

TOMASZ RZEPIŃSKI

## **Założenia epistemologiczne wykorzystania teorii zbiorów przybliżonych w ocenie i selekcji informacji klinicznych**

„- ...czy ten, który fałszywie sądzi o czymś co zna,  
mniema, że to nie jest to, tylko coś innego, co też zna,  
i tak, znając jedno i drugie, nie rozpoznaje jednego i drugiego?  
- To niemożliwe.”

„Teajtet”, Platon (1959), s. 104, XXXIB

### **Wstęp**

Pozyskiwanie informacji dla potrzeb podejmowanych w medycynie decyzji klinicznych może przebiegać w różny sposób. Przez długi czas dominowało przekonanie, że decyzje o metodzie terapii powinny być uzasadniane teoriami i modelami nauk podstawowych. W tym ujęciu decyzje terapeutyczne opierały się na wiedzy z zakresu biochemii, farmakokinetyki, patofizjologii oraz ustaleniach wielu innych dyscyplin szczegółowych. Miały one wyłącznie pośrednią ewidencję empiryczną: były potwierdzone, o ile potwierdzone empirycznie były teorie nauk podstawowych.

Uzyskane w latach 80. XX wieku dane wykazały jednak, że decyzje kliniczne oparte na ustaleniach z zakresu nauk podstawowych niejednokrotnie były błędne. Stosowana metodologia oceny efektywności terapii medycznych dopuszczała do zastosowania terapii, które skutkowały pogorszeniem stanu zdrowia pacjenta. Sytuacja ta doprowadziła do zmiany wytycznych w zakresie podejmowania decyzji klinicznych. Dokonało się

to za sprawą koncepcji metodologicznej określanej mianem koncepcji *Evidence-Based Medicine* (EBM)<sup>1</sup>. W zakresie tej koncepcji uznaje się, że podstawą dla podejmowania decyzji terapeutycznych muszą być odpowiednio zaprojektowane badania kliniczne<sup>2</sup>. Badania te ustalają zależności o charakterze statystycznym, nie ulega jednak wątpliwości, że dla oceny skuteczności terapii ważniejsze byłoby określenie zależności o charakterze przyczynowym. Taką właśnie ocenę umożliwia metoda wykorzystująca teorię zbiorów przybliżonych (*Rough Set Theory* – RST). Celem niniejszego artykułu jest jej omówienie oraz wskazanie założeń epistemologicznych, które leżą u podstaw jej wykorzystania dla potrzeb praktyki medycznej. Punktem wyjścia dla prowadzonych rozważań będzie przedstawienie zasadniczych zastrzeżeń formułowanych wobec postulatów epistemologicznych koncepcji EBM.

### Koncepcja EBM i ocena wiarygodności danych klinicznych

Zgodnie z koncepcją EBM podstawą podejmowania decyzji terapeutycznych powinny być odpowiednio zaprojektowane badania kliniczne. Wyróżnia się trzy główne ich typy: badania kliniczno-kontrolne, badania kohortowe oraz randomizowane badania kontrolne (*Randomized Controlled Trial* – RCT). Dwa pierwsze rodzaje to tzw. badania nieeksperymentalne<sup>3</sup>. Najbardziej cenionym w zakresie koncepcji EBM jest badanie typu RCT [Brzeziński, Szamotulska, 1997].

W badaniu RCT następuje losowy przydział pacjentów bądź do grupy osób podlegających leczeniu, bądź do nieleczonych, tzw. grupy kontrol-

<sup>1</sup> Będę posługiwał się oryginalnym terminem. Na różne tradycje tłumaczenia terminu „evidence-based medicine” zwracałem uwagę w: Rzepiński, 2012.

<sup>2</sup> Ściśle biorąc, formułowany jest postulat, aby podstawą działań były najbardziej wiarygodne dostępne dane. Oznacza to, że w przypadku braku wyników z badań klinicznych można korzystać z danych pochodzących z niższych poziomów hierarchii wiarygodności. Zagadnień tych nie będę przybliżał. Omawiałem je już w: Rzepiński, 2012.

<sup>3</sup> Z uwagi na brak miejsca w niniejszym artykule różnice pomiędzy tymi typami badań nie będą omawiane. Por. Brzeziński, Szamotulska, 1997; Wulff, Gotzsche, 2005.

nej<sup>4</sup>. Ocena skuteczności polega na porównaniu efektów terapii w grupie poddanej leczeniu i w grupie kontrolnej. RCT może być badaniem z podwójnie ślełą próbą (zarówno pacjent, jak i lekarz nie wiedzą, czy zastosowana została terapia czy placebo) lub badaniem z pojedynczo ślełą próbą (albo pacjent, albo lekarz nie wie, czy zastosowano terapię czy placebo).

W koncepcji EBM uznaje się, że badania typu RCT dostarczają najbardziej wiarygodnych danych dotyczących skuteczności terapii<sup>5</sup>. Zauważmy, że twierdzenie to stanowi silną tezę epistemologiczną. Ma ona jednocześnie bardzo praktyczny wymiar, w zakresie współczesnej medycyny określa wyraźne wytyczne postępowania dla podejmowania decyzji klinicznych<sup>6</sup>, warto zatem zastanowić się, w jaki sposób jest uzasadniana. Zagadnienie to jest przedmiotem analiz prowadzonych wspólnie przez statystyków, klinicystów oraz filozofów nauki.

John Worrall w formułowanej krytyce koncepcji EBM identyfikuje dwa główne argumenty przywoływane przez zwolenników procedury randomizacji [Worrall, 2002, 2007]. Po pierwsze, randomizacja – a ściślej biorąc, ślepa próba stosowana w zakresie randomizacji – eliminuje wpływ czynników subiektywnych na ocenę wyników prowadzonych badań klinicznych. Po drugie, poprawnie przeprowadzona randomizacja gwarantuje, że nastąpi równomierny rozkład czynników zakłócających w obu grupach: kontrolnej i badanej. Czynniki zakłócające to, najogólniej mówiąc, te dodatkowe cechy pacjentów, które nie różnicują ich pod względem formułowanej diagnozy (czyli nie mają wpływu na identyfikację schorzenia), ale mogą wpływać na efekty terapii. Drugi z wymienionych argumentów jest szczególnie ważny. Rozważmy badanie kliniczne, w którym pacjenci z rozpoznanym schorzeniem  $D$  zostali przydzieleni losowo do dwóch grup:  $A$  i  $B$ . Wobec pacjentów z grupy  $A$  zastosowano oddziaływanie

<sup>4</sup> Grupą kontrolną może być grupa nieleczona (placebo) lub leczona standardową terapią. Niekiedy z przyczyn etycznych nie stosuje się placebo.

<sup>5</sup> W istocie najwyżej w hierarchii wiarygodności danych umieszczane są metaanalizy, ale w kontekście analizowanych zagadnień tej kwestii nie rozwijam.

<sup>6</sup> Obecnie regulują to odpowiednie przepisy prawne. Ustalają one, że w procesie podejmowania decyzji terapeutycznych lekarz ma obowiązek kierowania się najbardziej wiarygodnymi wynikami badań klinicznych, czyli wynikami badań typu RCT (!) [Walter, 2004; Tuchołka, 2004].

terapeutyczne  $T$ , natomiast wobec pacjentów z grupy  $B$  imitowano tylko takie oddziaływanie. Jeżeli w obu grupach nastąpił równomierny rozkład czynników zakłócających, to zastosowane wobec pacjentów z grupy  $A$  oddziaływanie terapeutyczne  $T$  będzie jedynym czynnikiem różnicującym obie grupy. Jeżeli zatem u pacjentów należących do tej grupy nastąpi poprawa stanu zdrowia, to możemy mieć pewność, że miało to miejsce na skutek zastosowanej terapii  $T$ . Widoczne jest, że RCT jest badaniem opartym na kanonie jedynej różnicy, przy założeniu, że randomizacja gwarantuje równomierny rozkład czynników zakłócających w obu grupach. Jeżeli założenie to jest spełnione, to można wnosić, że wyniki badania RCT określają związki przyczynowo-skutkowe pomiędzy zastosowaną terapią a jej efektami. Problem polega jednak na tym, że założenie postulujące równomierny rozkład czynników zakłócających w procedurze randomizacji budzi wiele wątpliwości. Argumentacja na rzecz tego założenia przybiera następującą postać:

- (1) można dokonać oceny procedury randomizacji, określając rozkład wybranych czynników w obu grupach; są to tzw. czynniki znane;
- (2) jeżeli rozkład znanych czynników w obu grupach jest taki sam, to zwiększa się prawdopodobieństwo tego, że nastąpił również równomierny rozkład czynników nieznanymi<sup>7</sup>.

Na podstawie (1) i (2) wnioskuje się, że można ustalić związek przyczynowo-skutkowy pomiędzy oddziaływaniem terapeutycznym  $T$  a efektem  $R$ . Przyjmijmy, że  $P(R/T)$  to prawdopodobieństwo uzyskania efektu  $R$  po podjęciu oddziaływań terapeutycznych  $T$ . Zatem uznaje się, że jeżeli w badaniu z randomizacją stwierdzamy:

$$P(R/T) > P(R/\neg T),$$

to możemy wnosić, że  $T$  jest przyczyną wystąpienia zdarzenia  $R$  [Papineau, 1994, s. 440; Cartwright, 1989; Cartwright, 2010; Cartwright, Munro, 2010].

---

<sup>7</sup> Omówienie dyskusji prowadzonych w tym zakresie nie jest celem niniejszego artykułu. Ich analiza została przeprowadzona w: Rzepiński, 2012.

Przedstawione ustalenie stanowi rdzeń tzw. probabilistycznych koncepcji przyczynowości. Odnosząc się do tego ujęcia, J. Worrall proponuje rozważenie przykładu opartego na następujących założeniach: (i) w przypadku choroby  $D$  terapia  $T$  jest przyczyną zdarzenia  $R$  (wyzdrowienia) wtedy i tylko wtedy, gdy u pacjenta występują czynniki  $f_1, \dots, f_i$ , (ii) czynniki  $f_1, \dots, f_i$  bardzo rzadko występują w populacji i nie są znane lekarzom, (iii) w przypadku braku tych czynników terapia  $T$  jest przyczyną wystąpienia niekorzystnych efektów ubocznych u danego pacjenta, na przykład wzmoczenia objawów chorobowych, czyli:  $\neg R$ . Załóżmy, że: (iv) przeprowadzono badanie z randomizacją i że procedura randomizacji doprowadziła do równomiernego rozkładu wszystkich czynników znanych i nieznanych w grupie testowej i kontrolnej. Jednakże ze względu na fakt, że czynniki  $f_1, \dots, f_i$  bardzo rzadko występują w populacji, stwierdzono, że:

$$g(R/T) < g(R/\neg T),$$

gdzie  $g$  to względna częstość zdarzenia  $R$  odpowiednio ze względu na  $T$  lub  $\neg T$ .

Zgodnie z probabilistycznymi koncepcjami przyczynowości badacze powinni zatem wnosić, że terapia  $T$  jest przyczyną pogorszenia stanu zdrowia [Worrall, 2007, s. 467]. Wniosek ten jest jednak błędny z uwagi na założenie (i). Worrall przyznaje, że rozważany przykład jest fikcyjny, niemniej pozwala on wykazać, że randomizacja nie może stanowić podstawy dla wniosków ustalających zależności przyczynowe, bowiem równomierny rozkład znanych czynników zakłócających nie przesądza o równomiernym rozkładzie nieznanymi czynnikami zakłócającymi. Dlatego też należy uznać, że badania RCT pozwalają ustalić wyłącznie zależności o charakterze statystycznym<sup>8</sup>. Czy jednak jest w takim razie w ogóle miejsce w medycynie dla metod określających efekty terapii w kategoriach przyczynowych? Interesującą propozycję na ten temat oferuje teoria zbiorów przybliżonych (*Rough Set Theory*). W kolejnej części artykułu zosta-

<sup>8</sup> Warto zauważyć, że rozpowszechnione wśród klinicystów za sprawą koncepcji EBM przekonanie o największej wiarygodności badań RCT prowadzi do nadinterpretacji wyników tych badań: „Randomizowane badania kontrolowane są najbardziej rygorystycznym sposobem określania zależności przyczynowo-skutkowej pomiędzy postępowaniem leczniczym a jego wynikiem” [Nowakowska, 2004, s. 85, wyróżnienie T.Rz.].

ną przedstawione na poziomie intuicyjnym te zasadnicze aspekty teorii RST, które decydują o jej przydatności w ocenie danych pozyskiwanych dla procesu podejmowania decyzji klinicznych. Przeprowadzona analiza pozwoli zidentyfikować założenia epistemologiczne metody oceny terapii opierającej się na teorii zbiorów przybliżonych.

### Podstawowe intuicje teorii zbiorów przybliżonych

Teoria zbiorów przybliżonych została sformułowana w latach 80. XX wieku przez Zdzisława Pawlaka [Pawlak, 1982]. Zastosowanie RST w ocenie danych klinicznych ma dostarczyć rozwiązania problemu podejmowania decyzji terapeutycznych w warunkach niepewności. Problem jest oczywisty: otóż wnioski prowadzone w procesie podejmowania decyzji klinicznych opierają się na niepełnej wiedzy o stanie układów, klinicysta nie dysponuje bowiem wyczerpującymi informacjami o wszystkich czynnikach zakłócających przebieg terapii. Dokonując przybliżenia podstawowych intuicji teorii RST, warto jest jednak rozpocząć analizę od rozważenia wyidealizowanej sytuacji, w której posiadalibyśmy pełną (wyczerpującą) wiedzę o stanie danego układu.

Przyjmijmy zatem, że dysponujemy układem fizycznym  $F$ , w którym występuje pewna skończona liczba przedmiotów:  $\{a_1, \dots, a_k\}$ . Załóżmy również, że przedmioty te charakteryzują się cechami  $f_1, \dots, f_i$ , przy czym cechy te dla różnych przedmiotów naszego układu fizycznego przyjmują różne wartości. Czym byłoby wówczas posiadanie pełnej wiedzy o danym układzie fizycznym? Podążając platońskimi tropami wskazanymi w *Teajtecie*, można przyjąć następujące rozwiązanie: jeżeli dysponujemy wiedzą typu *episteme* o danych przedmiotach, to nie możemy ich ze sobą pomylić. Nie jest przecież możliwe – jak pisze Platon – że znając  $A$  i znając  $B$ , mylimy te dwa przedmioty. W odniesieniu do rozważanego przykładu oznaczałoby to, że dysponując wyczerpującą wiedzą o stanie układu, jesteśmy w stanie dokonać podziału logicznego występujących w nim przedmiotów.

Można zatem powiedzieć, że posiadanie pełnej wiedzy o danym układzie fizycznym wyraża się w możliwości dokonania klasyfikacji przed-

miotów z tego układu. Ta oczywista intuicja stanowić może punkt wyjścia dla przybliżenia zasadniczych idei teorii RST. Pragnąc jednak tego dokonać, należy poddać analizie przykład trochę bardziej złożony niż ten, który został powyżej wskazany.

Przyjmijmy, że układ  $F$  ma charakter diachroniczny, czyli przedmioty z tego układu podlegają zmianom w czasie. W układzie tym występują przedmioty  $\{a_1, \dots, a_k\}$ , które w czasie  $t_1$  charakteryzowały się wskazanymi wcześniej cechami  $f_1, \dots, f_i$ . Podobnie jak w poprzednim przypadku cechy te dla różnych przedmiotów przyjmują różne wartości. Załóżmy ponadto, że w czasie  $t_2$  przedmioty z rozważanego układu uzyskują dodatkową cechę  $r$ , która także przyjmuje różne wartości.

Posiadając wyczerpującą wiedzę o danym układzie diachronicznym, byłibyśmy w stanie przeprowadzić dwie klasyfikacje przedmiotów. Pierwsza byłaby wyznaczona przez wartości cech  $f_1, \dots, f_i$  w czasie  $t_1$ , natomiast druga przez wartości cechy  $r$  w czasie  $t_2$ . W konsekwencji przeprowadzonych podziałów można by dokonać jednoznacznego przyporządkowania członów podziału wyznaczonych w czasie  $t_1$  wartościami cech  $f_1, \dots, f_i$ , członom podziału wyznaczonym w czasie  $t_2$  wartościami cechy  $r$ . Precyzyjniej: można określić funkcję, która każdemu członowi klasyfikacji w czasie  $t_1$  przyporządkowuje dokładnie jeden człon klasyfikacji w czasie  $t_2$ . Rozważmy prosty przykład, w którym dla zbioru przedmiotów  $\{a_1, a_2, a_3, a_4\}$  dokonano podziału logicznego tego zbioru z uwagi na cechy  $f_1$  i  $f_2$  w czasie  $t_1$ , a następnie ten sam zbiór przedmiotów podzielono z uwagi na cechę  $r$  w późniejszym czasie  $t_2$ . Przyjmijmy, że wartości poszczególnych cech reprezentuje poniższa tabela.

**Tabela 1.** Wartości atrybutów dla przedmiotów  $a_1, \dots, a_4$  w czasie  $t_1$  i  $t_2$

	$f_1(a_i)/t_1$	$f_2(a_i)/t_1$	$r(a_i)/t_2$
$a_1$	0	1	<b>0</b>
$a_2$	1	0	<b>1</b>
$a_3$	0	0	<b>0</b>
$a_4$	0	1	<b>0</b>

Symbole  $a_1, \dots, a_4$  oznaczają przedmioty należące do zbioru  $U$ ,  $f_1$  i  $f_2$  to cechy tych przedmiotów w czasie  $t_1$ , z kolei  $r$  to cecha tych przedmiotów w czasie  $t_2$

Jak widać, można dokonać dwóch podziałów zbioru  $U = \{a_1, a_2, a_3, a_4\}$ . Pierwszym będzie rodzina zbiorów  $A = \{\{a_1, a_4\}, \{a_2\}, \{a_3\}\}$ . Drugim będzie rodzina zbiorów  $B = \{\{a_1, a_3, a_4\}, \{a_2\}\}$ . Każdemu elementowi rodziny  $A$  można zatem przyporządkować dokładnie jeden element rodziny  $B$ . Byłaby to sytuacja, w której posiadamy pełną wiedzę o stanie danego układu. Wiedzę o charakterze deterministycznym. Znając stan układu w czasie  $t_1$ , możemy określić stan układu w czasie  $t_2$ .

Problem polega jednak na tym, że w praktyce badawczej uczeni nie mają wyczerpującej wiedzy o danym układzie fizycznym. Dysponując natomiast niepełną wiedzą, klinicysta nie może być pewien, czy bierze pod uwagę wszystkie czynniki wpływające na przebieg terapii. Jeżeli istniałyby czynniki, które nie zostały wzięte pod uwagę, to mogłaby mieć miejsce sytuacja, w której przedmioty należące do tego samego członu klasyfikacji w czasie  $t_1$  uzyskiwałyby różne wartości cechy  $r$ , czyli należałyby do różnych członów klasyfikacji w czasie  $t_2$ . Teoria zbiorów przybliżonych pozwala uwzględnić właśnie tego rodzaju sytuacje problemowe, w których wnioskowania musimy opierać na niepełnej wiedzy. Przyjrzyjmy się rozwiązaniom, które w zakresie tej teorii są proponowane.

### **Teoria zbiorów przybliżonych a wnioskowanie kliniczne w warunkach niepewności**

Dla potrzeb prowadzonych rozważań przyjmijmy następujące ustalenia. Załóżmy, że: (i) rozważamy zbiór pacjentów  $U = \{a_1, \dots, a_8\}$ , u których rozpoznano chorobę  $D$ , (ii) symbole  $f_1, f_2, f_3$  niech oznaczają takie dodatkowe cechy pacjenta, które mogą mieć wpływ na przebieg terapii (są to zatem wspomniane wcześniej czynniki zakłócające). Przyjmijmy, że wszystkie cechy pacjentów będziemy określać mianem atrybutów. (iii) Atrybuty  $f_1$  oraz  $f_2$  przyjmują wartości 0 lub 1, natomiast atrybut  $f_3$  może przyjmować wartości 0, 1 lub 2. (v) W efekcie zastosowania terapii  $T$  uzyskano dwie klasy wyleczenia:  $\{Y_1, Y_2\}$ . Zauważmy, że zarówno sama terapia, jak i jej efekt to dodatkowe atrybuty charakteryzujące pacjentów. Oznacza to, że poza wymienionymi atrybutami  $f_1, f_2, f_3$  każdy z pacjentów



może być scharakteryzowany za pomocą dwóch dodatkowych atrybutów:  $T$ , przyjmującego tę samą wartość dla wszystkich pacjentów, oraz  $r$ , przyjmującego wartości 0 lub 1, które można interpretować: 0 – brak poprawy, 1 – wyleczenie. (vi) Wartości atrybutów dla poszczególnych pacjentów przedstawia tabela 2.

**Tabela 2.** Przykładowe wartości atrybutu  $r$  określającego efekt terapii przy ustalonych wartościach atrybutów przedterapeutycznych  $f_1, \dots, f_3$

	$f_1(a_i)$	$f_2(a_i)$	$f_3(a_i)$	$T(a_i)$	$r(a_i)$
$a_1$	0	1	0	1	<b>0</b>
$a_2$	1	0	2	1	<b>1</b>
$a_3$	0	0	0	1	<b>0</b>
$a_4$	1	0	2	1	<b>0</b>
$a_5$	0	1	0	1	<b>0</b>
$a_6$	1	1	1	1	<b>1</b>
$a_7$	0	1	1	1	<b>1</b>
$a_8$	0	0	1	1	<b>0</b>

Symbole  $a_1, \dots, a_8$  oznaczają pacjentów. Cechy  $f_1, f_2, f_3$  to atrybuty charakteryzujące przedterapeutyczny stan pacjentów.  $T$  to terapia, której zostali poddani pacjenci, natomiast  $r$  to stan pacjentów po przeprowadzonej terapii.

Każdy wiersz w tabeli dostarcza pewnych informacji o danym pacjencie. Tabelę taką można określić mianem *systemu informacyjnego*<sup>9</sup>. Zauważmy, że w rozważanym przypadku przedstawiony system informacyjny reprezentuje „fikcyjny” przykład Worralla, bowiem większość pacjentów nie odnosi żadnych korzyści z zastosowanej terapii. Przeprowadzenie badania RCT dokonałoby zatem wyłącznie uśrednienia wyników, wykazując, że terapia  $T$  nie jest korzystna – u pięciu pacjentów nie stwierdza się bowiem poprawy –  $\{a_1, a_3, a_4, a_5, a_8\}$ .

Zgodnie z ustaleniami dokonany w poprzednim paragrafie należy oczekiwać, że posiadanie wyczerpującej wiedzy o stanie układu pozwoliłoby nam dokonać dwóch klasyfikacji pacjentów: pierwszą – ze względu

<sup>9</sup> W teorii zbiorów przybliżonych pojęcie systemu informacyjnego jest definiowane znacznie bardziej precyzyjnie, jednak dla analizy prowadzonej w niniejszym artykule wystarczające jest założenie, że ogół informacji zestawionych w danej tabeli będzie określany jako *system informacyjny*.

na wartości atrybutów przedterapeutycznych ze zbioru  $K = \{f_1, f_2, f_3\}$ , drugą – z uwagi na wartość atrybutu  $r$ . Zauważmy, że atrybut  $T$  przyjmuje tę samą wartość dla wszystkich pacjentów (wszyscy zostali poddani terapii), nie wpływa zatem na żadną z przeprowadzanych klasyfikacji i można go pominąć. Do tabeli 2 został wprowadzony, aby zapobiec ewentualnym wątpliwościom czytelnika dotyczącym sposobu wyrażenia informacji o oddziaływaniach terapeutycznych w zakresie RST.

Ustalenie algorytmu decyzyjnego (czyli dla rozważanego przykładu: sprecyzowanie wskazań i przeciwwskazań do terapii) wymaga określenia takiego zakresu wartości atrybutów ze zbioru  $K$ , że zastosowanie terapii  $T$  przy określonych wartościach przyjmowanych przez  $f_1, \dots, f_i$  jest warunkiem wystarczającym tego, że atrybut  $r$  (czyli efekt terapii) uzyska wartość 1 lub 0. Sprecyzujemy tę intuicję odwołując się do prostych ustaleń formalnych.

Przyjmijmy, że  $Q = \{f_1, f_2, f_3, r\}$ . Zauważmy, że dla dowolnego  $A \subseteq Q$  można określić relację nierozróżnialności [*indiscernibility relation* –  $Ind(A)$ ] w zbiorze  $U$ . Przykładowo pacjenci  $a_1, a_5$  i  $a_7$  są nierozróżnialni ze względu na wartości atrybutów ze zbioru  $A = \{f_1, f_2\}$ . Relacja nierozróżnialności, będąc relacją równoważnościową, wyznacza klasy abstrakcji w zbiorze  $U$ , dokonując klasyfikacji pacjentów. Niech  $U/Ind(A)$  oznacza klasyfikację obiektów z  $U$  generowaną przez dany zbiór atrybutów  $A$ .

Zatem:

$$U/Ind(A) = \{\{a_1, a_5, a_7\}, \{a_2, a_4\}, \{a_3, a_8\}, \{a_6\}\}.$$

Odwołajmy się ponownie do intuicji związanych z pojęciem *episteme*. Załóżmy, że posiadamy wyczerpującą wiedzę o warunkach terapii. Oznaczałoby to, że klasom abstrakcji wyznaczonym przez relację równoważnościową ze względu na zbiór atrybutów  $K = \{f_1, f_2, f_3\}$  można przyporządkować klasy abstrakcji wyznaczone ze względu na jednoelementowy zbiór  $B = \{r\}$ . Wartości atrybutów  $f_1, f_2, f_3$  określałyby wówczas w sposób jednoznaczny wskazania lub przeciwwskazania do zastosowania terapii. W rozważanym przykładzie nie można jednak dokonać takiego przyporządkowania wartości atrybutów do klas wyleczenia. Pacjenci  $a_2$  i  $a_4$  zaburzają spójność uzyskanych wyników terapii. Przy tych samych warto-

ściach atrybutów  $f_1, f_2, f_3$  zastosowanie terapii  $T$  doprowadziło u tych pacjentów do uzyskania odmiennych efektów. Co jest powodem tej niespójności? Otóż problem polega na tym, że nie mamy wyczerpującej wiedzy o czynnikach wpływających na przebieg terapii. Należy uznać, że istnieje przynajmniej jeden nieznan nam atrybut, który różnicuje obu pacjentów. Jeżeli zatem nie jesteśmy w stanie ustalić, jakie atrybuty wpływają dodatkowo na przebieg terapii, musimy wnioskować z niepełnych danych.

W zakresie teorii zbiorów przybliżonych niespójność uzyskanych informacji można scharakteryzować za pomocą pojęć: *dolnego przybliżenia zbioru*, *górnego przybliżenia zbioru* i *dokładności przybliżenia* [Pawlak, 1991, 2001]. Punktem wyjścia dla sformułowania tych pojęć będą następujące spostrzeżenia:

- (1) relacja nierozróżnialności ze względu na zbiór atrybutów  $K = \{f_1, f_2, f_3\}$  wyznacza następującą klasyfikację:  
 $U/Ind(K) = \{\{a_1, a_5\}, \{a_2, a_4\}, \{a_3\}, \{a_6\}, \{a_7\}, \{a_8\}\};$
- (2) relacja nierozróżnialności z uwagi na jednoelementowy zbiór atrybutów  $B = \{r\}$  wyznacza dwie klasy wyleczenia pacjentów:  
 $U/Ind(B) = \{\{a_1, a_3, a_4, a_5, a_8\}, \{a_2, a_6, a_7\}\}$ . Przyjmijmy, że:  
 $Y_1 = \{a_1, a_3, a_4, a_5, a_8\}, Y_2 = \{a_2, a_6, a_7\}$ .

$K$ -dolnym przybliżeniem zbioru  $Y_i$  (dla  $i = 1$  lub  $i = 2$ ) jest suma tych wszystkich elementów rodziny  $U/Ind(K)$ , które zawierają się w zbiorze  $Y_i$ . Zatem dla rozważanego przykładu:

$$\begin{aligned} \underline{K}Y_1 &= \{a_1, a_5\} \cup \{a_3\} \cup \{a_8\} \\ \underline{K}Y_2 &= \{a_6\} \cup \{a_7\}. \end{aligned}$$

Dolne przybliżenie zbioru  $Y_i$  ze względu na zbiór atrybutów  $K$  jest zatem zbiorem tych wszystkich obiektów, które „z pewnością” należą do danej klasy wyleczenia na podstawie informacji o wartościach atrybutów ze zbioru  $K$ . Zauważmy, że dla pacjentów należących do dolnego przybliżenia zbioru można ustalić deterministyczny algorytm decyzyjny *DAD* określający warunki podjęcia lub zaniechania terapii.

*DAD*:

(reguła 1) Dla dowolnego pacjenta  $x_i$ , jeżeli  $f_1(x_i) = 1$  lub  $0$  oraz  $f_2(x_i) = 1$  i  $f_3(x_i) = 1$ , to zastosowanie terapii  $T$  powoduje efekt  $r(x_i) = 1$ .

(reguła 2) Dla dowolnego pacjenta  $x_i$ , jeżeli  $f_1(x_i) = 0$  oraz  $f_2(x_i) = 0$  oraz  $f_3(x_i) = 0$   
lub  $f_1(x_i) = 0$  oraz  $f_2(x_i) = 1$  i  $f_3(x_i) = 0$   
lub  $f_1(x_i) = 0$  oraz  $f_2(x_i) = 0$  i  $f_3(x_i) = 1$ ,  
to zastosowanie terapii  $T$  powoduje efekt  $r(x_i) = 0$ .

Algorytm decyzyjny *DAD* nie obejmuje wszystkich pacjentów z tabeli 2, bowiem pacjentów  $a_2$  i  $a_4$  nie można jednoznacznie przyporządkować do dolnego przybliżenia żadnej klasy wyleczenia na podstawie atrybutów ze zbioru  $K$ . W konsekwencji nie można również określić algorytmu *DAD* dla tych przyszłych pacjentów  $x_i$ , których wartości atrybutów będą identyczne z wartościami atrybutów pacjentów  $a_2$  i  $a_4$ . Zbiór  $\{a_2, a_4\}$  jest *obszarem niepewności klasyfikacji*.

Wobec przedstawionych do tej pory ustaleń można sformułować następujące zastrzeżenie: otóż algorytm decyzyjny *DAD* może być również określony na podstawie analizy podgrup po dokonanych badaniu RCT. Przeprowadzanie analizy podgrup budzi wątpliwości metodologów [Jaeschke, Cook, Guyatt, 1998, s. 116; Yusuf, Wittes, i in., 1991; Guillemin, 2007; Hernandez, Boersma, Murry i in., 2006], ale badanie RCT może być przecież od razu zaplanowane w taki sposób, aby uwzględnić wyłącznie wybrane zakresy wartości pewnych atrybutów, na przykład wiek [Worrall, 2009, s. 296]. Dlaczego zatem mielibyśmy uznać, że analiza informacji dokonana za pomocą teorii zbiorów przybliżonych stanowi interesującą alternatywę dla badań RCT? Otóż, w przeciwieństwie do badań klinicznych, teoria ta pozwala „wychwycić” związki przyczynowo-skutkowe w systemach informacyjnych zawierających dużą liczbę wyników niespójnych [Słowiński, 1992]. Realizacja tego celu jest możliwa dzięki temu, że RST pozwala przedstawić zależności pomiędzy wartościami atrybutów „przed terapią” a efektami terapii w kategoriach ilościowych. Pragnąc to uczynić, należy wprowadzić pojęcie *górnego przybliżenia zbioru*.

$K$ -górnym przybliżeniem zbioru  $Y_i$  jest suma tych wszystkich elementów rodziny  $U/Ind(K)$ , które mają część wspólną z  $Y_i$ . Zatem dla rozważanego przykładu:

$$\begin{aligned}\bar{K}Y_1 &= \{a_1, a_5\} \cup \{a_3\} \cup \{a_8\} \cup \{a_2, a_4\} \\ \bar{K}Y_2 &= \{a_2, a_4\} \cup \{a_6\} \cup \{a_7\}.\end{aligned}$$

Korzystając z pojęć dolnego i górnego przybliżenia zbioru, można dokonać ilościowej charakterystyki dokładności przybliżenia zbioru  $Y_i$  przez zbiór atrybutów  $K$ :

$$\alpha_K(Y) = \frac{\text{card}(\underline{K}Y_i)}{\text{card}(\bar{K}Y_i)},$$

gdzie  $\alpha_K(Y)$  to dokładność przybliżenia zbioru  $Y_i$  przez zbiór atrybutów  $K$ , a  $\text{card}(\dots)$  to liczność odpowiednio dolnego lub górnego przybliżenia zbioru  $Y_i$ . Dokładność przybliżenia pozwala zatem w sposób ilościowy scharakteryzować niespójność uzyskanych wyników terapii.

W rozważanym przykładzie można ustalić następujące dokładności przybliżenia dla poszczególnych zbiorów:

$$\begin{aligned}\alpha_K(Y_1) &= 4/6 = 0,66 \\ \alpha_K(Y_2) &= 2/4 = 0,5.\end{aligned}$$

Widoczne jest, że atrybuty ze zbioru  $K$  z większą dokładnością charakteryzują pacjentów, którym terapia  $T$  nie przyniesie korzyści, niż pacjentów, dla których terapia ta byłaby korzystna. Jest to zatem ilustracja problemu wskazanego przez Worralla.

Ustalenie dokładności przybliżenia zbioru  $Y_i$  przez zbiór atrybutów  $K$  pozwala określić doniosłość przyczynową atrybutu. Idea jest następująca: jeżeli atrybut jest przyczynowo istotny dla danego efektu terapii, to usunięcie go ze zbioru  $K$  spowoduje, że obniży się dokładność przybliżenia danej klasy wyleczenia. Doniosłość przyczynowa atrybutu jest określana dla efektu terapii. Zauważmy jednak, że zgodnie z dokonanymi ustaleniami efekt terapii jest również atrybutem. Można zatem powiedzieć, że ustalając doniosłość przyczynową pewnego atrybutu  $f_k$ , określamy jego wpływ na wartość pewnego innego atrybutu, np. atrybutu  $r$ .

Przyjmijmy, że dysponujemy zbiorem przedmiotów  $U = \{a_1, \dots, a_k\}$ , które w czasie  $t_1$  scharakteryzowane zostały za pomocą atrybutów  $f_1, \dots, f_i$ . W czasie  $t_2$  przedmioty ze zbioru  $U$  scharakteryzowano za pomocą atrybutu  $r$ , wyznaczającego klasyfikację przedmiotów z  $U$ :  $U/Ind(r) = \{Y_1, \dots, Y_m\}$ . Przyjmijmy, że  $Y_n$  jest klasą abstrakcji wyznaczoną relacją równoważnościową dla wartości atrybutu  $r = n$ . Niech  $K^* = K - \{f_k\}$ . Doniosłość przyczynową atrybutu  $f_k$  dla wartości  $n$  atrybutu  $r$  można wówczas określić jako:

$$\underline{Df}_{k_{r=n}} = \alpha_K(Y_n) - \alpha_{K^*}(Y_n).$$

Przybliżmy te ustalenia, odwołując się do przykładu opartego na systemie informacyjnym tabeli 2. Przyjmijmy, że celem będzie ustalenie doniosłości przyczynowej atrybutu  $f_2$  dla wystąpienia efektu  $r = 0$ . Pragnąc to ustalić, musimy obliczyć dokładność przybliżenia zbioru  $Y_1$  przez zbiór atrybutów  $K^* = K - \{f_2\}$ .

Ponieważ

$$\begin{aligned} \underline{K^*}Y_1 &= \{a_1, a_5\} \cup \{a_3\} \\ \bar{K^*}Y_1 &= \{a_1, a_5\} \cup \{a_3\} \cup \{a_8\} \cup \{a_2, a_4\}. \end{aligned}$$

Zatem

$$\alpha_{K^*}(Y_1) = 3/6 = 0,5.$$

Ponieważ, jak pokazane zostało wcześniej:

$$\alpha_K(Y_1) = 0,66.$$

Zatem doniosłość przyczynowa atrybutu  $f_2$  dla efektu  $r = 0$  określona na podstawie systemu informacyjnego tabeli 2 wynosi:

$$\underline{Df}_{2_{r=0}} = \alpha_K(Y_1) - \alpha_{K^*}(Y_1) = 0,16.$$

Zastosowanie RST w analizie danych medycznych pozwala zatem sformułować prosty algorytm oceny danych. Usunięcie różnych atrybutów ze zbioru  $K$  może prowadzić do obniżenia dokładności przybliżenia danej klasy  $Y_n$  o różne wartości. Jeżeli usunięcie atrybutu  $f_k$  prowadzi do większego obniżenia dokładności przybliżenia klasy  $Y_n$  niż usunięcie atrybutu  $f_m$ , to uznajemy, że atrybut  $f_k$  jest przyczynowo bardziej istotny dla efektu  $r$  niż atrybut  $f_m$ .

### Jakość klasyfikacji a identyfikacja zbędnych informacji klinicznych

Dokładność przybliżenia zbioru  $Y$  przez zbiór atrybutów  $K$  może być w RST uogólniona dla klasyfikacji. Posługujemy się wówczas pojęciem *jakości klasyfikacji*. Przyjmijmy, że jeżeli  $U/Ind(K)$  jest klasyfikacją elementów z  $U$  wyznaczoną przez wartości atrybutów z  $K$ , to zapis  $\kappa(\Omega)$  będzie oznaczał jakość klasyfikacji  $U/Ind(K)$ . Ogólnie można powiedzieć, że jakością klasyfikacji jest stopień przybliżenia klasyfikacji wyznaczonej przez wartości atrybutów ze zbioru  $K$  do klasyfikacji wyznaczonej przez wartości atrybutu  $r$ . Jest to zatem stosunek wszystkich „poprawnie” zaklasyfikowanych obiektów do liczby wszystkich obiektów z  $U$ . „Poprawnie” zaklasyfikowane obiekty to te, które są elementami dolnych przybliżeń zbiorów. Pojęcie jakości klasyfikacji można zatem sprecyzować następująco:

niech  $\chi$  będzie rodziną zbiorów, której elementami są  $\underline{K}Y_1$  oraz  $\underline{K}Y_2$  natomiast  $\Sigma\chi$  oznacza sumę rodziny  $\chi$ . Wówczas jakość klasyfikacji  $U/Ind(K)$  określimy<sup>10</sup>:

$$\kappa(\Omega) = \frac{\text{card}(\Sigma\chi)}{\text{card}(U)}$$

W przypadku systemu informacyjnego z tabeli 2 wartość  $\text{card}(\Sigma\chi) = 6$ , natomiast  $\text{card}(U) = 8$ . Zatem dla tego systemu informacyjnego:

$$\kappa(\Omega) = 6/8 = 0,75.$$

Sprecyzowanie pojęcia *jakości klasyfikacji* pozwala w prosty sposób zidentyfikować atrybuty, które nie są przyczynowo istotne dla efektów terapii. Intuicja jest następująca: dany atrybut  $f_i$  nie jest przyczynowo istotny dla efektów terapii wówczas, gdy usunięcie go ze zbioru atrybutów nie zmniejsza dokładności przybliżenia dla żadnej klasy wyleczenia, innymi słowy, usunięcie go nie powoduje zmiany dokładności przybliżenia dla żadnej klasy abstrakcji wyznaczonej wartością atrybutu  $r$ . Jeżeli natomiast nie zmienia się dokładność przybliżenia żadnej klasy abstrakcji, to

<sup>10</sup> Jak widać, łatwo stwierdzić:  $0 \leq \kappa(\Omega) \leq 1$ .

nie zmieni się również wartość jakości klasyfikacji. Wykorzystując zatem dotychczasowe ustalenia, można wprowadzić pojęcie *atrybutu zbędnego*:

Atrybut  $f_i$  określimy mianem atrybutu zbędnego w zbiorze atrybutów  $K$  wtw, gdy  $U/Ind(K) = U/Ind(K - \{f_i\})$ . W przeciwnym razie atrybut jest niezbędny.

Rozważmy przykład: (i) niech zbiór pacjentów  $U = \{a_1, a_2, a_3, a_4, a_5, a_6\}$ , (ii) zbiór  $K = \{f_1, f_2, f_3\}$  to zbiór atrybutów charakteryzujących pacjentów przed terapią, (iii) efekty terapii określone zostały za pomocą atrybutu  $r$  przyjmującego wartości 0 lub 1, (iv) informacje o poszczególnych pacjentach ilustruje tabela 3.

**Tabela 3.** Przykład systemu informacyjnego zawierającego zbędny atrybut

	$f_1(a_i)$	$f_2(a_i)$	$f_3(a_i)$	$r(a_i)$
$a_1$	0	1	1	1
$a_2$	1	0	1	1
$a_3$	1	1	2	1
$a_4$	0	1	2	1
$a_5$	1	0	1	0
$a_6$	0	1	0	0

Zgodnie z dokonanymi wcześniej ustaleniami dla dowolnego zbioru atrybutów można określić relację nierozróżnialności wyznaczającą klasy abstrakcji w zbiorze  $U$ . Załóżmy, że  $K' = \{f_1, f_2, f_3, r\}$ . Wówczas relacja nierozróżnialności generowana przez zbiór atrybutów  $K'$  wyznacza następującą klasyfikację pacjentów w zbiorze  $U$ :

$$U/Ind(K') = \{\{a_1\}, \{a_2\}, \{a_3\}, \{a_4\}, \{a_5\}, \{a_6\}\}.$$

Ustalmy klasy abstrakcji generowane przez poszczególne zbiory  $A_i \subseteq K'$ .

Dla  $A_1 = K' - \{f_3\}$  relacja nierozróżnialności wyznacza klasyfikację:

$$U/Ind(A_1) = \{\{a_1, a_4\}, \{a_2\}, \{a_3\}, \{a_5\}, \{a_6\}\}.$$

Ponieważ  $U/Ind(A_1) \neq U/Ind(K')$ , zatem atrybut  $f_3$  jest niezbędny w  $K'$ .

Z kolei dla  $A_2 = K' - \{f_1\}$  relacja nierozróżnialności wyznacza klasyfikację:

$$U/Ind(A_2) = \{\{a_1\}, \{a_2\}, \{a_3, a_4\}, \{a_5\}, \{a_6\}\}.$$



Podobnie jak poprzednio okazuje się, że  $U/Ind(A_2) \neq U/Ind(K')$ . Zatem atrybut  $f_1$  jest również niezbędny w zbiorze  $K'$ .

Dla  $A_3 = K' - \{f_2\}$  relacja nierozróżnialności wyznacza klasyfikację:

$$U/Ind(A_3) = \{\{a_1\}, \{a_2\}, \{a_3\}, \{a_4\}, \{a_5\}, \{a_6\}\}.$$

Jak widać,  $U/Ind(A_3) = U/Ind(K')$ . Zatem atrybut  $f_2$  nie jest przyczynowo istotny dla efektów terapii. Atrybut ten może być pominięty w procesie podejmowania decyzji klinicznych, nie różnicuje on bowiem pacjentów ze względu na efekty terapii.

Możliwość identyfikowania nieistotnych dla efektów terapii atrybutów przedterapeutycznych jest bardzo ważnym wyróżnikiem metody RST. Rozwój technik diagnostycznych zarówno w zakresie diagnostyki obrazowej, jak i diagnostyki biochemicznej pozwala uzyskiwać coraz więcej informacji o stanie pacjentów. Techniki te umożliwiają zdiagnozowanie choroby we wczesnym stadium oraz monitorowanie jej przebiegu. Wiadomo, że pacjenci, u których rozpoznano tę samą jednostkę chorobową, mogą różnić się wartościami wielu wskaźników diagnostycznych. Niejednokrotnie, odmienne wartości tych wskaźników mogą mieć kluczowe znaczenie dla efektów terapii. Z drugiej strony, zdarza się również tak, że różne wartości danego wskaźnika diagnostycznego nie mają żadnego wpływu na przebieg terapii [Rzepiński, 2007]. W takim przypadku użyteczność danego wskaźnika ogranicza się wyłącznie do procesu diagnozy, natomiast w procesie podejmowania decyzji terapeutycznych informacje o jego wartościach są zbędne. Nie ulega wątpliwości, że możliwość identyfikowania zbędnych dla procedury terapeutycznej informacji stanowi bardzo ważną zaletę teorii RST.

### **Przykład zastosowania teorii zbiorów przybliżonych w analizie danych klinicznych**

Pierwsze zastosowanie teorii zbiorów przybliżonych w ocenie danych medycznych zostało przedstawione w pracy Krzysztofa Słowińskiego [Słowiński, 1990, 1992; Pawlak, Słowiński i in., 1986]. Dotyczyło ono oceny efektów terapii operacyjnej choroby wrzodowej dwunastnicy. Otóż

od lat 70. XX wieku jedną z najczęściej stosowanych metod jej leczenia była *wagotomia wysoce wybiórcza*<sup>11</sup>. Technika ta polega na selektywnym przecięciu nerwów odpowiedzialnych za nadmierne wydzielanie soku żołądkowego. Spośród różnych technik operacyjnych ta powodowała najmniej uszkodzeń organów, co pozwalało zachować ich funkcję i gwarantowało utrzymanie określonego komfortu życia, jednak chirurdzy nie byli zgodni w ocenie jej długoterminowych efektów [Słowiński, 1990, s. 5]. W literaturze przedmiotu opisywane były zarówno przypadki pacjentów, u których stwierdzono poprawę po przeprowadzonej terapii, jak i pacjentów, którym nie przyniosła ona żadnych korzyści. Uzyskiwanie niezgodnych wyników wskazywało na wpływ czynników zakłócających przebieg terapii.

W omawianym przypadku rozważanymi czynnikami zakłócającymi były: czas trwania choroby, powikłania wrzodu, zalegająca objętość soku żołądkowego, stężenie kwasu solnego itp. Cechy te stanowiły zbiór wskaźników diagnostycznych. Różne ich wartości mogły identyfikować odmienne stany choroby wrzodowej dwunastnicy. Ponadto brano pod uwagę również takie cechy, których wartości nie zależały od przebiegu choroby (np. wiek i płeć), jakkolwiek przebieg choroby (oraz oczywiście efekt terapii) mógł od nich zależeć [Słowiński, 1990]. Wszystkie te cechy określić można mianem atrybutów. Uzyskiwanie odmiennych wyników terapii świadczyło o tym, że różne wartości tych atrybutów miały wpływ na efekty leczenia. Jednak chirurdzy nie byli zgodni nie tylko co do tego, jakie wartości, ale również jakie atrybuty mają zasadniczy wpływ na wyniki terapii. Odmienne precyzowano wskazania do wykonywania operacji. Niektórzy autorzy uznawali, że najistotniejszym przyczynowo atrybutem jest czas trwania choroby, inni jako podstawę dla wykonywania zabiegu przyjmowali wiek pacjenta. Najbardziej niezgodne opinie ujawniały się jednak w odniesieniu do wartości atrybutów związanych z wydzielaniem żołądkowym. Jako wskazanie do wykonywania zabiegu różni autorzy uznawali skrajne wartości tych atrybutów [Słowiński, 1990, s. 47].

---

<sup>11</sup> Do połowy lat 90. XX wieku. Później wagotomia wysoce wybiórcza została zastąpiona leczeniem farmakologicznym.

Opisana sytuacja reprezentowała problem epistemologiczny wskazany przez Worralla. Badania kliniczne dokonywałyby wyłącznie uśrednienia uzyskiwanych wyników, nie dostarczając jednoznacznych wskazań dla zróżnicowanych sytuacji problemowych [Słowiński, 1990, s. 5–6]. Pragnąc określić wskazania do podjęcia terapii, należało ustalić, które z rozważanych atrybutów są przyczynowo istotne oraz jakie ich wartości przesądzają o efektach terapii. W celu określenia takiego algorytmu decyzyjnego zastosowano metodę analizy danych wykorzystującą teorię zbiorów przybliżonych.

Oceniając skuteczność wagotomii wysoce wybiórczej, brano początkowo pod uwagę jedenaście atrybutów charakteryzujących 122 pacjentów poddanych w przeszłości temu zabiegowi. Określając długoterminowe efekty terapii, posługiwano się czterostopniową klasą Visicka<sup>12</sup>. Stwierdzono, że wyeliminowanie dwóch spośród branych pod uwagę jedenastu atrybutów nie zmniejsza jakości klasyfikacji pacjentów z uwagi na przyjęte klasy wyleczenia. Atrybuty te rozpoznano zatem jako zbędne w procesie ustalania wskazań do podejmowania terapii. W odniesieniu do pozostałych dziewięciu atrybutów sprawdzano, w jakim stopniu zmniejszy się jakość klasyfikacji przy usuwaniu kolejnych z nich. Postępowano przy tym w ten sposób, że najpierw usuwano pierwszy i sprawdzano jakość klasyfikacji dla pozostałych ośmiu. Następnie usuwano drugi i sprawdzano jakość klasyfikacji dla pierwszego i pozostałych siedmiu itd. Ostatecznie wyróżniono pięć (A–E) najbardziej istotnych dla efektów terapii atrybutów. Usunięcie któregośkolwiek z nich prowadziło do bardzo znaczącego obniżenia jakości klasyfikacji (z wartości początkowej 0,98 do wartości 0,4). Eliminowanie pozostałych czterech atrybutów (F–I) prowadziło do nieznacznego obniżenia jakości klasyfikacji (średnio do wartości 0,8) [Słowiński, 1990]. Wskazanie najbardziej istotnych atrybutów przedoperacyjnych pozwoliło ustalić modele pacjentów dla poszczególnych klas wyleczenia. Określono, przy jakich wartościach atrybutów zastosowanie wagotomii wysoce wybiórczej będzie prowadziło do określonych efektów terapeutycznych. Uzyskano zatem algorytm decyzyjny o charakterze deterministycznym.

<sup>12</sup> Jest to skala rangowa umożliwiająca ocenę efektów terapii choroby wrzodowej. Bliższa charakterystyka tej skali w niniejszym artykule jest niepotrzebna.

nym dla określonych wartości atrybutów. Algorytm ten pozwalał formułować przewidywania dotyczące stanu pacjentów po przeprowadzonej terapii ze względu na przedoperacyjne wartości atrybutów.

### **Założenia epistemologiczne metody RST**

Dla filozofa nauki zastosowanie teorii zbiorów przybliżonych w ocenie danych medycznych może być szczególnie interesującym przedmiotem analiz epistemologicznych. Warto przyjrzeć się, jakiego rodzaju założenia leżą u podstaw teorii RST i w jaki sposób wpływają one zarówno na procedurę selekcji informacji, jak i na sposoby ich wykorzystywania. Poniżej sformułowane zostały najistotniejsze zastrzeżenia wobec założeń przyjmowanych dla potrzeb analizy RST.

#### **A) Problem wielkości ilościowych w analizie RST**

Po pierwsze, należy zauważyć, że wiele z atrybutów charakteryzujących stan pacjenta to atrybuty, którym przypisywane są wartości ze zbioru liczb rzeczywistych (np. wyniki większości badań biochemicznych). Mamy zatem do czynienia z wielkościami ilościowymi, tymczasem zastosowanie metody RST wymaga charakterystyki pacjenta przeprowadzonej za pomocą wielkości jakościowych. Dla potrzeb RST konieczne jest zatem przekształcenie wielkości ilościowych na wielkości jakościowe reprezentowane za pomocą np. liczb całkowitych ze zbioru  $\{0, 1\}$  lub odpowiednio większego  $\{0, 1, 2\}$  itp. Przykładowo, przyjmujemy, że dla zakresu wartości atrybutu  $f_i$ , mieszczącego się w przedziale od 0,3 do 7,8 wartość atrybutu  $f_i = 0$ . Z kolei dla zakresu wartości powyżej 7,8 przyjmujemy, że  $f_i = 1$  itd. Podkreślić należy, że zróżnicowanie pacjentów z uwagi na wartości atrybutów przed terapią nie opiera się na różnicy: norma/patologia. Co więcej często nie odwołuje się nawet do ustalonych w zakresie diagnostyki wartości referencyjnych. Przekształcenie to ma charakter arbitralny. Dlatego też zwolennicy stosowania statystycznych metod oceny danych mogą twierdzić, że przekształcenie tego rodzaju jest uproszczeniem in-

formacji klinicznych, które może doprowadzić do błędnej oceny terapii. Rozważmy prosty przykład: przyjmijmy, że dysponujemy danymi dziesięciu pacjentów. U ośmiu z nich wartość atrybutu  $f_i = 7,7$ , u pozostałych dwóch wartość tego atrybutu wynosi  $0,7$ . Z perspektywy analiz statystycznych zakwalifikowanie pacjentów z wartością  $7,7$  do tej samej grupy, do której zakwalifikowaliśmy pozostałych dwóch pacjentów, jest błędem, prowadzi to bowiem do zafałszowania w ocenie informacji. Wykorzystując natomiast analizę statystyczną, można określić korelacje pomiędzy wartościami atrybutu  $f_i$  wyrażonymi ilościowo a wynikiem terapii.

W nawiązaniu do wskazanego zastrzeżenia rozważmy jeszcze jeden przykład. Przyjmijmy, że dla danego atrybutu  $f_i$ , którym jest stężenie pewnej substancji w organizmie, ustalony jest zakres wartości referencyjnych od  $0,3$  do  $0,78$ . U osób z rozpoznaną chorobą  $D$  zaobserwowano przekroczenie wartości  $0,78$ . Atrybut  $f_i$  może oczywiście stanowić wskaźnik diagnostyczny choroby  $D$ <sup>13</sup>. Załóżmy, że wartość tego atrybutu w rozważanej grupie osób chorych mieści się w przedziale od  $0,78$  do  $13$ . W tym miejscu pojawia się problem: w jaki sposób wyróżnić przedziały wartości dla atrybutu  $f_i > 0,78$ , które byłyby istotne dla efektów terapii? Najbardziej oczywistą odpowiedzią byłoby uznanie, że decydującym jest stopień rozwoju choroby. Przykładowo, wraz z rozwojem choroby zwiększa się wartość atrybutu  $f_i$ , tak, że w końcowej fazie osiąga wartość  $13$ . W takim przypadku nie ma jednak sensu angażowania metody RST dla ustalenia dosyć oczywistej zależności określającej, że mniej skuteczne są terapie stosowane w późniejszych fazach choroby.

Znacznie bardziej interesujący jest przykład, w którym wartość wskaźnika  $f_i$  dla różnych pacjentów nie jest skorelowana z etapem choroby, lecz zależy od pewnych dodatkowych – nieznanymi terapeutom – czynników. W takiej sytuacji nie ma jasności, jaka wartość atrybutu (niska, wysoka czy też bardzo wysoka) jest korzystna dla efektów terapii. Problem polega na tym, że nie wiemy, w jaki sposób wyróżnić zakresy tych wartości. Czy należy przyjąć, że niski zakres obejmuje wartości od

<sup>13</sup> Pominięta w tym miejscu zostaje kwestia ustalenia efektywności tego wskaźnika w rozpoznawaniu schorzenia  $D$ . W szczególności problem czułości i swoistości diagnostycznej testów.

0,78 do 3,4, czy może tylko do 2,6? Wybór jest w tym przypadku całkowicie arbitralny. Przybliżmy tę kwestię.

Przyjmijmy, że analiza danych medycznych dokonana metodą RST wykazała, że część pacjentów posiadających te same wartości atrybutów przed terapią należy do różnych klas wyleczenia. Można sformułować dwa wyjaśnienia uzyskanych wyników:

1) po pierwsze, zaobserwowanie niespójnych efektów terapii świadczyć może o tym, że nie wzięliśmy pod uwagę nieznanego nam atrybutu, który dodatkowo różnicuje przedterapeutyczne charakterystyki pacjentów. Innymi słowy, nie posiadamy wyczerpującej wiedzy o czynnikach wpływających na przebieg terapii. Przyjęcie tego rodzaju wyjaśnienia, stanowiące punkt wyjścia dla zastosowania teorii RST, wskazuje na ważną kwestię metodologiczną. Otóż, stosując metodę RST w ocenie informacji klinicznych, powinniśmy dysponować kryterium wstępnej selekcji atrybutów, które są rozpoznawane jako potencjalnie przyczynowo istotne dla efektów terapii. Należy wyraźnie podkreślić, że sama teoria zbiorów przybliżonych takiej metody selekcji atrybutów nie dostarcza, dlatego też w praktyce klinicznej zastosowanie teorii RST ogranicza się najczęściej do analizy tych atrybutów, które występują jako wskaźniki diagnostyczne danej choroby;

2) drugie wyjaśnienie niespójnych efektów terapii jest natomiast takie, że zostały przyjęte błędne zakresy wartości dla poszczególnych atrybutów. Niespójność uzyskanych wyników można wówczas wyeliminować, modyfikując je. Jeżeli dopasujemy zakresy wartości atrybutów tak, aby wyeliminować wyniki niespójne, to uzyskamy system informacyjny z bardzo wysoką wartością jakości klasyfikacji.

Problem polega na tym, że nie wiemy, które wyjaśnienie jest prawidłowe. Nie jesteśmy bowiem w stanie ustalić, czy niespójne wyniki są rezultatem pominięcia ważnego przyczynowo atrybutu, czy też stanowią efekt błędnego wyróżnienia zakresów wartości dla atrybutów, które zostały uwzględnione w analizie<sup>14</sup>. W kontekście drugiego z rozważanych wy-

<sup>14</sup> Warto przy tej okazji zwrócić uwagę na fakt, że w praktyce klinicznej problem ten ulega znacznie większemu skomplikowaniu, efekty terapii są bowiem bardzo często oceniane na podstawie tzw. miękkich punktów końcowych. Najogólniej, termin „miękkie punkty końcowe” odnosi się do wielkości, których pomiar jest niejednoznaczny, najczęściej

jaśniej warto jest powrócić do problemu wyróżniania zakresów wartości atrybutów. Wskazane zostało, że muszą one być wyznaczane w sposób arbitralny. W praktyce ocenia się jednak, czy zostały prawidłowo wyznaczone, odwołując się do wartości jakości klasyfikacji. Przyjrzyjmy się temu kryterium, nawiązując do omówionego przykładu wagotomii wysoce wybiórczej.

Przypomnijmy, że w przypadku oceny wagotomii wysoce wybiórczej analiza RST obejmowała 122 pacjentów. Tylko czterech z nich, mając taką samą charakterystykę atrybutów przedoperacyjnych, należało do różnych klas wyleczenia. Jak pisze Słowiński: „Świadczy to o prawidłowej definicji norm dla atrybutów. Gdyby normy te były zdefiniowane nieprawidłowo, [...] pacjenci należeliby do różnych klas. Wtedy jakość klasyfikacji byłaby znacznie niższa” [Słowiński, 1990, s. 32] Mamy zatem do czynienia z sytuacją, w której jakość klasyfikacji stanowi kryterium wyznaczania zakresów wartości atrybutów. Innymi słowy, uznaje się, że wysoka początkowa jakość klasyfikacji świadczy o przyjęciu prawidłowego zakresu dla wartości atrybutów. Jednakże przyjęcie jakości klasyfikacji jako kryterium wyznaczania zakresów wartości atrybutów budzi istotne zastrzeżenia epistemologiczne. Przeprowadzone wnioskowanie, mające na celu ustalenie doniosłości przyczynowej poszczególnych atrybutów, przybiera bowiem wówczas postać błędnego koła. Przybliżmy tę kwestię.

Przyjmijmy, że wysoka wartość jakości klasyfikacji będzie stanowiła kryterium świadczące o przyjęciu prawidłowego zakresu wartości atrybutów. Zauważmy, że jakość klasyfikacji zależy od dokładności przybliżeń poszczególnych klas. Z kolei dokładność przybliżeń poszczególnych klas pozwala określić doniosłość przyczynową poszczególnych atrybutów. Najbardziej doniosłe przyczynowo są te atrybuty, które najbardziej różni-

---

z uwagi na subiektywność oceny. Przykładowo, pacjent ocenia jakość życia, stopień odczuwanego bólu, ogólne fizyczne samopoczucie itp. Do wymienionych dwóch możliwych wyjaśnień należy zatem dołączyć jeszcze jedno. Trzeba wziąć pod uwagę, że niespójność klas wyleczenia mogła być skutkiem błędnie dokonanych pomiarów miękkich punktów końcowych terapii. Podkreślić należy, że wysoka „wiarygodność” badań klinicznych jest między innymi konsekwencją stosowania tych badań w ocenie „twardych” punktów końcowych takich jak zgon, zawał serca, udar mózgu, potrzeba hospitalizacji, potrzeba transfuzji itp. Wiarygodność wyników uzyskiwanych z badań dotyczących miękkich punktów końcowych jest znacznie mniejsza.

cją pacjentów. W jaki natomiast sposób uzyskać wysokie zróżnicowanie pacjentów? Przyjmując takie zakresy wartości atrybutów, jakie zapewniają wysoką jakość klasyfikacji! Mamy zatem błędne koło. Spójrzmy na przykładową tabelę ilustrującą opisaną sytuację.

**Tabela 4.** Przykładowe wartości atrybutów  $f_1, f_2$  i  $r$  dla pacjentów  $a_1, a_2, a_3$

	$f_1(a_i)$	$f_2(a_i)$	$r(a_i)$
$a_1$	0	0	<b>0</b>
$a_2$	1	0	<b>1</b>
$a_3$	1	0	<b>0</b>

Widać, że atrybutem najbardziej różnicującym pacjentów jest atrybut  $f_1$ . W rozważanym przypadku tylko ten atrybut odróżnia pacjenta  $a_1$  od pacjentów  $a_2$  i  $a_3$ . Atrybut  $f_2$  jest w istocie zbędny. Zauważmy jednak, że zmieniłoby się to wówczas, gdybyśmy zmienili zakresy jego wartości w taki sposób, że  $f_2(a_2) = 1$ . Wyeliminowalibyśmy niespójne wyniki dla pacjentów  $a_2$  i  $a_3$  oraz uzyskalibyśmy wysoką jakość klasyfikacji zapewniając tym samym doniosłość przyczynową atrybutu  $f_2$ . Aby to uzyskać, należałoby wyłącznie zmienić w odpowiedni sposób zakresy wartości atrybutów.

Widoczne jest zatem, że przyjęcie jakości klasyfikacji jako kryterium wyznaczania zakresów wartości atrybutów prowadzi do błędnego koła w procesie ustalania zależności przyczynowych metodą RST. Założenie wysokiej jakości klasyfikacji przesądza już o tym, które atrybuty będą rozpoznawane jako przyczynowo doniosłe.

## **B) Statystyczny charakter metody RST stosowanej w ocenie danych klinicznych**

Analizując założenia epistemologiczne metody RST, należy zwrócić uwagę na jeszcze jedną ważną kwestię. Otóż RST jest w istocie metodą quasi-statystyczną. Jakość klasyfikacji zależy bowiem od liczności elementów poszczególnych klas abstrakcji generowanych przez relację nieorozróżnialności. Oznacza to, że na ustalenie wartości jakości klasyfikacji



wpływ mają nie tylko wartości samych atrybutów, ale również liczba pacjentów należących do poszczególnych klas abstrakcji. Rozważmy przykład. Załóżmy, że rozpatrujemy sytuację opartą na danych przedstawionych w systemie informacyjnym tabeli 2. W paragrafie 3 obliczona została doniosłość przyczynowa atrybutu  $f_2$  dla wystąpienia efektu  $r = 0$ . Przypomnijmy, że dla rozważanego systemu informacyjnego:

$$\underline{D}f_{2|r=0} = \alpha_K(Y_I) - \alpha_{K^*}(Y_I) = 0,16.$$

Obecnie rozważmy, jak zmieni się ten wynik, jeżeli tabelę 2 uzupełnimy o pewne dodatkowe informacje. Otóż załóżmy, że zbiór pacjentów powiększymy o czterech pacjentów mających dokładnie taką samą wartość atrybutów, jaką posiadał pacjent  $a_1$ . Oznaczmy tych pacjentów symbolami:  $A_1, A_2, A_3, A_4$ . Całość informacji o pacjentach prezentuje wówczas poniższa tabela:

**Tabela 5.** Przykładowe rozszerzenie systemu informacyjnego z tabeli 2

	$f_1(a_i)$	$f_2(a_i)$	$f_3(a_i)$	$r(a_i)$
$a_1$	0	1	0	0
$A_1$	0	1	0	0
$A_2$	0	1	0	0
$A_3$	0	1	0	0
$A_4$	0	1	0	0
$a_2$	1	0	2	1
$a_3$	0	0	0	0
$a_4$	1	0	2	0
$a_5$	0	1	0	0
$a_6$	1	1	1	1
$a_7$	0	1	1	1
$a_8$	0	0	1	0

Na podstawie informacji z tabeli 5 możemy stwierdzić, że

$$\alpha_K(Y_I) = 0,8.$$

Natomiast dla zbioru  $K^* = \{K - f_2\}$

$$\alpha_{K^*}(Y_I) = 0,7.$$

Doniosłość przyczynowa atrybutu  $f_2$  dla efektu  $r = 0$  rozpatrywana na podstawie tabeli 5 wynosi zatem:

$$\underline{D}f_{2r=0} = \alpha_K(Y_1) - \alpha_{K^*}(Y_1) = 0,1.$$

Okazuje się zatem, że informacje dotyczące pacjentów od  $A_1$  do  $A_4$  zmieniają doniosłość przyczynową atrybutu  $f_2$ . Nie dziwiłoby to, gdyby uzyskane informacje różniły się od tych, które już posiadaliśmy dla pacjenta  $a_1$ . Tak jednak nie jest. Paradoksalnie, okazuje się zatem, że liczebność zbioru ma istotny wpływ na ocenę doniosłości przyczynowej atrybutów.

W praktyce klinicznej problem ten można rozwiązać, dokonując uproszczenia prowadzonej analizy i zakładając, że nie będą rozważani pacjenci mający dokładnie takie same wartości atrybutów przedterapeutycznych. Innymi słowy, należałoby przyjąć, że analizujemy wyłącznie te przypadki, gdy dany pacjent jest jedynym wzorcem, w którym następuje zestawienie określonych wartości atrybutów. Nie zmienia to jednak faktu, że statystyczny aspekt metody RST konstituuje założenie epistemologiczne posiadające wpływ na ocenę doniosłości przyczynowej atrybutów.

### Zakończenie

Teoria zbiorów przybliżonych jest jedną z wielu stosowanych wspólnie w medycynie metod oceny informacji klinicznych. Dla potrzeb jej wykorzystania stworzone zostały programy komputerowe: ROSE (*Rough Set Data Explorer*) i ProFIT (*Rough Processing of Fuzzy Information Tables*) [Prędko, Słowiński, Stefanowski i in. 1998]. Umożliwiają one szybką analizę danych medycznych i tworzenie algorytmów decyzyjnych [Słowiński, 2003, s. 411]. Metoda RST stanowi niewątpliwie interesującą alternatywę dla metod statystycznych [Krusińska, Stefanowski, Stromberg, 1994]. Pozwalając ustalić związki przyczynowe pomiędzy efektami terapii a przedterapeutycznymi wartościami atrybutów charakteryzujących pacjentów, RST staje się szczególnie ważnym narzędziem oceny informacji w przypadkach ilustrujących „fikcyjny” przykład Worralla, czyli w sytuacjach, gdy mamy uzasadnione podejrzenie, że terapia jest efek-

tywna wyłącznie dla niewielkiej grupy pacjentów charakteryzujących się określonymi cechami<sup>15</sup> [Stefanowski, Słowiński, 1997]. Jednakże zastosowanie metody RST w analizie danych klinicznych wymaga rozstrzygnięcia trzech ważnych kwestii epistemologicznych:

- (i) ustalenia niezależnego od RST kryterium wstępnej selekcji atrybutów rozważanych w systemie informacyjnym,
- (ii) ustalenia niezależnego od RST kryterium wyznaczania zakresów wartości atrybutów,
- (iii) założenia, że – z uwagi na quasi-statystyczny charakter metody RST – analizowane są wyłącznie te przypadki, w których dany pacjent jest jedynym wzorcem określonych wartości atrybutów.

Czy w świetle wskazanych zagadnień można uznać, że zastosowanie metody RST w analizie danych medycznych jest korzystniejsze niż wykonywanie klinicznych badań RCT opartych na metodologii statystycznej? Nie ulega wątpliwości, że jedną z zalet metody RST – w porównaniu z metodami statystycznymi – jest możliwość jej wykorzystania w sytuacjach, w których dysponujemy informacjami dotyczącymi bardzo dużej liczby atrybutów przy stosunkowo małej liczbie pacjentów. Metody statystyczne pozwalają ustalić korelacje wyłącznie dla niewielkiej liczby atrybutów przy stosunkowo dużej liczbie pacjentów. Każde zwiększenie liczby rozważanych atrybutów w zakresie metody statystycznej wymaga powiększenia zbioru badanych obiektów (pacjentów). W przeciwieństwie do metod statystycznych RST pozwala natomiast podejmować analizę przypadków, w których stosunek liczby pacjentów do liczby atrybutów jest bardzo niski<sup>16</sup>. Niewątpliwą wadą metody RST jest fakt, że należy ona do badań o charakterze retrospektywnym. W szczególności oznacza to, że nie można wyeliminować wpływu czynników subiektywnych na ocenę efektów terapii. Innymi słowy, nie można uniknąć tego zafałszowania,

---

<sup>15</sup> Warto nadmienić, że metoda ta jest coraz częściej wykorzystywana również poza sytuacjami oceny efektywności terapii, np. przy ocenie czułości i swoistości testów diagnostycznych.

<sup>16</sup> Podkreślić należy, że RST może być stosowane nawet w tych przypadkach, w których liczba pacjentów jest mniejsza od liczby atrybutów. Przykładem może być ocena terapii płukania otrzewnej w przypadkach ostrego zapalenia trzustki [Słowiński, 1990].

którego unikamy w przypadku badań klinicznych z randomizacją. Pomimo wskazanych zastrzeżeń wydaje się jednak, że RST może stanowić interesujące uzupełnienie stosowanych współcześnie w medycynie analiz statystycznych.

### Bibliografia

- Brzeziński Z., Szamotulska K., (1997), *Epidemiologia kliniczna*, Warszawa, Wydawnictwo Lekarskie PZWL.
- Cartwright N., (1989), *Nature's Capacities and Their Measurement*, Oxford, Clarendon Press.
- Cartwright N., (2010), „What are Randomized Controlled Trials Good for?”, *Philosophical Studies* 147, s. 59–70.
- Cartwright N., Munro E., (2010), „The Limitations of Randomized Controlled Trials in Predicting Effectiveness”, *Journal of Evaluation in Clinical Practice*, 16, s. 260–266.
- Guillemin F., (2007), „Primer: the Fallacy of Subgroup Analysis”, *Nature Clinical Practice Rheumatology*, 3(7), s. 407–413.
- Hernandez A., Boersma E., Murry G., Habbema J., Steyerberg E., (2006), „Subgroup Analyses in Therapeutic Cardiovascular Clinical Trials: Are Most of them Misleading?”, *American Heart Journal*, 151(2), s. 257–264.
- Jaeschke R., Cook D., Guyatt G., (1998b), „Evidence Based Medicine (EBM), czyli praktyka medyczna oparta na wiarygodnych i aktualnych publikacjach (POWAP)”, *Medycyna Praktyczna*, 5(87), s. 113–121.
- Krusińska E., Stefanowski J., Stromberg J., (1994), „Comparability and Usefulness of Newer and Classical Data Analysis Techniques. Application in Medical Domain Classification”, [w:] *New Approaches in Classification and Data Analysis, Studies in Classification, Data Analysis and Knowledge Organization*, [ed.] E. Diddey, Berlin, Springer Verlag, s. 644–652.
- Nowakowska M., (2004), „Model badania klinicznego” [w:] *Badania kliniczne – organizacja, nadzór i monitorowanie*, [red.] M. Walter, Warszawa.
- Papineau D., (1994), „The Virtues of Randomization”, *The British Journal for the Philosophy of Science*, 45(2), s. 437–450.
- Pawlak Z. (1982), „Rough Sets”, *International Journal of Computer and Information Sciences*, 11(5), s. 341–356.
- Pawlak Z., (1991), *Rough Sets. Theoretical Aspects of Reasoning about Data*, Dordrecht, Kluwer Academic Publishers.
- Pawlak Z., (2001), „Drawing Conclusions from Data – the Rough Set Way”, *International Journal of Intelligent Systems*, 16(1), s. 3–12.

- Pawlak Z., Słowiński K i in. (1986), „Rough Classification of Patients after Highly Selective Vagotomy for Duodenal Ulcer”, *International Journal of Man-Machine Studies*, 24, s. 413–433.
- Platon, (1959), *Teajtet*, Warszawa, Państwowe Wydawnictwo Naukowe.
- Predki B., Słowiński R., Stefanowski J., Susmaga R., Wilk S., (1998), „ROSE – Software Implementation of the Rough Set Theory”, [w:] *Rough Sets and Current Trends in Computing, Lecture Notes in Artificial Intelligence*, [eds.] L. Polkowski, A. Skowron, vol. 1424, Berlin, Springer-Verlag, s. 605–608.
- Rzepiński T., (2007), „Redundant Information in Diagnostic Reasoning” [w:] *XLogK-CA-07, Proceedings of the First ILLI International Workshop on Logic and Philosophy of Knowledge, Communication and Action*, [eds.] J. Arrazola, Larrazabal Universidad del Pais, Vasco.
- Rzepiński T., (2012), „Ewidencja empiryczna w procesie podejmowania decyzji klinicznych”, *Filozofia Nauki* 3(79), s. 13–33.
- Słowiński K., (1990), *Wykorzystanie teorii zbiorów przybliżonych do analizy leczenia wrzodu dwunastnicy wysoce wybiórczą wagotomią i ostrego zapalenia trzustki płukaniem otrzewnej*, Poznań.
- Słowiński K., (1992), „Rough Classification of HSV Patients”, [w:] *Intelligent Decision Support. Handbook of Applications and Advances of the Rough Sets Theory*, [ed] R. Słowiński, Dordrecht, Kluwer Academic Publishers, s. 77–93.
- Słowiński K., (2003), „Zbiory przybliżone”, [w:] *Kompendium informatyki medycznej*, red. R. Zajdel, E. Kački, Bielsko-Biała,  $\alpha$ -medica Press, s. 403–421
- Stefanowski J., Słowiński K., (1997), „Rough Set Theory and Rule Induction Techniques for Discovery of Attributes Dependencies in Medical Information Systems”, *Proc. of the First European Symposium on Principles of Knowledge Discovery: PKDD'97*, [eds.] J. Komorowski, J. Zytkow, Trondheim, Springer LNAI, 1263, s. 36–46.
- Tuchołka H., (2004), „Uregulowania prawne prowadzenia badań klinicznych w Polsce: wybrane aspekty”, [w:] *Badania kliniczne – organizacja, nadzór i monitorowanie*, [red.] M. Walter, Warszawa.
- Walter M., (2004), „Międzynarodowe uregulowania badań klinicznych. Deklaracja Helsińska, Zasady Dobrej Praktyki Badań Klinicznych (GCP), Międzynarodowa konferencja do spraw Harmonizacji” [w:] *Badania kliniczne – organizacja, nadzór i monitorowanie*, [red.] M. Walter, Warszawa.
- Worrall J., (2002), „What Evidence in Evidence-Based Medicine?”, *Philosophy of Science*, 69(S3), s. 316–330.
- Worrall J., (2007), „Why There’s No Cause to Randomize”, *British Journal for the Philosophy of Science*, 58, s. 451–488.
- Worrall J., (2009), „Do We Need Some Large, Simple Randomized Trials in Medicine”, [w:] *EPSA Philosophical Issues in the Science*, [eds.] M. Suarez, M. Dorato, M. Redei, Heidelberg, London, New York, s. 289–303.
- Wulff H., Göttsche P., (2005), *Racjonalna diagnoza i leczenie. Wprowadzenie do medycyny wiarygodnej, czyli Evidence-Based Medicine*, Łódź, Aktis.

Yusuf S., Wittes J., i in. (1991), „Analysis and Interpretation of Treatment Effects in Subgroups of Patients in Randomized Clinical Trials”, *Journal of American Medical Association*, 266, s. 93–98.

**Epistemological Assumptions Concerning the Use of *Rough Set Theory* for Evaluating and Selecting Clinical Data**

ABSTRACT. The purpose of the present paper is to discuss the most basic intuitions that are connected with using rough set theory when evaluating clinical data. Furthermore, the article examines the epistemological assumptions that have to be made when the method is applied in formulating decision algorithms in clinical practice.

KEY WORDS: clinical decision algorithms, Randomized Control Trial, Rough Set Theory, epistemology

Tomasz Rzepiński, Zakład Logiki i Metodologii Nauk, Instytut Filozofii, Uniwersytet im. Adama Mickiewicza, ul. Szamarzewskiego 89C, 60–569 Poznań, Katedra Biologii i Ochrony Środowiska, Uniwersytet Medyczny im. Karola Marcinkowskiego w Poznaniu, ul. Rokietnicka 8, rzepinski@wp.pl