

Marek Walesiak

*Katedra Ekonometrii i Informatyki
Akademia Ekonomiczna im. Oskara Langego we Wrocławiu
Wydział Gospodarki Regionalnej i Turystyki
w Jeleniej Górze*

PROBLEMY WYBORU W PROCEDURZE CONJOINT ANALYSIS*

1. Wprowadzenie

Podstawy teoretyczne metody *conjoint analysis* stworzyli psycholog matematyczny R.D. Luce oraz statystyk J.W. Tukey [Luce, Tukey 1964]. Pierwsze zastosowanie tej metody w marketingu przedstawiono w pracy [Green, Rao 1971], (zob. [Walesiak, Bąk 2000, s. 13]).

W zastosowaniach marketingowych metodologia *conjoint analysis* wykorzystywana jest do modelowania i pomiaru preferencji konsumentów względem produktów opisanych wieloma atrybutami (cechami). Modelowanie preferencji konsumentów pozwala na wyjaśnienie procesu postępowania konsumenta, którego wynikiem jest ocena oferowanych produktów i w efekcie wybór jednego z nich. Wśród modeli preferencji wyróżnia się modele kompensacyjne oraz niekompensacyjne. Kryterium podziału tych modeli jest możliwość wzajemnej rekompensaty ocen atrybutów, na podstawie których konsument dokonuje całkowitej oceny produktu. Szerzej na ten temat traktują prace: [Bąk 2000a, s. 72–77], [Zwerina 1997, s. 2–3].

W pomiarze preferencji konsumentów wyróżnia się podejście dekompozycyjne, kompozycyjne oraz mieszane (por. [Green, Srinivasan 1990]). W podejściu dekompozycyjnym całkowite preferencje respondentów otrzymuje się na podstawie dokonanych przez nich ocen profilów (produktów, usług) opisanych wybranymi atrybutami. Następnie, wykorzystując metody estymacji, dokonuje

* Pracę wykonano w ramach projektu badawczego nr 5 H02B 030 21 finansowanego przez Komitet Badań Naukowych w latach 2001–2003.

Tabela 1

Procedura *conjoint analysis*

Krok	Nazwa kroku w procedurze	Metody
1	Podejście stosowane do pomiaru struktury preferencji	dekompozycyjne, kompozycyjne, kompozycyjno-dekompozycyjne
2	Specyfikacja problemu badawczego	
3	Wybór postaci modelu zależności zmiennych i modelu preferencji	
	3.1. Wybór postaci modelu zależności zmiennych 3.2. Wybór postaci modelu preferencji	modele addytywne: efektów głównych, z interakcjami modele: liniowy, kwadratowy, odrębnych użyteczności cząstkowych, mieszany
4	Gromadzenie danych	
	4.1. Wybór metody prezentacji danych 4.2. Określenie skali pomiaru preferencji respondentów 4.3. Generowanie zbioru profilów 4.4. Określenie formy i sposobu prezentacji profilów 4.5. Wybór formy ankiety 4.6. Ustalenie niezbędnej liczebności próby	pełnych profilów wyboru, prezentacji par atrybutów, porównywania parami, oceny poziomów i atrybutów, wyboru spośród zbiorów profilów skale metryczne (ilorazowa, przedziałowa), skale niemetryczne (porządkowa, nominalna) pełny układ czynnikowy, cząstkowy układ czynnikowy, próba losowa rozkładu wielowymiarowego opis słowny, forma kart z opisami słownymi poziomów atrybutów, forma graficzna (rysunki, fotografie), model trójwymiarowy, produkty fizyczne wywiad osobisty, wywiad telefoniczny, kwestionariusz wysyłany pocztą, metoda komputerowo-interakcyjna, kombinacja kilku metod
5	Wybór metody estymacji parametrów (użyteczności cząstkowych) modelu <i>conjoint analysis</i>	– metryczne: KMNK – niemetryczne: MONANOVA, PREFMAP, LINMAP, bazujące na prawdopodobieństwie wyboru (LOGIT, PROBIT)
6	Ocena wiarygodności pomiaru	ocena trafności i rzetelności pomiaru
7	Interpretacja wyników pomiaru metodą <i>conjoint analysis</i> w przekroju indywidualnych respondentów i danych zagregowanych	– analiza użyteczności cząstkowych – określenie relatywnej ważności każdej zmiennej w procesie wyboru produktu przez nabywcę
8	Obszary wykorzystania wyników	– segmentacja rynku – symulacja udziałów w rynku

Źródło: opracowanie własne na podstawie prac: [Green, Srinivasan 1978; 1990], [*Conjoint...* 2000, s. 9]; [*Multivariate...*, 1998, s. 401–402, 419], [Walesiak, Bąk 2000, s. 22], [Walesiak 2000].

się podziału całkowitych preferencji respondentów poprzez obliczenie udziału każdego z atrybutów w oszacowanej całkowitej wartości użyteczności profilu.

W podejściu kompozycyjnym użyteczność całkowita profilu jest ważoną sumą ocen poziomów atrybutów, gdzie wagi wyrażają ważność poszczególnych atrybutów (zob. [Zwerina 1997, s. 3]). W podejściu mieszanym (kompozycyjno-dekompozycyjnym) łączy się cechy obu podejść.

Pod pojęciem *conjoint analysis* rozumie się zespół wielu metod badawczych składających się na ogólną procedurę *conjoint analysis* (tabela 1). W artykule scharakteryzowano te kroki procedury, które wymagają zasadniczych rozstrzygnięć decyzyjnych z punktu widzenia metodologii *conjoint analysis*.

2. Specyfikacja problemu badawczego*

Przy wyborze produktu nabywca bierze pod uwagę różne jego atrybuty (cechy, charakterystyki), dlatego w badaniach można traktować każdy produkt jako obiekt wielowymiarowy. Badacz określa więc dla danego produktu lub usługi ich podstawowe atrybuty oraz sporządza listę ich poziomów wartości (wariantów, przedziałów zmienności).

Stawiając problem badawczy, należy w metodologii *conjoint analysis* rozwiązać następujące zagadnienia:

1) typ atrybutów zastosowanych przy rozwiązaniu problemu badawczego. W rozwiązywaniu konkretnego problemu badawczego badacz musi uwzględnić najistotniejsze atrybuty. Dwa atrybuty pełnią specyficzną rolę w badaniu – cena oraz marka produktu. Wpływają one na pozostałe atrybuty opisujące produkty konkretnego badania, są więc z nimi skorelowane. Powoduje to powstawanie efektów interakcyjnych;

2) liczba atrybutów przyjęta w badaniu. P.E. Green i V. Srinivasan [1978] sugerują, aby do opisu jednego profilu w tradycyjnej metodzie *conjoint analysis* stosować nie więcej niż 6 atrybutów. Stanowi to niewątpliwie ograniczenie tej metodologii, zwłaszcza w studiach dotyczących rynku dóbr i usług produkcyjnych, gdzie należy uwzględnić znacznie więcej atrybutów (zob. [Wedel, Kamakura 1998, s. 299]). Wynika to z faktu, że przy dużej liczbie atrybutów i dużej liczbie ich poziomów znacznie rośnie liczba możliwych kombinacji przedstawianych respondentowi do oceny. Pojawia się wtedy problem zdolności percepcji i rzetelności wskazań dokonywanych przez respondentów, co ostatecznie może zaważyć na wynikach badań i ich wartości poznawczej. Istnieje kilka sposobów pozwalających na zwiększenie liczby atrybutów w badaniu:

– uwzględnienie cząstkowych eksperymentów czynnikowych pozwala znacznie zmniejszyć liczbę ocenianych przez respondentów profili i jedno-

* Punkt ten opracowano na podstawie pracy: [Walesiak, Bąk 2000, s. 23–24].

częściej zwiększyć liczbę atrybutów, jednak ich liczba w zasadzie jest nie większa niż 9 [Multivariate..., 1998, s. 404],

– stosowanie nietradycyjnych metod *conjoint analysis* (np. hybrydowa, ACA – adaptacyjna metoda *conjoint analysis*) pozwala zwiększyć liczbę atrybutów w jednym badaniu do ok. 30;

3) określenie poziomów dla poszczególnych atrybutów. Zwiększanie liczby poziomów daje możliwość precyzyjniejszego opisu profili, ale jednocześnie obniża jakość (precyzję) ocen respondentów. Wprowadzenie tylko dwóch poziomów powoduje, że wśród typów związków zachodzących między użytecznościami cząstkowymi i poziomami zmiennych wystąpi tylko związek liniowy. Dopiero uwzględnienie trzech poziomów pozwala rozpatrywać związki np. kwadratowe. Liczba uwzględnionych poziomów atrybutów wpływa również na ich ważność w procesie wyboru produktu (usługi) przez nabywcę. Zwiększenie liczby poziomów powoduje na ogół zwiększenie ważności danego atrybutu [Wedel, Kamakura 1998, s. 300]. Zaleca się, aby liczba poziomów dla wszystkich atrybutów przyjętych w badaniu była zbliżona i zawierała się w przedziale od trzech do pięciu [Simmons, Esser 2000, s. 77].

3. Wybór postaci modelu zależności zmiennych i modelu preferencji

W procedurze modelowania *conjoint analysis* konstruuje się modele, w których należy określić [Multivariate..., 1998, s. 408–412], [Walesiak, Bąk 2000, s. 24]:

– charakter zależności zachodzących między zmiennymi. Wyróżnia się dwa typy modeli określających zależność użyteczności całkowitej od użyteczności cząstkowych: model addytywny (efektów głównych) oraz model uwzględniający interakcje między zmiennymi (efektów głównych i współdziałania). Modele te pokazują, w jaki sposób respondent w procesie postrzegania i percepcji produktu łączy (scala, agreguje) użyteczności cząstkowe poszczególnych zmiennych w celu oszacowania użyteczności całkowitej danego profilu;

– typ zależności między wartościami użyteczności cząstkowych zmiennych objaśniających a wartościami poziomów tych zmiennych.

Model addytywny, uwzględniający oprócz efektów głównych również wybrane interakcje między atrybutami, przyjmuje postać (por. [Akaah, Korgonkar 1983], [Walesiak, Bąk 2000, s. 25]):

$$\hat{U}_{is} = b_s + \sum_{j=1}^m \sum_{p=1}^{m_j} u_{jp(s)} x_{jp(i)} + \sum_{j=1}^{m-1} \sum_{k=j+1}^m \sum_{p=1}^{m_j} u_{jkp(s)} x_{jkp(i)}, \quad (1)$$

gdzie:

\hat{U}_{is} – oszacowana użyteczność całkowita i -tego profilu dla s -tego respondenta,

$u_{jp(s)}$ – szacowana użyteczność cząstkowa p -tego poziomu j -tej zmiennej objaśniającej dla s -tego respondenta (efekt główny p -tego poziomu j -tej zmiennej objaśniającej),

$x_{jp(i)}$ – zmienna sztuczna reprezentująca p -ty poziom j -tej zmiennej objaśniającej w i -tym profilu ($x_{jp(i)} = 1$, gdy występuje i $x_{jp(i)} = 0$, gdy nie występuje),

$u_{jpk(s)}$ – szacowana użyteczność cząstkowa wynikająca z efektu dwuczynnikowych interakcji między zmiennymi objaśniającymi $j \times k$ dla s -tego respondenta (efekt interakcji pierwszego rzędu),

$x_{jkp(i)}$ – zmienna sztuczna reprezentująca efekty dwuczynnikowych interakcji między zmiennymi objaśniającymi $j \times k$ w i -tym profilu ($x_{jkp(i)} = 1$, gdy występuje i $x_{jkp(i)} = 0$, gdy nie występuje),

b_s – wyraz wolny modelu,

$b = 1, \dots, m$ – numer zmiennej objaśniającej (atributu),

m_j – liczba poziomów j -tej zmiennej objaśniającej.

Model addytywny, uwzględniający tylko efekty główne, redukuje się do postaci:

$$\hat{U}_{is} = b_s + \sum_{j=1}^m \sum_{p=1}^{m_j} u_{jp(s)} x_{jp(i)}. \quad (2)$$

W zastosowaniach praktycznych metodologii *conjoint analysis* korzysta się głównie z modelu addytywnego uwzględniającego tylko efekty główne. Wynika to z faktu, że w modelu uwzględniającym interakcje zwiększa się znacznie liczba szacowanych parametrów, co oznacza, że należy zwiększyć liczby profili ocenianych przez respondentów.

Rozróżnia się następujące typy związków zachodzących między użytecznościami cząstkowymi i poziomami zmiennych (por. [*Multivariate...*, 1998, s. 410–412], [Walesiak, Bąk 2000, s. 26]):

- model wartości oczekiwanej (liniowy, wektorowy),
- model kwadratowy (idealny lub antyidealny),
- model odrębnych użyteczności cząstkowych,
- model mieszany, będący kombinacją wymienionych modeli.

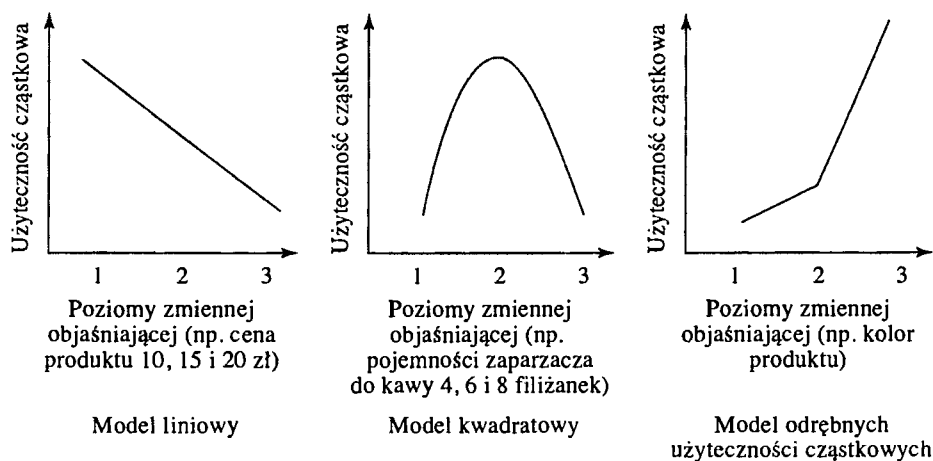
W modelu liniowym i kwadratowym zakłada się, że dana zmienna objaśniająca mierzona jest na skali metrycznej, natomiast w modelu odrębnych użyteczności cząstkowych – na skali niemetrycznej. Typy relacji zachodzących między użytecznościami cząstkowymi i poziomami zmiennych objaśniających przedstawiono na rys. 1.

4. Gromadzenie danych*

4.1. Wybór metody prezentacji danych

W *conjoint analysis* do prezentacji danych stosuje się metody [Carroll, Green 1995], [Multivariate..., 1998, s. 412–414, 424–425], [Walesiak, Bąk 2000, s. 28–29], [Wedel, Kamakura 1998, s. 302]:

- pełnych profilów wyboru (*full-profile approach*),
- prezentacji dwóch atrybutów jednocześnie nazywaną również metodą korzystającą z macierzy kompromisów (*two-attributes-at-a-time approach* lub *trade-off matrix approach*),
- porównywania profilów parami (*pairwise comparison method*),
- wyboru spośród zbiorów profilów (*the experimental choice approach*),
- oceny poziomów i atrybutów (*self-explicated data approach*).



Rys. 1. Typy relacji zachodzących między użytecznościami cząstkowymi i poziomami zmiennych objaśniających

Źródło: opracowanie własne.

Metoda pełnych profilów wyboru obejmuje zbiór wszystkich możliwych profilów będących kombinacją atrybutów i ich poziomów. Wadą tej metody jest ograniczenie liczby atrybutów i poziomów uwzględnianych w projektowanym eksperymencie. Wraz ze wzrostem ich liczby znacznie rośnie bowiem liczba możliwych kombinacji przedstawianych respondentowi do oceny. Pojawia się więc problem zdolności percepcji i rzetelności wskazań dokonywanych

* Punkt ten opracowano na podstawie pracy: [Walesiak 2000].

przez respondentów. Zastosowanie technik redukcji rozmiaru eksperymentu pozwala znacznie zmniejszyć liczbę ocenianych przez respondentów profilów i jednocześnie zwiększyć liczbę atrybutów do 9 (w praktyce liczba atrybutów nie przekracza 6).

Do zalet tej metody należy zaliczyć (zob. [Multivariate..., 1998, s. 412–413]):

- przedstawienie respondentom do oceny profilów opisanych wszystkimi wybranymi atrybutami jednocześnie (z taką sytuacją konsument styka się na rynku),

- uwzględnienie interakcji występujących między atrybutami, które mogą powodować pewne efekty synergiczne,

- możliwość wyboru skali pomiaru preferencji respondentów (porządkowa, przedziałowa lub ilorazowa).

Metoda prezentacji dwóch atrybutów jednocześnie polega na prezentowaniu respondentom do oceny par atrybutów w formie macierzy. Liczba kolumn (wierszy) macierzy jest równa liczbie poziomów pierwszego (drugiego) z atrybutów. W metodzie tej porównuje się wszystkie możliwe pary atrybutów, co oznacza, że dla m atrybutów otrzymuje się $m(m - 1)/2$ macierzy. Zadaniem respondenta jest porangowanie wszystkich kombinacji poziomów wyróżnionych dla dwóch porównywanych atrybutów. Zaletą tej metody jest możliwość uwzględnienia dużej liczby atrybutów, ponieważ respondent ranguje w danym momencie kombinacje poziomów tylko dwóch atrybutów. Metoda ta w praktyce nie jest stosowana zbyt często z uwagi na jej liczne wady (por. [Multivariate..., 1998, s. 412], [Vriens, Wittink 1994, s. 17–19], [Walesiak, Bąk 2000, s. 30]):

- cechuje ją sztuczność (respondent ocenia profile w poszczególnych krokach ankiety na podstawie fragmentarycznych informacji),

- jest uciążliwa dla respondenta w przypadku dużej liczby atrybutów i ich poziomów,

- metoda ta prowadzi do przeceniania przez respondentów znaczenia atrybutów mniej ważnych i niedoceniań rangi atrybutów istotnych,

- nie daje możliwości zastosowania technik redukcji rozmiaru eksperymentu rynkowego wykorzystujących cząstkowe układy czynnikowe,

- oceny respondentów mogą być tylko prezentowane na skali porządkowej (rangowanie),

- do szacowania parametrów modelu (użyteczności cząstkowych) wymagane są tylko specyficzne metody estymacji (np. MONANOVA).

Metoda porównywania profilów parami łączy w sobie metodę pełnych profilów wyboru z metodą korzystającą z macierzy kompromisów. Respondent w poszczególnych krokach porównuje profile parami (każdy profil może, ale nie musi być opisany pełnym zestawem atrybutów). Respondent nie ocenia tutaj wszystkich profilów jednocześnie (jak w metodzie pełnych profilów wyboru), lecz w każdym kroku określania swoich preferencji wskazuje na jeden z dwóch prezentowanych profilów. Zatem dla n profilów dokonuje $n(n - 1)/2$ wskazań.

Przyjmuje się, że respondent jest w stanie ocenić nie więcej niż 25 par profilów (zob. [Vriens, Wittink 1994, s. 21]). Dla ograniczenia liczby porównywanych par korzysta się w tej metodzie z technik redukcji rozmiaru eksperymentu rynkowego. Ponadto dla uzyskania jednoznaczności ocen respondentów postuluje się, aby była przestrzegana zasada przechodniości preferencji (jeżeli $A > B$ i $B > C$, to $A > C$, gdzie symbol $>$ oznacza preferencję lewego argumentu względem prawego).

Metoda wyboru spośród zbiorów profilów polega na tym, że:

– tworzy się zbiory profilów (zob. pkt 4.3), z których każdy zawiera dwa lub więcej profilów (każdy profil jest opisany wybranymi poziomami wszystkich atrybutów),

– respondenci proszeni są o wybór najbardziej preferowanego profilu w ramach każdego zbioru profilów. Respondent może zrezygnować z wyboru profilu w danym zbiorze, jeżeli żaden z oferowanych nie spełnia jego oczekiwań.

Liczba atrybutów w metodzie wyboru spośród zbiorów profilów w zasadzie nie powinna przekraczać 10 (podobnie jak w metodzie pełnych profilów), a liczba poziomów dla każdego atrybutu 15 (por. [Orme 2000]).

Do zalet podejścia opartego na wyborach zalicza się [Zwerina 1997, s. 6], [Multivariate..., 1998, s. 425–429], [Bąk 2000b]):

– stwarzanie możliwości bardziej realistycznej symulacji decyzji zakupu zachodzących na rynku w porównaniu z metodą pełnych profilów wyboru,

– wprowadzenie opcji umożliwiającej respondentowi rezygnację z wyboru profilu, co pozwala oszacować nie tylko udziały poszczególnych profili w rynku, ale również wielkość popytu,

– w porównaniu z innymi metodami prezentacji danych jest dla respondenta mniej skomplikowana i bardziej realistyczna.

Metoda prezentacji danych oparta na wyborach ma również wady [Zwerina 1997, s. 6], [Multivariate..., 1998, s. 428–429], [Bąk 2000b):

– w porównaniu z innymi metodami prezentacji danych prowadzi do zgromadzenia danych o mniejszej zawartości informacyjnej (pomiar preferencji respondentów dokonany jest na skali nominalnej),

– dla oszacowania parametrów modelu opartego na wyborach wymaga się zgromadzenia dużej liczby obserwacji.

Metoda oceny poziomów i atrybutów składa się z dwóch etapów. Najpierw respondent ocenia poziomy atrybutów, np. w 10-punktowej skali pozycyjnej. Następnie respondent, wykorzystując skalę stałych sum, określa relatywną ważność poszczególnych atrybutów opisujących badane obiekty. Iloczyn oceny poziomu i oceny atrybutu daje w rezultacie użyteczność cząstkową, natomiast użyteczność całkowita profilu jest sumą tych iloczynów obliczoną dla wszystkich atrybutów. Model danych samowyjaśniających ma zatem charakter kompozycyjny w odróżnieniu od wcześniejszych metod prezentacji danych, które wykorzystywane są w podejściach dekompozycyjnych *conjoint analysis*.

Zaletą tego podejścia jest możliwość uwzględnienia przy opisie profilów do 30 atrybutów. Do istotnych wad tej metody zalicza się [*Multivariate...*, 1998, s. 424], [Zwerina 1997, s. 4]:

- sztuczność ocen respondentów, nie otrzymują oni bowiem do oceny pełnego obrazu danego produktu,
- przy ocenie ważności atrybutów prowadzi do niedoceniaenia ważnych atrybutów oraz przeceniania znaczenia mniej ważnych atrybutów.

4.2. Określenie skali pomiaru preferencji respondentów

W metodologii *conjoint analysis* respondenci wyrażają swoje preferencje, oceniając poszczególne profile. Otrzymana w ten sposób zmienna zależna mierzona jest na skali (por. [Vriens, Wittink 1994, s. 36–38], [Walesiak 1996, s. 91]):

a) ilorazowej (istnieje tutaj naturalny punkt zerowy, który oznacza zupełny brak wielkości mierzonej zmiennej). Respondenci oceniają profile:

- przez podanie prawdopodobieństwa subiektywnego ich wyboru. Prawdopodobieństwo subiektywne „to pewna miara siły (stopnia) przekonania o tym, że zajdzie pewne zdarzenie” (zob. [Czerwiński 1999, s. 77]). Zakłada się, że człowiek jest w stanie przypisywać liczbowe miary sile swoich przekonań oraz miary siły przekonań, czyli subiektywne prawdopodobieństwa, podlegają takim samym prawom formalnym jak prawdopodobieństwa klasyczne lub częstościowe (chodzi o zasady dodawania i mnożenia prawdopodobieństw) [Czerwiński 1999, s. 77],

- na skali stałych sum (respondent dokonuje podziału procentów lub stałej kwoty pieniędzy zgodnie z jego preferencjami wobec ocenianych profili);

b) przedziałowej, gdy respondenci oceniają poszczególne profile na skali pozycyjnej (*rating scale*), gdzie wartości ekstremalne oznaczają odpowiednio profil najmniej atrakcyjny i najbardziej atrakcyjny. Pomiar taki traktuje się jako przedziałowy. Nie jest to pomiar na skali przedziałowej *sensu stricto*, ponieważ nie można tutaj określić stałej jednostki;

c) porządkowej, gdy respondenci porządkują poszczególne profile, np. przez nadanie im rang będących kolejnymi liczbami naturalnymi (rangę 1 przyporządkowuje się profilowi, który był wybierany w pierwszej kolejności, rangę n profilowi, który był wybierany w ostatniej kolejności);

d) nominalnej dwumianowej (respondenci wybierają jeden spośród dwóch profili) lub wielomianowej (respondenci wybierają jeden spośród więcej niż dwóch profili).

4.3. Generowanie zbioru profilów

Eksperyment, w którym uwzględnia się wszystkie atrybuty i ich poziomy nazywa się pełnym eksperymencie czynnikowym. Liczba profilów uzyskanych w tym układzie jest iloczynem poziomów poszczególnych atrybutów.

Cząstkowe eksperymenty czynnikowe projektuje się w celu redukcji liczby profilów przedstawianych respondentom do oceny.

Efektywne liniowe układy (*linear designs*) cząstkowych eksperymentów czynnikowych projektowane dla potrzeb tradycyjnej metodologii *conjoint analysis* (do prezentacji danych stosuje się metody pełnych profilów wyboru oraz porównywania profilów parami) charakteryzują dwie właściwości [Huber, Zwerina 1996], [Zwerina 1997, s. 55]:

- ortogonalność (*orthogonality*), czyli niezależność kolumn macierzy reprezentującej układ eksperymentu (otrzymuje się zerowe wartości wszystkich iloczynów skalarnych obliczonych między kolumnami macierzy),

- zrównoważenie poziomów atrybutów (*level balance*) – każdy poziom danego atrybutu występuje z taką samą częstością w układzie eksperymentu (np. dla atrybutu z trzema poziomami każdy poziom występuje w układzie w 1/3 profilów).

W rzeczywistych problemach badawczych nie zawsze jest możliwe uzyskanie ortogonalnego układu czynnikowego spełniającego dodatkowo zrównoważenie poziomów atrybutów (por. [Haaijer, Wedel 2000, s. 327]). Uzależnione to jest od liczby atrybutów, liczby ich poziomów oraz liczby generowanych przez nie profilów. Proponuje się wykorzystanie programów komputerowych, które optymalizują oba kryteria (zob. [Zwerina 1997, s. 23]). Kryteria optymalizacyjne w tworzeniu efektywnych liniowych układów cząstkowych eksperymentów czynnikowych omówiono m.in. w pracach: [Huber, Zwerina 1996], [Zwerina 1997, s. 19–22, 51–54], [Kuhfeld 1998].

W pakiecie statystycznym SPSS for Windows dostępna jest procedura generująca układ ortogonalny uwzględniający tylko efekty główne. W procedurze tej każdy poziom jednego atrybutu występuje z każdym poziomem innego atrybutu z taką samą lub proporcjonalną częstością, co zapewnia niezależność oszacowanych efektów głównych [SPSS *Conjoint...*, 1997, s. 9].

Efektywne układy cząstkowych eksperymentów czynnikowych projektowane dla potrzeb dyskretnych modeli wyboru (do prezentacji danych stosuje się metody wyboru spośród zbiorów profilów) charakteryzują się dodatkowymi dwiema właściwościami [Huber, Zwerina 1996], [Zwerina 1997, s. 55]:

- minimalną powtarzalnością poziomów atrybutów w ramach poszczególnych zbiorów profilów wyboru (*minimal level overlap within choice sets*),

- zrównoważeniem użyteczności profilów w ramach poszczególnych zbiorów profilów wyboru (*utility balance within choice sets*).

Prostą metodą wygenerowania zbiorów profilów dla potrzeb dyskretnych modeli wyboru jest metoda cykliczna (*cyclic design*) [Zwerina 1997, s. 50]. W pierwszej fazie tej metody generuje się układ ortogonalny. Każdy profil stanowi załączek zbioru profili. Kolejne profile w każdym zbiorze tworzy się w sposób cykliczny. Tworzony profil zawiera numer poziomu każdego atrybutu o jeden większy od profilu poprzedniego (w przypadku, gdy profil opi-

sany jest najwyższym numerem poziomu atrybutu numeracja rozpoczyna się od poziomu najniższego). W metodzie tej liczba profili w każdym zbiorze jest ograniczona do maksymalnej liczby poziomów atrybutów. Metoda cykliczna zapewnia optymalne spełnienie warunku ortogonalności, zrównoważenia poziomów atrybutów i minimalnej powtarzalności poziomów atrybutów w ramach poszczególnych zbiorów profili wyboru.

4.4. Ustalenie niezbędnej liczebności próby

W każdym badaniu za pomocą metod statystycznej analizy wielowymiarowej należy zwracać uwagę na liczebność próby, ponieważ zbyt mała próba powoduje, że (zob. [Jajuga, Walesiak 1997]):

- za pomocą testów trudno jest zidentyfikować rezultaty statystycznie istotne (ze względu na małą moc testów). Mocą testu statystycznego dla pewnej hipotezy nazywa się prawdopodobieństwo odrzucenia hipotezy alternatywnej, gdy jest ona fałszywa (por. [Kendall, Buckland 1986, s. 101]). Moc testu wyraża się wzorem $1 - \beta$ (błąd II rodzaju). Przy danym poziomie istotności moc testu wzrasta, gdy zwiększa się liczebność próby (por. [Multivariate..., 1998, s. 11]);

- stosunkowo łatwo można otrzymać rezultaty, które są zbyt dobrze (w sposób sztuczny) dopasowane do danych z próby. W tej sytuacji nie można uogólniać otrzymanych wyników.

Liczebność próby uzależniona jest od:

a) zastosowanego wariantu metody *conjoint analysis*. Do najczęściej stosowanych wariantów tej metody należą:

- klasyczny, oparty na pełnych profilach wyboru,
- adaptacyjny, wykorzystujący przy prezentacji danych metodę ocen poziomów i atrybutów oraz metodę porównywania parami (ACA – *Adaptive Conjoint Analysis*),

- oparty na wyborach (CBC – *Choice-Based Conjoint Analysis*);

b) obszaru wykorzystania wyników (segmentacja rynku, symulacja udziałów w rynku).

W metodzie klasycznej i adaptacyjnej ACA estymuje się indywidualne użyteczności cząstkowe dla każdego respondenta z osobna.

W metodzie klasycznej, wykorzystującej do estymacji użyteczności cząstkowych metodę najmniejszych kwadratów, minimalna liczba profili ocenianych przez poszczególnych respondentów dana jest nierównością:

$$n \geq p - m + 1, \quad (3)$$

gdzie:

n – liczba profili ocenianych przez respondentów,

p – liczba poziomów dla wszystkich atrybutów,

m – liczba atrybutów.

Nierówność (3) nawiązuje do założenia metody najmniejszych kwadratów, które mówi, że liczba obserwacji musi być co najmniej równa liczbie szacowanych parametrów strukturalnych. B. Orme [1998a] sugeruje, że dla otrzymania statystycznie istotnych rezultatów liczba obserwacji (profilów ocenianych przez respondentów) powinna trzykrotnie przewyższać liczbę szacowanych parametrów ($p - m + 1$). Należy jednak pamiętać, że respondent nie jest w stanie ocenić jednocześnie zbyt wielu profili, zwykle więc ogranicza się ich liczbę do pewnego podzbioru. Liczba ocenianych profili uzależniona jest od typu respondentów (wiek, wykształcenie itp.) i nie powinna przekraczać 30 profili (zob. [Wedel, Kamakura 1998, s. 299]).

W metodzie adaptacyjnej ACA należy zdecydować ile par profili należy przedstawić respondentowi do oceny. B. Orme [1998a] sugeruje, że dla otrzymania statystycznie istotnych rezultatów liczba porównywanych par profili powinna być równa:

$$3(p - m - 1) - p, \quad (4)$$

gdzie:

- p – liczba poziomów dla wszystkich atrybutów,
- m – liczba atrybutów.

Z kolei w metodach opartych na wyborach szacuje się zagregowane użyteczności cząstkowe dla zbiorowości respondentów (w wypadku wykorzystania wielomianowych modeli logitowych) lub indywidualne użyteczności cząstkowe w przekroju respondentów (metoda hierarchiczna Bayesa lub metoda ICE – Individual Choice Estimation).

Wielkość próby w wypadku metod opartych na wyborach, w których szacuje się zagregowane użyteczności cząstkowe dla zbiorowości respondentów, wyznacza się z nierówności (zob. [Johnson 1996], [Orme 1998a]):

$$S \cdot t \cdot a/c \geq 500, \quad (5)$$

gdzie:

- S – liczba respondentów,
- t – liczba zbiorów profili,
- a – liczba profili w zbiorze (z wykluczeniem opcji „bez wyboru”),
- c – liczba cel. W wypadku uwzględniania tylko efektów głównych c równa się maksymalnej liczbie poziomów atrybutów. Uwzględnienie dwuczynnikowych interakcji powoduje, że c równa się iloczynowi poziomów dwóch atrybutów o największej liczbie poziomów.

Przykładowe projekty spełniające regułę (5) zawiera tabela 2. Wielkość próby w wypadku metod opartych na wyborach, w których szacuje się indywidualne użyteczności cząstkowe w przekroju respondentów (np. metoda hierarchiczna Bayesa) nie może być wyznaczona analogicznie jak w metodzie kla-

sycznej i adaptacyjnej ACA. W tym wypadku estymacja indywidualnych użyteczności cząstkowych wymaga bowiem informacji pochodzących od wielu respondentów (zob. [Orme 1998a]).

Tabela 2

Przykładowe projekty spełniające regułę (5)

S	t	a	Największa liczba poziomów dwóch atrybutów	Liczba cel (c)		S · t · a/c	
				A	B	A	B
100	20	4	4, 4	4	16	2000	500
150	15	5	4, 5	5	20	2250	562,5
300	15	5	5, 5	5	25	4500	900
400	10	3	4, 5	5	20	2400	600
500	15	3	6, 6	6	36	3750	625

A – efekty główne, B – interakcje dwuczynnikowe

Źródło: opracowanie własne.

Obszar wykorzystania wyników conjoint analysis (segmentacja rynku, symulacja udziałów w rynku) powoduje, że dla uzyskania reprezentatywnych wyników zachodzi potrzeba ustalenia niezbędnej liczebności zbioru obserwacji (liczby respondentów w badaniu). W literaturze poświęconej *conjoint analysis* nie ma formalnych propozycji w tym zakresie. Liczebność zbioru obserwacji może zostać wyznaczona arbitralnie przez badacza, który kieruje się własnym osądem, wiedzą i doświadczeniem, lub wielkość ta zostaje zdeterminowana przez budżet przeznaczony na zebranie danych (zob. [Mynarski 2000, s. 35]). W praktyce do określenia liczebności zbioru obserwacji korzysta się z doświadczeń historycznych. Według szacunków P. Cattina i D.R. Wittinka [1982] próba powinna obejmować od 100 do 1000 respondentów, przy czym za typową należy uznać próbę od 300 do 550. Na podstawie komercyjnych zastosowań tej metody na rynku amerykańskim i zachodnioeuropejskim D.R. Wittink i P. Cattin [1989] ustalili, że mediana wielkości próby wynosiła 300 elementów. O ile wielkość tę można uznać za zasadną dla rynku dóbr i usług konsumpcyjnych, o tyle dla rynku dóbr i usług produkcyjnych dopuszczalne są próby mniejsze od 100 elementów.

Zwiększonej liczebności próby wymagają studia segmentacyjne rynku w porównaniu z wykorzystaniem wyników *conjoint analysis* do symulacji udziałów w rynku.

Właściwości klasycznej, adaptacyjnej oraz opartej na wyborach *conjoint analysis*

Właściwości metod	Wariant metody		
	klasyczny	ACA	CBC
Liczba atrybutów	do 9 (zwykle do 6)	do 30 (zwykle od 8 do 15)	do 10
Podejście stosowane do pomiaru struktury preferencji	dekompozycyjne	kompozycyjno-dekompozycyjne	dekompozycyjne
Rodzaj modelu	addytywny	addytywny	addytywny z interakcjami
Metody prezentacji danych do oceny przez respondentów	– pełnych profili wyboru – porównywania parami	– faza I – podejście kompozycyjne: ocena poziomów i atrybutów – faza II – podejście dekompozycyjne: porównywanie parami	wyбір spośród zbiorów profili
Skale pomiaru preferencji respondentów	ilorazowa, przedziałowa, porządkowa	ilorazowa, przedziałowa, porządkowa	nominalna
Forma ankiety	wszystkie formy	komputerowo-interakcyjna	wszystkie formy
Poziom estymacji użyteczności cząstkowych	A. Indywidualne użyteczności cząstkowe w przekroju respondentów B. Jednoczesne wyznaczenie segmentów i szacowanie użyteczności cząstkowych	indywidualne użyteczności cząstkowe w przekroju respondentów	A. Indywidualne użyteczności cząstkowe w przekroju respondentów B. Zagregowane użyteczności cząstkowe (dla całej próby lub segmentów) C. Jednoczesne wyznaczenie segmentów i szacowanie użyteczności cząstkowych
Metoda estymacji użyteczności cząstkowych	A. MONANOVA, KMNK B. Metody optymalizacyjne ^a	KMNK	A. HB, ICE B. MNL C. LCA ^b
Obszary wykorzystania wyników	segmentacja, symulacja udziałów w rynku	segmentacja, symulacja udziałów w rynku	segmentacja, symulacja udziałów w rynku

KMNK – klasyczna metoda najmniejszych kwadratów, MONANOVA – monotoniczna analiza wariancji, HB – metoda hierarchiczna Bayesa, ICE – Individual Choice Estimation, MNL – wielomianowy model logitowy, LCA – Latent Class Analysis

^a metody: Hagerty'ego, hierarchicznej lub niehierarchicznej regresji skupieniowej, regresji skupieniowej, rozmytej regresji skupieniowej (zob. [Wedel, Kamakura 1998, s. 308–312]); ^b inne metody przedstawiono w pracy [Wedel, Kamakura 1998, s. 320]

Źródło: opracowanie własne na podstawie: [Bąk 2000a], [Coinjoint..., 2000], [Multivariate..., 1998, s. 404–405, 424–429], [Orme 1998b; 2000], [Wedel, Kamakura 1998, s. 297–325].

5. Metody estymacji parametrów

Celem estymacji parametrów w modelu *conjoint analysis* jest oszacowanie wartości użyteczności cząstkowych poziomów atrybutów. Metody estymacji można podzielić na dwie grupy (por. np. [Green, Srinivasan 1978], [Haaijer, Wedel 2000, s. 323], [Walesiak, Bąk 2000, s. 47], [Zwerina 1997, s. 2]):

1) metryczne metody estymacji parametrów stosowane w wypadku, gdy preferencje respondentów są mierzone co najmniej na skali przedziałowej. Do metod tego typu zalicza się metodę najmniejszych kwadratów;

2) niemetryczne metody estymacji parametrów stosowane wówczas, gdy preferencje respondentów są mierzone:

– na skali porządkowej. Do metod tego typu zalicza się m.in.: MONANOVA (*MONotonic ANalysis of VAriance*), PREFMAP (*PREFerence MAPping*), LINMAP (*LINear programming techniques for Multidimensional Analysis of Preferences*),

– na skali nominalnej. Do najważniejszych metod tego typu zalicza się analizę logitową i analizę probitową. Są to metody oparte na prawdopodobieństwie wyboru stosowane w dyskretnych modelach wyboru (CBC – *Choice Based Conjoint Analysis*).

W badaniach empirycznych najczęściej wykorzystywane są następujące warianty metody *conjoint analysis* (por. [Bąk 2000a], [Orme 2000]):

- klasyczny,
- wariant adaptacyjny (ACA – *Adaptive Conjoint Analysis*),
- oparty na wyborach (CBC – *Choice-Based Conjoint Analysis*).

Podstawowe właściwości wariantów metod *conjoint analysis* prezentuje tabela 3.

6. Podsumowanie

W artykule w syntetycznym ujęciu zaprezentowano procedurę *conjoint analysis*. Scharakteryzowano te kroki procedury, które wymagają zasadniczych rozstrzygnięć decyzyjnych z punktu widzenia metodologii *conjoint analysis*. Szczegółowej analizie poddano takie zagadnienia, jak:

- wybór podejścia stosowanego do pomiaru struktury preferencji,
- specyfikacja problemu badawczego,
- wybór postaci modelu zależności zmiennych i modelu preferencji,
- wybór metody gromadzenia danych,
- wybór metody estymacji parametrów (użyteczności cząstkowych).

W syntetycznej formie zaprezentowano właściwości klasycznej, adaptacyjnej oraz opartej na wyborach *conjoint analysis*.

Literatura

- Akaah I.P., Korgaonkar P.K. [1983], *An Empirical Comparison of the Predictive Validity of Self-explicated, Huber-Hybrid, Traditional Conjoint, and Hybrid Conjoint Models*, „Journal of Marketing Research”, May, 20.
- Bąk A. [2000a], *Conjoint analysis jako metoda pomiaru postaw i preferencji konsumentów [w:] Pomiar w badaniach rynkowych i marketingowych*, pod red. M. Walesiaka, IV Warsztaty Metodologiczne, Prace Naukowe Akademii Ekonomicznej we Wrocławiu, nr 856.
- Bąk A. [2000b], *Dyskretne modele wyborów conjoint analysis w badaniach marketingowych*, „Ekonometria” 6, Prace Naukowe, AE we Wrocławiu, nr 881.
- Carroll J.D., Green P.E. [1995], *Psychometric Methods in Marketing Research*, Part I: *Conjoint Analysis*, „Journal of Marketing Research”, November, 32.
- Cattin P., Wittink D.R. [1982], *Commercial Use of Conjoint Analysis: a Survey*, „Journal of Marketing”, Summer.
- Conjoint Measurement: Methods and Applications* [2000], A. Gustafsson, A. Herrmann, F. Huber (eds), Berlin, Springer.
- Czerwiński Z. [1999], *Granice stosowalności teorii prawdopodobieństwa [w:] Przestrzenno-czasowe modelowanie i prognozowanie zjawisk gospodarczych*, Materiały z XX Ogólnopolskiego Seminarium Naukowego (Zakopane 27–30 IV 1998 r.), pod red. A. Zeliasia, Wydawnictwo AE w Krakowie, Kraków.
- Green P.E., Rao V.R. [1971], *Conjoint Measurement for Quantifying Judgmental Data*, „Journal of Marketing Research”, September, 8.
- Green P.E., Srinivasan V. [1978], *Conjoint Analysis in Consumer Research: Issues and Outlook*, „Journal of Consumer Research”, September, 5.
- Green P.E., Srinivasan V. [1990], *Conjoint Analysis in Marketing: New Developments with Implications for Research and Practice*, „Journal of Marketing”, October, 54.
- Haaijer R., Wedel M. [2000], *Conjoint Choice Experiments: General Characteristics and Alternative Model Specifications [w:] Conjoint Measurement: Methods and Applications*, A. Gustafsson, A. Herrmann, F. Huber (eds), Berlin, Springer.
- Huber J., Zwerina K. [1996], *The Importance of Utility Balance in Efficient Choice Designs*, „Journal of Marketing Research”, August, 33.
- Jajuga K. [1990], *Modele z dyskretną zmienną objaśnianą [w:] Estymacja modeli ekonometrycznych*, pod red. S. Bartosiewicz, PWE, Warszawa.
- Jajuga K., Walesiak M. [1997], *Uwagi o badaniach niewyczerpujących przy zastosowaniu metod statystycznej analizy wielowymiarowej [w:] Statystyka regionalna. Sondaż i integracja baz danych*, Materiały z konferencji naukowej (Baranowo pod Poznaniem, 25–27 IX 1996 r.), AE w Poznaniu, Poznań.
- Johnson R. [1996], *Getting the Most from CBC – part 1*, <http://www.sawtoothsoftware.com/TechPap.htm>, Sawtooth Software.
- Kendall M.G., Buckland W.R. [1986], *Słownik terminów statystycznych*, PWE, Warszawa.
- Kuhfeld WF. [1998], *Efficient Experimental Designs Using Computerized Searches*, <http://www.sawtoothsoftware.com/TechPap.htm>, Sawtooth Software.
- Luce R.D., Tukey J.W. [1964], *Simultaneous Conjoint Measurement: a New Type of Fundamental Measurement*, „Journal of Mathematical Psychology”, February, 1.
- Multivariate Data Analysis* [1998], J.F. Hair, R.E. Anderson, R.L. Tatham, W.C. Black, Englewood Cliffs, Prentice-Hall.
- Mynarski S. [2000], *Praktyczne metody analizy danych rynkowych i marketingowych*, Kantor Wydawniczy Zakamycze, Kraków.
- Orme B. [1998a], *Sample Size Issues for Conjoint Analysis Studies*, <http://www.sawtoothsoftware.com/TechPap.htm>, Sawtooth Software.

- Orme B. [1998b], *Which Conjoint Method Should I Use?*
<http://www.sawtoothsoftware.com/TechPap.htm>, Sawtooth Software.
- Orme B. [2000], *Which Conjoint Method Should I Use?* <http://www.sawtoothsoftware.com/TechPap.htm>, Sawtooth Software.
- Simmons S., Esser M. [2000], *Developing Business Solutions from Conjoint Analysis [w:] Conjoint Measurement: Methods and Applications*, A. Gustafsson, A. Herrmann, F. Huber (eds), Berlin, Springer.
- SPSS Conjoint™ 8.0 [1997], SPSS Inc., Chicago.
- Vriens M., Wittink D.R. [1994], *Conjoint Analysis in Marketing*, maszynopis powielony.
- Walesiak M. [1996], *Metody analizy danych marketingowych*, PWN, Warszawa.
- Walesiak M. [2000], *Gromadzenie danych w procedurze conjoint analysis*, „Przegląd Statystyczny”, t. 48, z. 1–2.
- Walesiak M., Bąk A. [2000], *Conjoint analysis w badaniach marketingowych*, Wydawnictwo AE we Wrocławiu, Wrocław.
- Wedel M., Kamakura W.A. [1998], *Market Segmentation. Conceptual and Methodological Foundations*, Kluwer Academic Publ., Boston–Dordrecht–London.
- Wittink D.R., Cattin P. [1989], *Commercial Use of Conjoint Analysis: an Update*, „Journal of Marketing”, July.
- Zwerina K. [1997], *Discrete Choice Experiments in Marketing*, Physica-Verlag, Heidelberg–New York.