

Nr 51

PRACE NAUKOWE

Uniwersytetu Ekonomicznego we Wrocławiu

Projektowanie, ocena i wykorzystanie danych rynkowych

Redaktor naukowy
Józef Dziechciarz



Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu
Wrocław 2009

Spis treści

Wstęp	7
Sylwester Białowas , Kolejność pytań w kwestionariuszu wywiadu osobistego a zniekształcenia pomiaru wywołane heurystyką zakotwiczenia	9
Marta Dziechciarz , Podejścia do oceny atrakcyjności segmentów rynku jako etapu kończącego proces segmentacji rynku	14
Bartłomiej Jefmański , Rozmyta metoda k -średnich w identyfikacji przynależności obiektów do segmentów rynkowych – na przykładzie rynku samochodowego	28
Iwona Kasprzyk , Wykorzystanie konfiguracyjnej analizy częstości w analizie klas ukrytych	37
Jolanta Kowal , Wybrane teoretyczne i praktyczne aspekty metodologii badań jakościowych	46
Magdalena Kowalska-Musiał , Relacje partnerskie w układach diadycznych – ocena i analiza danych	76
Mariusz Łapczyński , Modele hybrydowe CART-LOGIT w analizie danych rynkowych	85
Roman Pawlukowicz , Średnia arytmetyczna cen transakcyjnych nieruchomości a wartość rynkowa nieruchomości	96
Marcin Pelka , Porównanie strategii klasyfikacji danych symbolicznych	106
Adam Sagan , Metaanaliza danych w marketingu zorientowanym na dowody – orientacja kliniczna w badaniach rynkowych i marketingowych	114
Piotr Tarka , Zastosowanie analizy regresji i sztucznych sieci neuronowych w badaniach satysfakcji klientów	125
Barbara Worek , Rzetelność i trafność w badaniach jakościowych: ocena jakości danych	136

Summaries

Sylwester Białowas , The anchoring heuristic and the bias of the measurement in marketing research	13
Marta Dziechciarz , Determining the attractiveness of market segments as the ending step of segmentation process	27
Bartłomiej Jefmański , Fuzzy c-means in market segments membership identification – a car market example	36
Iwona Kasprzyk , Application of configural frequency analysis in latent class analysis	45

Jolanta Kowal , Some chosen theoretical and practical aspects of qualitative research	75
Magdalena Kowalska-Musiał , Dyadic relationship – data evaluation and analysis	84
Mariusz Łapczyński , The hybrid CART-LOGIT models in analysing market data	95
Roman Pawlukowicz , Arithmetic mean of transactional prices of properties and property's market value	105
Marcin Pelka , Comparison of symbolic data clustering strategies	113
Adam Sagan , Meta-analysis in evidence-based marketing: clinical orientation in marketing research	124
Piotr Tarka , Artificial neural networks and regression comparison analysis within customer satisfaction data	135
Barbara Worek , Reliability and validity in qualitative research: data quality evaluation	147

Piotr Tarka

Uniwersytet Ekonomiczny w Poznaniu

ZASTOSOWANIE ANALIZY REGRESJI I SZTUCZNYCH SIECI NEURONOWYCH W BADANIACH SATYSFAKCJI KLIENTÓW

1. Wstęp

Badania satysfakcji klientów powinny dostarczać nie tylko informacji na temat specyficznych zmiennych warunkujących właściwy u nich poziom satysfakcji (w zakresie której ostateczny wynik jest identyfikowany i interpretowany poprzez elementarne zasady statystyki opisowej), ale także informacji odzwierciedlającej dokładny obraz związków przyczynowo-skutkowych na temat tejże satysfakcji. Chodzi zatem już nie tylko o elementarny opis wyników, ale, po pierwsze, o weryfikację i obserwację następujących po sobie etapów i tym samym wynikających z nich ograniczeń analitycznych oraz, po drugie, dokładną identyfikację wszystkich uwarunkowań w sferze przyczyn i skutków, powodujących u klientów wzrost lub spadek poziomu satysfakcji. I tak na przykład w analizie regresji wielorakiej badanie związków może zachodzić m.in. w wyniku zestawienia (postrzeganych przez klientów) wielu zmiennych związanych z danym produktem lub usługą i tym samym obserwacji tych zmiennych w odniesieniu do stopnia ich wpływu (powiązania) z ogólnym poziomem satysfakcji klienta [Anton 1996; Vavra 1997]. Współczynniki regresji będą wówczas wyznaczać wagę i określać poziom dla każdej rozpatrywanej w analizie zmiennej wpływającej na ogólny wymiar satysfakcji [Rust, Zahorik, Keiningham 1994, 1996; Vavra 1997].

2. Model cząstkowych najmniejszych kwadratów w ujęciu regresji (PLS)

Do analizy danych w zakresie satysfakcji klientów można wykorzystać model cząstkowych najmniejszych kwadratów (*partial least squares*). Regresja metodą PLS stanowi rozszerzenie modelu liniowej regresji wielorakiej i jest standardowym narzędziem do modelowania związków występujących w obrębie pomiarów wielo-

wymiarowych. Metoda ta jest niezwykle przydatna w eksploracji zmiennych związanych z satysfakcją klientów [Ryan, Rayner, Morrison 1999; Johnson, Gustafsson 2000; Anderson, Fornell 2000]. Głównym celem PLS jest budowa modelu liniowego w postaci:

$$Y = XB + E, \quad (1)$$

gdzie: Y – macierz odpowiedzi o wymiarach n (liczba przypadków) na m (liczba zmiennych),

X – macierz predyktorów (układu (eksperymentu) o wymiarach n (liczba przypadków) na p (liczba zmiennych),

B – macierze współczynników regresji o wymiarach p na m ,

E – składnik losowy modelu o takich samych wymiarach jak macierz Y .

Przy wyznaczaniu wartości zmiennych model PLS tworzy macierz wag W (o wymiarach p na c) dla X , taką że $T = XW$, tzn. kolumny macierzy W stanowią wektory wag dla kolumn macierzy X , tworząc odpowiednią macierz wartości zmiennych T (o wymiarach n na c).

Wagi te są obliczane w taki sposób, że każda z nich maksymalizuje kowariancję pomiędzy odpowiedziami a odpowiadającymi im wartościami zmiennych. Dalej wykorzystuje się procedurę zwykłej metody najmniejszych kwadratów dla regresji Y względem T w celu utworzenia macierzy Q zawierającej ładunki dla Y (lub inaczej wagi dla Y) takie, że $Y = TQ + E$. Po obliczeniu Q otrzymujemy równanie:

$$Y = XB + E, \quad (2)$$

gdzie: $B = WQ$.

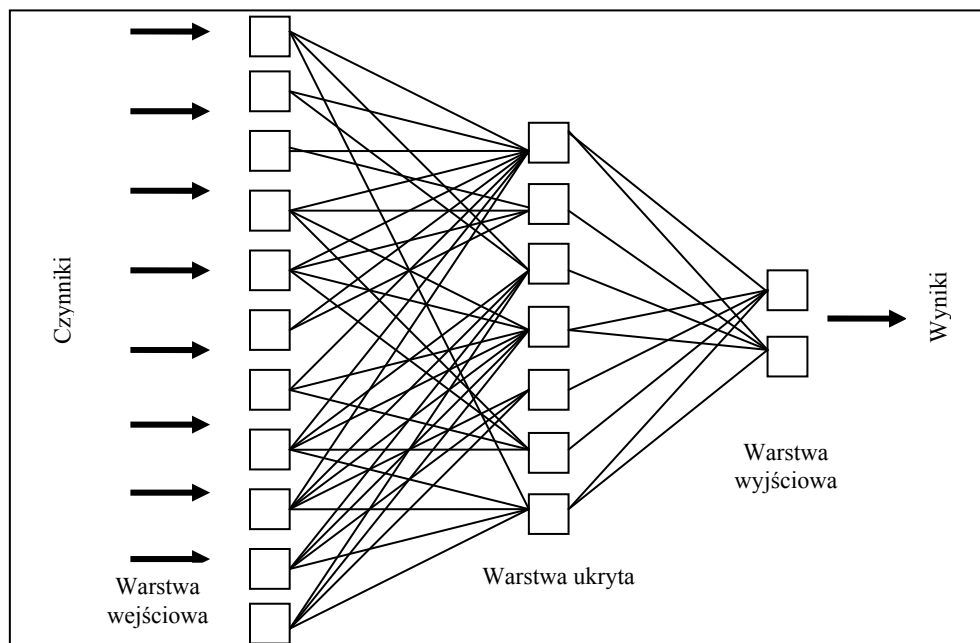
Sam model PLS jest niestety narażony na współliniowość, dlatego też alternatywą dla modelu regresji jest model sztucznej sieci neuronowej, który coraz częściej wykorzystuje się w analizach satysfakcji klientów [Hackl, Westlund 2000; Willson, Wragg 2001].

3. Model sztucznej sieci neuronowej (SSN)

Konstrukcja modelu sztucznej sieci neuronowej polega na ułożeniu warstw składających się z wielu neuronów. Do każdego neuronu dociera określona liczba sygnałów wejściowych (wartości) $x_i, i = 1, \dots, n$ na jedno wyjście y .

Neurony tworzą strukturę jednokierunkową. Oznacza to, że przesyłanie sygnałów odbywa się w kierunku od wejścia do wyjścia – bez sprzężeń zwrotnych. Sieć można interpretować jako model typu wejście – wyjście, którego parametrami są wagi oraz wartości progowe. Sieć taka może modelować – przy odpowiedniej liczbie warstw i neuronów – funkcję o prawie dowolnej złożoności. Samo określenie liczby warstw i neuronów w kolejnych warstwach jest bardzo ważnym etapem pro-

cesu konstrukcji perceptronu wielowarstwowego [Bishop 1995]. Strukturę sztucznych sieci neuronowych zaprezentowano na rys. 1.



Rys. 1. Ogólna struktura sztucznej sieci neuronowej

Źródło: opracowanie własne na podstawie [Witkowska 2002, s. 1- 36].

W neuronie obliczana jest ważona suma wejść (suma wartości sygnałów wejściowych przemnożonych przez odpowiednie współczynniki wagowe), a następnie odejmowana jest od niej wartość progowa. Kombinacja liniowa wejść z uwzględnieniem wyrazu wolnego przyjmuje następującą postać [Witkowska 2002]:

$$e = w_0 + \sum_{i=1}^n w_i x_i = w_0 + \mathbf{w}^T \mathbf{x}, \quad (3)$$

gdzie: $\mathbf{x} = [x_i]$ – wektor $[n \times 1]$ sygnałów wejściowych,

$\mathbf{w} = [w_i]$ – wektor $[n \times 1]$ wag, określających stopień ważności informacji przekazywanej i -tym wejściem oraz stanowiących pamięć neuronu (kodującą relacje zachodzące między sygnałami wejściowymi i sygnałem wyjściowym).

Uproszczenie kolejno występującego wzoru wiąże się z przyjęciem obok sygnałów wejściowych x_i ($i = 1, 2, \dots, n$), zmiennej $x_0 = 1$. W rezultacie wzór określający na pobudzenie neuronu przyjmuje następującą postać:

$$e = \sum_{i=1}^n w_i x_i = \mathbf{w}^T \mathbf{x}. \quad (4)$$

Wyznaczony poziom pobudzenia staje się argumentem funkcji przejścia (funkcji aktywacji), która oblicza wartość wyjściową neuronu:

$$y = \varphi(e), \quad (5)$$

gdzie: φ – funkcja aktywacji neuronu.

Funkcja aktywacji przyjmuje postać liniową lub nieliniową. Zależności, jakie się kształtują na podstawie sygnałów wejściowych i wyjściowych, mają charakter dowolny. Najprostszy neuron liniowy to funkcja tożsamościowa:

$$\varphi(e) = e. \quad (6)$$

W zakresie sieci nieliniowych wykorzystuje się z kolei neurony o progowej funkcji aktywacji (tzw. perceptrony):

$$\varphi(e) = \begin{cases} 1 & \text{gdy } e \geq 0 \\ 0 & \text{gdy } e < 0 \end{cases}. \quad (7)$$

4. Zalety i wady sztucznych sieci neuronowych

Sieci neuronowe mogą być wykorzystywane praktycznie w każdej sytuacji, gdzie pomiędzy zmiennymi zależnymi i niezależnymi istnieje rzeczywista zależność lub zespół zależności, nawet jeśli są one bardzo skomplikowane i niewyraźne w klasyczny sposób, poprzez korelacje czy różnice między grupami przypadków. Zdaniem niektórych uczonych [Fausett 1994; Bishop 1995; Hassoum 1995; Callan 1999] zaletą sieci neuronowych jest połączenie modeli struktur występujących w mózgu człowieka (w wyniku inspiracji naukowców biologią) z modelami matematycznymi [Uysal, Roubi 1999; Fadlalla, Lin 2001; Nguyen, Cripps 2001]. D. Witkowska twierdzi wręcz, że sztuczne sieci neuronowe mogą być bardzo skutecznym narzędziem obliczeniowym, umożliwiającym realizację idei masowego równoległego przetwarzania informacji, które nie wymaga programowania z jednoczesnym wykorzystaniem automatycznego procesu uczenia.

Pierwowzorem sztucznych sieci neuronowych jest ludzki mózg, który składa się z 10^{10} komórek nerwowych, przetwarzających dane w sposób równoległy w trybie równoczesnej pracy wielu połączonych ze sobą neuronów. Dzięki możliwości uczenia się oraz swoistej strukturze sztuczne sieci neuronowe wykazują pewne właściwości podobne do procesów myślowych zachodzących u człowieka. Cechuje je mianowicie zdolność przetwarzania informacji rozmytych, chaotycznych i niekompletnych, szybkie i efektywne przetwarzanie dużych ilości danych oraz przetwarzanie równoległe i rozproszone.

Wśród wad sztucznych sieci neuronowych należałoby z kolei wymienić:

1) przetwarzanie danych wyłącznie numerycznych, należących do ściśle określonego przedziału (w zakresie danych nienumerycznych zachodzi konieczność przekalowania danych),

2) realizację obliczeń przy założeniu dużej liczebności próby. Liczba wymaganych przypadków budujących zbiór uczący sięga rzędu setek lub tysięcy, bardzo rzadko zaś wystarczająca liczba przypadków jest mniejsza od stu [Witkowska 2002].

5. Analiza danych poprzez model sztucznych sieci neuronowych *versus* model regresji

Wykorzystanie sztucznych sieci neuronowych do analizy związków wielu zmiennych skutecznie eliminuje ograniczenia, jakie pojawiają się chociażby w zakresie regresji [Hill, Remus 1994; Wray, Palmer, Bejou 1994; Uysal, Roubi 1999]. W badaniach przeprowadzanych w sferze satysfakcji klientów związku występujące między zmiennymi wpływającymi na określony poziom satysfakcji mają najczęściej kształt nieliniowy [Jones, Sasser 1995; Johnson, Gustafsson 2000; Willson, Wragg 2001]. Prawdę powiedziawszy, wszystkie złożone systemy, których modele chcemy budować, są w mniejszym lub większym stopniu nieliniowe. Często jednak decydujemy się na opisywanie ich za pomocą formuł liniowych, ponieważ wyznaczenie modelu liniowego i jego wykorzystanie jest łatwe. Niedokładność jednak, jaka jest wnoszona poprzez model liniowy, jest duża, a zatem zachodzi konieczność stworzenia modelu nieliniowego. Dla regresji wiąże się to z doбором takich parametrów tego modelu, aby odwzorowywał on posiadane dane w optymalny sposób. Twórca projektu musi odgadnąć kształt danych w związku z określonym badanym przez niego zjawiskiem. Sieci neuronowe są natomiast w stanie ten problem wyeliminować. Sieć, poprzez proces uczenia się, może sama znaleźć nieliniowy model rozważanego systemu. Sieci nie trzeba podawać żadnych założeń dotyczących kształtu modelu. Wątpliwości może budzić jedynie fakt, że uzyskany w trakcie uczenia się sieci błąd osiągnął swój poziom minimalny, przez co otrzymany model może być odległy od modelu optymalnego.

Sieci neuronowe (w odróżnieniu od regresji) nabywają umiejętności opisu zależności w trakcie procesu uczenia się na podanych przykładach. Badacz powinien jednak wiedzieć, czy istnieje jakakolwiek zależność między proponowanymi do analizy zmiennymi, sygnałami (na wejściu do sieci) a nieznanymi wartościami wynikowymi, które chciałby związać z jej wyjściami. Charakter tej zależności nie musi być jednak znany, ponieważ ustala ją sieć w trakcie procesu uczenia. W modelach regresji trzeba ocenić związek między zmiennymi niejako *a priori*. Tak szczegółowa specyfikacja nie jest wymagana przy SSN. Procedura ustalająca zależności dokonuje się niemal automatycznie. Automatyczna estymacja przy odpowiednio zachodzących

interakcjach między wieloma zmiennymi wpływa z kolei na lepszy (wiarygodniejszy) końcowy wynik [Wray, Palmer, Bejou 1994].

Przewagą SSN nad modelem regresji jest także dokładniejsza identyfikacja niewyraźnych zależności występujących w zbiorze danych lub likwidacja zależności pomiędzy zmiennymi, które mogą dostarczać (na różne sposoby) tych samych informacji. W sieci neuronowej wystarczy wykorzystać w charakterze wejść pewien ich podzbiór. Wybiera się spośród zmiennych skorelowanych odpowiednią reprezentację, tak zbudowaną, aby zmienne zachowane w tej reprezentacji już dalej nie były wzajemnie skorelowane. Wadą tego podejścia jest to, że procedury (jakie dokonują się podczas analizy) są bardzo czasochłonne. Wielokrotnie trzeba ponawiać próby uczenia się i oceny sieci, eliminując po kolei różne zmienne i ich kombinacje.

6. Metodyka badań


Badania przeprowadzono metodą wywiadu bezpośredniego z wykorzystaniem kwestionariusza na próbie składającej się z 1145 klientów dokonujących zakupów farmaceutyków (leków) w losowo wybranych aptekach w Polsce (na podstawie danych z firmy MilwardBrown SMG/KRC, 2007). Podczas wywiadu klientów proszono w pierwszej kolejności o podanie **ogólnej oceny** w odniesieniu do jakości produktów oferowanych oraz usług świadczonych przez daną aptekę. Jakość ta z założenia miała się przekładać na wysoki lub niski poziom satysfakcji klientów. Ocena podawana przez klientów obejmowała 5-stopniową skalę, gdzie: 1 oznaczało „bardzo niska jakość produktów i usług”, a 5 – „bardzo wysoka jakość produktów i usług”. Ten sam obszar badano przy użyciu skali od 0 do 100 (**ogólnie** słaba jakość – wysoka jakość).

W drugiej części badania klientów proszono o ocenę 17 wymiarów apteki obejmujących **ważność** (wagę) proponowanych w aptece produktów i usług, warunkujących poziom jakości apteki, i tym samym stopień zadowolenia klientów. Pytania (do 17 wymiarów – zmiennych) sformułowano w formie stwierdzeń, na które klient udzielał odpowiedzi, do 5-stopniowej skali, gdzie: wartość 1 oznaczała „zdecydowanie się nie zgadzam”, a wartość 5 – odpowiedź typu „zdecydowanie się zgadzam”.

7. Analiza danych

Ważność poszczególnych zmiennych wpływających na ogólny poziom postrzeganej jakości, a tym samym zadowolenia klientów wykazano poprzez analizę regresji i sztucznych sieci neuronowych. Do obliczeń wykorzystano oprogramowanie *Statistica*. W pierwszej części analizy opartej na regresji 17 zmiennych (tj. wyodrębnionych do badania wymiarów i włączonych do analizy) potraktowano jako zmienne objaśniające (niezależne), a ogólny poziom satysfakcji wynikający z jakości produktów i usług apteki potraktowano jako zmienną objaśnianą (zależną). Na podstawie współczynników korelacji policzono względną ważność dla każdej zmiennej [Rust,

Zahorik, Keiningham 1994]. Oszacowane wyniki odzwierciedlające względną ważność zmiennych w odniesieniu do ogólnego poziomu satysfakcji, mierzonego jako średnia na 100-punktowej skali, przeniesiono na mapę percepcji (rys. 2). Na jej podstawie stwierdzono, że najważniejsze zmienne to wymiary, które odznaczały się wysokimi wartościami w sferze ważności (wagi) oraz wysokimi wartościami zadowolenia (inaczej wykonania usług/produktów lub tzw. wydajności apteki).



Rys. 2. Ważność zmiennych a ogólny poziom satysfakcji w relacji do jakości produktów/usług w aptekach

Źródło: opracowanie własne na podstawie przeprowadzonych obliczeń w programie *Statistica*.

Analizę satysfakcji klientów przeprowadzono również z wykorzystaniem skonstruowanego modelu sztucznych sieci neuronowych (SSN). Do analizy wybrano 1 zmienną wyjściową (tj. ogólny postrzegany przez klientów poziom jakości usług/produktów warunkujących u nich satysfakcję) i 17 zmiennych wejściowych (oceniane przez respondentów w badaniu wymiary).

Pierwszą czynnością (w zakresie przyjętego modelu) było sprawdzenie poziomu rzetelności/dokładności modelu. W analizie model wyjaśniał aż 98,4% wszystkich przypadków. Następnie na podstawie 11 wybranych (spośród 17 rozpatrywanych) zmiennych określono ich wpływ w kontekście mierzonej satysfakcji klientów (tab. 1).

Tabela 1. Zmienne (przed interakcją) w relacji do jakości produktów i usług aptek warunkujących ogólny poziom satysfakcji klientów

Lista zmiennych	Zmienne (przed interakcją)
W aptece są zawsze odpowiednie leki na półce	4.6
Leki „spod lady” mają lepszą jakość	3.7
Ulotki dołączane do leków są dobrze przygotowane (zawierają dużo informacji i są czytelne)	3.1
Ceny leków w aptece kształtują się na odpowiednim poziomie	3.0
Broszury, jakie można dostać w aptece na temat poszczególnych leków, dostarczają użytecznych informacji	2.6
Zakres dostępnych w aptece leków jest bardzo szeroki	2.4
Reklamy, z jakimi spotykam się w aptece, powodują, że mam większą świadomość i wiedzę na temat leków	1.9
Apteka ma dobrą lokalizację	1.7
W aptece istnieje możliwość porównywania cen leków	1.0
Obsługa apteki jest bardzo miła	0.8
Oznaczenia cenowe leków są w aptece dobrze widoczne	0.6

Źródło: opracowanie własne na podstawie przeprowadzonych obliczeń w programie *Statistica*.

W tab. 1 pokazano wyniki w zakresie wpływu wybranych zmiennych na ogólny poziom zadowolenia klientów z jakości usług/produktów. W tym ujęciu ich wartości zostały policzone niezależnie, tj. bez interakcji. Dopiero przeprowadzenie interakcji pomiędzy zmiennymi spowodowało zagregowanie ich wartości, co w rezultacie przełożyło się na wyższy poziom badanej satysfakcji. Jest to pewien efekt doskonalenia (podwyższania) jakości wygenerowanych wartości zmiennych. Zilustrowano to na przykładzie kolejnych dwóch i trzech zmiennych (zob. tab. 2).

Połączenie i porównanie dwóch pierwszych zmiennych „*W aptece są zawsze odpowiednie produkty farmaceutyczne*” i „*W aptece istnieje możliwość porównywania cen leków*” dało lepszy rezultat, jakiego z całą pewnością nie można byłoby osiągnąć przy zachowaniu niezależności zmiennych. Efekt ten powstał w wyniku uruchomienia interakcji i tym samym zaistniałej pomiędzy tymi zmiennymi synergii. W sumie oddziaływanie tych zmiennych w wyniku łącznej interakcji symultanicznej ukształtowało się na poziomie 6.0. Brak interakcji (przy założeniu niezależności ocen tych samych zmiennych) generował słabszy wynik – wpływ (tab. 1) o 0.4 punktu (4.6 dla zmiennej „*W aptece są zawsze odpowiednie produkty farma-*

Tabela 2. Zmienne w relacji do jakości produktów i usług aptek warunkujących ogólny poziom satysfakcji klientów po przeprowadzonej interakcji i synergii tych zmiennych

Lista zmiennych	Zmienne (po interakcji)
W aptece są zawsze odpowiednie leki na półce + W aptece istnieje możliwość porównywania cen leków	6.0
W aptece są zawsze odpowiednie leki na półce + W aptece istnieje możliwość porównywania cen leków + Oznaczenia cenowe leków są w aptece dobrze widoczne	7.1
Ulotki dołączane do leków są dobrze przygotowane + Broszury, jakie można dostać w aptece na temat leków, dostarczają użytecznych informacji	7.3

Źródło: opracowanie własne na podstawie przeprowadzonych obliczeń w programie *Statistica*.

ceutyczne” + **1.0** dla zmiennej „*W aptece istnieje możliwość porównywania cen leków*” = **5.6**).

Dodanie trzeciej zmiennej do tych samych zmiennych spowodowało zwiększenie poziomu skorelowania tej zmiennej z jakością usług/produktów, a tym samym z poziomem zadowolenia. W wyniku połączenia wartość osiągnęła poziom **7.1**, podczas gdy suma wartości dla tych samych zmiennych, oszacowanych niezależnie, wyniosła **4.6 + 1.0 + 0.6 = 6.2**. Różnica więc jest dosyć widoczna – 0,9 pkt. Podobny efekt interakcji i synergii można także zauważyć na przykładzie trzeciej kombinacji zmiennych (tab. 2, wiersz 3).

8. Podsumowanie

Uczenie się sieci i automatyczne wykrywanie przez sieć związków nie zawsze i nie w pełni zaspokaja oczekiwania i potrzeby informacyjne menedżerów (w tym przypadku kierowników aptek) poszukujących w obrębie danych tzw. wyższej wartości dodanej. Narzędzie to z całą pewnością poszerza wachlarz możliwości analitycznych menedżera i zmniejsza margines błędu w zakresie podejmowanych przez niego decyzji, ale nie daje 100% pewności, a już na pewno nie może zastąpić badania związków analizowanych poprzez modele regresji. Wykluczenie z obszaru decyzyjnego analiz opartych na regresji byłoby więc błędem. Analiza regresji dostarcza również ciekawych wyników. Wprawdzie stopień odniesienia i poziom ingerencji analityka w model regresji są większe niż w przypadku sztucznych sieci neuronowych, to jednak regresja staje się idealnym uzupełnieniem sztucznych sieci, przez co zmniejsza się błąd, jaki może popełnić osoba podejmująca decyzje w biznesie. Znajomość przez menedżera obydwu metod analizy powinna ułatwiać właściwą alokację środków/zasobów organizacji w celu podwyższania jakości usług lub produktów, a tym samym oddziaływać na poziom satysfakcji klientów.

Literatura

- Anderson E.W., Fornell C., *Foundations of the American customer satisfaction index*, "Total Quality Management" 2000, 11, 7, s. 869-882.
- Anton J., *Customer relationship management. Making hard decisions with soft numbers*, Upper Saddle River, NJ: Prentice Hall 1996.
- Bishop C.M., *Neural networks for pattern recognition*, Oxford University Press, Oxford 1995.
- Callan R., *The essence of neural networks*, Prentice Hall Europe, London 1999.
- Fadlall A., Lin C.H., *An analysis of the applications of neural networks in finance*, "Interfaces" 2001, 31, 4 (July/August), s. 112-122.
- Fausett L., *Fundamentals of neural networks*, Upper Saddle River, NJ: Prentice-Hall 1994.
- Grønholdt L., Martensen A., Kristensen K., *The relationship between customer satisfaction and loyalty: cross-industry differences*, "Total Quality Management" 2000, 11, 4/5/6 (July), s. 509-514.
- Hackl P., Westlund A.W., *On structural equation modelling for customer satisfaction measurement*, "Total Quality Management" 2000, 11, 4/5/6, s. 820-825.
- Hassoum M.H., *Fundamentals of artificial neural networks*, MA: The MIT Press, Cambridge, 1995.
- Hill T., Remus W., *Neural network approach for intelligent support of managerial decision making*, "Decision Support System's" 1994, 11, s. 449-459.
- Johnson M.D., Gustafsson A., *Improving customer satisfaction, loyalty, and profit*, University of Michigan Business School Management Series, CA: Jossey-Bass, San Francisco 2000.
- Jones T.O., Sasser W.E. Jr., *Why satisfied customers defect*, "Harvard Business Review" 1995, 73, 6 (November-December), s. 88-99.
- Nguyen N., Cripps A., *Predicting housing value: a comparison of multiple regression analysis and artificial neural networks*, "Journal of Real Estate Research" 2001, 22, 3, s. 313-336.
- Rust R.T., Zahorik A.J., Keiningham T.L., *Return on quality: measuring the financial impact of your company's quest for quality*, Ill: Probus, Chicago 1994.
- Rust R.T., Zahorik A.J., Keiningham T.L., *Service marketing*, HarperCollins, New York 1996.
- Ryan M.J., Rayner R., Morrison A., *Diagnosing customer loyalty drivers: partial least squares vs regression*, "Marketing Research" 1999, 11, 2 (Summer), s. 19-26.
- Uysal M., Roubi S.E., *Artificial neural networks versus multiple regression in tourism demand analysis*, "Journal of Travel Research" 1999, 38, November, s. 111-118.
- Vavra T.G., *Improving your measurement of customer satisfaction: a guide to creating, conducting, analyzing and reporting customer satisfaction measurement program*, Wis.: ASQ Quality Press, Milwaukee 1997.
- Willson E., Wragg T., *We cannot diagnose the patient's illness... but experience tells us what treatment works*, "International Journal of Market Research" 2001, 43, 2, s. 189-215.
- Witkowska D., *Sztuczne sieci neuronowe i metody statystyczne – wybrane zagadnienia finansowe*, C.H. Beck, Warszawa 2002.
- Wray B., Palmer A., Bejou D., *Using neural network analysis to evaluate buyer-seller relationships*, "European Journal of Marketing" 1994, 28, 10, s. 32-48.

ARTIFICIAL NEURAL NETWORKS AND REGRESSION COMPARISON ANALYSIS WITHIN CUSTOMER SATISFACTION DATA

Summary

The use of artificial neural networks (ANN) as an alternative approach to regression has gained popularity in different fields, and some studies have demonstrated the superiority of ANN over regression. The literature points to several limitations in regression that are overcome by ANN. This paper demonstrates the usefulness of ANN in customer satisfaction analysis. The author suggests that the application of ANN in customer satisfaction analysis is useful in identifying existing patterns in the data, and synergies between the drivers of satisfaction. The advantages of using ANN are highlighted and the managerial implications of ANN to identify the key drivers and set priorities for improvements are demonstrated.