

Barbara Wąsikowska
Uniwersytet Szczeciński

Fatimah Furajji
College of Science
University of Basrah

BADANIE PREFERENCJI ZAKUPOWYCH KOBIEŃ I MĘŻCZYŹN METODĄ ZBIORÓW PRZYBLIŻONYCH

Streszczenie

W artykule przedstawiono niestandardowy sposób badania preferencji zakupowych kobiet i mężczyzn. Główny nacisk został położony na prezentację metody, która została użyta w przeprowadzonym badaniu. Teorię zbiorów przybliżonych zastosowano do identyfikacji reguł zachowań kobiet i mężczyzn kupujących sprzęt AGD.

Słowa kluczowe: zachowania konsumenckie, badanie preferencji, zbiory przybliżone, odkrywanie wiedzy.

Wstęp

Badania preferencji stanowią obecnie główny obszar zainteresowań badaczy z zakresu ekonomii i zarządzania. Są one podstawową kategorią badawczą w modelowaniu zachowań konsumentów na rynku, uwzględniającą racjonalność podejmowania decyzji. Pojęcie preferencji jest stosowane powszechnie w literaturze naukowej, lecz jego znaczenie jest różne w zależności od danej dziedziny wiedzy. Preferencje są podstawowym pojęciem w teorii ekonomii, szczególnie w teorii wyboru konsumenta. Zazwyczaj przyjmuje się, że preferencje odzwierciedlają i formalizują osobiste gusty i nie zależą od czynników ekonomicznych (takich jak cena dobra, budżet konsumenta), ale wyłącznie odczuć subiektywnych (takich jak: satysfakcja, zadowolenie, szczęście) lub użyteczności. Indywidualne preferencje pozwalają dokonywać wyboru w sytuacji występowania wielu alternatyw.

Celem rozważań jest przedstawienie sposobu analizy danych marketingowych metodą sztucznej inteligencji tj. metodą zbiorów przybliżonych. Dane potrzebne do przeprowadzenia badań zostały zebrane metodą ankietową w Iraku, w 2011 roku i dotyczą preferencji zakupowych kobiet i mężczyzn. W artykule weryfikowany jest pogląd, że zastosowanie teorii zbiorów przybliżonych do analizy danych marketingowych może stanowić znaczące uzupełnienie przeprowadzonych badań poznawczych przy użyciu metod klasycznych.

Zastosowanie metod sztucznej inteligencji w badaniach marketingowych

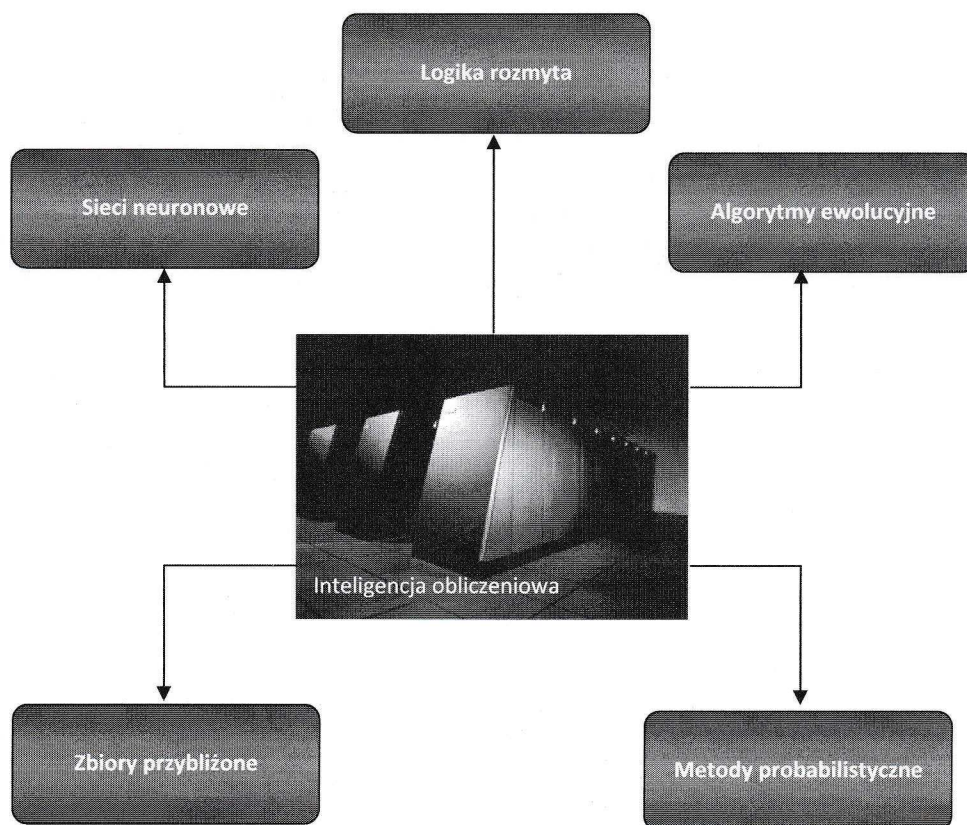
W ciągu ostatnich lat obserwuje się dynamiczny rozwój sztucznej inteligencji (dziedziny informatyki graniczącej z innymi naukami). Ten szczególnie szybki rozwój sztucznej inteligencji związany jest ściśle ze wzrostem mocy obliczeniowej komputerów, jak

również ze wzrostem liczby dostępnych danych. Istotą systemów opartych na sztucznej inteligencji jest możliwość przetwarzania danych wyrażonych zarówno w formie numerycznej, binarnej jak i w formie lingwistycznej, logicznej. Dane te mogą się także składać z uporządkowanych sekwencji elementów lub tablic i zawierać elementy opisane w bardzo nieprecyzyjny, a nawet subiektywny sposób.

Do niedawna informacje słowne (np. mały dochód firmy, wysoka jakość produktu itp.) nie były w ogóle stosowane w metodach opartych na matematyce konwencjonalnej. Niebranie pod uwagę tych informacji ograniczało znacznie skuteczność i efektywność różnych metod modelowania, prognozowania, badania rynku, projektowania itp. Zaczęto więc poszukiwać nowych metod, dzięki którym możliwe byłoby wykorzystanie również tego typu informacji. W ostatnich latach opracowano także wiele metod hybrydowych, łączących systemy uczące się z systemami ewolucyjnymi i rozmytymi. Podstawowe metody inteligencji obliczeniowej, które powstały w wyniku prowadzonych badań, przedstawiono na schemacie 1.

Schemat 1

Podstawowe metody inteligencji obliczeniowej



Źródło: opracowanie własne na podstawie: L. Rutkowski, *Metody i techniki sztucznej inteligencji*, Wydawnictwo Naukowe PWN, Warszawa 2005.

Wymienione na schemacie 1 metody znajdują wiele zastosowań w obszarach biznesowych. Jednym z takich obszarów jest marketing, a w szczególności obszar komunikacji z klientami. Ma to szczególne znaczenie w okresie, w którym niezwykle popularne stały się koncepcje marketingu partnerskiego czy też budowania trwałych relacji z klientami (CRM). Współczesne oprogramowanie wykorzystujące metody i techniki sztucznej inteligencji można wykorzystać w kilku obszarach związanych z budową relacji z klientami, np.:

- a) przygotowaniu baz danych klientów, ich czyszczeniu,
- b) prowadzeniu dialogu z klientem w języku naturalnym,
- c) automatycznym odpowiadaniu na zapytania klienta wysłane emailem.

Metody sztucznej inteligencji stosuje się również coraz częściej do badania zachowań konsumentów podczas zakupów. Również rozwój badań w obszarze neurobiologii oraz funkcjonowania mózgu człowieka pozwala lepiej poznawać zachowania konsumentów. Wiedza o nabywcy staje się bardziej dokładna, jeśli powstaje w wyniku interdyscyplinarnego spojrzenia na uwarunkowania jego działań¹.

Zbiory przybliżone w definiowaniu reguł zachowań konsumentów

Teoria zbiorów przybliżonych, zapoczątkowana przez Zdzisława Pawłaka w latach 80. ubiegłego wieku i rozwijana przez szereg lat przez jej twórcę i wielu innych badaczy, stanowi teoretyczną podstawę różnych metod i narzędzi informatycznych, które umożliwiają m.in. indukcję reguł decyzyjnych czy też redukcję zbiorów danych. Teoria zbiorów przybliżonych zyskała dużą popularność i jest obecnie skutecznie wykorzystywana m.in. w eksploracji danych i odkrywaniu wiedzy, złożonych zadaniach klasyfikacji oraz w komputerowych systemach wspomagania decyzji. Dziedziny, w których teoria ta została dotychczas zastosowana to m.in. medycyna, farmakologia, biznes (bankowość, badania rynku), rozpoznawanie mowy, obrazów, lingwistyka, sztuczna inteligencja. Na popularność tej metody złożyło się wiele czynników. Przede wszystkim teoria zbiorów przybliżonych wraz z algorytmami ją wykorzystującymi, pozwala analizować duże zbiory danych umożliwiając przy tym na redukcję zbioru cech opisujących obiekty do niezbędnego minimum (tzw. redukt zbioru atrybutów warunkowych), usuwając niespójność w danych, jeśli taka ma miejsce oraz generując z danych tzw. reguły minimalne, a więc symulując postępowanie eksperta z danej dziedziny, który zazwyczaj swą wiedzę potrafiłby najszybciej przedstawiać jako takie właśnie reguły (zapisy postaci: Jeżeli ... i ... to ...). Za zaletę teorii zbiorów przybliżonych należy uznać fakt, że:

- a) nie wymaga ona założeń dotyczących danych (np. prawdopodobieństwa czy rozmytości),
- b) zawiera szybkie algorytmy analizy danych,
- c) ułatwia interpretację wyników,
- d) charakteryzuje się znaczną prostotą matematyczną².

W ramach niniejszego artykułu przedstawiony został sposób użycia zbiorów przybliżonych do stworzenia bazy reguł zachowań kobiet i mężczyzn podczas dokonywania zakupu sprzętu AGD. Pytanie, które postawiły sobie autorki brzmiało: jak ważne jest dla kobiet i mężczyzn zapewnienie wysokich standardów bezpieczeństwa kupowanego przez nich sprzętu AGD? Dane do badania zostały zebrane metodą ankietową wśród kobiet

¹ J. Żmija, z recenzji książki H. Mruk, M. Sznajder, *Neuromarketing. Interdyscyplinarne spojrzenie na klienta*, Wydawnictwo Uniwersytetu Przyrodniczego w Poznaniu, Poznań 2008.

² Z. Pawlak, *Zbiory przybliżone – nowa matematyczna metoda analizy danych*, „Miesięcznik Politechniki Warszawskiej” 2004, nr 5, s. 2.

i mężczyzn zamieszkujących Basrę w Iraku. Uzyskane dane zostały następnie ułożone w postaci tzw. pierwotnej tablicy informacyjnej (por. tabela 1). Tablicą informacyjną nazywamy uporządkowaną piątkę $T=(U, Q, D, V, f)$, gdzie D jest to zbiór cech (atrybutów) decyzyjnych, U jest zbiorem obiektów (przykładów) i jest zwany uniwersum, Q jest zbiorem cech (atrybutów warunkowych), $V=Uq \in Q$ i Vq jest zbiorem wszystkich możliwych wartości cech, natomiast $f: U \times Q \rightarrow V$ jest funkcją informacyjną³. Tablicowy sposób reprezentacji danych posiada dwie zasadnicze cechy: uniwersalność, co oznacza, że pozwala na gromadzenie i przechowywanie różnorodnych danych oraz efektywność co oznacza, że umożliwia w łatwy sposób komputerową analizę tak zapisanych danych.

Pierwsza kolumna zawiera numery nadane poszczególnym ankietowanym osobom (od p1 do p174). W następnych trzech kolumnach znajdują się wartości atrybutów warunkowych, atrybutami tymi są:

- płeć badanej osoby,
- wiek badanej osoby,
- wykształcenie osoby ankietowanej.

Tabela 1

Fragment pierwotnej tablicy informacyjnej

Lp.	Płeć	Wiek	Wykształcenie	Czy zapewnienie wysokich standardów bezpieczeństwa kupowanego przez mnie sprzętu AGD jest dla mnie ważne?
p1	kobieta	18-24	bez wykształcenia	nieważne
p2	mężczyzna	powyżej 54	bez wykształcenia	obojętne
p3	mężczyzna	powyżej 54	średnie	bardzo ważne
p4	mężczyzna	35-44	wyższe	bardzo ważne
p5	kobieta	45-54	średnie	bardzo ważne
p6	kobieta	18-24	wyższe	bardzo ważne
p7	kobieta	18-24	wyższe	bardzo ważne
p8	kobieta	18-24	średnie	bardzo ważne
p9	kobieta	25-34	wyższe	bardzo ważne
p10	kobieta	25-34	wyższe	bardzo ważne
p11	mężczyzna	25-34	wyższe	ważne
p12	mężczyzna	powyżej 54	średnie	bardzo ważne
p13	kobieta	25-34	wyższe	bardzo ważne
.
.
.
p174	kobieta	35-44	średnie	bardzo ważne

Źródło: opracowanie własne.

³ L. Rutkowski, *Metody i techniki sztucznej inteligencji*, Wydawnictwo Naukowe PWN, Warszawa 2005, s. 21.

W ostatniej kolumnie znajduje się atrybut decyzyjny informujący o tym jak ważne było dla badanej osoby zapewnienie wysokiego standardu bezpieczeństwa kupowanego przez nią sprzętu AGD. W kolejnym kroku, zgodnie z teorią zbiorów przybliżonych, dane zebrane w pierwotnej tabeli informacyjnej poddano dyskretyzacji oraz kodowaniu. Sposób dyskretyzacji oraz kodowania wartości poszczególnych atrybutów podany został w tabeli 2.

Tabela 2**Dyskretyzacja oraz kodowanie wartości atrybutów pierwotnej tabeli informacyjnej**

Sposób kodowania atrybutu płeć	Sposób dyskretyzacji oraz kodowania atrybutu wiek	Sposób kodowania atrybutu wykształcenie	Sposób kodowania atrybutu decyzyjnego
oznaczenie atrybutu: q1 M – mężczyzna K – kobieta	oznaczenie atrybutu: q2 v1 – [od 18 do 24 lat] v2 – [od 25 do 34 lat] v3 – [od 35 do 44 lat] v4 – [od 45 do 54 lat] v5 – [od 55 i więcej]	oznaczenie atrybutu: q3 v1 – bez wykształcenia v2 – podstawowe v3 – gimnazjalne v4 – średnie v5 – wyższe	oznaczenie atrybutu: d A1 – nieważne A2 – obojętne A3 – ważne lub bardzo ważne

Źródło: jak w tabeli 1.

W wyniku przeprowadzonej dyskretyzacji oraz kodowania otrzymano wtórną tablicę informacyjną (por. tabela 3).

Tabela 3**Fragment wtórnej tabeli informacyjnej**

No	q1 (płeć)	q2 (wiek)	q3 (wykształcenie)	d (decyzja)
p1	K	v1	v1	A1
p2	M	v5	v1	A2
p3	M	v5	v4	A3
p4	M	v3	v5	A3
p5	K	v4	v4	A3
p6	K	v1	v5	A3
p7	K	v1	v5	A3
p8	K	v1	v4	A3
p9	K	v2	v5	A3
p10	K	v2	v5	A3
.
.
.
p174	K	v3	v4	A3

Źródło: jak w tabeli 1.

Tak przygotowane wstępnie dane poddano analizie metodą zbiorów przybliżonych używając do tego programu DAT (*Data Analysis Toolbox*) działającego w środowisku MATLAB R2010a. Na podstawie przeprowadzonych wstępnie obliczeń tj. wyznaczeniu zbiorów elementarnych (czyli zbiorów przykładów zawierających te same wartości atrybutów warunkowych), konceptów decyzyjnych (czyli zbiorów przykładów zawierających tę samą wartość decyzji) podjęto próbę zredukowania zbioru atrybutów warunkowych. W wyniku przeprowadzonych badań stwierdzono, że wszystkie atrybuty warunkowe są istotne (żaden z atrybutów nie jest atrybutem redundantnym) i stanowią one rdzeń zbioru. Zbadano więc istotność poszczególnych atrybutów warunkowych obliczając dla każdego a atrybutów znormalizowany współczynnik istotności (por. tabela 4).

Tabela 4
Istotność poszczególnych atrybutów warunkowych

Atrybut	Istotność
pleć	0,2880
wiek	0,6400
wykształcenie	0,4000

Źródło: jak w tabeli 1.

Z analizy wynika, że istotność każdego z wybranych atrybutów jest większa niż zero, co potwierdza fakt, że nie można żadnego z nich usunąć z tablicy decyzyjnej – wszystkie atrybuty są w mniejszym lub większym stopniu istotne. Im wartość istotności atrybutu jest bliższa jedności, tym atrybut jest bardziej istotny. Dwie najbardziej istotne cechy to wiek ankietowanej osoby oraz jej wykształcenie.

Kolejnym krokiem było dokonanie aproksymacji (przybliżenia) zbioru, czyli wyznaczenie dolnych i górnych przybliżeń, brzegu zbioru oraz obszarów pozytywnych i negatywnych zbioru (dokładne wyjaśnienie tych pojęć oraz odpowiednie wzory można znaleźć między innymi w pracach)⁴. Na podstawie otrzymanych wyników obliczono współczynnik jakości przybliżenia gamma, który informuje w ilu procentach analizowane przykłady oraz atrybuty warunkowe pozwalają wyznaczyć reguły pewne. Jakość przybliżenia zbioru F wyraża się następującym wzorem:

$$\gamma_{\tilde{Q}}(F) = \frac{\text{card}(\text{Pos}_{\tilde{Q}}(F))}{\text{card}(U)} \quad (1)$$

gdzie w liczniku znajduje się liczebność przykładów zawartych w pozytywnym regionie zbioru a w mianowniku liczebność przykładów zawartych w całym uniwersum zbioru. W tym wypadku wartość współczynnika gamma wyniosła 72%, co oznacza że 72% przykładów w tablicy informacyjnej generuje reguły w 100% pewne. W wyniku przeprowadzenia dalszych analiz otrzymano tablicę decyzyjną zawierającą 42 reguły. Fragment tablicy decyzyjnej przedstawiono w tabeli 5.

⁴ A. Mrózek, Płonka, *Analiza danych metodą zbiorów przybliżonych. Zastosowania w ekonomii, medycynie i sterowaniu*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1999, s. 9-25; Z. Pawlak, *Zbiory przybliżone, nowa matematyczna metoda analizy danych*, „Miesięcznik Politechniki Warszawskiej” 2004, nr 5, s. 4-5; L. Rutkowski, *Metody i techniki sztucznej inteligencji*, op. cit., s. 20-45.

W tabeli tej podano również następujące charakterystyki liczbowe:

- wsparcie reguły, które oznacza ilość przykładów popierająca daną regułę,
- pewność reguły, którą oblicza się dzieląc wsparcie danej reguły/ilość reguł posiadających tą samą przesłankę,
- wymieniono przykłady (obiekty) popierające daną regułę.

Tabelę tę podzielono na część dobrze i źle zdefiniowaną. W części źle zdefiniowanej zawarte zostały reguły sprzeczne (w sumie 12 reguł), natomiast w części dobrze zdefiniowanej zawarto pozostałych 30 reguł. W następnym kroku dokonano uproszczenia reguł podobnych znajdujących się w tabeli dobrze zdefiniowanej. W tabeli 6 przedstawiono algorytm decyzyjny zawierający przykładowe otrzymane reguły.

Tabela 5

Fragm. tablicy decyzyjnej

Lp.	Płeć	Wiek	Wykształcenie	Atrybut decyzyjny	Wsparcie reguły	Pewność reguły	Przykłady popierające regułę
1	K	v1	v1	A1	1	1	p1
2	K	v4	v3	A3	1	1	p95
3	K	v4	v4	A3	7	1	p5, p49, p75, p129, p163, p168, p170
4	K	v4	v5	A1	1	0.1	p14
5	K	v4	v5	A3	9	0.9	p23, p44, p80, p118, p125, p138, p152, p153, p166
6	K	v5	v4	A3	1	1	p56
7	K	v5	v5	A3	3	1	p74, p164, p171
8	M	v1	v1	A3	1	1	p92
9	M	v1	v3	A3	1	1	p18
10	M	v1	v5	A3	4	1	p30, p87, p111, p148
11	M	v2	v2	A3	2	1	p80, p101
12	M	v2	v3	A3	5	1	p32, p38, p68, p72, p120
13	M	v2	v4	A3	4	1	p40, p93, p104, p150
14	M	v2	v5	A3	18	1	p11, p15, p20, p47, p48, p50, p53, p70, p99, p107, p108, p112, p116, p129, p145, p149, p158, p161

Źródło: jak w tabeli 1.

Tabela 6

Algorytm decyzyjny

Nr reguły	Przykładowe reguły algorytmu decyzyjnego
1	Jeżeli płeć = K i wiek = v1 i wykształcenie = v1 to d=A1
2	Jeżeli płeć = K i wiek = v3 i wykształcenie = v5 to d=A3
3	Jeżeli płeć = M i wiek = v2 i wykształcenie = v4 to d=A3
4	Jeżeli płeć = M i wiek = v5 i wykształcenie = v5 to q5 = A1

Źródło: jak w tabeli 1.

Po przeanalizowaniu reguł z części dobrze zdefiniowanej poddano analizie również reguły sprzeczne. Nie należy z góry odrzucać reguł sprzecznych. Wymagają one należytego przeanalizowania. Może się bowiem okazać, że informacje w nich zawarte mogą być bardzo użyteczne. Choć są to reguły sprzeczne, to należy zwrócić uwagę na to, ile przypadków popiera daną regułę. I tak na przykład regułę nr 3 popiera aż 14 przypadków na 16 zawierających takie same wartości atrybutów warunkowych (informuje o tym charakterystyka zwana pewnością reguły). Tym czasem reguły do niej sprzeczne (reguła nr 1 i 2) poparte są tylko jednym przypadkiem. Należało by więc zastanowić czy nie wziąć pod uwagę słuszności reguły nr 3, a odrzucić reguły nr 1 i 2 jako błędne. Podobnie ma się rzecz w przypadku pozostałych reguł sprzecznych zawartych w tabeli 7.

Tabela 7
Wybrane reguły sprzeczne

Nr reguły	Przykłady reguł sprzecznych	Pewność reguły
1	Jeżeli płeć =K i wiek = v2 i wykształcenie = v5 to d=A1	1/ 16
2	Jeżeli płeć =K i wiek = v2 i wykształcenie = v5 to d=A2	1/ 16
3	Jeżeli płeć =K i wiek = v2 i wykształcenie = v5 to d=A3	14/ 16
4	Jeżeli płeć =K i wiek = v4 i wykształcenie = v5 to d=A1	1/ 10
5	Jeżeli płeć =K i wiek = v4 i wykształcenie = v5 to d=A3	9/ 10
6	Jeżeli płeć =M i wiek = v3 i wykształcenie = v4 to d=A1	1/ 10
7	Jeżeli płeć =M i wiek = v3 i wykształcenie = v4 to d=A3	9/ 10

Źródło: jak w tabeli 1.

Tabela 8
Reguły poparte największą liczbą przypadków

Nr reguły	Reguła	Liczba przypadków popierających regułę
1	Jeżeli płeć = kobieta i wykształcenie \neq brak to decyzja = ważne lub bardzo ważne. Opis słowny reguły: Dla kobiety posiadającej wykształcenie co najmniej podstawowe zapewnienie wysokich standardów bezpieczeństwa sprzętu elektrycznego jest ważne lub bardzo ważne.	66
2	Jeżeli płeć = mężczyzna i wiek = powyżej 24 lat i wykształcenie \neq brak to decyzja = ważne lub bardzo ważne. Opis słowny reguły: Dla mężczyzny, w wieku powyżej 24 lat, posiadającego wykształcenie co najmniej podstawowe zapewnienie wysokich standardów bezpieczeństwa sprzętu elektrycznego jest ważne lub bardzo ważne.	90

Źródło: jak w tabeli 1.

Ostatecznie w wyniku przeprowadzonego uproszczenia reguł otrzymano osiem reguł.

Spośród tychże ośmiu reguł dwie reguły zasługują na szczególną uwagę. Są to bowiem reguły poparte bardzo dużą liczbą przypadków (por. tabela 8).

Wnioski

Na podstawie otrzymanych reguł oraz analizy istotności poszczególnych atrybutów warunkowych stwierdzono, że atrybutami warunkowymi mającymi największy wpływ na atrybut decyzyjny są:

- a) w przypadku kobiet – wykształcenie,
- b) w przypadku mężczyzn – oprócz wykształcenia istotną rolę odgrywa również wiek.

Z otrzymanych reguł, popartych największą liczbą przypadków jasno wynika, że dla kobiet posiadających wykształcenie minimum podstawowe, niezależnie od wieku, zapewnienie wysokich standardów bezpieczeństwa urządzeń elektrycznych jest ważne lub bardzo ważne. Natomiast w przypadku mężczyzn takie zapewnienie jest istotne tylko dla mężczyzn w wieku powyżej 24 lat. Dla młodszych mężczyzn dbałość o bezpieczeństwo urządzeń elektrycznych nie miała już tak wielkiego znaczenia. Dla osób nieposiadających żadnego wykształcenia zapewnienie wysokich standardów bezpieczeństwa urządzeń elektrycznych nie było w ogóle istotne. Ciekawy wydaje się być również fakt, że wśród mężczyzn w posiadających wykształcenie wyższe zdarzali się tacy, dla których problem bezpieczeństwa urządzeń elektrycznych był również bez znaczenia, natomiast wśród wykształconych kobiet nie było ani jednego takiego przypadku.

Podsumowanie

Przedstawione w artykule badania koncentrowały się na analizie danych dotyczących preferencji zakupowych kobiet i mężczyzn. Celem badania było sprawdzenie, czy podczas zakupu sprzętu AGD badani respondenci zwracali uwagę na to, aby kupowany przez nich sprzęt zapewniał wysokie standardy bezpieczeństwa. Do przeanalizowania zebranych danych posłużono się zbiorami przybliżonymi. Otrzymane wyniki pozwalają na stwierdzenie, że zastosowana w badaniach metoda sztucznej inteligencji tj. metoda zbiorów przybliżonych może być z powodzeniem stosowana w praktyce jako skuteczne narzędzie analiz tego typu danych. Stworzona baza reguł preferencji zakupowych kobiet i mężczyzn może stanowić bazę wiedzy dla firm produkujących sprzęt AGD i może być wskazówką na co zwracają uwagę te dwie grupy konsumentów podczas dokonywania zakupu produkowanych przez te firmy urządzeń.

Examining Male and Female Purchase Preferences by Means of the Rough Sets Method

Summary

The paper presents a non-standard way of conducting research on male and female purchase preferences. The main emphasis is put on the method, which was used in the research – the rough

set theory. This method was applied to identify rules of male and female behaviour while buying electrical appliances.

Key words: consumer behaviour, preferences, rough set theory, data mining.

Изучение предпочтений в отношении покупок у женщин и мужчин по методу приближенных совокупностей

Резюме

В статье представлен нестандартный способ изучения предпочтений женщин и мужчин в отношении покупок. Основной упор сделали на представлении метода, который был использован в проведенном изучении. Теория приближенных совокупностей была применена для выявления правил поведения женщин и мужчин, покупающих предметы бытовой техники.

Ключевые слова: потребительское поведение, изучение предпочтений, приближенные совокупности, выявление знаний.