

---

## Wykorzystanie zbiorów przybliżonych w analizie Kansei

### **Bohdan Ludwiszewski**

Politechnika Gdańska  
Wydział Zarządzania i Ekonomii  
ul. Narutowicza 11/12  
80-233, Gdańsk

### **Krzysztof Redlarski**

Politechnika Gdańska  
Wydział Zarządzania i Ekonomii  
ul. Narutowicza 11/12  
80-233, Gdańsk

### **Jacek Wachowicz**

Politechnika Gdańska  
Wydział Zarządzania i Ekonomii  
ul. Narutowicza 11/12  
80-233, Gdańsk  
jwach@zie.pg.gda.pl

### **Abstrakt**

W artykule przedstawiono podstawowe założenia metody *Rough Set Analysis*. Dzięki możliwości zapisywania atrybutów w postaci deskryptywnej doskonale nadaje się ona do wyodrębniania zależności pomiędzy obserwacjami odczuć. Predestynuje to metodę *Rough Set Analysis*, jako jedną z miękkich metod, dla wykorzystania w analizie *Kansei*.

### **Słowa kluczowe**

Kansei, projektowanie, interfejs użytkownika, Rough Set Analysis

### **Wstęp**

Analiza Kansei odwołuje się do emocji, które z natury są trudne do obiektywnej obserwacji. Nie można ich bezpośrednio zmierzyć, co powoduje, że dla prowadzenia badań Kansei naturalnym wydaje się poszukiwanie alternatywnych metod badawczych, tzw. miękkich. Postulują one, by w odróżnieniu od klasycznych metod wnioskowania, badane wartości nie musiały być bardzo jednoznaczne. Przykładowo, kiedy ludzie mówią o osobie wysokiej, każdy wie co to oznacza. Nie można jednak dokładnie podać granicznego wzrostu, powyżej którego osoba jest uważana za wysoką, a poniżej – za niską. Pewną nieokreśloność danych pozwalają właśnie wprowadzić

metody miękkie, wśród których możemy znaleźć sieci neuronowe, logikę rozmytą, czy zbiory przybliżone.

Idea zbiorów przybliżonych (ang. Rough Sets) opiera się na tak zwanej funkcji przynależności. Nieco upraszczając całą teorię możemy przyjąć, że posiadamy pewne atrybuty wejściowe i związane z nimi w pewien sposób atrybuty wyjściowe. Nawet jeżeli nie wiemy, w jaki sposób są one ze sobą związane – możemy przedstawić je jako dwuwymiarową tablicę, w której kolumny będą związane ze zmiennymi wejściowymi oraz wyjściowymi, wiersze zaś będą reprezentować obserwowane przypadki. W tak przedstawionej tabeli dla dowolnego stanu wyjściowego możemy zidentyfikować trzy rodzaje pól w kolumnach wyjściowych – te, dla których system daje odpowiedź jednoznacznie pozytywną, te dla których system daje odpowiedź jednoznacznie negatywną oraz te, dla których system daje odpowiedź niejednoznaczną.

Zbiory przybliżone są sformalizowaną teorią wyodrębniającą wcześniej przytoczone obszary przy pomocy tzw. funkcji przynależności (związanej bezpośrednio z danymi dostarczonymi systemowi). Największym problemem związanym z wykorzystaniem metody jest określenie sposobu konstruowania funkcji przynależności – oraz późniejszego jej testowania. W praktycznych zastosowaniach funkcja przynależności jest konstruowana w oparciu o część obserwowanych przypadków, a następnie jej jakość jest określana na pozostałej części zaobserwowanych przypadków. Weryfikacja ta ma na celu określenie jakości skonstruowanej funkcji przynależności.

Jeżeli okaże się ona dobra, wówczas może ona zostać wykorzystana jako narzędzie do predykcji atrybutów

wyjściowych na podstawie wartości atrybutów wejściowych.

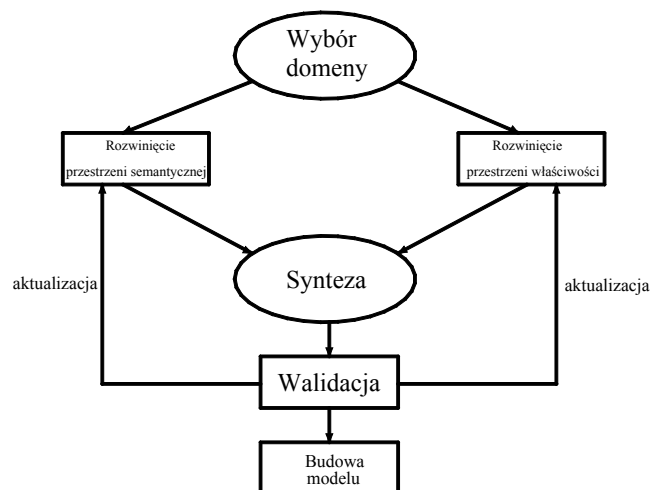
Dzięki możliwości zapisywania atrybutów w postaci deskryptywnej metoda Rough Sets doskonale nadaje się do wyodrębniania zależności pomiędzy obserwacjami odczuć.

Celem niniejszego artykułu jest przedstawienie możliwości wykorzystania metody analizy Rough Sets w Kansei Engineering.

### **Zastosowanie algorytmów analitycznych w procesie Kansei Engineering**

Szczególnie istotnym elementem procesu Kansei Engineering jest etap syntezy, w którym następuje próba połączenia własności technicznych projektowanych obiektów z przestrzenią semantyczną [17] – co zostało zilustrowane na rysunku 1. Na etapie tym wykorzystuje się różnorodne matematyczne i niematematyczne statystyczne algorytmy obliczeniowe. Do najczęściej stosowanych zalicza się:

- Linear regression [2]
- General Linear Model (GLM) [3]
- QT1 [4]
- Neural Networks [5]
- Genetic Algorithm [6]
- Rough Set Analysis [7]



Rys. 1. Proces Kansei Engineering. Źródło: Schütte 2002, Schütte, Eklund, 2003

Zbiory przybliżone służą do przetwarzania danych o nieostrym charakterze z wykorzystaniem intuicyjnie rozumianych reguł wnioskowania. Są możliwe do zastosowania dla poszukiwania ukrytych zależności w danych wejściowych, w tym do wspomaganie decyzji w zakresie przypadków mogących zostać opisanych za pomocą dyskretnych atrybutów.

### Pojęcie zbiorów przybliżonych – Rough Sets

Zbiory przybliżone (Rough Sets) i ich teoria zostały rozwinięte na początku lat osiemdziesiątych przez Z. Pawlaka i jego współpracowników jako metoda radzenia sobie z niekompletnymi zbiorami informacji. Zostały one dogłębnie opisane w monografiach.

Zbiory przybliżone są zbiorami określonymi na przestrzeni podzielonej w sposób dyskretny. Dyskretyzacja przestrzeni następuje poprzez określenie

zbioru elementarnego, którego wielkość zależy od stopnia przybliżenia przestrzeni. Zbiory przybliżone mają tę ciekawą właściwość, że elementy znajdujące się w obszarze zbioru elementarnego są między sobą nierozróżnialne i możemy o nich powiedzieć jedynie tyle, że posiadają wartości wszystkich cech takie jak cały zbiór elementarny. Funkcja przynależności do zbioru przybliżonego przyjmuje wartości odpowiadające numerowi grupy do której dany element został przypisany 1 - gdy dany element należy do grupy 1, 2 - gdy dany element należy do grupy 2, i tak dalej, dodatkowo pojawia się tu wartość 0, która zostaje przyporządkowana do elementów niesklasyfikowanych, to znaczy takich, o których nie jesteśmy w stanie powiedzieć do której grupy należą.

### Podstawowe działania

Podstawowe działania na zbiorach przybliżonych są takie same, jak działania na zbiorach klasycznych.

Dodatkowo wprowadza się kilka nowych pojęć, które nie są używane w przypadku zbiorów klasycznych, a w szczególności relację nierozróżnialności, pojęcia przybliżenia dolnego i górnego.


Relację nierozróżnialności definiujemy następująco: dla każdego podzbioru cech  $B \subseteq A$

$$IND(B) = \{(x, y) \in U^2 : \forall_{a \in B} a(x) = a(y)\}$$

Relację nierozróżnialności (ang. Indiscernibility) elementów  $x$  i  $y$  zapisujemy w postaci

$$x \text{ IND}(B) y$$

co oznacza, że  $x$  jest w relacji nierozróżnialności z  $y$  w zbiorze cech  $B$ , a więc, że elementy  $x$  oraz  $y$  mają te same wartości podzbioru cech  $B$ , czyli że ze względu na zbiór cech  $B$ , elementów  $x$  i  $y$  nie da się między sobą rozróżnić,



Rys. 2. Proces Kansei Engineering. Źródło: oprac. własne

Dolne przybliżenie zbioru  $X$  w przestrzeni aproksymacji ( $S$ ) definiujemy jako:

$$\underline{S}(X) = \{x \in U : [x]_{IND(B)} \subseteq X\}$$

jest to największy podzbiór w  $S$  zawarty w  $X$ .

Górne przybliżenie zbioru  $X$  w przestrzeni aproksymacji ( $S$ ) definiujemy z kolei jako:

$$\overline{S}(X) = \{x \in U : [x]_{IND(B)} \cap X \neq \emptyset\}$$

Brzeg zbioru przybliżonego:

$$Bnd(X) = \overline{S}(X) - \underline{S}(X)$$

Najważniejsze własności zbioru przybliżonego zostały przedstawione na rysunku 2.

### Reprezentacja wiedzy

Informacja w systemie opartym na metodzie zbiorów przybliżonych przechowywana jest w postaci tabelaryzowanej, dzięki czemu można wyodrębnić atrybuty warunkowe (przesłanki) oraz atrybuty decyzyjne. Zapis taki reprezentuje zgromadzoną wiedzę w postaci reguł IF-THEN, zebraną przez eksperta lub ekspertów. Nierzadko jednak wskazania ekspertów mogą się różnić, a co za tym idzie, tablica informacyjna staje się niespójna - pojawiają się reguły niepewne. Dużą zaletą systemu decyzyjnego opartego na zbiorach przybliżonych jest możliwość przetwarzania reguł sprzecznych. Z drugiej strony, systemy te operują na wartościach dyskretnych. Jeśli dane wejściowe są ciągłe, wówczas w fazie wstępnej należy przeprowadzić kwantyzację, zwaną również dyskretyzacją.

Sama tablica decyzyjna nie umożliwiła przetwarzania informacji, które nie zostały uwzględnione podczas tworzenia tej tablicy. Aby wartość atrybutu decyzyjnego lub atrybutów pojawiła się na wyjściu systemu decyzyjnego, pewna reguła musi zostać uaktywniona. Oznacza to, że muszą być spełnione wszystkie jej przesłanki, tzn. wartości atrybutów wejściowych muszą się zgadzać z wartościami atrybutów warunkowych. W przypadku, gdy na wejściu systemu pojawia się wartość atrybutu, która nigdy wcześniej nie wystąpiła, system

nie zareaguje. Dlatego też, obiekty zebrane w tablicy decyzyjnej nazywane są także *faktami*. Wykorzystanie własności zbiorów przybliżonych umożliwia rozszerzenie możliwości takiej tablicy, co prowadzi do znacznego uproszczenia reguł. W konsekwencji, system decyzyjny nabiera cech generalizacji i stanowi efektywne oraz inteligentne narzędzie obróbki danych. Należy przy tym wspomnieć, że do oceny jakości pracy takiego systemu decyzyjnego wykorzystującego bazę reguł zaproponowano szereg różnych metod.

Często celem systemu decyzyjnego opartego na zbiorach przybliżonych jest poszukiwanie ukrytych, a więc niejawnych reguł, które legły u podstaw wyboru dokonywanego przez eksperta (lub ekspertów). Takie procesy wydobywania wiedzy ze zbioru danych określane są anglojęzycznymi terminami, które nie mają jeszcze swoich polskich odpowiedników. Są to "*knowledge discovery*" i "*data mining*", co można przetłumaczyć jako "*odkrywanie wiedzy*" i "*wydobywanie reguł*".

Nie istnieje uniwersalny sposób wydobywania wiedzy z danych, a istniejące metody w różny sposób wykorzystują własności zbiorów przybliżonych. W bogatej literaturze przedmiotu można znaleźć informacje dotyczące istniejących systemów wnioskowania opartego na zbiorach przybliżonych, np. LERS, ROSETTA czy też PRIMEROSE.

Jak wspomniano, w systemach opartych na zbiorach przybliżonych istotną rolę odgrywa sposób reprezentacji wiedzy. Informacja przechowywana jest w tabeli w ten sposób, że: kolumny reprezentują *atrybuty*, wiersze *obiekty*, zaś elementami tablicy są *wartości atrybutów* dla poszczególnych obiektów i atrybutów. Taka tabela nazywana jest *tablicą decyzyjną* lub *systemem*

*informacyjnym*. Przykładowa tablica decyzyjna może mieć postać jak w Tabeli 1.

<b>U</b>	<b>Q</b>				
	<b>A</b>				<b>D</b>
	<b>a1</b>	<b>a2</b>	<b>a3</b>	<b>a4</b>	<b>d</b>
<b>1</b>	A	No	10	-5	Low
<b>2</b>	B	Yes	30	-5	High
<b>3</b>	A	?	10	7	High
<b>4</b>	A	Yes	50	7	High
<b>5</b>	B	No	10	-5	High
<b>6</b>	B	No	10	-5	Low

Tabela 1. Przykładowa tablica decyzyjna. Źródło: oprac. własne

Wówczas:

a) zbiór obiektów  $U = \{1, 2, 3, 4, 5, 6\}$

b) zbiór atrybutów  $A = \{a1, a2, a3, a4\}$

c) zbiór decyzji  $D = \{d\}$

d) poszczególne zbiory wartości kolejnych atrybutów mają postać:

$$V_{a1} = \{A, B\}, V_{a2} = \{Yes, No, ?\},$$

$$V_{a3} = \{10, 20, 30, 50\}, V_{a4} = \{-5, -7\},$$

$$V_d = \{Low, High\},$$

natomiast zbiór wartości atrybutów:

$$V = \{V_{a1}, V_{a2}, V_{a3}, V_{a4}\} = \{(A, B), (Yes, No, ?),$$

$$(10, 20, 30, 50), (-5, -7), (Low, High)\}$$

Tablica decyzyjna umożliwia tworzenie reguł IF-THEN. Zatem dane zgromadzone w tablicy jak powyżej reprezentowane są bezpośrednio przez następujące reguły:

1. **IF**  $a_1 = A$  **AND**  $a_2 = Yes$  **AND**  $a_3 = 20$  **AND**  $a_4 = -5$  **THEN**  $d = Low$
2. **IF**  $a_1 = B$  **AND**  $a_2 = Yes$  **AND**  $a_3 = 30$  **AND**  $a_4 = -5$  **THEN**  $d = High$
3. **IF**  $a_1 = A$  **AND**  $a_2 = ?$  **AND**  $a_3 = 10$  **AND**  $a_4 = 7$  **THEN**  $d = High$
4. **IF**  $a_1 = A$  **AND**  $a_2 = Yes$  **AND**  $a_3 = 50$  **AND**  $a_4 = 7$  **THEN**  $d = High$
5. **IF**  $a_1 = B$  **AND**  $a_2 = No$  **AND**  $a_3 = 10$  **AND**  $a_4 = -5$  **THEN**  $d = High$
6. **IF**  $a_1 = B$  **AND**  $a_2 = No$  **AND**  $a_3 = 10$  **AND**  $a_4 = -5$  **THEN**  $d = Low$

Po przeprowadzeniu obliczeń z wykorzystaniem metodyki zbiorów przybliżonych, wiedza zawarta w tablicy decyzyjnej jest opisywana przez następujące reguły:

- reguły pewne

1. **IF**  $a_3 = 30$  **THEN**  $d = High$
2. **IF**  $a_3 = 50$  **THEN**  $d = High$
3. **IF**  $a_4 = 7$  **THEN**  $d = High$
4. **IF**  $a_1 = A$  **AND**  $a_3 = 10$  **AND**  $a_4 = -5$  **THEN**  $d = Low$

- reguły niepewne

1. **IF**  $a_1 = B$  **THEN**  $d = High$
2. **IF**  $a_2 = No$  **THEN**  $d = Low$

### Zastosowania

Jak widać, wynikiem zastosowania metody Rough Set Analysis jest powstanie zbioru reguł decyzyjnych, który może posłużyć do konstruowania systemów decyzyjnych. Powstają one zwykle w czterech iteracyjnych krokach, które obejmują:

- Identyfikację możliwych zbiorów wartości
- wyodrębnienie atrybutów warunkowych (przesłanek) oraz atrybutów decyzyjnych
- stworzenie reguł decyzyjnych w postaci IF ... THEN
- implementację w systemie decyzyjnym

Zastosowanie teorii zbiorów przybliżonych znajduje wiele zastosowań, w szczególności można wyróżnić:

- rozpoznawanie obrazów (ang. „pattern recognition”),
- uczenie się maszyn (ang. „machine learning”),
- systemy ekspertowe (ang. „experts systems”),
- systemy decyzyjne.

### Podsumowanie

Metoda Rough Sets może być wykorzystana dla przetwarzania danych o nieostrych charakterze z wykorzystaniem intuicyjnie rozumianych reguł wnioskowania. Dzięki naturalnej postaci reguł decyzyjnych mogą one być modyfikowane przez ekspertów. Jej właściwości są możliwe do zastosowania dla poszukiwania ukrytych zależności w danych wejściowych. Metoda Rough Set Analysis jest stosowana w praktyce do wspomagania decyzji w zakresie przypadków mogących zostać opisanymi za

pomocą dyskretnych atrybutów. Metoda może pomagać zidentyfikować istotne elementy wpływające na odczucia. Sprawia to, że w sposób naturalny staje się metodą wpisującą się w filozofię Kansei.

Artykuł został przygotowany z wykorzystaniem wsparcia grantu badawczego Ministerstwa Nauki i Szkolnictwa Wyższego nr 34/N-COST/2007/0

### **Bibliografia**

- [1] Ishikara, S. 2001, Kansei Engineering Procedure and Statistical Analysis, Workshop at International Conference on Affective Human Factors Design, (Singapore).
- [2] Arnold K., Burkhard, D. 2001, Kansei Engineering- From the Customers Point of View, Special Report LiTH-IKP-R-1226, IKP, Linköping.
- [3] Nishino, T., Nagamachi, M. and Ishihara, S. 2001, Rough Set Analysis on Kansei Evaluation of Color, *Proceedings of The International Conference on Affective Human Factors Design, (Singapore: Asean Academic Press)*,
- [4] Grimsaeth K.: Kansei Engineering. Linking emotions and product features, PJWSTK 2004.
- [5] Nagamachi M. Kansei Engineering: A New Consumer-Oriented Technology for Product Development w: Karwowski W., Marras W.S. ed., Occupational Ergonomics, Design and Management of Work Systems, CRC Press, New York 2003
- [6] Nishino, T. Exercises on Kansei Engineering, Hiroshima International University, 2001
- [7] Schütte S. Engineering Emotional Values in Product Design -Kansei Engineering in Development, Linköpings Universitet, Sweden, 2005
- [8] Schütte S., Eklund J. Product Design for Heart and Soul. An Introduction to Kansei Engineering Methodology, Linköpings Universitet, Sweden 2003
- [9] Pawlak, Z., "Rough Sets: Theoretical Aspects of Reasoning about Data", Kluwer Academic Publishers, Dordrecht Netherlands, 1991
- [10] Greco, S., Matarazzo, B., and Slowinski, R. 2001, "Rough sets theory for multicriteria decision analysis," European Journal of Operational Research, Vol. 129, No. 1. Pp1-47.
- [11] Zadeh L.A, 2005 "Toward a generalized theory of uncertainty (GTU)- an outline", Information Sciences, Vol. 172, No. 1-2 . Pp1-40.
- [12] Zhai, L.Y., Khoo, L.P., and Fok, S.C. 2002, "Feature extraction using rough set theory and generic algorithms an application for the simplification of product quality evaluation," Computers & Industrial Engineering, Vol. 43, No. 4. Pp 661-676.