynkowej adekwatności czynszu najmu w gminnych zasobach mieszkaniowych. [W:] Zarządzanie nieruchomościami i analiza efektywności inwestowania. Studia i Materiały Towarzystwa Naukowego Nieruchomości vol. 14, nr 1, 159–175.
- StatSoft. Wprowadzenie do sieci neuronowych. 2001. Statsoft Polska Sp. z o.o. Kraków <www.statsoft.pl>.
- Tadeusiewicz R., 1993. Sieci neuronowe. Akademicka Oficyna Wydawnicza RM Warszawa.
- Wiśniewski R., 1999. Metodyczne i praktyczne aspekty zastosowania sztucznej inteligencji w takсации powszechnej. Rozprawa doktorska wykonana pod kier. prof. nadzw. dr hab. inż. R. Żróbka. Wydział Geodezji i Gospodarki Przestrzennej. Uniwersytet Warmińsko-Mazurski Olsztyn (maszynopis).

MODELLING OF THE COMMUNE'S BUSSINESS PREMISES TENANCY WITH THE APPLICATION OF ARTIFICIAL NEURAL NETWORKS

Abstract. In this thesis self-survey results were revealed relating to the application of the artificial neural networks used for specifying market models of business premises' rental rates taken from the selected urban commune's resource. The research procedure consists in training selected networks with data from the local real estate market, and transforming detected relationships – through the agency of established models – to estimating the potential rates of the market city council accommodation rentals. On this basis the market

adequacy degree of the actual rates of commune's premises rentals was estimated for the commercial, service, storage and public functions. Empirical researches were carried out on the local real estate market of the city of Olsztyn. In order to describe the phenomenon of self-moulding of the market business premises rental, one-way three-level and radial elementary function networks have been chosen. Analyses have revealed the relatively low degree of convergence between the actual city council's accommodation rentals and adequate rentals potentially determined by the market. This degree was strongly diverse depending on the type of business being run in the premises, and the evaluation of its influence on the society and the urban economy. The research methodology used, as well as received outcomes, can serve to streamlining commune's premises resources management, elicitation of rental policy including.

Key words: commune's real estate management, market, neural networks

Zaakceptowano do druku – Accepted for print: 29.03.2007