

Wykorzystanie algorytmu k -prototypów w segmentacji klientów przedsiębiorstwa w marketingu wielopoziomym

Łukasz Sroka^a

Streszczenie. Segmentacja klientów odgrywa istotną rolę w przygotowaniu strategii marketingowej przedsiębiorstwa. Zróżnicowanie nabywców pod względem ich cech i zachowań oraz zrozumienie tego, jak kształtują się ich preferencje i potrzeby, jest kluczowe dla określenia efektywnych narzędzi marketingowych. Celem artykułu jest przedstawienie możliwości wykorzystania metody k -prototypów w procesie segmentacji klientów. W badaniu za pomocą tego algorytmu uczenia maszynowego wyróżniono klastry oraz przeprowadzono analizę statystyczną powstałych grup. Posłużono się danymi sprzedażowymi za okres od września do października 2020 r., które uzyskano z przedsiębiorstwa handlowego działającego w systemie marketingu wielopoziomowego (MLM). Dokonano podziału na sześć segmentów, znacznie różniących się między sobą pod względem cech charakterystycznych dla klientów przedsiębiorstwa MLM.

Algorytm k -prototypów jako metoda segmentacyjna zadowalająco przetworzył dane zarówno numeryczne, jak i kategoryjne i w ten sposób umożliwił wyznaczenie klastrów. Otrzymane wyniki pozwoliły stwierdzić, że w badanym przedsiębiorstwie występują grupy klientów nastawionych na maksymalizację korzyści wskazanych jako cel działalności w planie marketingowym, niezdecydowanych co do dalszego trwania w strukturach tej jednostki oraz niewiązanych swojej przyszłości z przedsiębiorstwem.

Słowa kluczowe: segmentacja, metoda k -prototypów, marketing wielopoziomowy, MLM

JEL: C38, C19, D12

The use of the k -prototypes method in the segmentation of customers of a company in the Multi-Level Marketing

Abstract. Segmentation of clients plays an important role in designing a company's marketing strategy. Differentiating between groups of customers in terms of their characteristics and behaviours, and understanding how customer preferences and needs are shaped, is key to determining effective marketing tools. The aim of the paper is to present the potential of the k -prototypes method in the customer segmentation process. In the study, conducted according to the above-mentioned type of machine learning algorithm, clusters were extracted and the statistical analysis of the groups thus obtained was carried out, using sales data of a trading company operating in the Multi-Level Marketing (MLM) system for the period from September to October 2020. As a result, the company's customers were divided into six segments, significantly different from each other in terms of features characteristic for clients of an MLM enterprise.

^a Uniwersytet Ekonomiczny w Katowicach, Wydział Statystyki, Ekonometrii i Matematyki, Polska / University of Economics in Katowice, Faculty of Statistics, Econometrics and Mathematics, Poland.
ORCID: <https://orcid.org/0000-0001-5721-2475>. E-mail: lukasz.sroka@edu.uekat.pl.

The k -prototypes algorithm, adopted here as a segmentation method, satisfactorily processed both numerical and categorical data, and made it possible to identify the clusters. The results obtained by means of this method demonstrated that there are groups of clients of the examined company which focused on maximizing the benefits indicated in the marketing plan as the aim of the company's operations, customers undecided as to whether to continue in the entity's structure, and customers who did not plan to associate their future with the examined company.

Keywords: segmentation, k -prototypes method, Multi-Level Marketing, MLM

1. Wprowadzenie

Przedsiębiorstwa decydują się na stosowanie strategii segmentacji w celu prowadzenia polityki sprzedażowej jak najlepiej dopasowanej do różnych typów odbiorców. Menedżerowie zdają sobie sprawę, że dobrze dopasowana akcja marketingowa odgrywa znaczącą rolę w kształtowaniu wyniku finansowego jednostki gospodarczej. Wiedza na temat klientów pozwala na wytypowanie grup najlepszych pod względem opłacalności (czyli takich, które dokonują częstych zakupów o wysokiej wartości), a zwiększenie aktywizacji grup opłacalnych finansowo może przynieść znaczny wzrost przychodów przedsiębiorstwa (Rószkiewicz, 2002).

Nabywcy mają określone preferencje i wzorce zachowań w stosunku do różnych produktów. Ze względu na te cechy można – za pomocą dostępnych metod badawczych – podzielić ich na segmenty. Prawidłowe ustalenie profilu danej grupy klientów stanowi ważny element w planowaniu działań marketingowych, zwłaszcza dotyczących marketingu bezpośredniego (Angowski i in., 2017). Marketing bezpośredni opiera się na budowaniu długotrwałej, indywidualnej i obopólnie korzystnej więzi z klientem, do czego wykorzystywane są bazy danych z cechami nabywców (Retzler, 1988). Uczestnikami marketingu bezpośredniego są klienci odpowiednio wyselekcjonowani przez przedsiębiorstwo, a celem oddziaływania na nabywcę jest uzyskanie bezpośredniej pozytywnej reakcji przejawiającej się powstaniem relacji między przedsiębiorstwem a klientem.

Niniejszy artykuł skupia się na problemie analizy wzorców zachowań klientów przedsiębiorstwa prowadzącego marketing wielopoziomowy (ang. *multi-level marketing* – MLM). Mimo że zagadnienie segmentacji klientów jest ważne dla różnego typu przedsiębiorstw, w jednostkach MLM segmentacja odgrywa szczególną rolę ze względu na relację między przedsiębiorstwem a klientem. Ponadto w przedsiębiorstwach MLM analizuje się nie tylko wartość zakupionych produktów; istotne są również dane o liczbie nowych klientów, a także informacje, od jak dawna dany klient znajduje się w strukturach MLM. Dodatkową różnicą między klientami przedsiębiorstw niedziałających w MLM a klientami przedsiębiorstw MLM jest to, że klienci przedsiębiorstwa MLM mogą otrzymywać dodatkowe bonusy w postaci go-

tówkowej bądź rabatów na produkty. Bonusy te są przyznawane za dokonane zakupy oraz rekrutację nowych klientów. Wszystkie dodatkowe bonusy oferowane przez przedsiębiorstwo MLM określa plan marketingowy.

Mimo szczególnej relacji z klientami jednostki MLM, tak samo jak pozostałe przedsiębiorstwa, potrzebują dokładnych informacji na temat odbiorców swoich produktów, a podział klientów na grupy znacznie ułatwia przygotowanie odpowiednich działań promocyjnych.

Celem artykułu jest przedstawienie możliwości wykorzystania metody k -prototypów w procesie segmentacji klientów przedsiębiorstwa. Dodatkowo zaproponowano narzędzia marketingowe odpowiednie dla danego segmentu klientów, takie jak akcje aktywacyjne czy akcje związane z udzielaniem rabatów na produkty. Narzędzia te mogą posłużyć przedsiębiorstwu do bezpośredniego oddziaływania na każdą z wyróżnionych grup klientów.

2. Zastosowanie segmentacji w marketingu sieciowym

Temat segmentacji klientów przedsiębiorstwa MLM nie jest nowym zagadnieniem. Mimo to w literaturze, zarówno światowej, jak i polskiej, występuje niewiele prac, które podejmują problem grupowania z wykorzystaniem algorytmów uczenia maszynowego.

Za twórcę segmentacji (klasteryzacji) uznaje się Wendella R. Smitha, który twierdził, że dzięki grupowaniu klientów przedsiębiorstwo jest w stanie racjonalnie i precyzyjnie dostosowywać swoje produkty oraz działania marketingowe do wymogów konsumentów (Rószkiewicz, 2002). Głównym celem segmentacji jest podział klientów na kilka jednorodnych grup o zbliżonych preferencjach i potrzebach (Wedel i Kamakura, 2002). Aby strategia segmentacyjna była adekwatna do potrzeb, przedsiębiorstwo powinno odpowiedzieć sobie na następujące pytania (Duliniec, 1994, s. 54–55):

- czy potrzeby klientów przedsiębiorstwa są zróżnicowane?
- czy przedsiębiorstwo oferuje specyficzne produkty ściśle określonym klientom?
- czy istnieje możliwość rozróżnienia klientów pod względem ich wartości dla przedsiębiorstwa?
- czy w przeprowadzonej segmentacji wyróżniono grupę klientów, która zapewnia dochodowość przedsiębiorstwa i do której można dotrzeć z gwarancją pozytywnej reakcji na działanie przedsiębiorstwa?

W literaturze przedmiotu wskazuje się wiele zalet klasteryzacji. Należą do nich przede wszystkim efektywniejsze oddziaływanie przez przedsiębiorstwo na mniejsze grupy klientów, możliwość pomiaru wielkości oraz siły nabywczej danej grupy, a także łatwiejsza komunikacja poprzez dostosowanie wiadomości do cech odbior-

ców z danego klastra (Angowski i in., 2017). Ponadto analiza segmentacyjna pozwala na uzyskanie informacji o różnicach istniejących między nabywcami w odniesieniu do motywów podejmowanych decyzji zakupowych (Żakowska-Biemans i in., 2013).

W badaniach dotyczących jednostek MLM analizie poddaje się nabywców, którzy prowadzą własną działalność gospodarczą, dlatego odpowiednie określenie założeń ma kluczowe znaczenie dla przygotowania prawidłowej strategii. Ponadto strategia segmentacyjna powinna być bezpośrednio powiązana z celem jednostki gospodarczej. Ze względu na trudności z wyborem właściwej metody oraz problemy z danymi ważne jest, aby cechy wybrane do opisu segmentów we właściwy sposób charakteryzowały badaną grupę (Kauf, 2014).

W literaturze dotyczącej zagadnień segmentacji podaje się wiele kryteriów grupowania, takich jak: lokalizacja, demografia, aspekty społeczno-ekonomiczne, podejście konsumenta do produktu oraz zachowanie klienta (Verani i in., 2012). W przypadku problematyki omawianej w niniejszym artykule przedmiotem analizy są klienci uczestniczący w marketingu sieciowym, dlatego główne kryteria segmentacyjne są nieco inne niż w przedsiębiorstwach zajmujących się wyłącznie sprzedażą. Wiąże się to z tym, że w MLM zarobki uczestników zależą od obowiązującego planu marketingowego (Gregor i Wadlewski, 2014).

Strategia dystrybucyjna w MLM polega na prowadzeniu przez uczestnika sprzedaży osobistej przy wykorzystaniu sieci własnych kontaktów. Im bardziej sieć się rozrasta, tym większe korzyści z planu marketingowego otrzymuje klient. Nowi klienci, zrekrutowani przez danego uczestnika sprzedaży osobistej, stanowią grupę zwaną strukturą partnerską. Zwiększanie się bazy klientów przedsiębiorstwa pozytywnie wpływa na sprzedaż produktów. Oznacza to, że im więcej jest aktywnych struktur posiadanych przez przedsiębiorstwo, tym szybciej następuje jego rozwój (Wadlewski i Modliński, 2016). Taki model biznesowy powoduje, że jednostka zwraca uwagę nie tylko na to, ile pieniędzy dany klient przeznacza na zakup produktów, lecz także na to, jak dany uczestnik rozwija swoją strukturę.

Poznanie charakterystyki grup pozwala na przygotowanie odpowiednich strategii marketingowych oraz narzędzi sprzedażowych w celu efektywnego oddziaływania na klienta.

3. Metoda badania

W celu sprawdzenia przydatności algorytmu k -prototypów w procesie segmentacji klientów przedsiębiorstwa MLM przeanalizowano zbiór danych za okres od września do października 2020 r. uzyskany od jednostki działającej w systemie MLM¹.

¹ Ze względu na to, że przedsiębiorstwo nie wyraziło zgody na publikację swojej nazwy ani informacji wrażliwych, niektóre dane zostały zanonimizowane.

Zbiór otrzymany od badanej jednostki zawierał dane 18 503 klientów i składał się z następujących cech:

- numeru klienta;
- stażu działania w strukturach MLM (w miesiącach);
- liczby zamówień klienta;
- średniej wartości zakupionych produktów;
- średniej liczby zakupionych produktów;
- średniej miesięcznej liczby nowych klientów w strukturze;
- najczęściej kupowanego produktu;
- drugiego najczęściej kupowanego produktu.

Jednostka, od której uzyskano dane, jest przedsiębiorstwem handlowym zajmującym się sprzedażą suplementów diety oraz kosmetyków na polskim rynku. W jej portfolio znajduje się ponad 200 produktów zarówno dla kobiet, jak i mężczyzn. Przedsiębiorstwo działa ponad 15 lat. W swoim planie marketingowym przykładą wagę do budowy i utrzymania struktur sprzedażowych stworzonych przez uczestników MLM – prowadzi akcje rekrutacyjne oraz oferuje dodatkowe bonusy dla najlepszych sponsorów (osób, które w danym okresie pozyskały największą liczbę klientów). Ponadto specyfika rynku, na którym działa badane przedsiębiorstwo, polegająca na dużej konkurencji cenowej wymaga przygotowywania comiesięcznych specjalnych akcji promocyjnych: okresowej obniżki ceny produktów w celu pobudzenia sprzedaży detalicznej.

W procesie segmentacyjnym coraz częściej wykorzystuje się algorytmy uczenia maszynowego, a dokładniej – algorytmy uczenia nienadzorowanego. Do najczęściej stosowanych można zaliczyć metodę k -średnich (Boschetti i Massaron, 2017). Rozszerzeniem tego algorytmu są dwie inne metody: k -modes oraz k -prototypów. Różnica w zastosowaniu tych algorytmów jest następująca: algorytm k -średnich umożliwia grupowanie wyłącznie danych numerycznych, algorytm k -modes pozwala grupować wyłącznie zmienne kategoryjne, a algorytm k -prototypów pozwala na grupowanie zarówno zmiennych numerycznych, jak i kategoryjnych (Hong-Jun i in., 2018; Huang, 1998).

Algorytm k -prototypów należy do algorytmów iteracyjno-optymalizacyjnych ze względu na sposób działania – w czasie iteracji dokonywana jest optymalizacja uzyskanych wyników, przedstawionych jako odległość względem wszystkich obserwacji danej grupy (Amymen Ben Haj Kacem i in., 2015).

Przyjmujemy, że zbiór danych X zawiera zestaw n obiektów opisany przez m_r zmiennych numerycznych oraz m_c zmiennych kategoryjnych. Celem algorytmu k -prototypów jest znalezienie k grup, w przypadku których poniższa funkcja celu jest minimalizowana:

$$J = \sum_{j=1}^k \sum_{i=1}^n p_{ij} d(x_i Q_j),$$

gdzie:

$p_{ij} \in \{0,1\}$ – zmienna binarna określająca przynależność zmiennej j , która przyjmuje wartość 1, gdy należy do danego segmentu, natomiast 0 – gdy do niego nie należy,

Q_j – prototyp (reprezentant danej grupy obserwacji) klastra j ,

$d(x_i, Q_j)$ – miara niepodobieństwa zdefiniowana jako

$$d(x_i, Q_j) = \sum_{r=1}^m (x_{ir} - q_{jr})^2 + \gamma_j \sum_{c=1}^m \delta(x_{ic}, q_{jc}),$$

gdzie:

x_{ir} – wartość zmiennej numerycznej dla każdego obiektu x_i ,

x_{ic} – wartość zmiennej kategoryjnej dla każdego obiektu x_i .

Dla wartości centralnej klastra j q_{jr} jest średnią dla zmiennej numerycznej r i klastra j , a q_{jc} jest wartością najczęstszą (modą) dla zmiennej kategoryjnej c i klastra j . Ponieważ algorytm k -prototypów na zmiennych kategoryjnych wykorzystuje miary odmienności, wyłącznie jedna, najczęstsza wartość może należeć do danego klastra. W przypadku zmiennych kategoryjnych $\delta(p,q) = 0$ dla $p = q$ i $\delta(p,q) = 1$ dla $p \neq q$. γ_j jest wagą zmiennych kategoryjnych dla klastra (Amymen Ben Haj Kacem i in., 2015).

Utrudnieniem przy korzystaniu z metody k -prototypów jest konieczność określenia optymalnej liczby segmentów dla danego zbioru danych. Do najczęściej stosowanych metod określania liczby skupień należy metoda łokcia (ang. *elbow method*), wykorzystująca wewnątrzgrupową sumę kwadratów błędów (zniekształcenia). Pozwala ona znaleźć taką liczbę segmentów, dla której wewnątrzgrupowa suma kwadratów błędów przestaje gwałtownie maleć, a dodanie kolejnego segmentu nie wprowadza dużej poprawy zniekształcenia (Raschka i Mirjalili, 2019, s. 327–330).

Dodatkową wadą metody k -prototypów jest to, że każda grupa ma podobną liczbę obserwacji. Problem ten wynika ze sposobu, w jaki działa algorytm, oraz z jego bazowych założeń (Grzyb, 2019). Metoda ta jest również bardzo wrażliwa na dobór punktów startowych, wybieranych losowo przy pierwszej iteracji, oraz na dane odstające. Dane odstające w modelu mają istotny wpływ na wyznaczanie segmentów, ponieważ przy ustalaniu grup algorytm określa średnią wartość dla wszystkich obserwacji w klastrze. Aby przeciwdziałać zaburzeniom działania modelu, usuwa się odstające zmienne (Grzyb, 2019).

W badaniu omawianym w niniejszym artykule procedura badawcza segmentacji składała się z pięciu etapów:

1. Dane otrzymane od przedsiębiorstwa poddano analizie statystycznej w celu określenia, które z otrzymanych zmiennych powinny zostać dodane do modelu.
2. Aby ograniczyć wpływ danych odstających na działanie algorytmu, dane numeryczne zlogarytmowano i usunięto dane odstające, posługując się regułą 1.5 IQR (ang. *interquartile range*).
3. Po zredukowaniu skośności danych oraz usunięciu wartości odstających zmienne numeryczne poddano standaryzacji.
4. Przy użyciu metody łokcia określono liczbę segmentów.
5. Dane poddano segmentacji za pomocą algorytmu k -prototypów.

Do przeprowadzenia badania wykorzystano program Python wraz z następującymi bibliotekami: Pandas, Numpy, Matplotlib, Seaborn, Kmodes i Sklearn.

4. Wyniki badania

Jak wskazano w części poświęconej metodzie badania, algorytm k -prototypów wyznacza segmenty na podstawie zmiennych zarówno numerycznych, jak i kategoryjnych. Tablica 1 przedstawia współczynniki korelacji rang Spearmana dla danych numerycznych. Analiza wykazała silny związek między średnią wartością a średnią liczbą zakupionych produktów. Aby nie komplikować modelu, usunięto zmienną dotyczącą liczby zakupionych produktów.

Tabl. 1. Współczynnik korelacji rang Spearmana dla analizowanych cech klientów


Cechy klientów	<i>SP</i>	<i>LZ</i>	<i>LZP</i>	<i>WZP</i>	<i>LNK</i>
<i>SP</i>	1
<i>LZ</i>	0,021***	1	.	.	.
<i>LZP</i>	-0,159***	0,279***	1	.	.
<i>WZP</i>	-0,089***	0,256***	0,880***	1	.
<i>LNK</i>	0,113***	0,436***	0,167***	0,133***	1

Uwaga. *** – $p < 0,05$. *SP* – staż pracy, *LZ* – liczba zamówień, *LZP* – liczba zakupionych produktów, *WZP* – wartość zakupionych produktów, *LNK* – liczba nowych klientów.

Źródło: opracowanie własne na podstawie danych uzyskanych z przedsiębiorstwa MLM.

Wykres przedstawia wewnątrzgrupową sumę kwadratów błędów, zwaną zniekształceniem. Analiza wykazała, że zniekształcenie zaczyna znacząco spadać przy sześciu segmentach.

Wykres zniekształcenia w zależności od liczby segmentów



Źródło: opracowanie własne na podstawie danych uzyskanych z przedsiębiorstwa MLM.

W tablicach 2–4 zebrano wyniki analizy statystycznej każdego z sześciu segmentów. Ze względu na to, że dane wykorzystane w badaniu są danymi rzeczywistymi, nazwy produktów zastąpiono literami. W przypadku gdy w danym segmencie zarówno pierwszy, jak i drugi najczęściej kupowany produkt był taki sam, do dalszej analizy brano kolejny produkt z listy.

Tabl. 2. Wartości cech klientów

Segmenty	Liczba nowych klientów	Wartość zakupów w zł	Staż w miesiącach	Liczba zamówień
Średnia arytmetyczna				
1	0,21	833,19	38,81	1,54
2	0,36	576,01	3,94	1,01
3	1,27	846,60	4,55	2,60
4	0,34	325,80	11,98	2,40
5	0,44	239,16	27,19	1,03
6	7,07	626,35	33,23	2,69
Minimum				
1	0	254,08	6	1
2	0	158,36	1	1
3	0	226,03	1	2
4	0	73,51	2	2
5	0	72,54	5	1
6	1	188,28	4	2

Tabl. 2. Wartości cech klientów (dok.)

Segmenty	Liczba nowych klientów	Wartość zakupów w zł	Staż w miesiącach	Liczba zamówień
Maksimum				
1	1	2799,75	251	1
2	2	2362,50	14	2
3	9	2797,84	22	3
4	4	424,51	115	3
5	3	310,52	249	2
6	27	2663,86	245	3
Odchylenie standardowe				
1	0,53	410,18	25,90	0,68
2	0,45	282,16	2,46	0,04
3	0,68	390,35	2,98	0,49
4	0,77	118,11	11,79	0,48
5	1,06	92,09	22,84	0,17
6	3,05	385,13	23,05	0,56

Źródło: opracowanie własne na podstawie danych uzyskanych z przedsiębiorstwa MLM.

Tabl. 3. Produkty najczęściej kupowane

Segmenty	Produkt	
	najczęściej kupowany	drugi najczęściej kupowany
1	A	B
2	A	C
3	A	B
4	B	A
5	A	brak
6	A	B

Źródło: opracowanie własne na podstawie danych uzyskanych z przedsiębiorstwa MLM.

W tabl. 4 zamieszczono informacje o rozłożeniu liczby klientów w każdym z segmentów.

Tabl. 4. Liczebność segmentów oraz udział danego klastra w całkowitej liczbie klientów

Segmenty	Liczba klientów	Udział w całkowitej liczbie klientów w %
1	2710	15,08
2	3023	16,82
3	2946	16,39
4	2887	16,06
5	3411	18,98
6	2995	16,66

Źródło: opracowanie własne na podstawie danych uzyskanych z przedsiębiorstwa MLM.

Segment 5 obejmuje ok. 19% wszystkich klientów, a każdy z pozostałych segmentów – od ok. 15% do ok. 17%.

Na podstawie otrzymanych wyników zidentyfikowano profile klientów z każdego segmentu. Segment 1 – starzy wyjadacze – składa się z klientów, którzy cechują się najdłuższym średnim stażem współpracy z przedsiębiorstwem oraz wysokimi średnimi wydatkami na zakupy, pomimo że nie robią ich regularnie. Klienci z tego segmentu nie są zainteresowani budowaniem struktur i rekrutacją nowych klientów ani udziałem w planie marketingowym. Może to wynikać z ich nastawienia wyłącznie na konsumpcję. Kupują produkty, ponieważ mają satysfakcję z ich użytkowania. W tym segmencie kupowane są przede wszystkim produkty najlepiej się sprzedające: A i B. Głównymi metodami marketingowymi, jakie można zastosować w przypadku tej grupy konsumentów, mogą być specjalne promocje (obniżki cen, rabaty na produkty inne niż dwa kluczowe jako zachęta do spróbowania czegoś nowego), a także akcje mające na celu zwiększenie aktywizacji klientów. Programy zachęcające do zwiększonej rekrutacji nowych klientów można w przypadku tej grupy uznać za mało skuteczne.

Segment 2 – młodzi niezdecydowani – to klienci, którzy dopiero rozpoczęli działalność w MLM. Rekrutują niewielu nowych klientów. Analizując średnią liczbę zamówień, można zauważyć, że nie są oni przekonani co do dalszej współpracy z jednostką, mimo że dokonują zakupów o wysokiej średniej wartości. Bardzo możliwe, że z czasem klienci z tego segmentu przekształcą się w konsumentów z segmentu 1. Segment 2 preferuje inną kombinację produktów niż większość grup: A i C. W przypadku tego typu klientów głównymi narzędziami marketingowymi powinny być akcje ukierunkowane na aktywizację nabywców oraz na prezentację zalet programu marketingowego. Bez odpowiedniego nakierowania klienci z tego segmentu opuszczą strukturę przedsiębiorstwa.

Segment 3 – młode gwiazdy – podobnie jak segment 2 składa się z klientów, których średni staż w strukturach MLM jest krótki, ale którzy średnio składają najwięcej zamówień. Dodatkowo robią zakupy o wysokiej średniej wartości oraz są zainteresowani rekrutacją nowych klientów. Mimo niewielkiego stażu mają już średnio po jednym nowym kliencie. Podstawowym koszykiem produktów w tym segmencie są produkty A i B. Głównym zadaniem z punktu widzenia interesu przedsiębiorstwa jest nie stracić klientów z tego klastra i zachęcić ich do dalszej aktywności. W tym celu można zastosować zarówno promocje, jak i akcje nagradzające rekrutację.

Segment 4 – klienci detaliczni – stanowią osoby, które działają w MLM już od pewnego czasu i bardzo często robią zakupy, ale nie wydają dużych kwot i nie są zainteresowani pozyskiwaniem nowych klientów. Interesują się przede wszystkim produktami A i B. Narzędzia marketingowe, jakie mogą być zastosowane w ich przypadku, to promocje produktowe w celu zachęcenia do większych zakupów.

Segment 5 – znudzeni – charakteryzuje się bardzo małą średnią liczbą zamówień oraz niską średnią wartością zakupionych produktów. Znajdują się w nim klienci o dłuższym stażu, którzy rzadko składają zamówienia i nie są zainteresowani rozwojem swoich struktur partnerskich. Jako jedyny klastr nie mają drugiego najczęściej kupowanego produktu poza produktem A. Aby zachęcić klientów z tej grupy do większej aktywności, przedsiębiorstwo powinno zastosować promocje oraz akcje aktywacyjne.

Segment 6 – sponsorzy – cechuje się zdecydowanie największą średnią liczbą nowych klientów oraz największą średnią liczbą dokonywanych zamówień. Znajdują się w nim klienci z długim stażem, którzy chętnie dokonują zakupów o dużej wartości. Liczba rekrutacji może wskazywać na to, że klienci z tego klastra są zainteresowani realizacją planu marketingowego i osiąganiem z niego korzyści. Koszyk najczęściej kupowanych produktów jest standardowy: A i B. Klienci z tej grupy są ważni z punktu widzenia MLM, ponieważ dzięki nim rozwija się cała struktura. Nie potrzebują szczególnych zachęt. Zadaniem przedsiębiorstwa jest utrzymanie ich aktywności zakupowej i rekrutacyjnej na jak najwyższym poziomie; dobrymi narzędziami mogą być akcje rekrutacyjne.

5. Podsumowanie

Segmentacja klientów pod względem wybranych cech jest bardzo pomocna przy podejmowaniu decyzji marketingowych przez przedsiębiorstwa. Podział klientów na klastry pozwala na zastosowanie narzędzi, które będą efektywnie oddziaływać na potrzeby klienta. W artykule wykazano, że algorytm k -prototypów jako metoda segmentacji zadowalająco przetwarza zarówno dane numeryczne, jak i kategoryjne.

Podział danych na segmenty za pomocą algorytmu pozwolił na wyodrębnienie grup różniących się pod kątem analizowanych cech. Otrzymane wyniki zgadzają się z zaprezentowaną teorią dotyczącą metody k -prototypów. Algorytm podzielił klientów na grupy o niemalże równej liczbie. Klastry te, mimo podobnych rozmiarów, charakteryzują się odmiennymi cechami. Ponadto istnieje możliwość wyróżnienia grup klientów, którzy mogą być dla przedsiębiorstwa bardziej dochodowi (młode gwiazdy, klienci detaliczni, starzy wyjadacze) oraz takich, których należy bardziej zaktywizować (młodzi niezdecydowani, znudzeni).

Algorytm k -prototypów może być również narzędziem uzupełniającym metody segmentacji rynku, które wykorzystują klasyczne kryteria, takie jak demografia czy uwarunkowania społeczno-ekonomiczne.

Należy jednak pamiętać o ograniczeniach metody k -prototypów, do których należą konieczność samodzielnego wyboru liczby segmentów oraz podział danych na w miarę równe segmenty (w przypadku nadreprezentacji w danych jednego z profi-

łów klientów algorytm dzieli dane na równe grupy, nie uwzględniając tego, że jedna grupa powinna być znacznie większa). Kolejne badania w zakresie wykorzystania tej metody mogą dotyczyć zarówno ominięcia powyższych ograniczeń, jak i zastosowania algorytmu w segmentacji wieloetapowej, polegającej na przeprowadzeniu grupowania wcześniej otrzymanego segmentu.

Badanie może stanowić punkt wyjścia do prowadzenia dalszych, bardziej pogłębionych analiz w celu znalezienia efektywniejszych kryteriów segmentacji klientów przedsiębiorstw MLM.

Bibliografia

- Amymen Ben Haj Kacem, M., Ben N'cir, C., Essoussi, N. (2015). Parallel K-prototypes for clustering Big Data. W: M. Núñez, N. Thanh Nguyen, D. Camacho, B. Trawiński (red.), *Computational Collective Intelligence* (s. 629–632). Madrid: Springer.
- Angowski, M., Domańska, K., Kijek, T. (2017). Zastosowanie metod K-średnich w segmentacji nabywców na rynku produktów spożywczych. *Metody Ilościowe w Badaniach Ekonomicznych*, 18(4), 521–530.
- Boschetti, A., Massaron, L. (2017). *Python. Podstawy nauki o danych*. Gliwice: Helion.
- Duliniec, E. (1994). *Badania marketingowe w zarządzaniu przedsiębiorstwem*. Warszawa: Wydawnictwo Naukowe PWN.
- Gregor, B., Wadlewski, A. (2014). Multi Level Marketing jako model biznesu. *Marketing i Rynek*, 3, 15–31.
- Grzyb, M. (2019, 17 lipca). *K-prototypów – grupowanie zmiennych kategorycznych i ciągłych*. <https://mateuszgrzyb.pl/k-prototypow-grupowanie-zmiennych-kategorycznych-i-ciaglych>.
- Hong-Jun, J., Byoungwook, K., Jongwang, K., Soon-Young, J. (2018). An efficient grid-based k-prototypes algorithm for sustainable decision-making on spatial objects. *Sustainability*, 10(8), 1–20. <https://doi.org/10.3390/su10082614>.
- Huang, Z. (1998). Extensions to the k-Means Algorithm for Clustering Large Data Sets with Categorical Values. *Data Mining and Knowledge Discovery*, 2(3), 283–304. <https://doi.org/10.1023/A:1009769707641>.
- Kauf, S. (2014). Wykorzystanie metody taksonomii wrocławskiej w segmentacji rynku. W: E. Gatnar, G. Maciejewski (red.), *Metody ilościowe w badaniach marketingowych* (s. 65–79). Katowice: Wydawnictwo Uniwersytetu Ekonomicznego w Katowicach.
- Raschka, S., Mirjalili, V. (2019). *Python. Uczenie maszynowe*. Gliwice: Helion.
- Retzler, K. (1988). *Direct Marketing: The Proven Path to Successful Sales*. Glenview: Scott, Foresman and Company.
- Rószkiewicz, M. (2002). *Metody ilościowe w badaniach marketingowych*. Warszawa: Wydawnictwo Naukowe PWN.
- Verani, M., Bartels, J., Dagevos, H., Sijtsema, S., Onwezen, M., Antonides, G. (2012). Segments of Sustainable Food Consumers: A Literature Review. *International Journal of Consumer Studies*, 36(2), 123–132.

- Wadlewski, A. A., Modliński, A. (2016). Strategia rozwoju sieci dystrybucji firmy MLM. Przykład matrycowego planu kompensacyjnego. W: A. A. Wadlewski, A. Modliński (red.), *Innowacyjne działania w obszarze zarządzania i marketingu* (s. 133–142). Łódź: Wydawnictwo Uniwersytetu Łódzkiego. https://www.nist.gov.pl/files/zalacznik/1461863038_Wadlewski_Innowacyjno%C5%9B%C4%87.pdf.
- Wedel, M., Kamakura, W. A. (2002). Introduction to the special issue on market segmentation. *International Journal of Research in Marketing*, 19(3), 181–183.
- Żakowska-Biemans, S., Gutkowska, K., Sajdakowska, M. (2013). Segmentacja konsumentów z uwzględnieniem skłonności do zaakceptowania innowacji w produktach żywnościowych pochodzenia zwierzęcego. *Handel Wewnętrzny*, (4), 141–154.