

Marcin Pelka

Uniwersytet Ekonomiczny we Wrocławiu

ZASTOSOWANIE ANALIZY *UNFOLDING* W OCENIE PREFERENCJI UCZNIÓW SZKOŁY POLICEALNEJ

Streszczenie: W artykule przedstawiono analizę *unfolding* preferencji uczniów szkoły policealnej. W tym celu zaprezentowano podstawowe pojęcia z zakresu analizy *unfolding*. W części empirycznej przedstawiono i porównano wyniki analizy *unfolding* otrzymane z wykorzystaniem algorytmów SMACOF i PREFSCAL.

Słowa kluczowe: analiza *unfolding*, SMACOF, PREFSCAL, preferencje uczniów szkoły policealnej.

1. Wstęp

Preferencje konsumentów są odzwierciedleniem gustów konsumentów i zależą wyłącznie od ich zadowolenia, satysfakcji czy użyteczności, jaką im zapewniają. Preferencje pozwalają konsumentom dokonywać wyborów w obliczu rozmaitych alternatyw. W teorii ekonomii, a zwłaszcza mikroekonomii i mikroekonometrii, preferencje są jednym z ważniejszych pojęć.

Preferencje konsumentów są jednym z ważniejszych zagadnień, jakie powinny być wzięte pod uwagę przez przedsiębiorstwa przy planowaniu produktu, ponieważ gdyby przedsiębiorstwo wiedziało z pewnym wyprzedzeniem, jakimi kryteriami kierują się jego klienci, wówczas mogłoby zaprojektować odpowiedni produkt odpowiadający tym kryteriom, a produkt taki odniósłby niewątpliwie sukces. Firmy, aby ustalić, czego chcą klienci, prowadzą badania preferencji konsumentów, chcąc poznać, jakie są kryteria, wartości decydujące o zakupie tego, a nie innego produktu.

Metodą skalowania wielowymiarowego znajdującą zastosowanie w analizie preferencji jest analiza *unfolding*. Jej celem jest wykrycie wspólnej przestrzeni punktów reprezentujących respondentów i badane obiekty. Otrzymana w ten sposób konfiguracja pozwala na ocenę zależności występujących pomiędzy obiektami, respondentami i pomiędzy obiektami a respondentami. W odróżnieniu do pozostałych metod skalowania wielowymiarowego, w których danymi wejściowymi jest macierz odległości, w analizie *unfolding* dane wejściowe zestawia się w macierzy preferencji.

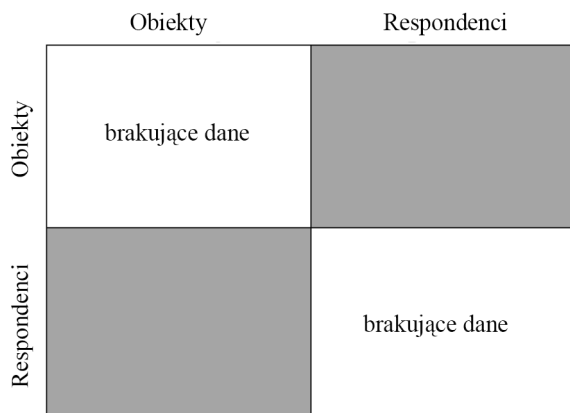
Macierz ta reprezentuje w wierszach respondentów (obiekty), a w kolumnach – obiekty (respondentów); zob. tab. 1.

Tabela 1. Macierz preferencji dotycząca pięciu przykładowych produktów (obiektów) i sześciu respondentów

		Obiekty				
		A	B	C	D	E
Respondenci	1	1	7	7	9	6
	2	4	6	4	2	1
	3	5	3	6	3	7
	4	9	2	1	5	5
	5	7	1	2	6	4
	6	6	8	1	3	9

Źródło: opracowanie własne (dane umowne).

Macierz preferencji może być również w szczególnym przypadku traktowana jako podmacierz macierzy podobieństw (por. rys. 1).



Rys. 1. Macierz preferencji jako podmacierz macierzy podobieństw

Źródło: [Zaborski 2003, s. 186; Borg, Groenen 2005, s. 295].

Zacienione prostokąty na rys. 1 zawierają te same dane – są to oceny preferencji respondentów – z tą różnicą, że wiersze (odpowiednio kolumny) jednego prostokąta są jednocześnie kolumnami (odpowiednio wierszami) drugiego prostokąta.

Pozycję, jaką zajmują punkty reprezentujące respondentów na mapie percepcyjnej, oznaczają tzw. **punkty idealne**. Punkt taki oznacza obiekt o najbardziej prefe-

rowanej przez respondenta (czy respondentów) kombinacji cech. Pozycję punktów oznaczających obiekty w stosunku do punktów idealnych oznaczają względne preferencje respondentów.

2. Podejścia stosowane w analizie *unfolding*

Podobnie jak w skalowaniu wielowymiarowym, tak i w analizie *unfolding* wyróżnia się dwa podejścia w otrzymywaniu współrzędnych kolumn i wierszy¹:

1. **Bezpośrednie**, w którym respondenci uwzględniają w badanych obiektach hipotetyczny obiekt idealny ze względu na badane cechy, a następnie następuje porównanie pozostałych obiektów z obiektem idealnym.

2. **Pośrednie**:

- **zewnętrzne** (*external unfolding*), w którym współrzędne zarówno wierszy, jak i kolumn są otrzymywane za pomocą odpowiednich algorytmów bezpośrednio z macierzy preferencji;
- **wewnętrzne** (*internal unfolding*), w którym znane są pewne współrzędne, zazwyczaj są to współrzędne dla obiektów (pochodzą one np. ze skalowania wielowymiarowego), a pozostałe współrzędne są dopasowywane do posiadanej mapy percepcyjnej.

W analizie *unfolding* wyróżnia się również podejścia co do preferencji respondentów:

1. **Niezależne** (*unconditional unfolding*), w którym wymagane jest porównanie wszystkich elementów macierzy preferencji. Zakłada się tutaj, że jeżeli i -ty respondent przyporządkowuje obiektowi A niższą wartość niż j -ty respondent obiektowi B , to wtedy A jest bardziej podobny do obiektu idealnego i -tego respondenta niż B do punktu j -tego respondenta.

2. **Zależne** (*conditional unfolding*), w którym dokonuje się porównań w ramach poszczególnych wierszy odpowiadających poszczególnym respondentom.

Wyróżnia się ponadto metryczne i niemetryczne metody skalowania wielowymiarowego w analizie *unfolding*. W **podejściu niemetrycznym** mamy do czynienia z sytuacją, gdy zarówno dane wejściowe, jak i wyniki skalowania wielowymiarowego są mierzone na skali porządkowej. **Podejście metryczne** wymaga, aby oceny preferencji i dane wejściowe były mierzone na skali przedziałowej lub ilorazowej. W części empirycznej wykorzystane zostaną jedynie metody metryczne.

3. Algorytm wyznaczania współrzędnych bezpośrednio na podstawie macierzy preferencji

Algorytm wyznaczania współrzędnych punktów idealnych i punktów reprezentujących obiekty bezpośrednio na podstawie macierzy preferencji można przedstawić za


¹ Opracowano na podstawie prac: [Borg, Groenen 2005; Cox, Cox 2000; Zaborski 2001; Zaborski 2003, s. 185-194].

pomocą rys. 2. Analiza *unfolding* prowadzi do wyznaczenia takiej konfiguracji punktów (\mathbf{X}, \mathbf{Y}) , która minimalizuje sumę kwadratów reszt wyrażającą się wzorem (por. [Cox, Cox 2000, s. 121]):

$$S = f(\mathbf{X}, \mathbf{Y}) = \sum_{k=1}^m \sum_{i=1}^n \left\{ \delta_{ki}^2 - (\mathbf{x}_k - \mathbf{y}_i)^T (\mathbf{x}_k - \mathbf{y}_i) \right\}^2, \quad (1)$$

gdzie: δ_{ki} oznacza preferencje respondentów, w których $k = 1, \dots, m$, a $i = 1, \dots, n$, przy czym m oznacza liczbę respondentów, a n – liczbę obiektów, \mathbf{x}_k oznacza punkty reprezentujące respondentów, \mathbf{y}_i oznacza punkty reprezentujące objekty.

Poszukiwanie konfiguracji (\mathbf{X}, \mathbf{Y}) ma charakter iteracyjny (zob. rys. 2). Najpierw dla początkowej konfiguracji wyjściowej \mathbf{Y} wyznacza się minimum funkcji S względem \mathbf{X} , a następnie dla wyznaczonych w ten sposób \mathbf{X} minimalizuje się funkcję S względem \mathbf{Y} .



Rys. 2. Algorytm analizy *unfolding*

Źródło: [Zaborski 2003, s. 188].

W **fazie skalowania optymalnego** oblicza się odległości pomiędzy punktami wyznaczonymi w poprzednich etapach, a następnie wyznacza się funkcję regresji w taki sposób, aby odległości między punktami i odpowiadające im oceny preferencji spełniały warunek monotoniczności, gwarantując jednocześnie minimalizację funkcji dopasowania.

Proces poszukiwania współrzędnych (\mathbf{X}, \mathbf{Y}) zostaje zakończony, jeżeli wartość funkcji-kryterium (funkcji S) jest mniejsza od pewnej wcześniej ustalonej wielkości (kryterium stopu) lub jeśli osiągnięto założoną wcześniej liczbę iteracji (a).

4. Analiza preferencji uczniów szkół policealnych


Kandydaci jednej ze szkół policealnych² funkcjonujących na wałbrzyskim rynku w czasie rekrutacji zimowej w roku szkolnym 2008/2009 otrzymali ankietę opraco-

² Nazwa szkoły nie może zostać ujawniona ze względu na brak zgody jej dyrekcji.

waną przez szkołę policealną. Mieli oni wskazać w niej najważniejsze czynniki decydujące o wyborze tej, a nie innej szkoły policealnej oraz o danej formy nauki (liceum ogólnokształcące, liceum uzupełniające lub jeden z sześciu kierunków policealnych). Kandydaci mieli do wyboru takie czynniki, jak:

- 1) dobra lokalizacja miejsca nauki,
- 2) darmowa nauka w szkole,
- 3) dobra opinia o szkole,
- 4) dodatkowe bezpłatne zajęcia – czynnik ten nie został uwzględniony w dalszej części analizy ze względu na fakt, że szkoła nie prowadzi jeszcze żadnych dodatkowych bezpłatnych zajęć, kursów czy fakultetów,
- 5) konieczność podniesienia swoich kwalifikacji,
- 6) chęć podniesienia swoich kwalifikacji lub uzupełnienie i uaktualnienie swojej wiedzy,
- 7) prawo do pobierania renty rodzinnej w trakcie nauki,
- 8) możliwość odroczenia służby wojskowej.


Kandydaci wskazywali w ankiecie najważniejsze czynniki poprzez wstawienie znaku „X” w przy nazwie czynnika, a każdy z kandydatów mógł wskazać dowolną liczbę czynników. W trakcie rekrutacji zebrano łącznie 262 ankiety dla różnych typów szkół. Liczebność ankiet z podziałem na różne typy szkół prezentuje rys. 3.



Rys. 3. Liczebność zebranych ankiet z podziałem na różne typy szkół

Źródło: opracowanie własne.

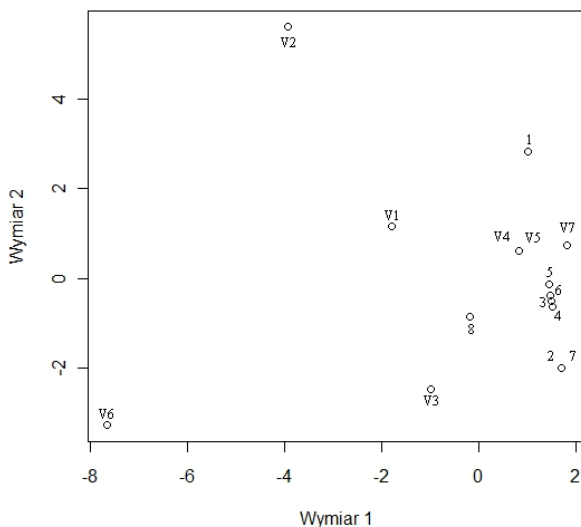
Do celów badania preferencji z wykorzystaniem analizy *unfolding* zagregowano wskazania kandydatów dotyczące poszczególnych czynników w ramach wymienionych typów szkół (zob. rys. 3). Następnie obliczono średnią wskazań czynników w poszczególnych typach szkół. Tak otrzymany pomiar pozwala na zastosowanie



1 – administracja; 2 – hotelarstwo; 3 – informatyka; 4 – LO; 5 – logistyka; 6 – LU; 7 – rachunkowość; 8 – logistyka, V1 – dobra lokalizacja; V2 – darmowa szkoła; V3 – opinia o szkole; V4 – konieczność podniesienia kwalifikacji; V5 – chęć podniesienia kwalifikacji; V6 – renta rodzinna; V7 – odroczenie służby wojskowej.

Rys. 4. Wyniki otrzymane z wykorzystaniem algorytmu SMACOF

Źródło: obliczenia własne z wykorzystaniem programu R.



1 – administracja; 2 – hotelarstwo; 3 – informatyka; 4 – LO; 5 – logistyka; 6 – LU; 7 – rachunkowość; 8 – logistyka, V1 – dobra lokalizacja; V2 – darmowa szkoła; V3 – opinia o szkole; V4 – konieczność podniesienia kwalifikacji; V5 – chęć podniesienia kwalifikacji; V6 – renta rodzinna; V7 – odroczenie służby wojskowej.

Rys. 5. Wyniki otrzymane z wykorzystaniem algorytmu PREFSCAL

Źródło: obliczenia własne w programie SPSS.

metrycznych procedur analizy *unfolding*. Wykorzystano w tym celu algorytmy SMACOF (pakiet *smacof*, funkcja *smacofRect* z programu **R**) oraz PREFSCAL (dostępny w SPSS). Algorytm PREFSCAL zostały wybrany ze względu na fakt, że można ustalić w nim parametr karania dla rozwiązań zdegenerowanych). Wyniki analizy *unfolding* z wykorzystaniem algorytmów SMACOF i PREFSCAL przedstawiają rys. 4 i 5.

5. Wnioski

W odniesieniu do algorytmu zarówno SMACOF, jak i PREFSCAL najmniej istotnym czynnikiem okazała się chęć nauki w szkole. W przypadku algorytmu SMACOF za czynnik mało istotny dla uczniów szkół policealnych należy uznać również to, że nauka w szkole jest bezpłatna. Niezależnie od zastosowanego algorytmu ważnymi czynnikami decydującymi o wyborze szkoły policealnej (niezależnie od kierunku) okazały się: dobra opinia o szkole, konieczność podniesienia kwalifikacji, lokalizacja szkoły oraz możliwość odroczenia służby wojskowej.

W przypadku algorytmu SMACOF trudno wskazać jednoznacznie, które czynniki decydują o wyborze tego, a nie innego kierunku w szkole policealnej. Jedynie w odniesieniu do uczniów liceum ogólnokształcącego, liceum uzupełniającego i uczniów policealnej szkoły logistyki ważniejszym czynnikiem jest możliwość otrzymywania renty rodzinnej. W przypadku algorytmu PREFSCAL można stwierdzić, że chęć podniesienia kwalifikacji jest o wiele ważniejszym czynnikiem decydującym o wyborze szkoły dla uczniów szkół policealnych administracji, rachunkowości i turystyki niż dla uczniów innych kierunków. Natomiast niezależnie od typu szkoły (poza uczniami policealnej szkoły hotelarstwa) istotnymi czynnikami decydującymi o wyborze szkoły są: dobra opinia o szkole, konieczność podniesienia kwalifikacji, lokalizacja szkoły, możliwość odroczenia służby wojskowej i możliwość pobierania renty rodzinnej. Wyniki otrzymane z wykorzystaniem algorytmu PREFSCAL sugerują, że uczniowie policealnej szkoły hotelarstwa przy wyborze kierują się innymi czynnikami niż te, które przedstawiono im do oceny.

Dla algorytmu SMACOF wyniki otrzymano po przeprowadzeniu 188 iteracji; uzyskano funkcję STRESS na poziomie 0,02 (jest to wartość surowej, nieznormalizowanej funkcji STRESS i nie może ona zostać zinterpretowana). Dodatkowo w odniesieniu do algorytmu SMACOF możemy mieć do czynienia z rozwiązaniem zdegenerowanym (na co wskazywać może bliskie położenie punktów reprezentujących poszczególne typy szkół i czynniki).

Wyniki dla algorytmu PREFSCAL otrzymano, przyjmując zakres kary na poziomie 0,5, a siłę kary – na poziomie 0,5. Ostatecznie po przeprowadzeniu 2601 iteracji otrzymano funkcję STRESS na poziomie 0,00 (wartość ukaranej funkcji STRESS wyniosła 0,0001). Zbliżone wyniki otrzymano, przyjmując zakres kary na poziomie 1,0, a siłę kary – na poziomie 0,5. Wówczas po przeprowadzeniu 2265 iteracji otrzymano funkcję STRESS na poziomie 0,00 (wartość ukaranej funkcji

STRESS wyniosła 0,00009). Obydwa te wyniki (STRESS i ukarany STRESS) sugerują, że otrzymano idealne dopasowanie punktów do danych przy jednoczesnym uniknięciu rozwiązania zdegenerowanego.

Literatura

Borg I., Groenen P.J.F., *Modern Multidimensional Scaling. Theory and Applications*, Springer-Verlag, New York 2005.

Cox T.F., Cox M.A.A., *Multidimensional Scaling. Second Edition*, Chapman and Hall, London 2000.

Lattin J., Carroll J.D., Green P.E., *Analyzing Multivariate Data*, Thomson Learning, Toronto 2003.

Zaborski A., *Identyfikacja czynników determinujących preferencje konsumentów z wykorzystaniem analizy unfolding*, [w:] K. Jajuga, M. Walesiak, *Taksonomia 10, Klasyfikacja i analiza danych – teoria i zastosowania*, AE, Wrocław 2003, s. 185-194.

Zaborski A., *Skalowanie wielowymiarowe w badaniach marketingowych*, AE, Wrocław 2001.

APPLICATION OF UNFOLDING ANALYSIS IN THE EVALUATION OF COLLEGE STUDENTS PREFERENCES

Summary: The paper presents the application of unfolding analysis of college students preferences. To obtain such a goal basic terms of unfolding analysis are presented. In the empirical part of the paper the results of unfolding analysis obtained by applying SMACOF and PREFSCAL algorithms are presented and compared.