

Andrzej Bąk

PRZYKŁADY ZASTOSOWAŃ METOD DEKOMPOZYCYJNYCH W BADANIACH MARKETINGOWYCH

1. Wstęp

Od początku lat siedemdziesiątych XX w. metody dekompozycyjne, w tym przede wszystkim metody *conjoint analysis*, stały się jednym z podstawowych narzędzi pomiaru i analizy preferencji konsumentów produktów i usług opisanych wieloma zmiennymi [Green, Srinivasan 1990; Green, Krieger, Wind 2001]. Według szacunków (por. [Cattin, Wittink 1982; Wittink, Cattin 1989; Wittink, Vriens, Burhenne 1994]), w latach 1971-1991 notowano rocznie w Europie i Stanach Zjednoczonych kilkaset komercyjnych zastosowań tych metod. Zastosowania te obejmowały m.in. takie dobra i usługi, jak (por. [Green, Tull, Albaum 1988; Walesiak, Bąk 2000]) dobra konsumpcyjne trwałego użytku (np. samochody, aparaty fotograficzne i kamery filmowe, opony samochodowe, mieszkania), dobra konsumpcyjne nietrwałego użytku (np. szampony do włosów, mydła, paliwa), usługi finansowe (np. karty kredytowe, polisy ubezpieczeniowe, karty stałego klienta), inne usługi (np. telefoniczne, medyczne, hotelowe, z oferty agencji zatrudnienia, wypożyczanie samochodów), dobra przemysłowe (np. koparki, drukarki, komputery osobiste), transport (np. lotniczy, kolejowy).

Metody dekompozycyjne są stosowane na gruncie badań marketingowych jako narzędzie analizy danych preferencyjnych wykorzystywanych w takich celach, jak (por. [Hair i in. 1995; 1998; Walesiak, Bąk 1997; 2000]):

- identyfikacja struktury preferencji konsumentów dóbr (usług), tj. oszacowanie użyteczności cząstkowych poziomów atrybutów, wag atrybutów i użyteczności całkowitych profiliów,
- wspomaganie procesu projektowania nowego lub modyfikacji istniejącego produktu (usługi) poprzez identyfikację najbardziej istotnych cech,

- segmentacja rynku i optymalizacja produktów (usług) adresowanych do poszczególnych segmentów,
- analiza konkurencji i przemieszczania się produktów (usług) na rynku i w segmentach rynku,
- szacowanie udziałów w rynku i w segmentach rynku,
- modelowanie symulacyjne rynku (analiza skutków alternatywnych decyzji rynkowych i produkcyjnych),
- wspomaganie decyzji dotyczących cen produktów (usług),
- badania reklamy, promocji i kanałów dystrybucji,
- zastosowania niekonwencjonalne, m.in. w sądownictwie, lotnictwie, telekomunikacji, farmaceutyce.

W artykule przedstawiono w formie syntetycznej główne założenia metod dekompozycyjnych (*conjoint analysis* i metod opartych na wyborach). Zastosowania tych metod w badaniach marketingowych zilustrowano przykładami badań empirycznych. Wskazują one na możliwości wykorzystania metod dekompozycyjnych w analizie preferencji, segmentacji rynku oraz w analizie udziałów w rynku. W przytoczonych przykładach zamieszczono także odniesienia do oprogramowania komputerowego, które jest wykorzystane na etapie gromadzenia danych i estymacji modeli dekompozycyjnych.

2. Charakterystyka metod dekompozycyjnych

Podstawowym założeniem dekompozycyjnych metod pomiaru preferencji wyrażonych (deklarowanych), wykorzystywanych w badaniach marketingowych, jest prezentacja respondentom zbioru obiektów opisanych zmiennymi objaśniającymi, z których każda przyjmuje określone wartości. Głównym celem badań jest pomiar preferencji konsumentów względem ocenianych obiektów. Wynikiem pomiaru jest zbiór wartości zmiennej objaśnianej, reprezentujący preferencje empiryczne respondentów. Zgodnie z terminologią stosowaną w literaturze przedmiotu zmienne objaśniające opisujące dobra lub usługi nazywa się atrybutami (*attributes*) (ze względu na niemetryczny charakter skal pomiaru ich wartości) lub czynnikami (*factors*), natomiast ich realizacje są nazywane poziomami (*levels*) (zgodnie z terminologią stosowaną w planowaniu doświadczeń)¹. Atrybuty i ich poziomy generują różne warianty dóbr lub usług nazywane profilami (*profiles*, *stimuli*, *treatments*, *runs*). Liczba wszystkich możliwych do wygenerowania profili zależy od liczby atrybutów i liczby poziomów (jest to iloczyn liczby poziomów wszystkich atrybutów)².

¹ Układy doświadczałne odgrywają w metodach dekompozycyjnych bardzo ważną rolę i stanowią jeden z najważniejszych etapów procedury badawczej.

² Inaczej zbiór profili jest to produkt kartezjański zbiorów poziomów poszczególnych atrybutów.

Na podstawie zgromadzonych ocen respondentów (użyteczności całkowitych profilów) dokonuje się podziału (dekompozycji) całkowitych preferencji w celu oszacowania tzw. użyteczności cząstkowych poziomów atrybutów oraz obliczenia udziałów poszczególnych atrybutów w całkowitej użyteczności każdego profilu (por. [Green, Wind 1975]).

Model dekompozycyjny reprezentuje zależność między preferencjami konsumentów a atrybutami profilów, którą to zależność w sposób ogólny można przedstawić w postaci równania:

$$U_{is} = f_s(\mathbf{X}, \beta, \varepsilon_{is}), \quad (1)$$

gdzie: U_{is} – użyteczność rzeczywista i -tego profilu dla s -tego konsumenta,
 f_s – funkcja użyteczności (preferencji) s -tego konsumenta,

Tabela 1. Charakterystyka dekompozycyjnych metod pomiaru preferencji wyrażonych

Charakterystyka	Metody <i>conjoint analysis</i>	Metody oparte na wyborach
Podstawy teoretyczne	aksjomatyczna teoria addytywnego jednoczesnego pomiaru łącznego <i>conjoint measurement</i> , której podstawy sformułowali R.D. Luce i J.W. Tukey w 1964 r. (por. [Coombs, Dawes, Tversky 1977])	teoria użyteczności losowej, której zręby i podstawowe założenia zaproponował w 1927 r. L.L. Thurstone (por. [Coombs, Dawes, Tversky 1977])
Skala pomiaru preferencji	skale niemetryczne i metryczne: • porządkowa • przedziałowa • ilorazowa	skale niemetryczne: • nominalna • porządkowa
Metoda gromadzenia danych o preferencjach	• pełne profile • porównania profilów parami • porównania atrybutów parami	• pełne profile • częściowe profile
Generowanie profili do badań	jednostopniowe procedury generowania układów czynnikowych: • pełny układ czynnikowy, • cząstkowy układ czynnikowy	jednostopniowe lub dwustopniowe procedury generowania układów czynnikowych: • pełny układ czynnikowy, • cząstkowy układ czynnikowy
Model regresji	liniowy model regresji wielorakiej	model probabilistyczny
Transformacja zmiennej objaśnianej	liniowa, monotoniczna	logitowa, probitowa
Zmienne sztuczne	tak	tak
Estymacja użyteczności cząstkowych	klasyczna metoda najmniejszych kwadratów, metoda monotonicznej analizy wariancji, algorytmy LINMAP, PREFMAP	metoda największej wiarygodności, algorytmy numeryczne (E-M), metody symulacyjne (MCMC)
Ocena wiarygodności pomiaru	ocena trafności i rzetelności	ocena trafności i rzetelności
Wykorzystanie wyników	szacowanie udziałów w rynku (pośrednio), segmentacja (dwufazowa)	szacowanie udziałów w rynku (bezpośrednio), segmentacja (jednofazowa)

- X – macierz zawierająca realizacje zmiennych objaśniających opisujących profile (poziomy atrybutów lub realizacje zmiennych sztucznych),
- β – macierz parametrów (użyteczności częściowych),
- ε_{is} – składnik losowy modelu.

O wyborze metody pomiaru i analizy preferencji (w tym także o postaci modelu dekompozycyjnego) stosowanym w konkretnym badaniu decyduje w pierwszym rzędzie³ skala pomiaru preferencji. Pomiar preferencji konsumentów na skalach mocnych (metrycznych) implikuje stosowanie metod *conjoint analysis* (np. modelu regresji wielorakiej ze zmiennymi sztucznymi). Pomiar preferencji na skalach słabych (niemetrycznych, np. nominalnej) przesądza o konieczności stosowania metod opartych na wyborach (np. wielomianowego lub warunkowego modelu logitowego).

Istotna różnica między metodami *conjoint analysis* i metodami opartymi na wyborach dotyczy podstaw teoretycznych, sposobów i skal pomiaru preferencji (metod gromadzenia danych) oraz postaci formułowanych modeli (tab. 1)⁴. Ogólna idea badawcza jest jednak wspólna. W obu ujęciach przedstawia się respondentom do oceny zbiór profilów opisanych atrybutami w celu uzyskania informacji o empirycznych użytecznościach całkowitych, a następnie za pomocą metod statystycznych i algorytmów komputerowych przeprowadza się dekompozycję użyteczności całkowitych i oblicza użyteczności częściowe (por. [Green, Wind 1975]). Z tego względu metody te zalicza się do grupy dekompozycyjnych metod badania preferencji wyrażonych (deklarowanych w badaniu). Podstawowe charakterystyki obu grup metod zawiera tab. 1 (por. [Walesiak, Bąk 2000]).

3. Przykład zastosowania *conjoint analysis*

Badanie preferencji nabywców czekolad. Przykład przedstawia badanie preferencji konsumentów (nabywców) czekolad. Celem badania jest identyfikacja czynników, którymi w głównej mierze kierują się nabywcy wybierając określone produkty. Badanie zostało przeprowadzone wśród studentów WGRiT w Jeleniej Górze w 2000 r. Ze 100 rozprawdzonych ankiet uzyskano 87 poprawnie wypełnionych kwestionariuszy⁵.

W badaniu uwzględniono atrybuty i poziomy przedstawione w tab. 2, które generują w kompletnym eksperymencie czynnikowym 144 profile. Do przygotowania zbioru zredukowanego wykorzystano częściowy ortogonalny układ czynnikowy.

³ Na ostateczną formę modelu mają wpływ także inne czynniki, m.in. założone cele badania, metoda gromadzenia danych, poziom agregacji danych.

⁴ W literaturze przedmiotu pozostaje otwarta dyskusja dotycząca wzajemnych relacji między metodami *conjoint analysis* i metodami dyskretnych wyborów (por. Louviere 2000; Glowa, Lawson 2000)].

⁵ Dane na potrzeby pracy magisterskiej zgromadziła W. Nowak [2001].

wy⁶ i uzyskano ostatecznie zbiór 16 profili (tab. 3). Układ czynnikowy przedstawiony w tab. 3 zawiera dodatkowo 3 profile symulacyjne, które nie są oceniane przez respondentów, ale będą wykorzystane w „prognozowaniu” udziałów w rynku. Zadaniem respondentów było uporządkowanie według własnych preferencji 16 wariantów czekolady.

Tabela 2. Atrybuty i poziomy charakteryzujące czekolady

Atrybut	Poziomy
Rodzaj czekolady	mleczna, nadziewana, bakaliowa, gorzka
Cena	niska, średnia, wysoka
Rodzaj opakowania	miękkie, twarde
Waga	mała, średnia, duża
Wartość kaloryczna	mała, duża

Źródło: opracowanie własne.

Tabela 3. Układ ortogonalny badania z uwzględnieniem profili symulacyjnych

Rodzaj	Cena	Opakowanie	Waga	Kaloryczność	Status	Card
Bakaliowa	wysoka	miękkie	średnia	mała	plan	1
Bakaliowa	średnia	twarde	mała	duża	plan	2
Nadziewana	niska	twarde	mała	mała	plan	3
Gorzka	niska	twarde	mała	mała	plan	4
Gorzka	średnia	twarde	średnia	mała	plan	5
Mleczna	niska	twarde	średnia	duża	plan	6
Gorzka	wysoka	miękkie	mała	duża	plan	7
Mleczna	średnia	miękkie	duża	mała	plan	8
Bakaliowa	niska	twarde	duża	duża	plan	9
Bakaliowa	niska	miękkie	mała	mała	plan	10
Mleczna	wysoka	twarde	mała	duża	plan	11
Nadziewana	średnia	miękkie	mała	duża	plan	12
Nadziewana	wysoka	twarde	duża	mała	plan	13
Mleczna	niska	miękkie	mała	mała	plan	14
Gorzka	niska	miękkie	duża	duża	plan	15
Nadziewana	niska	miękkie	średnia	duża	plan	16
Gorzka	niska	twarde	średnia	mała	symulacja	17
Mleczna	wysoka	miękkie	mała	duża	symulacja	18
Nadziewana	średnia	miękkie	duża	mała	symulacja	19

Źródło: opracowanie własne.

Podstawę estymacji parametrów metodą najmniejszych kwadratów stanowiły modele regresji wielorakiej ze zmiennymi sztucznymi. Oszacowano użyteczności częściowe na poziomie indywidualnym (w przekroju respondentów) i zagregowanym (w przekroju całej próbki)⁷. Wyniki estymacji modelu *conjoint analysis* dla całej próbki przedstawia tab. 4. Obejmują one użyteczności częściowe poziomów poszczególnych atrybutów, przeciętną ważność każdego atrybutu oraz jakość dopa-

⁶ Zastosowano polecenie ORTHOPLAN z programu SPSS for Windows.

⁷ Zastosowano polecenie CONJOINT z programu SPSS for Windows.


sowania modelu do preferencji empirycznych, mierzoną współczynnikiem korelacji liniowej Pearsona i współczynnikiem korelacji rang Kendalla. Znaczenie, jakie w procesie oceny profilów przypisują respondenci poszczególnym atrybutom, zilustrowano ponadto na rys. 1. Przedstawione wyniki wskazują na decydujące znaczenie dwóch atrybutów: rodzaju czekolady (na skrajnych biegunach mleczna i gorzka) i ceny (na skrajnych biegunach niska i wysoka) w procesie oceny proponowanych profilów czekoladowych.

Tabela 4. Zbiorcze wyniki estymacji modelu *conjoint analysis*

Atrybut	Poziomy atrybutu	Użyteczność cząstkowa poziomu (parametr modelu)	Przeciętna ważność atrybutu (w %)
Rodzaj czekolady	mleczna	-1,0891	56,79
	nadziejwana	-0,7328	
	bakaliowa	-0,9224	
	gorzka	2,7443	
Cena	niska	-0,5709	16,42
	średnia	0,1188	
	wysoka	0,4521	
Rodzaj opakowania	miękkie	-0,0287	5,43
	twarde	0,0287	
Waga	mała	-0,1686	10,61
	średnia	0,1734	
	duża	-0,0048	
Wartość kaloryczna	mała	-0,6466	10,75
	duża	0,6466	
Wyraz wolny		8,6849	—

Dopasowanie modelu: współczynnik korelacji Pearsona $R = 0,989$; współczynnik Kendalla $\tau = 0,912$.

Źródło: opracowanie własne.



Rys. 1. Przeciętna „ważność” atrybutów opisujących czekolady

Źródło: opracowanie własne.

Segmentacja rynku nabywców czekolad. Użyteczności częściowe oraz wynikające z nich użyteczności całkowite profilów mogą stanowić podstawę segmentacji nabywców, ponieważ odwzorowują one reakcje konsumentów na określone warianty (profile) rzeczywistych lub hipotetycznych produktów lub usług.

Zgodnie z założeniami *conjoint analysis*, na podstawie zdefiniowanego modelu i zgromadzonych danych, szacuje się wartości użyteczności częściowych, które informują o wadze, jaką każdy respondent wiąże z danym poziomem każdego atrybutu. Wynikiem tego etapu procedury *conjoint analysis* jest macierz użyteczności częściowych⁸, w której liczba wierszy odpowiada liczbie respondentów, a liczba kolumn jest równa liczbie poziomów wyróżnionych dla wszystkich atrybutów. Macierz ta stanowi podstawę segmentacji rynku ze względu na wyspecyfikowany przedmiot badań.

W praktycznych badaniach segmentacyjnych korzystających z metod *conjoint analysis* najczęściej stosowane jest podejście *post hoc*, w którym do podziału zbioru respondentów na klasy (segmenty) na podstawie użyteczności częściowych wykorzystuje się metody klasyfikacji danych. Ze względu na pewne szczególne własności (jednoznaczna kwalifikacja obiektów do grup, efektywne przetwarzanie dużych zbiorów) bardzo często stosuje się metodę *k*-średnich⁹, należąca do grupy metod optymalizacji iteracyjnej.

Procedura segmentacji na podstawie użyteczności częściowych oszacowanych metodą *conjoint analysis* i z wykorzystaniem programu SPSS for Windows obejmuje następujące kroki:

- oszacowanie użyteczności częściowych na poziomie indywidualnym (w przekroju respondentów) i oszacowanie użyteczności całkowitych każdego profilu w przekroju respondentów (polecenie CONJOINT),
- klasyfikację respondentów na podstawie użyteczności całkowitych profilów metodą *k*-średnich (polecenie QUICK CLUSTER),
- uporządkowanie danych według segmentów (polecenie SORT CASES),
- przyporządkowanie danych ankietowych do segmentów (polecenie MATCH FILES),
- oszacowanie użyteczności częściowych i całkowitych w przekroju segmentów (polecenie CONJOINT).

Procedura ta została zastosowana do danych uzyskanych w badaniu preferencji nabywców czekolad (87 respondentów). W rezultacie otrzymano trzy segmenty o następujących liczebnościach: I segment – 18 osób; II segment – 45 osób; III segment – 24 osoby. Podstawowe charakterystyki wyodrębnionych segmentów, tj. użyteczności częściowe poziomów (*U*) i przeciętne ważności atrybutów (*W*) w segmentach, zawiera tab. 5.

⁸ W programie SPSS for Windows macierz użyteczności częściowych uzyskuje się w wyniku wykonania polecenia CONJOINT.

⁹ Procedura *k*-średnich jest dostępna m.in. w pakietach statystycznych SPSS for Windows i SAS/STAT.

Tabela 5. Użyteczności częściowe i ważność atrybutów w segmentach

Atrybut	Poziomy atrybutu	Segment					
		I		II		III	
		<i>U</i>	<i>W</i>	<i>U</i>	<i>W</i>	<i>U</i>	<i>W</i>
Rodzaj czekolady	mleczna	-1,3056	53,04	-2,7556	56,95	2,1979	59,32
	nadziejawa	-0,6389		-1,3000		0,2604	
	bakaliowa	3,7639		-1,0556		-4,1875	
	gorzka	-1,8194		5,1111		1,7292	
Cena	niska	-0,4259	14,70	-0,5037	15,41	-0,8056	19,59
	średnia	0,2407		-0,0204		0,2882	
	wysoka	0,1852		0,5241		0,5174	
Rodzaj opakowania	miękkie	-0,0278	6,54	-0,0694	5,43	0,0469	4,59
	twarde	0,0278		0,0694		-0,0469	
Waga	mała	-0,2685	15,01	-0,1741	9,61	-0,0833	9,19
	średnia	-0,4421		0,3065		0,3854	
	duża	0,7106		-0,1324		-0,3021	
Wartość kaloryczna	mała	-0,4097	10,72	-0,8750	12,61	-0,3958	7,31
	duża	0,4097		0,8750		0,3958	

Źródło: opracowanie własne.

Badanie udziałów w rynku z wykorzystaniem symulatorów wyboru. W badaniach preferencji metodą *conjoint analysis* uwzględnia się na ogół podzbiór profili uzyskany w rezultacie zastosowania częściowego układu czynnikowego. Dodatkowo można oszacować użyteczności całkowite oraz symulowane udziały w rynku profili, które nie były oceniane przez respondentów. Profile te, nazywane profilami symulacyjnymi, mogą być utworzone już po oszacowaniu użyteczności częściowych. Na podstawie uzyskanych wyników i analizy preferencji można wytypować takie kombinacje poziomów atrybutów, które mogą generować profile o potencjalnie dużych użytecznościach całkowitych i udziałach w rynku. Analizę symulacyjną przeprowadza się na podstawie wyników otrzymanych dla całej badanej zbiorowości respondentów oraz w poszczególnych segmentach. Prognozowanie udziału w rynku zaprojektowanych produktów szacuje się z wykorzystaniem następujących modeli (reguł): maksymalnej użyteczności („pierwszej pozycji”), BTL (Bradley-Terry-Luce) i logitowy (por. [Walesiak, Bąk 2000]).

W modelu maksymalnej użyteczności¹⁰ oblicza się odsetek respondentów, u których dany profil otrzymał najwyższą ocenę użyteczności całkowitej wśród profili będących przedmiotem symulacji. Reguła maksymalnej użyteczności ma zatem charakter deterministyczny, ponieważ zakłada, że konsument zawsze wybierze profil o największej użyteczności.

¹⁰ Model ten przedstawia zależność: $P_{is} = \begin{cases} 1, & \text{gdy } \hat{U}_{is} = \max(\hat{U}_{is}), \\ 0, & \text{w przeciwnym razie,} \end{cases}$

gdzie: P_{is} – prawdopodobieństwo wyboru *i*-tego profilu przez *s*-tego respondenta; U_{is} – oszacowana użyteczność całkowita.

Modele BTL i logitowy mają charakter probabilistyczny, ponieważ są oparte na szacunku prawdopodobieństwa wyboru określonego profilu, obliczonym na podstawie użyteczności całkowitych otrzymanych w wyniku zastosowania procedury *conjoint analysis*. W modelu BTL¹¹ użyteczność całkowitą, odpowiadającą danemu profilowi, dzieli się przez sumę użyteczności całkowitych profili będących przedmiotem symulacji (obliczenia wykonuje się osobno dla każdego respondenta, a następnie oblicza się ich wartość przeciętną). Model logitowy¹² różni się od modelu BTL tym, że w obliczeniach stosuje się logarytmy naturalne wartości użyteczności całkowitych zamiast samych użyteczności.

Na podstawie wyników uzyskanych w badaniu dotyczącym preferencji nabywców czekolad wytypowano trzy profile symulacyjne o charakterystykach zamieszczonych w tab. 6 (zob. też tab. 3).

Tabela 6. Charakterystyka profili symulacyjnych

Profil symulacyjny	Rodzaj czekolady	Cena	Rodzaj opakowania	Waga	Wartość kaloryczna
17	gorzka	niska	twarde	średnia	mała
18	mleczna	wysoka	miękkie	mała	duża
19	nadziewana	średnia	miękkie	duża	mała

Źródło: opracowanie własne.

Wyniki dotyczące profili symulacyjnych przedstawiono w tab. 7. Zawierają one oszacowania użyteczności całkowitych (są to wartości teoretyczne obliczone na podstawie modelu regresji wielorakiej) oraz symulowane udziały w rynku. Największe szanse znalezienia nabywców ma profil 19.

Tabela 7. Wyniki analizy udziałów w rynku profili symulacyjnych

Profil symulacyjny	Prognozowana użyteczność całkowita	Prognozowane udziały w rynku (w %)		
		model maksymalnej użyteczności	model BTL	model logitowy
17	6,6	21,84	26,67	22,97
18	8,5	34,48	34,68	35,52
19	9,6	43,68	38,65	41,51

Źródło: opracowanie własne.

¹¹ Model ten przedstawia zależność: $P_{is} = \hat{U}_{is} / \sum_{i=1}^n \hat{U}_{is}$, gdzie n – liczba profili.

¹² Model ten przedstawia zależność: $P_{is} = \exp(\hat{U}_{is}) / \sum_{i=1}^n \exp(\hat{U}_{is})$.

Oprogramowanie komputerowe. Obliczenia do przykładu wykonano za pomocą poleceń i opcji pakietu statystycznego SPSS for Windows. W pakiecie tym oferowane są narzędzia programowe wspomagające badania preferencji wyrażonych w zakresie metody *conjoint analysis* opartej na pełnych profilach wyboru. Dostępne procedury wspierają zwłaszcza etap przygotowania danych (ortogonalny układ czynnikowy) oraz etap estymacji użyteczności częściowych (model regresji wielorakiej). Na etapie przygotowania danych do modelu *conjoint analysis* wykorzystuje się polecenia ORTHOPLAN i PLANCARDS. Na etapie estymacji użyteczności częściowych wykorzystuje się natomiast polecenie CONJOINT (por. [Walesiak, Bąk 1997; 2000]). W zadaniach segmentacji można wykorzystać m.in. polecenie QUICK CLUSTER. Program umożliwia także oszacowanie modelu dyskretnych wyborów za pomocą polecenia COXREG, ale nie wspomaga w tych badaniach etapu przygotowania danych.

4. Przykład zastosowania metody wyborów dyskretnych

Ilustracją metody wyborów dyskretnych jest badanie preferencji konsumentów piwa jasnego przeprowadzone w lipcu 2002 r. wśród mieszkańców Jeleniej Góry i Lwówka Śląskiego (por. [Bąk, Rybicka 2004]). W Polsce od początku lat dziewięćdziesiątych XX w. systematycznie rośnie produkcja i spożycie piwa. W związku z tym rynek piwa w Polsce dynamicznie się rozwija i zmienia. Skutkiem tego jest m.in. zmiana struktury spożywanych wyrobów alkoholowych, przede wszystkim na korzyść właśnie piwa.

Celem badania jest identyfikacja czynników, które wywierają decydujący wpływ na wybór określonych gatunków i marek piwa. W badaniu uwzględniono atrybuty i poziomy zamieszczone w tab. 8. Prowadzi to do układu czynnikowego typu L^{MP} (gdzie L oznacza liczbę poziomów każdego z atrybutów, M jest liczbą wszystkich atrybutów, P zaś to liczba profili w każdym zbiorze) o rozmiarze $3^{4 \times 5}$. Przeprowadzono redukcję kompletnego układu czynnikowego za pomocą iteracyjnego algorytmu Fedorova, umożliwiającego znalezienie optymalnego nieortogonalnego układu czynnikowego¹³ z wytypowanego wstępnie zestawu danych. Szczegółową charakterystykę badania zawiera tab. 9.

¹³ Do oceny jakości statystycznej generowanych układów częściowych stosuje się miary efektywności (optymalności) oparte na macierzy informacyjnej $(X^T X)^{-1}$ lub bazujące na odległości układu czynnikowego od wstępnie wytypowanego zbioru tzw. obserwacji kandydujących. Do najczęściej stosowanych miar optymalności, wykorzystujących macierz informacyjną, należą miary D , A oraz G efektywności. Wartości miar efektywności są wyskalowane w przedziale (0; 100) dla odpowiednio zakodowanych planów czynnikowych (wyższe wartości wskazują efektywniejszy układ czynnikowy). Informują one o względnej optymalności układu w odniesieniu do hipotetycznego układu ortogonalnego.

Tabela 8. Atrybuty i poziomy charakteryzujące piwo jasne

Atrybut	Poziomy
Kraj	Polska, Niemcy, Czechy, Holandia, Dania
Cena	do 2 zł, 2-4 zł, powyżej 4 zł
Zawartość alkoholu	do 1,0%, od 1,8-5,0%, powyżej 5,0%
Rodzaj opakowania	butelka, puszka, kufel
Pojemność opakowania	0,33 l, 0,5 l, powyżej 0,5 l

Źródło: opracowanie własne.

Tabela 9. Charakterystyka badania

Element badania	Charakterystyka szczegółowa
Eksperyment czynnikowy	- kompletny układ czynnikowy: $3^{4 \cdot 5}$ zbiorów (20 zmiennych po 3 poziomy) - wstępny zbiór danych: 19 683 zbiorów - minimalna liczba zbiorów: $20 \cdot (3-1) + 1$ zbiorów - przyjęte w badaniu: 45 zbiorów - efektywność układu czynnikowego: $D = 85,96$
Układ badania	- liczba bloków: 3 - liczba zbiorów w bloku: 15 - liczba profili w zbiorze: 6 (5 plus opcja rezygnacji z wyboru)
Liczba ankiet	- rozprowadzonych: 300 - wykorzystanych: 235

Źródło: opracowanie własne.

Każdy z respondentów oceniał 15 zbiorów zawierających po 6 profili (5 profili reprezentujących różne poziomy atrybutów charakteryzujących piwo oraz opcja rezygnacji z wyboru któregośkolwiek z nich). Na rysunku 2 przedstawiono jeden ze zbiorów ocenianych przez respondentów. Uzyskano 235 poprawnie wypełnionych ankiet z następującym podziałem na bloki: blok 1: 75, blok 2: 78, blok 3: 82 ankiety. Łącznie zgromadzono 21 150 obserwacji. Estymację użyteczności częściowych przeprowadzono na podstawie warunkowego modelu logitowego¹⁴, który umożliwia obliczenie teoretycznego prawdopodobieństwa wyboru określonego profilu. W wyniku estymacji warunkowego modelu logitowego uzyskano oszacowania parametrów przedstawione w tab. 10.

Oszacowane użyteczności częściowe poziomów atrybutów zostały wykorzystane do obliczenia użyteczności całkowitych każdego z profili. Następnie obliczo-

¹⁴ Model ten ma postać: $P_{ki} = \frac{\exp(\mathbf{X}_{ki}^T \boldsymbol{\beta})}{\sum_{l=1}^n \exp(\mathbf{X}_{kl}^T \boldsymbol{\beta})}$, gdzie: P_{ki} – prawdopodobieństwo wyboru i -tego

profilu opisanego k -tym wektorem atrybutów; $\mathbf{X}_{ki}$ – k -ty wektor macierzy atrybutów opisujący i -ty (wybrany) profil; $\boldsymbol{\beta}$ – wektor parametrów szacowanych metodą największej wiarygodności.

Wybierz preferowany profil piwa jasnego lub zrezygnuj z wyboru (zaznacz jedną z 6 opcji):

Kraj	Cena	Alkohol	Opakowanie	Pojemność	Wybieram opcję
Polska	2-4 zł	pow. 5,0 %	kufel	pow. 0,5 l	1
Niemcy	pow. 4 zł	do 1,0 %	puszka	0,5 l	2
Czechy	pow. 4 zł	do 1,0 %	puszka	0,33 l	3
Dania	2-4 zł	1,8–5,0 %	butelka	0,5 l	4
Holandia	do 2 zł	do 1,0 %	kufel	0,33 l	5
Żaden z tych profili					6

Rys. 2. Przykład zbioru ocenianego przez respondentów

Źródło: opracowanie własne.

Tabela 10. Oszacowane parametry modelu wyborów dyskretnych

Atrybut	DF	Parametr	Błąd	χ^2	$Pr > \chi^2$	Iloraz szans
Kraj						
Polska	1	-0,19009	0,08048	5,5779	0,0182	0,827
Niemcy	1	-0,84030	0,08626	94,8857	<,0001	0,432
Czechy	1	-0,66955	0,08359	64,1529	<,0001	0,512
Dania	1	-0,96916	0,09008	115,7588	<,0001	0,379
Holandia	1	-1,37733	0,09538	208,5386	<,0001	0,252
brak	0	0	.	.	.	.
Cena						
brak	0	0	.	.	.	.
2-4 zł	1	0,35644	0,05740	38,5609	<,0001	1,428
do 2 zł	1	0,50510	0,05521	83,7052	<,0001	1,657
pow. 4 zł	0	0	.	.	.	.
Alkohol						
brak	0	0	.	.	.	.
1,8-4,5%	1	-0,02562	0,05012	0,2614	0,6092	0,975
do 1,0%	1	-0,85350	0,05995	202,7177	<,0001	0,426
pow. 5,0%	0	0	.	.	.	.
Opakowanie						
brak	0	0	.	.	.	.
butelka	1	0,18360	0,05470	11,2653	0,0008	1,202
kufel	1	0,25960	0,05625	21,3002	<,0001	1,296
puszka	0	0	.	.	.	.
Pojemność						
brak	0	0	.	.	.	.
0,33 l	1	-0,31304	0,05465	32,8142	<,0001	0,731
0,5 l	1	0,00462	0,05182	0,0080	0,9289	1,005
powyżej 0,5 l	0	0	.	.	.	.

Źródło: opracowanie własne.

no prawdopodobieństwa wyboru profilów w każdym ze zbiorów oraz prawdopodobieństwa wyboru każdego profilu z całego ocenianego zestawu. Wybrane wyniki w postaci pięciu profilów o największych prawdopodobieństwach wyboru i pięciu profilów o najmniejszych prawdopodobieństwach wyboru spośród 270 ocenianych profilów zestawiono w tab. 11.

Tabela 11. Wartości prawdopodobieństw wyboru

Kraj	Cena	Alkohol	Opakowanie	Pojemność	Prawdopodobieństwo
Największe prawdopodobieństwa wyboru					
Polska	do 2 zł	pow. 5,0%	kufel	pow. 0,5 l	0,0104
Polska	do 2 zł	1,8-4,5%	kufel	pow. 0,5 l	0,0102
Polska	do 2 zł	pow. 5,0%	butelka	0,5 l	0,0097
Polska	do 2 zł	1,8-4,5%	butelka	pow. 0,5 l	0,0094
Polska	2-4 zł	pow. 5,0%	kufel	pow. 0,5 l	0,0090
Najmniejsze prawdopodobieństwa wyboru					
Holandia	pow. 4 zł	do 1,0%	butelka	pow. 0,5 l	0,0008
Dania	pow. 4 zł	do 1,0%	puszka	0,33 l	0,0007
Holandia	2-4 zł	do 1,0%	puszka	0,33 l	0,0007
Holandia	pow. 4 zł	do 1,0%	puszka	pow. 0,5 l	0,0006
Holandia	pow. 4 zł	do 1,0%	butelka	0,33 l	0,0006


Źródło: opracowanie własne.

Interpretację oszacowanych parametrów warunkowego modelu logitowego ułatwia tzw. iloraz szans informujący o stymulującym lub destymulującym wpływie oszacowanej wartości na prawdopodobieństwo wyboru danego profilu. Wartości ilorazu szans są obliczane na podstawie wyrażenia wykładniczego e^{β_l} , w którym wykładnikiem potęgi jest oszacowana wartość parametru (β_l – użyteczność cząstkowa l -tego poziomu atrybutu). Jeżeli $\exp(\beta_l) > 1$, to wpływ poziomu atrybutu na wybór profilu jest pozytywny; jeżeli $\exp(\beta_l) < 1$, to wpływ poziomu atrybutu na wybór profilu jest negatywny; jeżeli natomiast $\exp(\beta_l) = 1$, to wpływ poziomu atrybutu na wybór profilu jest neutralny (por. [Rószkiewicz 2002]).

Na rysunku 3 przedstawiono ilorazy szans dla parametrów, których wartości są różne od zera ($\exp(\beta_l) \neq 1$). Wartość ilorazu szans większa od 1 wskazuje na stymulujący wpływ parametru, natomiast wartość ilorazu szans mniejsza od 1 wskazuje, iż wpływ ten jest destymulujący.

Wnioski dotyczące przykładu zastosowania metody dyskretnych wyborów:

- w Polsce dominuje spożycie piwa krajowej produkcji,
- o wyborze profilu piwa decydują w kolejności cechy: cena, rodzaj opakowania, pojemność opakowania, zawartość alkoholu, kraj,
- wpływ stymulujący na prawdopodobieństwo wyboru mają: cena do 2 zł, cena 2-4 zł, opakowanie kufel, opakowanie butelka, pojemność 0,5 l.



Rys. 3. Wartości ilorazu szans dla parametrów modelu różnych od zera

Źródło: opracowanie własne.

Oprogramowanie komputerowe. Obliczenia do zaprezentowanego przykładu wykonano za pomocą procedur pakietu statystycznego SAS/STAT. W pakiecie tym oferowane są narzędzia programowe wspomagające badania preferencji wyrażonych zarówno tradycyjnymi metodami *conjoint analysis*, jak i metodami opartymi na wyborach. Dostępne procedury wspierają zwłaszcza etap gromadzenia danych oraz etap estymacji użyteczności częściowych. Na etapie gromadzenia danych do modeli preferencji szczególnie przydatne są procedury generujące pełne i częściowe układy czynnikowe: PROC PLAN, PROC FACTEX i PROC OPTEX. Na etapie estymacji użyteczności częściowych wykorzystuje się natomiast najczęściej procedury PROC TRANSREG i PROC PHREG (por. [Kuhfeld 2003]).

Literatura

- Anttila M., Heuvel R.R. van den, Müller K. (1980), *Conjoint Measurement for Marketing Management*. „European Journal of Marketing” nr 14 (7), s. 397-408.
- Bąk A., Rybicka A. (2004), *Application of Discrete Choice Methods in Consumer Preference Analysis*, [w:] D. Baier, K.-D. Wernecke (red.), *Innovations in Classification, Data Science, and Information Systems*, Proc. 27th Annual GfKI Conference, University of Cottbus, 12-14 marca 2003, Springer-Verlag, Heidelberg-Berlin, s. 305-312.

- Cattin P., Wittink D.R. (1982), *Commercial Use of Conjoint Analysis: a Survey*, „Journal of Marketing” nr 46, s. 44-53.
- Coombs C.H., Dawes R.M., Tversky A. (1977), *Wprowadzenie do psychologii matematycznej*, PWN, Warszawa.
- Glowa T., Lawson S. (2000), *Discrete Choice Experiments and Traditional Conjoint Analysis*, [URL:] http://www.ncresearch.com/Choice_Conjoint_May2000.pdf.
- Green P.E., Krieger A.M., Wind Y. (2001), *Thirty Years of Conjoint Analysis: Reflections and Prospects*, [URL:] <http://www-marketing.wharton.upenn.edu/ideas/pdf>.
- Green P.E., Srinivasan V. (1990), *Conjoint Analysis in Marketing: New Developments with Implications for Research and Practice*, „Journal of Marketing” nr 54, s. 3-19.
- Green P.E., Tull D.S., Albaum G. (1988), *Research for Marketing Decisions*, Prentice-Hall, Englewood Cliffs.
- Green P.E., Wind Y. (1975), *New Way to Measure Consumers' Judgments*, „Harvard Business Review” nr 53, s. 107-117.
- Hair J.F., Anderson R.E., Tatham R.L., Black W.C. (1995), *Multivariate Data Analysis with Readings*, Prentice-Hall, Englewood Cliffs.
- Hair J.F., Anderson R.E., Tatham R.L., Black W.C. (1998), *Multivariate Data Analysis*, Prentice-Hall, Englewood Cliffs.
- Kuhfeld W.F. (2003), *Marketing Research Methods in SAS. Experimental Design, Choice, Conjoint, and Graphical Techniques*, [URL:] <http://support.sas.com/techsup/technote/ts689.pdf>. SAS Institute, Cary.
- Louviere J.J. (2000), *Why Stated Preference Discrete Choice Modelling is NOT Conjoint Analysis (and what SPDCM is)*, [URL:] http://www.memetrics.com/products/SPDCM_whitepaper.pdf.
- Nowak W. (2001), *Wybrane metody statystyczne w badaniach marketingowych czekolady*, praca magisterska, AE, Wrocław, Jelenia Góra.
- Rószkiewicz M. (2002), *Metody ilościowe w badaniach marketingowych*, PWN, Warszawa.
- Walesiak M., Bąk A. (1997), *Realizacja badań marketingowych metodą conjoint analysis z wykorzystaniem pakietu statystycznego SPSS for Windows*, AE, Wrocław.
- Walesiak M., Bąk A. (2000), *Conjoint analysis w badaniach marketingowych*, AE, Wrocław.
- Wittink D.R., Cattin P. (1989), *Commercial Use of Conjoint Analysis: an Update*, „Journal of Marketing” nr 53, s. 91-96.
- Wittink D.R., Vriens M., Burhenne W. (1994), *Commercial Use of Conjoint Analysis in Europe: Results and Critical Reflections*, „International Journal of Research in Marketing” nr 11, s. 41-52.

EXAMPLES OF APPLICATIONS OF DECOMPOSITIONAL METHODS IN MARKETING RESEARCH

Summary

Stated consumer preferences refer to hypothetical market behavior of consumers. In this case the analytical methods are based on data collected *a priori* by means of surveys to register intentions stated by consumers at the moment of survey taking. The methods used for stated preference analysis include conjoint analysis and discrete choice methods. In this paper outlines of both groups methods are given. Next, two examples of their application in marketing research are discussed.