

Marzena Fortuna

Przewidywanie popytu mieszkaniowego

Problemy Rozwoju Miast 1/1-2, 73-92

2004

Artykuł został zdigitalizowany i 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.

PREDYKCJA POPYTU MIESZKANIOWEGO

Abstrakt. Znajomość mechanizmu dostosowywania się popytu na danym rynku może mieć kapitalne znaczenie dla inwestorów i ich projektów. Rozpoczęcie budowy obiektów w okresie dużego na nie popytu nie gwarantuje sukcesu. Przewlekanie terminu zakończenia budowy może spowodować, że oddanie obiektu do użytku nastąpi już w okresie niedoboru popytu, a to z kolei doprowadzić może do bankructwa całego przedsięwzięcia.

Dla uczestników procesów inwestycyjnych określenie prognoza popytu jest podstawową informacją pozwalającą na planowanie działalności. Bez określenia, choćby z dużym przybliżeniem, trendów rozwoju w gospodarce uczestnicy procesów inwestycyjnych narażeni są na podejmowanie decyzji obarczonych zbyt wielkim ryzykiem.

Unikalność produktu, jakim jest mieszkanie, wynikająca z indywidualnych potrzeb klienta, niepowtarzalności rozwiązań projektowych i indywidualnych warunków lokalizacyjnych, wpływa na niską produktywność, a w konsekwencji na wysoki koszt i cenę mieszkań. Dlatego też eksperckie profesjonalne, dedykowane i interaktywne podejście, wspomagane komputerowymi suportami decyzyjnymi, stanowi obecnie nowoczesny trend światowy w budownictwie.

Słowa kluczowe: popyt mieszkaniowy, wskaźniki kształtujące popyt, predykcja, regresja, sieci neuronowe

Powszechne są opinie, że w latach 1996-2002 w Polsce budowano mało, długo i drogo. Sytuacja była taka, że można mówić o kryzysie w tej dziedzinie.

Warto w tym miejscu przypomnieć, że mieszkanie jest najbardziej kapitałochłonnym dobrem konsumpcyjnym, powstającym w długim cyklu inwestycyjnym. Jest zarówno dobrem konsumpcyjnym najdroższym, jak też dobrem pierwszej potrzeby.

Rynek mieszkaniowy obejmuje transakcje kupna-sprzedaży mieszkań, zarówno nowych jak i z drugiej ręki. Jest on determinowany z jednej strony zapotrzebowaniem zgłoszonym przez nabywców na produkt budowlany, jakim jest mieszkanie (popytem), z drugiej zaś powinien być zrównoważony przez zdolność produkcyjną firm budowlanych (podaż). Jeśli chodzi o podaż, to w ostatnich latach nie ma ograniczeń ani ze strony możliwości realizacyjnych, ani producentów materiałów budowlanych, jedyny problem może dotyczyć obowiązujących przepisów i standardów w Unii

Europejskiej. Jest natomiast wiele ograniczeń i nieokreśloności, które można zauważyć po stronie popytu: obowiązujące nowe przepisy Unii Europejskiej, indywidualizacja potrzeb i standardów zamieszkiwania, wyraźny spadek realnych dochodów przeważającej części ludności, wysoce niekorzystne relacje między średnią płacą i średnim dochodem gospodarstwa domowego a ceną 1 m² powierzchni mieszkania itp.

Z punktu widzenia deweloperów wiedza o poziomie popytu nie tylko dostarcza informacji o możliwości korzystnej sprzedaży mieszkań, ale i pomaga przewidzieć istotne zmiany w sektorze, pozwala na stworzenie bardziej realnego planu działania.

Niestety próba oszacowania popytu, a w związku z tym określenie sprzedaży mieszkań obfituje w trudności związane z charakterystyką tego produktu.

Z punktu widzenia nabywców sprzedaż mieszkań związana jest ściśle z pięcioma istotnymi grupami czynników [Szafranko E., 2001]:

- 1) czynnikami fizycznymi, tj. cechami środowiska naturalnego wpływającymi na kształt inwestycji (ukształtowanie terenu, wielkość i kształt działki, położenie względem innych punktów);
- 2) czynnikami technicznymi, czyli wielkością mieszkania, stanem technicznym, rozwiązaniami materiałowymi i technologicznymi, infrastrukturą itp.;
- 3) czynnikami ekonomicznymi, czyli siłami wpływającymi na wielkość popytu i podaży;
- 4) czynnikami prawnymi, np. planem zagospodarowania przestrzennego, formą władania nieruchomością;
- 5) czynnikami społeczno-socjologicznymi, np.: stylem życia, modą, przyzwyczajeniami.

Pomimo znacznej potrzeby oszacowania popytu mieszkaniowego nie jest to zadanie łatwe. Wymaga ono kompleksowego przeglądu wielu różnorodnych czynników, najczęściej ekonomicznych, albowiem to one na początku wywierają decydujący wpływ na nasze decyzje mieszkaniowe.

Wskaźniki statystyczne (budowlane, ekonomiczne i społeczne) wpływające na zapotrzebowanie na mieszkania

Analiza danych

Dobór wskaźników w wielowymiarowej analizie danych jest jednym z najważniejszych a zarazem najtrudniejszych zagadnień. Od jakości zestawu wskaźników zależy nie tylko wiarygodność ostatecznych wyników, ale i trafność podejmowanych na tej podstawie decyzji w sprawach związanych np. z prognozowaniem popytu.

Punktem wyjścia jest skonstruowanie wstępnej listy wskaźników, co wbrew pozorom nie jest zadaniem łatwym. Badaczowi nie wolno opuścić żadnego ze wskaźników mających istotne znaczenie przy wyjaśnianiu przedmiotu badania, a jednocześnie musi on usunąć wskaźniki, które słabo, pośrednio lub pozornie wyjaśniają ten przedmiot. Mniejszym złem jest zatem wprowadzenie wskaźników nieistotnych w początkowej fazie – ponieważ mogą być one w dalszej fazie usunięte – niż opuszczenie wskaźników istotnych, które mogą w dużym stopniu wypaczyć wyniki badań [Walesiak M., 1996].

Zestawiając listę potencjalnych wskaźników, należy wziąć pod uwagę:

- koszt uzyskania informacji,
- dostępność danych statystycznych,
- wiarygodność danych statystycznych.

Widać więc, jak ważne jest właściwe przygotowanie badań w zakresie wyjaśnienia i usunięcia wszelkich wątpliwości oraz rzetelność w zbieraniu materiału. Błędy powstałe na etapie zbierania danych nie mogą być usunięte w dalszych badaniach. Materiał obarczony grubymi błędami zawsze prowadzi do zniekształcenia wyników prognozowania. Jedynie błędy losowe nie są zbyt niebezpieczne, ponieważ przy dużej masie danych liczbowych mają tendencję do kompensowania się [Zeliaś A., Pawełek B., Wanat S., 2003].

Jednym z podstawowych warunków poprawnego przeprowadzenia prognozowania popytu mieszkaniowego jest zbieranie materiału statystycznego, który musi być kompletny, rzetelny i wiarygodny. W świetle uwag dotyczących problemów występujących przy właściwym gromadzeniu danych liczbowych zebranie kompletnych informacji statystycznych jest zadaniem niezmiernie trudnym, a w niektórych przypadkach niemożliwym do wykonania.

W zależności od charakteru zmiennej prognozowanej zmieniają się wymagania co do zakresu i dokładności danych statystycznych. Zawsze jednak problemy narastają wraz ze wzrostem liczby obserwacji, zasięgu czasowego i liczby wyspecyfikowanych potencjalnych zmiennych objaśniających co spowodowane jest nie tylko brakiem materiałów źródłowych, lecz także ich ograniczonością, niekiedy pewne informacje istnieją wyłącznie dla niektórych obiektów, lat czy zmiennych.

Należy pamiętać o tym, że dane publikowane w oficjalnych źródłach charakteryzują się różnym stopniem wiarygodności. Wiele informacji statystycznych podawanych w międzynarodowych rocznikach statystycznych ma np. charakter szacunków, co wynika z konieczności dokonywania licznych korekt informacji podawanych przez krajowe US.

Wskaźniki wpływające na popyt mieszkaniowy

Badanie popytu mieszkaniowego powinno być prowadzone od momentu, w którym wygasły sposoby wspierania budownictwa mieszkaniowego charakterystyczne dla gospodarki centralnie planowanej, tj. od roku 1993 [Zaniewska H., 1997].

Wskaźniki kształtujące popyt na mieszkania [Werner W. A., 1994]:

Wskaźniki mieszkaniowe:

- liczba mieszkań wybudowanych, zarówno oddanych do użytku jak i rozpoczętych, w różnym stopniu zaawansowania,
- liczba wydanych pozwoleń na budowę,
- cena 1 m² powierzchni użytkowej mieszkania,
- stan zasobów mieszkaniowych (struktura wieku budynków, rodzaje materiałów, z których zostały zbudowane, wyposażenie w instalacje, zużycie nominalne w stosunku do wieku i faktyczne wynikające z częstotliwości remontów oraz destrukcyjnych wpływów otoczenia).

Wskaźniki społeczno-ekonomiczne:

stan rynku pracy:

- liczba pracujących,
- stopa bezrobocia,
- perspektywy ekonomiczne zakładów pracy, tendencje rozwoju,
- sytuacja materialna mieszkańców:
- wielkość przeciętnego miesięcznego wynagrodzenia brutto w gospodarce,
- środki własne (przeznaczone z bieżących dochodów i zgromadzonych przez ludność oszczędności),

zasoby kapitałowe potencjalnych klientów:

- depozyty i inne zobowiązania gospodarstw domowych,
- możliwości uzyskiwania kredytów bankowych, pożyczek z innych źródeł,
- stopa oprocentowania kredytów mieszkaniowych,
- stopa oprocentowania redyskonta weksli,
- wydatki i profil konsumpcji,
- spożycie indywidualne (z dochodów osobistych) gospodarstw domowych,
- należności od gospodarstw domowych,

PKB,

nakłady brutto na środki trwałe,

inflacja,

podaż pieniądza M₂¹.

¹ Wskaźnik M₂ podano za Biuletynami Statystycznymi GUS z lat 1996-2003.

Wskaźniki demograficzne:

- liczba ludności,
- liczba zawartych małżeństw,
- liczba i wielkość gospodarstw domowych,
- struktura wieku mieszkańców.

Czynniki socjalne i przesłanki psychologiczne:

- poziom optymizmu nabywców,
- segment mieszkań popularnych, apartamentów i mieszkań o podwyższonym standardzie,
- preferencje lokalizacyjne,
- aktywność mieszkańców,
- styl życia,
- motywacje i aspiracje mieszkańców dotyczące poprawy swojej sytuacji mieszkaniowej, zainteresowania.

Badanie rynku jest procesem złożonym, który nie poddaje się prostej kwantyfikacji. Wykorzystanie wyników badań wiąże się zawsze, jak w każdej działalności gospodarczej, z ryzykiem.

Stosunkowo łatwo jest zebrać dane przedstawiające wielkość, stan i strukturę zasobów mieszkaniowych, natomiast trudne są badania społeczno-ekonomiczne. Wiele danych zbieranych jest bowiem metodą ankiet i wywiadów, w których odpowiedzi nie zawsze są wiarygodne.

Przetworzone wyniki badań nad popytem stwarzają jednak podstawy do określenia „celowego rynku”, czyli w przypadku budownictwa mieszkaniowego wyboru grupy ludności, której można zaproponować realizację ich potrzeb i aspiracji.

W ofercie rynkowej trzeba więc wyeksponować właściwości proponowanego towaru, które są szczególnie pożądane przez klientów inwestorów. Poza względnie oczywistymi informacjami ofertowymi dotyczącymi:

- lokalizacji (walory komunikacyjne, ekologiczne, prestiżowe),
- rozwiązań przestrzennych obiektów budowlanych (oryginalne bryły, powiązanie z przyrodą, wygodne wnętrza),
- materiałów budowlanych i wyposażenia (trwałość, ekologia, wysoki standard),
- ceny i warunków finansowania (cena adekwatna do oferowanej jakości, korzystne warunki kredytowe),
- cyklu realizacji zamówienia.

Zaobserwować można eksponowanie dotychczas mniej znaczących w Polsce właściwości, jak:

- zapewnienie systemu bezpieczeństwa (teren wydzielony, pilnowany przez służby ochrony),
- uniezależnienie od publicznej infrastruktury technicznej (własna kotłownia, własne ujęcie wody),
- walory sąsiedzkie (osiedle, domy przeznaczone dla biznesmenów, ludzi sztuki),
- wyposażenie w infrastrukturę społeczną (własny basen, kort tenisowy),
- renoma projektanta (wybitny architekt...).

Wybór wskaźników służących do predykcji

Pierwszy etap badań stanowił przegląd obszernej literatury dotyczącej wskaźników statystycznych (budowlanych, ekonomicznych i społecznych) związanych z popytem dla budownictwa mieszkaniowego. Dzięki niemu większość możliwych do zdobycia istotnych wskaźników uwzględniono w predykcji².

Lista 14 wskaźników użytych do predykcji:

- produkt krajowy brutto,
- nakłady brutto na środki trwałe,
- populacja ludności,
- liczba zawartych małżeństw,
- cena 1 m² powierzchni użytkowej mieszkania,
- stopa bezrobocia,
- zatrudnienie,
- stopa inflacji,
- podaż pieniądza M₂,
- przeciętne miesięczne wynagrodzenie brutto w gospodarce,
- liczba mieszkań oddanych do użytku,
- liczba wydanych pozwoleń na budowę,
- średnioważone oprocentowanie depozytów,
- średnioważone oprocentowanie kredytów.

Popyt dla budownictwa mieszkaniowego reprezentowany jest przez liczbę m² powierzchni użytkowej mieszkania oddanych do użytku, ponieważ wydaje się, iż jest on

² Kwartalne dane dla wybranych wskaźników, związanych z popytem dla budownictwa mieszkaniowego, zostały zebrane na podstawie następujących pozycji:

- Roczniki statystyczne, Biuletyny Statystyczne, Informacja o sytuacji gospodarczej kraju, Budownictwo mieszkaniowe. Budownictwo wyniki działalności w 2002 r.,
 - Baza danych umieszczona na stronie Głównego Urzędu Statystycznego,
 - Bazy danych udostępnionej na stronie Narodowego Banku Polskiego.
- Dane te dotyczą lat 1996-2002.

dokładniejszą miarą popytu niż liczba pozwoleń wydanych na budowę czy też liczba mieszkań oddanych do użytku.

W pracy tej nie zostały wykorzystane istotne wskaźniki, dotyczące: cen materiałów budowlanych, kredytów mieszkaniowych. Brak tych wskaźników jest spowodowany niekompletnością danych (udostępniane są dane roczne albo od jakiegoś okresu³).

Następnie dane i zidentyfikowane wskaźniki, które mają wpływ na liczbę budowanych i sprzedawanych mieszkań, zebrano i wprowadzono do komputera dla analizy statystycznej, która stanowi drugi etap. Do oceny statystycznej istotności tych wskaźników wykorzystano procedurę STEPWISE (dostępną pod MATLABem).

Wyodrębnienie wskaźników do predykcji sprzedaży mieszkań za pomocą procedury STEPWISE

Do oceny statystycznej istotności 14 wskaźników została wykorzystana ogólna procedura regresji krokowej (procedura STEPWISE) dostępna pod MATLABem. Ogólna regresja krokowa jest techniką wybierania zmiennych. W regresji w przód na każdym kroku nowe niezależne, statystycznie istotne zmienne są dodawane do modelu (zmienne z najwyższym statystycznym F lub najniższą wartością p). W regresji w tył wszystkie niezależne zmienne są początkowo wprowadzane do modelu i sekwencyjnie wyprowadzane, jeśli nie spełniają istotnych kryteriów, aż do momentu, gdy pozostałe człony są statystycznie istotne. Ogólna regresja krokowa używa obydwu tych technik.

Jak widać, w procedurze tej występuje powtarzane badanie na każdym etapie regresji zmiennych niezależnych, wprowadzonych do modelu w poprzednich etapach. Zmienna niezależna, która mogła być najlepszą pojedynczą zmienną do wprowadzenia w poprzedzającym etapie, może w etapie późniejszym być zbyteczna ze względu na swoją zależność od innych zmiennych niezależnych, występujących teraz w regresji. Proces ten trwa tak długo, aż żadnej ze zmiennych nie będzie można dopuścić do równania i żadnej odrzucić [Draper N.R., Smith H., 1973].

Regresja krokowa to wybranie najlepszego objaśniającego modelu z najmniejszą liczbą zmiennych w jak najkrótszym czasie.

W pierwszym kroku działania procedury został już wyodrębniony jeden wskaźnik statystycznie istotny z najwyższym $F=58,73$ – mieszkania oddane do użytku. Następny istotny statystycznie wskaźnik został wyłoniony dopiero po redukcji pięciu innych (średnioważonego oprocentowania kredytów, ceny 1 m² pow. użytkowej

³ Np. średnioważone oprocentowanie kredytów mieszkaniowych jest udostępnione dopiero za 2002 r. w Biuletynie Informacyjnym Narodowego Banku Polskiego.

mieszkań, stopy inflacji, PKB i liczby wydanych pozwoleń na budowę) – bezrobocie (F=107,2).


W dalszym toku postępowania po redukcji wskaźnika średnioważone oprocentowanie depozytów w zł osób prywatnych, został wyodrębniony trzeci wskaźnik – zatrudnienie (F=124,8).

Ostatni wskaźnik wchodzący do modelu to populacja ludności (F=240,7). Po drodze zostały usunięte wskaźniki liczby małżeństw zawartych, nakładów brutto na środki trwałe, podaży pieniądza M₂, przeciętnego miesięcznego wynagrodzenia brutto w gospodarce.

Współczynniki, przedziały ufności oraz inne istotne zmienne w regresji krokowej po ostatnim istotnym kroku przedstawiono na ryc. 1.

Column #	Parameter	Confidence Intervals	
		Lower	Upper
1	-0.212	-0.3719	-0.05214
2	-0.2947	-0.4649	-0.1245
3	-0.2138	-0.3438	-0.08384
4	0.9154	0.8254	1.005

RMSE	R-square	F	P
0.04047	0.9767	240.7	0



Ryc. 1

W wyniku selekcji statystycznej została zredukowana lista wskaźników z 14 do 4 statystycznie istotnych: populacji ludności, stopy bezrobocia, zatrudnienia, liczby mieszkań oddanych do użytku. Generalnie, krótsza lista wskaźników jest korzystniejsza dla modelowania, bo pozwala uniknąć problemów związanych z przetrenowaniem sieci czy współliniowością.

Krótki opis każdego z wyżej wymienionych wskaźników, odzwierciedlający związek z popytem na budownictwo mieszkaniowe przedstawiony został poniżej.

Populacja ludności. Demograficzny wpływ jest często przytaczany jako jeden z istotnych czynników oddziałujących na popyt mieszkaniowy. W gruncie rzeczy nie da się zaprzeczyć, że wzrost populacji oraz jej struktura zasadniczo wpływa na wzrost popytu na budownictwo mieszkaniowe [Hillebrandt P.M., 2000].

Szybszemu wzrostowi populacji towarzyszy szybszy poziom aktywności budowlanej i na odwrót. W Polsce „z demograficznej prognozy GUS wynika, że na przełomie wieków (1995-2005) o 1,3 mln osób zwiększy się liczba ludności w wieku zakładania rodzin, przy równoczesnym wzroście o 2,6 mln liczby ludności w średnim i starszym wieku. Te dwa równoległe wyże demograficzne sprawiają, że młode rodziny nie mogą liczyć na opuszczone mieszkania po starszym pokoleniu” [Kulesza H., 1999]. Faktem jest więc, że zapotrzebowanie na nowe mieszkania jest ogromne.

Poziom bezrobocie. Bezrobocie jest miarą całkowitej liczby osób niezatrudnionych, które są gotowe i zdolne do pracy. Jest ono ściśle związane z sytuacją społeczno-gospodarczą kraju. Dlatego wzrost bezrobocia może spowodować spadek nowych inwestycji w kraju, oznacza on, między innymi redukcję zdolności do kupna mieszkania. „Wysokie bezrobocie, szczególnie wśród młodzieży, powoduje brak odpowiednich dochodów, uniemożliwia oszczędzanie na mieszkanie i drastycznie wpływa na ograniczenie bieżącego i przyszłego popytu mieszkaniowego” [Dominiak W., 1999].

Bezrobocie należy do głównych społecznych problemów współczesnej gospodarki rynkowej. „Bezrobocie powoduje marnotrawstwo zasobów, przede wszystkim pracy ludzkiej. Ograniczone zostają dochody ludności. Straty ponoszone w okresie wysokiego bezrobocia to największe udokumentowane marnotrawstwo we współczesnej gospodarce” [Kulwicki E., Czyż M., Karcz B., Kukuła U., 1997].

Zatrudnienie. Jeśli zatrudnienie jest głównym źródłem dochodów domowych, to dochody te przeznaczane są po kolei na dobra pierwszej potrzeby, a dopiero później na dobra droższe, takie jak mieszkanie. Dlatego też spadek wzrostu zatrudnienia może spowodować zmniejszenie zainteresowania kupnem mieszkania, spadek nowych inwestycji w kraju. Wzrost dochodów ludności jest bardzo istotny i dlatego przewidywania powinny być oparte na poziomie bezrobocia, wzroście zarobków i innych rodzajów dochodów. To nie mieszkania są drogie, to my za mało zarabiamy. Proszę zwrócić uwagę na drastyczną różnicę cen mieszkań np. w Krakowie i w miastach o mniejszej aktywności gospodarczej i niższych zarobkach, widać, jak popyt dyktuje i wielkość budownictwa i cenę.

Liczba mieszkań oddanych do użytku. Mieszkanie jest generalnie uważane za towar konsumpcyjny, jest też najdroższym produktem kupowanym przez przeciętne gospodarstwo. W Polsce potrzeby mieszkaniowe nie są zaspokojone. Zmniejsza się w stosunku do potrzeb liczba oddawanych do użytku mieszkań. Wzrost liczby budowanych mieszkań przy zwiększeniu kierowanych na nie środków może wpłynąć pozytywnie na zatrudnienie, a więc spadek bezrobocia i walkę z recesją gospodarczą. Pociąga za sobą wzrost dochodów, które można wydatkować na cele mieszkaniowe.

Zastosowanie metody Gaussa-Newtona do poszerzenia liczby wskaźników do predykcji

W zagadnieniach nieliniowych istnieje obecnie kilka metod stosowanych do uzyskania estymatorów za pomocą typowych programów obliczeniowych. Jednym z nich jest metoda Gaussa-Newtona (linearyzacji, rozwinięcia w szereg Taylora), która wykorzystuje na kolejnych etapach wyniki metody najmniejszych kwadratów dla przypadku liniowego.

Jak już wcześniej wspomniano, generalnie krótsza lista wskaźników jest korzystniejsza dla modelowania. Wydaje się jednak, że 4 statystycznie istotne wskaźniki to za mało, aby efektywnie przeprowadzić predykcję. Dlatego też, zdecydowano się na poszerzenie tej listy o 2 wskaźniki za pomocą dopasowania średniokwadratowego metodą Gaussa-Newtona.

$$\text{Model ma postać } Y_{nx1} = f(X_{n \times p}, \beta_{p \times 1}) + \varepsilon_{nx1},$$

gdzie: Y_{nx1} – obserwacje,

$X_{n \times p}$ – macierz wejść,

$\beta_{p \times 1}$ - wektor parametrów,

ε_{nx1} - błąd.

Dopasowanie odbywa się za pomocą funkcji wymiernej wielu zmiennych

o postaci $y = \frac{a_0 + a_1 x_1^2 + a_2 x_2^2 + \dots + a_n x_n^2}{c_0 + c_1 x_1^2 + c_2 x_2^2 + \dots + c_n x_n^2}$, gdzie c_0, c_1, \dots, c_n nie wszystkie równe zeru.

Jest ono przeprowadzone za pomocą NLINFIT – funkcji dopasowania średniokwadratowego metodą Gaussa-Newtona, narzędzia dostępnego pod MATLABem.

Po wykonaniu powyższych procedur dla rozważanego przypadku $Y_{14 \times 1} = f(X_{14 \times 6}, \beta_{6 \times 1}) + \varepsilon_{14 \times 1}$, najkorzystniejsza jest postać funkcji

$$y = \frac{\beta_1 x_1^2 - \beta_2 x_{12}^2}{1 + \beta_3 x_6^2 + \beta_4 x_{14}^2 + \beta_5 x_4^2 + \beta_6 x_{11}^2}, \text{ gdzie oprócz 4 wskaźników znajdujących się}$$

w modelu wzięto pod uwagę 2 nowe: produkt krajowy brutto i średnioważone oprocentowanie kredytów.

Dla tak zadanej funkcji błąd średniokwadratowy wyniósł tylko 0,12775.

Krótki opis 2 nowych wskaźników dołączonych do predykcji, odzwierciedlających związek z popytem dla budownictwa mieszkaniowego, przedstawiony jest poniżej.

Produkt krajowy brutto: „Decydujące znaczenie dla oceny sytuacji kształtującej warunki rozwoju budownictwa mieszkaniowego mają poziom i tempo wzrostu PKB” [Dominiak W., Uchman R., 2001]. PKB obrazuje końcowy rezultat działalności wszystkich podmiotów gospodarki narodowej. Zasadniczym składnikiem PKB od strony jego tworzenia jest suma wartości dodanej brutto wszystkich sekcji gospodarki narodowej.

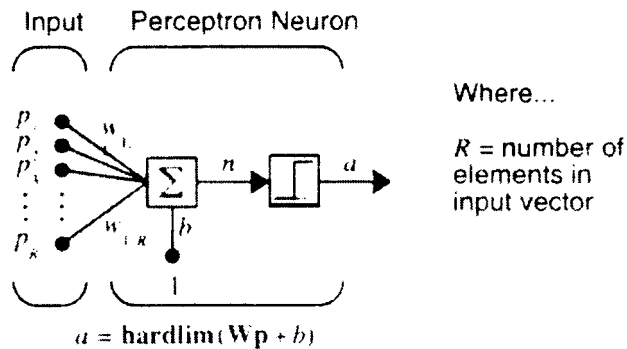
Średnioważone oprocentowanie kredytów. Wśród barier występujących w budownictwie mieszkaniowym należałoby przede wszystkim wymienić wielkość zasobów środków pieniężnych, które mogą być przekształcone w efektywny popyt mieszkaniowy „zmniejszenie popytu... wynika z faktu, że potencjalni nabywcy mieszkań nie mają możliwości sfinansowania zakupu mieszkań z uwagi na niski poziom zasobności społeczeństwa i wysokie stopy procentowe” [Kulesza H., 2002]. Z powyższych słów wynika, że główną barierą jest niski udział kredytów w finansowaniu budownictwa mieszkaniowego, a w szczególności ich wysoki koszt. Nie ulega wątpliwości, że rozwój kredytów mieszkaniowych może odegrać szczególną rolę w przełamaniu obecnego impasu w budownictwie mieszkaniowym.

Wybór sieci neuronowych w modelowaniu popytu mieszkaniowego

Jest truizmem stwierdzenie, że w ostatnich latach bardzo gwałtownie wzrosło zainteresowanie sieciami neuronowymi. Nie jest to wynik zbiegu okoliczności czy efekt chwilowej mody. Sieci neuronowe po prostu okazały się wygodnym narzędziem, przydatnym w realizacji bardzo wielu różnych praktycznych zadań. W istocie są one z powodzeniem stosowane w niezwykle szerokim zakresie, w tak różniących się od siebie dziedzinach jak finanse, medycyna, zastosowania inżynierskie, geologia czy fizyka. W rzeczywistości zastosowań tych może być znacznie więcej, ponieważ sieci neuronowe mogą być zastosowane wszędzie tam, gdzie pojawiają się problemy związane z przetwarzaniem i analizą danych, z ich predykcją, optymalizacją, klasyfikacją czy sterowaniem.

Sieci neuronowe są bardzo wyrafinowaną techniką modelowania, zdolną do odwzorowywania nadzwyczaj złożonych funkcji. W szczególności sieci neuronowe mają charakter nieliniowy, co istotnie wzbogaca możliwości ich zastosowań. Zalety sieci neuronowych nie ograniczają się jedynie do tego, że umożliwiają one swobodne i łatwe tworzenie modeli nieliniowych. Sieci umożliwiają także kontrolę nad złożonym modelem wielowymiarowości, który przy stosowaniu innych metod znacznie utrudnia próby modelowania funkcji nieliniowych z dużą liczbą zmiennych niezależnych.


Perceptron



Ryc. 2

Zadaniem perceptronu jest zaklasyfikowanie wektora $\mathbf{p} = [p_1, \dots, p_N]^T$ do jednej z dwu klas oznaczonych literami L_1 i L_2 . Perceptron klasyfikuje wektor \mathbf{p} do klasy L_1 , jeżeli sygnał wyjściowy a przyjmuje wartość 1 oraz do klasy L_2 , jeżeli sygnał wyjściowy a przyjmuje wartość 0. Zatem perceptron dzieli przestrzeń wektorów wejściowych \mathbf{p} na dwie półprzestrzenie rozdzielone hiperpłaszczyzną (granica decyzyjną) o równaniu $\mathbf{Wp} + \mathbf{b} = 0$ ($w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b = 0$).

Wektor wejścia leżący nad granicą decyzyjną L klasyfikujemy do klasy L_1 , a poniżej do klasy L_2 .



Ryc. 3

Perceptron jest wykorzystywany do wstępnej analizy problemu, do zidentyfikowania istotnych kwartałów w zbiorze danych.

Dla rozważanego przykładu sieć perceptron została utworzona za pomocą narzędzia GUI w Neural Toolbox, procedury **nntool**. Wektor wejścia przyjmuje postać $p = [p_1 p_2 p_3 p_4 p_5 p_6]$ (jedno wejście z 6 elementami), wektor target $t=[0 0.04 0.01 \dots 0.19 0.3 0.66]$, funkcja hardlim i jedno wyjście.

Perceptron sklasyfikował wektor $p = [p_1, \dots, p_N]^T$ do jednej z dwóch klas. Wyniki zostały przedstawione poniżej.

Tabela 1. Sygnały wyjściowe oraz błędy średniokwadratowe między sygnałami zadanymi a wyjściowymi dla danych uczących sieć

Lata (kwartały)	1996 (I)	(II)	(III)	(IV)	1997 (I)	(II)	(III)	(IV)	1998 (I)	(II)
a	0	0	0	0	0	0	0	0	0	0
e	0	0,04	0,01	0,58	0,11	0,14	0,11	0,68	0,21	0,16

Lata (kwartały)	1998 (III)	(IV)	1999 (I)	(II)	(III)	(IV)	2000 (I)	(II)	(III)	(IV)
a	0	0	0	0	0	1	0	0	0	1
e	0,30	0,59	0,16	0,17	0,17	-0,36	0,25	0,19	0,30	-0,34

Tabela 2. Sygnały wyjściowe dla dwóch lat poddanych sprawdzeniu

Lata (kwartały)	2001 (I)	(II)	(III)	(IV)	2002 (I)	(II)	(III)	(IV)
a	0	0	0	1	0	0	0	1

Perceptron zidentyfikował dla danych uczących sieć jako istotne 2 kwartały: 1999 (IV) i 2000 (IV), podobnie jak dla danych sprawdzających sieć: 2001 – IV, 2002 – IV. Ponieważ sieć poddana uczeniu ma małą liczbę danych wprowadzanych, w dalszych rozważaniach nadal będą brane pod uwagę wszystkie uprzednio brane pod uwagę kwartały. Sytuacja wyglądałaby całkiem inaczej, gdyby tych danych było np. kilka tysięcy, wtedy do dalszych rozważań zostałyby wzięte tylko te istotne, zidentyfikowane przez sieć.

Otwarte i zamknięte metody uczenia jednokierunkowych sieci wielowarstwowych

Metoda z siecią otwartą (*Feedforward network*) nie ma sprzężeń zwrotnych, w przeciwieństwie do metod z sieciami zamkniętymi (gradientowych, hesjanowych), które je mają.

Podstawową cechą **gradientowych** metod uczenia jest wykorzystanie w trakcie modyfikowania wag sieci informacji o wartości gradientu minimalizowanej funkcji błędu.

Gradientowe metody wykorzystane do danego problemu:

- Batch Gradient Descent;
- Batch Gradient Descent with Momentum,
- Variable Learning Rate Backpropagation,
- Resilient Backpropagation,
- Fletcher-Reeves Conjugate Gradient,
- Polak-Ribiera Conjugate Gradient,
- Powell-Beale Conjugate Gradient,
- Scaled Conjugate Gradient.

Podstawową cechą **hesjanowych** metod uczenia jest wykorzystanie w trakcie modyfikowania wag sieci informacji o macierzy drugich pochodnych (hesjanach) funkcji błędu.

Hesjanowe metody wykorzystane do danego problemu:

- BFGS Quasi-Newton;
- Levenberg-Marquardt.

Parametry trenowania powyższych sieci:

- `net.trainParam.show=50` – stan wytrenowania;
- `net.trainParam.lr=0.05` – szybkość uczenia;
- `net.trainParam.epochs=300` – liczba iteracji zadania;
- `net.trainParam.goal=1e-3` – tolerancja;
- `net.trainParam.min_grad=1e-25` – amplituda gradientu;
- `net.trainParam.time=100` – zadany czas uczenia.

Gdy `lr` jest za duże, algorytm jest niestabilny, gdy jest za małe, występuje długi czas zbieżności procesu uczenia.

Test stopu występuje wtedy, gdy:

- liczba iteracji > epochs;
- wartość funkcji celu < goal;
- amplituda gradientu < min grad;
- czas uczenia > time (sec).

Bardzo trudno jest ustalić z góry, który algorytm będzie najszybszy dla danej aplikacji. Porównanie sieci dla danego problemu zależy więc będzie od złożoności problemu, liczby danych w zbiorze trenującym, liczby wag i biases w sieci, zadanej tolerancji błędu i przeznaczenia sieci, tj. od tego czy służy ona do rozpoznania wzorca, klasyfikacji czy też aproksymacji.

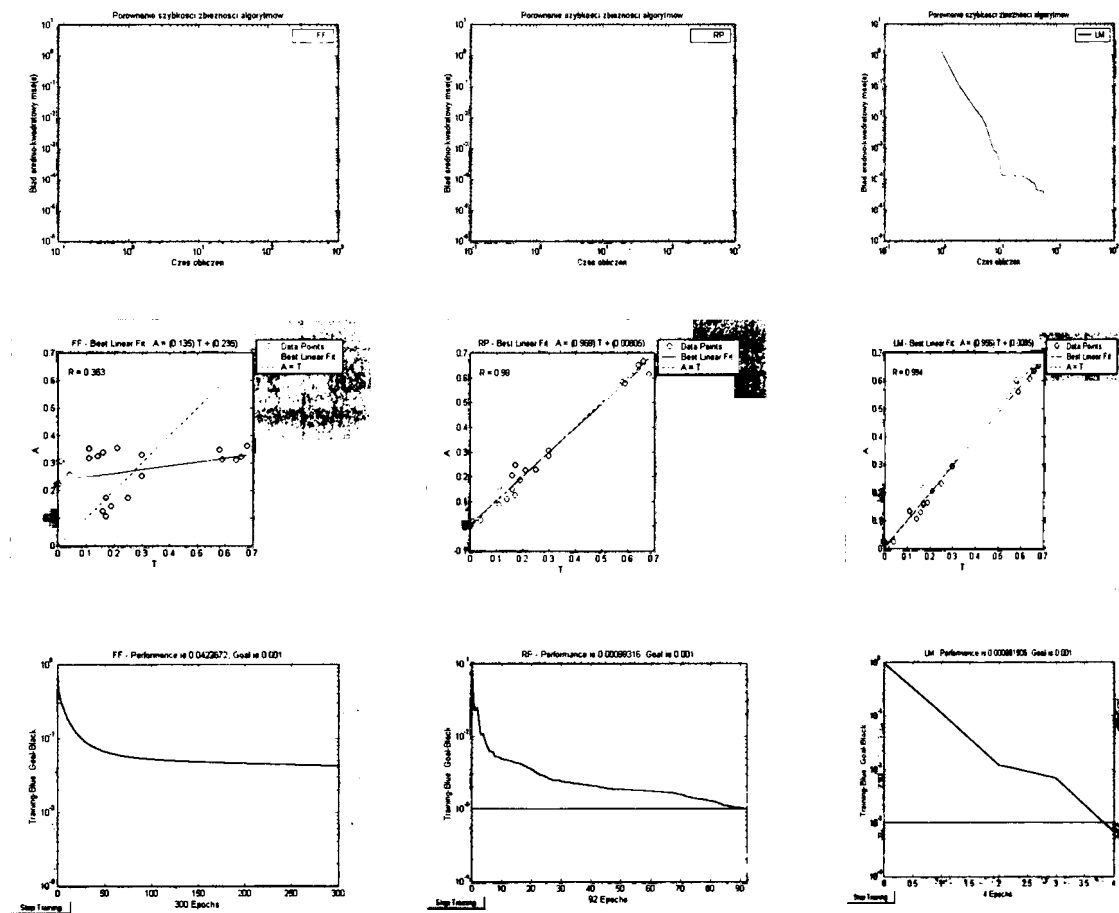
Tabela 3. Porównanie algorytmów

Akronim algorytmu	Algorytm	Struktura sieci	Tolerancja błędu	Średni czas [s]	Stosunek czasów obliczeń	Czas		Odchylenie standardowe czasu	Błąd średniokwadratowy
						min	max		
FF	Feedforward Network	1-3-1	1e-3	1.0840	5.3399	0.9800	1.6500	0.1139	0.0423
BGDB	Batch Gradient Descent Backpropagation	1-3-1	1e-3	1.1973	5.8980	1.0500	1.9200	0.1465	0.0080
BGDMB	Batch Gradient Descent with Momentum Backpropagation	1-3-1	1e-3	1.2757	6.2842	1.2100	1.4300	0.0409	0.0305
GDX	Variable Learning Rate Backpropagation	1-3-1	1e-3	1.1903	5.8635	1.1000	1.2100	0.0318	0.0072
RP	Resilient Backpropagation	1-3-1	1e-3	0.8077	3.9788	0.2800	1.3200	0.3360	0.0010
CGFR	Fletcher-Reeves Conjugate Gradient	1-3-1	1e-3	1.0510	5.1773	0.5400	2.2500	0.4347	0.0010
CGP	Polak-Ribiere Conjugate Gradient	1-3-1	1e-3	1.1020	5.4285	0.4400	2.0400	0.3748	0.0010
CGB	Powell-Beale Conjugate Gradient	1-3-1	1e-3	1.0403	5.1246	0.5000	2.2500	0.3899	0.0010
SCG	Scaled Conjugate Gradient	1-3-1	1e-3	1.0730	5.2857	0.3800	2.2000	0.4610	0.0010
BFG	BFGS Quasi-Newton	1-3-1	1e-3	0.7523	3.7059	0.3800	1.5400	0.2525	0.0010
LM	Levenberg-Marquardt	1-3-1	1e-3	0.2030	1.0000	0.1100	0.6100	0.0913	0.0007

W tym przypadku sieć będzie służyła do aproksymacji. Struktura sieci 1-3-1 z **tansig** funkcją transferową w warstwie ukrytej i liniową funkcją transferową w warstwie wyjścia. Sieć będzie używała 11 algorytmów trenowania. Testowanie nastąpi za pomocą 30 różnych prób dla losowych początkowych wag. Będzie ono trwało aż do momentu, gdy tolerancja błędu średniokwadratowego będzie mniejsza niż 0.003.

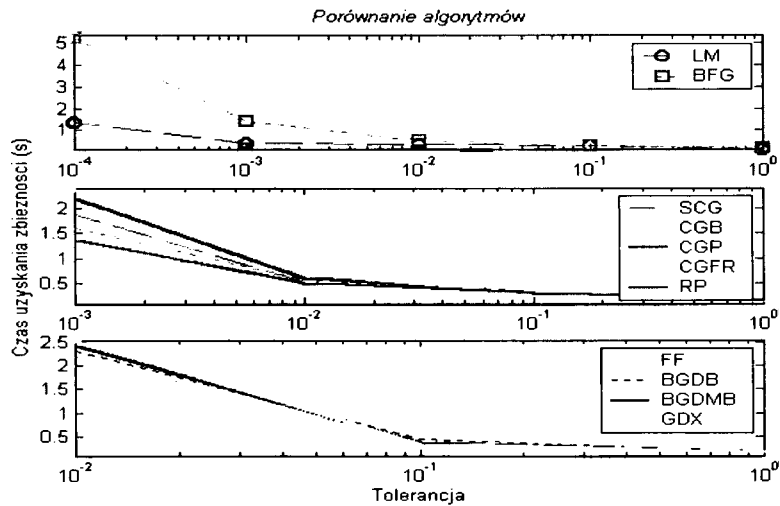
Z tab. 3 wynika, że najszybsze i zarazem najdokładniejsze okazały się metody hesjanowe, a w szczególności algorytm Levenberga-Marquardta, który jest prawie cztery razy szybszy niż następny algorytm. Metody gradientów sprzężonych i metody wstecznej propagacji błędów są w zasadzie porównywalne. Najgorszą jest metoda Feedforward Network, co sugeruje, że sieci otwarte nie za bardzo nadają się do rozwiązywanego problemu.

Na ryc. 4 zostały porównane reprezentatywne sieci: Feedforward Network, Resilient Backpropagation i Levenberga-Marquardta. Jak widać, zarówno pod względem szybkości zbieżności algorytmów, jak też ich regresyjnego dopasowania algorytm Levenberga-Marquardta jest najlepszy. Błąd algorytmu obniża się bardziej gwałtownie w czasie niż wśród innych pokazanych algorytmów. Można również zauważyć, że trenowana sieć w algorytmie Feedforward Network nie osiągnęła założonego celu.



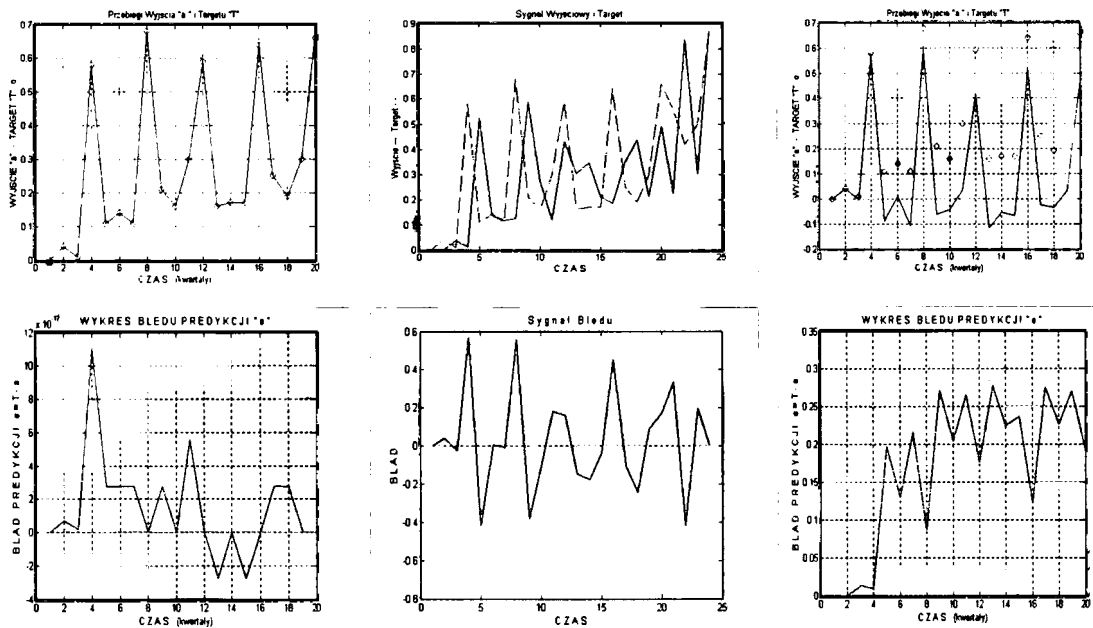
Ryc. 4. Porównanie 3 reprezentatywnych sieci

Na ryc. 5 została porównana szybkość zbieżności wszystkich branych pod uwagę algorytmów. Czas, który jest potrzebny do uzyskania zbieżności, kontra błąd średniokwadratowy. Można zauważyć, że błąd jest redukowany. Najlepiej zachowującymi się algorytmami, kiedy błąd jest redukowany, są: LM, BFG, a najgorzej GDZ i BGDMB.



Ryc. 5. Porównanie algorytmów

Predykcja



Ryc. 6. Predykcja liniowa, adaptacyjna i AR

Algorytm liniowej predykcji symulacyjnej polega na symulacji liniowego neuronu przewidującego następną wartość sygnału w każdym kroku czasowym, rozwiązuje problem predykcji przez wybór wag i biases w sieci z liniową funkcją przejścia jako modelem neuronu. Błąd jest rzędu 10^{-17} .

Algorytm liniowej predykcji adaptacyjnej polega na symulacji adaptacyjnego liniowego neuronu filtrującego sygnał, który wraz z błędem jest zwracany wraz z nową siecią. Jest on szczególnie cenny, gdy na rynku występują gwałtowne zmiany.

Na ryc. 6 można zauważyć, jak dobrze liniowy neuron jest w stanie adaptować się do zmian w targacie i przewidywać jego zachowanie w czasie.

Przybliżenie liniowe może być przeprowadzone również przy pomocy metod AR: Yule-Walkera, forward-backward (default), najmniejszych kwadratów LS, Burga, geometrycznej sieci. Zastosowanie liniowej predykcji AR Yule-Walkera daje nam wartość minimalnej wariancji błędu predykcji w wysokości 0,2 – 0,27.

Wnioski

Potrzeby każdego społeczeństwa są generatorami popytu na różnego rodzaju dobra, w tym oczywiście mieszkania.

Przed podjęciem przez inwestorów decyzji o rozpoczęciu budowy obiektu mieszkaniowego należy zatem uzyskać informacje o występującym popycie. Pierwszym krokiem projektowym jest analiza tego popytu, a następnie ocena jego ważności (względem przyjętych uprzednio kryteriów).

W związku z powyższym w artykule stworzono i zaprezentowano nowoczesne systemowe podejście wyposażone w metody i techniki, dzięki którym można uzyskać dedykowaną z punktu widzenia zastosowania prognozę popytu mieszkaniowego. Predykcja ta polegała na przewidzeniu następnych wartości popytu, przy danych jego ostatnich 5 wartościach. Z powyższych badań wynika, że neuron jest w stanie dobrze przewidywać zachowanie w czasie targetu przy minimalnych wariancjach błędu.

Przeprowadzone badania są wstępem do stworzenia interaktywnego dedykowanego suportu do predykcji popytu mieszkaniowego jako dedykowanego wejścia w podejściu systemowym do procesu planowania adekwatnych do prognozowanej sytuacji rozwiązań technologicznych i korzystnej realizacji przedsięwzięć budowlanych.

Literatura

1. Bryx M., *Finansowanie rozwoju budownictwa mieszkaniowego*. SGH, Warszawa 1999.
2. Chow G.C., *Ekonometria*. PWN, Warszawa 1995.
3. *Decyzje symulacyjne, Sieci neuronowe*. Red. Rymarczyk M., Wydawnictwo Wyższej Szkoły Handlowej, Poznań 1997.
4. Deutsch R., *Teoria estymacji*. PWN, Warszawa 1969.
5. Dominiak W., *Mieszkalnictwo w gospodarce narodowej*. Sprawy Mieszkaniowe z. 2-3/1999, IGM.
6. Dominiak W., Uchman R., *Makroekonomiczne uwarunkowania rozwoju budownictwa mieszkaniowego w Polsce*, Sprawy Mieszkaniowe, z. 3/2001, IGM.
7. Draper N.R., Smith H., *Analiza regresji stosowana*, PWN, Warszawa 1973.
8. Hertz J., Krogh A., Palmer R., *Wstęp do teorii obliczeń neuronowych*, Wydawnictwo Naukowo-Techniczne, Warszawa 1995.

9. Hillebrandt P.M., *Economic Theory and the Construction Industry*, Macmillan, London 2000.
10. Kulesza H., *Rządowy program „Mieszkalnictwo”. Próba oceny*. IGM, Sprawy Mieszkaniowe, nr 1/2002.
11. Kulesza H., *Sytuacja mieszkaniowa w Polsce w drugiej połowie XX wieku*. Sprawy mieszkaniowe, nr 2-3/1999, IGM.
12. Kulwicki E., Czyż M., Karcz B., Kukuła U., *Ekonomia wybrane zagadnienia*. Kraków 1997.
13. Lula P., *Jednokierunkowe sieci neuronowe w modelowaniu zjawisk ekonomicznych*, Wydawnictwo Akademii Ekonomicznej w Krakowie, Kraków 1999.
14. Osowski S., *Sieci neuronowe w ujęciu algorytmicznym*, Wydawnictwo Naukowo-Techniczne, Warszawa 1996.
15. Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, PWN, Łódź 1999.
16. *Sieci neuronowe*, Seminarium, Warszawa 14 października 1999 r.
17. *Strategia mieszkaniowa gminy miejskiej. Założenia, zakres, metody*. Red. Zaniewska H., IGM, Warszawa 1997.
18. Szafranko E., *Czynniki kształtujące ceny mieszkań na przykładzie regionu olsztyńskiego*, Problemy Rozwoju Budownictwa, 2/2001.
19. Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza PM, Warszawa 1993.
20. Walesiak M., *Metody analizy danych marketingowych*, PWN, Warszawa 1996.
21. Welfe A., *Ekonometria*, PWN, Warszawa 1995.
22. Werner W.A., *Proces inwestycyjny dla architektów*, Oficyna Wydawnicza Politechniki Warszawskiej, 1994.
23. Zeliaś A., Pawełek B., Wanat S., *Prognozowanie ekonomiczne: teoria, przykłady, zadania*. PWN, Warszawa 2003.

Streszczenie

Wszyscy inwestorzy budując domy (mieszkania) są bardzo zainteresowani wykorzystaniem profesjonalnych suportów decyzyjnych, których brak jest obecnie bardzo dotkliwie odczuwany. Przyczyną tego zainteresowania jest fakt, iż ponoszą oni nie tylko duże nakłady finansowe, ale podejmują również określony wysiłek organizacyjny związany z planowaniem i realizacją bardzo złożonego przedsięwzięcia budowlanego. Z punktu widzenia inwestorów wiedza o prognozowanym poziomie popytu dostarcza im kluczowej informacji wejściowej dla planowania adekwatnych i dedykowanych dla prognozowanej sytuacji rozwiązań technologicznych i korzystnej realizacji przedsięwzięcia budowlanego, z zapewnieniem minimum ryzyka i zgodności rozwiązań proponowanych z obowiązującym zagospodarowaniem przestrzennym terenu.

Zadanie adekwatnego oszacowania, a tym bardziej adaptacyjnego prognozowania popytu mieszkaniowego stanowi istotne wyzwanie naukowe z uwagi na liczne trudności (np. permanentny brak danych lub słabą ich jakość) i duży stopień nieokreśloności związany zarówno z charakterystyką tego popytu jak i realizacją bardzo złożonego wieloaspektowego przedsięwzięcia budowlanego.

Oszacowanie popytu mieszkaniowego wymaga kompleksowej identyfikacji wielu różnorodnych czynników mających wpływ na parametry realizacji procesu budowlanego, a co się z tym ściśle wiąże również na nasze decyzje mieszkaniowe.

W artykule dokonano identyfikacji istotnych wskaźników mających wpływ na proponowany model popytu mieszkaniowego. Określono metody i naukowe techniki

badawcze wykorzystane do analizy statystycznej zebranego materiału. Analizę tą przeprowadzono za pomocą programu MATLAB a w szczególności procedur STEPWISE i NLINFIT. W oparciu o tą analizę zidentyfikowano istotne determinanty modelowanych zjawisk, które wykorzystano do uczenia sieci neuronowych. Przy uczeniu sieci neuronowych zastosowano różne metody statyczne i dynamiczne (perceptron, gradientowe, gradientu sprzężonego, drugiego rzędu wykorzystujące aproksymację Hesjanu). Efektywność tych metod była badana (parametry, struktura sieci) i weryfikowana (analiza post optymalizacyjna) i porównywana. Wybrano dedykowaną metodę dla tego konkretnego zastosowania. Nauczone sieci były wykorzystywane dla potrzeb liniowej i adaptacyjnej predykcji popytu mieszkaniowego (np. dla przewidzenia następnych wartości popytu, przy danych jego ostatnich 5 wartościach).

PREDICTING THE HOUSING DEMAND

Summary

All investors who build homes or flats are very much interested in the use of professional decision support tools. The reason of that interest is the fact that investors incur not only high financial expenditures, but they also make organisational efforts related to planning and implementation of complex construction projects. From the investors' viewpoint, the knowledge of projecting demand will give them key data for planning adequate technological solutions, complying with the projected situations, and profitable completion of a construction project at low risk and in compliance with the physical plan.

The task of adequate evaluation and adaptive diagnosing of housing demand constitutes an essential scientific challenge due to a number of difficulties (e.g. lack of data or poor quality of data) and a large degree of uncertainty related to the demand characteristics and the execution of complex and comprehensive construction projects.

Evaluation of housing demand requires a comprehensive identification of many diverse factors that affect the parameters of the building process, and it also affects our housing decisions.

The paper identifies essential indicators that affect the proposed housing demand model. It determines scientific methods and techniques used for the statistical analysis of collected materials. The analysis was conducted with the application of the MATLAB software, including in particular STEPWISE and NLINFIT procedures. Based on that analysis, the author identified essential determinants of the events subjected to modelling. They were later applied to teaching neuronal networks. In that process, various static and dynamic methods were applied (perceptron, gradient, adjoint gradient, second order with function approximation (Hesjan)). The effectiveness of those methods was tested (with parameters, and network structure), verified (post-optimisation analysis) and compared. A dedicated method for a specific application was selected. Developed networks were used for the need of linear and adaptive prediction of housing demand (e.g. to project future demand figures based on the last five figures).

Key Words: housing demand, demand indicators, prediction, regression, neuronal networks

Mgr Marzena Fortuna
Instytut Zarządzania w Budownictwie i Transporcie
Politechnika Krakowska