




**POLSKA AKADEMIA NAUK**  
**Instytut Badań Systemowych**

**WSPOMAGANIE INFORMATYCZNE  
ROZWOJU  
SPOŁECZNO-GOSPODARCZEGO  
I OCHRONY ŚRODOWISKA**

**Redakcja:**  
**Jan Studziński**  
**Ludostaw Drelichowski**  
**Olgierd Hryniewicz**





**WSPOMAGANIE INFORMATYCZNE  
ROZWOJU  
SPOŁECZNO-GOSPODARCZEGO  
I OCHRONY ŚRODOWISKA**

Polska Akademia Nauk Instytut Badań Systemowych

**Seria: BADANIA SYSTEMOWE**

**tom 36**

---

**Redaktor naukowy:**

**Prof. dr hab. Jakub Gutenbaum**

Warszawa 2004

**WSPOMAGANIE INFORMATYCZNE  
ROZWOJU  
SPOŁECZNO-GOSPODARCZEGO  
I OCHRONY ŚRODOWISKA**

Redakcja:

Jan Studziński  
Ludosław Drelichowski  
Olgierd Hryniewicz

**Książka wydana dzięki dotacji KOMITETU BADAŃ NAUKOWYCH**

Książka zawiera wybór artykułów poświęconych omówieniu aktualnego stanu badań w kraju w zakresie rozwoju modeli, technik i systemów zarządzania oraz ich zastosowań w różnych dziedzinach gospodarki narodowej. Wyodrębnioną grupę stanowią artykuły omawiające aplikacyjne wyniki projektów badawczych i celowych KBN.

Recenzenci artykułów:

Dr Lucyna Bogdan  
Prof. dr hab. inż. Olgierd Hryniewicz  
Dr Grażyna Petriczek  
Prof. dr hab. inż. Andrzej Straszak  
Dr inż. Jan Studziński



Senia 45187

Komputerowa edycja tekstu: Anna Gostyńska

© Instytut Badań Systemowych PAN, Warszawa 2004

**Wydawca: Instytut Badań Systemowych PAN**  
**ul. Newelska 6, 01-447 Warszawa**

Sekcja Informacji Naukowej i Wydawnictw IBS PAN  
tel. 836-68-22

Druk: Zakład Poligraficzny Urzędu Statystycznego w Bydgoszczy  
Nakład 110 egz.

**ISBN 83-85847-92-8**  
**ISSN 0208-8028**

# SYSTEM EKSPERTOWY PROGNOZOWANIA BANKRUCTW PRZEDSIĘBIORSTW\*

*Izabela Rejer*

*Uniwersytet Szczeciński  
<i\_rejer@uoo.univ.szczecin.pl>*

*The main aim of this article is to present the outcome of a survey which was carried out in order to establish a knowledge base for an expert system of a bankruptcy prediction. The main problem which was encountered during the survey was that the expert knowledge could not be acquired through the direct interviews with experts but had to be explored from the set of examples of the system's behaviour. A neural network was used to deal with this task. However, since it was not possible to explain the neural network's outputs to the expert system's user, at the end of the survey the neural network model had to be translated into fuzzy rules.*

**Keywords:** Expert system, knowledge base, fuzzy rules, neural model.

## 1. Wprowadzenie

Wiedza w systemie ekspertowym przedstawiana jest najczęściej w postaci reguł logicznych opisujących działanie badanego systemu, zdefiniowanych przez eksperta dziedzinowego (Mulawka, 1996). Nie zawsze jednak możliwe jest stworzenie bazy wiedzy w całości opartej na regułach eksperckich. W przypadku bardzo skomplikowanych systemów ekspert często nie potrafi udzielić jednoznacznej odpowiedzi na pytanie dlaczego podjął daną decyzję albo wydał dane orzeczenie. Jest to wynikiem tego, że ekspert rozwiązując pewną konkretną sytuację decyzyjną często korzysta w takim samym stopniu z ogólnie obowiązujących reguł jak i ze swojej intuicji. Ekspert czasami jest w stanie określić jedynie pewne ogólne reguły rządzące badanym systemem, natomiast wiedza szczegółowa, leżąca u podstaw wydawanych przez niego decyzji musi zostać przekształcona na reguły logiczne w inny, nie wymagający jego bezpośredniego udziału, sposób. Jednym z możliwych rozwiązań tego problemu jest wykorzystanie w procesie pozyskiwania wiedzy sieci neuronowych, umożliwiających bezpośrednią indukcję wiedzy ze zbioru przykładów opisujących zachowanie badanego systemu.

---

\* Praca wykonana w ramach projektu badawczego KBN nr 1H02C05419.

Oczywiście, tworząc system ekspertowy trzeba mieć na uwadze to, że o jakości jego działania świadczy nie tylko zgromadzona w nim wiedza, ale również sposób prezentowania jej użytkownikowi. Zadaniem systemu ekspertowego nie jest bowiem jedynie wskazanie decyzji, która powinna zostać podjęta w danej sytuacji decyzyjnej, ale również „wyjaśnienie” użytkownikowi dlaczego powinien on podjąć taką właśnie decyzję. Zastosowanie sieci neuronowej w procesie pozyskiwania wiedzy pozornie bardzo utrudnia wyjaśnianie proponowanych przez system decyzji. Wynika to z faktu, że sieć neuronowa budując modele typu „black-box”, nie pozwala użytkownikowi na bezpośredni wgląd w procesy rządzące badanym systemem. Problem ten można jednak przezwyciężyć tworząc moduł objaśniający systemu ekspertowego oparty nie bezpośrednio na modelu neuronowym, ale na regułach rozmytych wygenerowanych z tego modelu.

Niniejszy artykuł przedstawia badania, które zostały przeprowadzone w celu zbudowania bazy wiedzy dla potrzeb systemu ekspertowego do prognozowania stopnia zagrożenia bankrutwem. Z uwagi na fakt, że próby stworzenia bazy wiedzy w oparciu o wywiady z ekspertami nie dały pozytywnych rezultatów (głównie ze względu na bardzo duże różnice zdań pomiędzy poszczególnymi ekspertami), bazę wiedzy zbudowano indukując reguły rozmyte z danych pomiarowych opisujących działanie analizowanego systemu.

## 2. Opis badanego systemu

Budowę bazy wiedzy systemu ekspertowego opisywanego w niniejszym artykule rozpoczęto od zgromadzenia odpowiednio szerokiej wiedzy dziedzinowej. W tym celu ustalono zestaw 55 czynników, które zgodnie z opiniami różnych ekspertów informują o stanie ekonomicznym firmy (kilka przykładowych czynników przedstawiono w tab. 1).

**Tablica 1.** Przykładowe czynniki informujące o stanie ekonomicznym firmy

1	zysk netto / stan końcowy aktywów ogółem
2	zysk netto / przychody ogółem
3	(zysk netto + odsetki) / przychody ogółem
4	koszty finansowe / sprzedaż
5	wskaźnik bieżącej płynności
6	aktywa finansowe / zobowiązania bieżące
7	kapitał pracujący / kapitał całkowity
8	zobowiązania krótkoterminowe / przychody ze sprzedaży
9	kapitał pracujący / przychody ze sprzedaży
10	środki pieniężne / przychody ze sprzedaży
11	zobowiązania bieżące / zobowiązania ogółem
12	aktywa obrotowe / aktywa ogółem



Dane dotyczące kształtowania się wyizolowanych czynników w wybranych firmach (1091 firm) w roku 2000 zaczerpnięto z: Monitorów Polskich B, Wydziałów Gospodarczych Sądów Rejonowych oraz z bazy spółek giełdowych Notoria Serwis.

Przed rozpoczęciem budowy bazy wiedzy systemu zgromadzone dane pomiarowe musiały zostać poddane procesowi normalizacji. Działanie to było konieczne z dwóch powodów. Po pierwsze, badane zmienne wejściowe były wyrażone w odmiennych miernikach (procentowym i wartościowym) oraz cechowały się bardzo zróżnicowanymi przedziałami wartości (np.  $<0, 3>$  i  $<-10.000, 1000>$ ). Po drugie, wiele zmiennych wejściowych systemu charakteryzowało się występowaniem dużej liczby tak zwanych „outliers’ów”, czyli wartości leżących daleko poza ich typowymi przedziałami zmienności. O ile pierwszy z wskazanych problemów można było rozwiązać przy pomocy powszechnie stosowanej procedury normalizacyjnej „min-max”, o tyle w przypadku drugiego problemu standardowa metoda, polegająca na eliminacji próbek pomiarowych leżących zbyt daleko od typowych przedziałów zmienności zmiennych wejściowych, nie mogła zostać zastosowana. Wynikało to z bardzo dużej liczby potencjalnych zmiennych wejściowych badanego systemu oraz ze zbyt wysokiego procentu „outliers’ów” występującego w przypadku większości zmiennych. Przeprowadzenie w takiej sytuacji eliminacji „outliers’ów” spowodowałoby odrzucenie znacznej części danych, a więc znacznie zużyłoby wiedzę o badanym systemie. Jediną możliwością pozostawienia całej posiadanej informacji w zbiorze danych przy jednoczesnym rozwiązaniu problemu „outliers’ów” było zastosowanie właściwej procedury normalizacyjnej, odmiennej oczywiście od prostej procedury „min-max”. W opisywanych badaniach transformacji zbioru danych dokonano przy wykorzystaniu funkcji wykładniczej danej wzorem

$$x' = \begin{cases} e^{(-x*a)} & \text{dla } x > 0 \\ 1 & \text{dla } x = 0 \\ e^{(x*b)} & \text{dla } x < 0 \end{cases} \quad (1)$$

gdzie:

- $x$  – wartości źródłowe,
- $x'$  – wartości znormalizowane,
- $a, b$  – parametry funkcji wykładniczej.

Znormalizowane dane zostały następnie wykorzystane w procesie budowy modelu neuronowego analizowanego systemu, który miał stanowić podstawę do indukcji reguł rozmytych składających się na bazę wiedzy tworzonego systemu ekspertowego. W pierwszych eksperymentach związanych z budową modelu próbowano wykorzystać bezpośrednio znormalizowane dane źródłowe. Podejście to

nie pozwoliło jednak na zbudowanie modelu charakteryzującego się rozsądną wartością błędu. Minimalny błąd modelowania, który udało się uzyskać przekraczał wartość 18%. Tak wysoka wartość błędu skłoniła do wnikliwego przeanalizowania struktury zbioru danych zawierającego informacje o analizowanym problemie. W wyniku analizy odkryto wiele niejednoznaczności występujących w badanym zbiorze, związanych przede wszystkim z dwuznacznym klasyfikowaniem analogicznych zestawów danych wejściowych. Analizując strukturę zbioru zaobserwowano, że dane w pewnych podprzestrzeniach pełnej przestrzeni wejściowej tworzą dość wyraźne klaster. Nałożenie na zidentyfikowane klaster wartości zmiennej wyjściowej powodowało jednak każdorazowo utratę jednoznaczności podziału i mieszanie się klastrów. Z czego wynikała wspomniana sytuacja? Dlaczego te same wartości zmiennych wejściowych raz wskazywały na firmę kontynuującą działalność, a innym razem na firmę postawioną w stan upadłości? Odpowiedź na postawione pytanie jest stosunkowo prosta, jeżeli zostanie wzięty pod uwagę interes firmy oraz interes jej właścicieli. Złe wyniki ekonomiczne firmy nie muszą wcale oznaczać jej bankructwa, jeżeli nie leży to w interesie jej właściciela. Dopóki firma nie spełni określonych w prawie warunków może być sztucznie utrzymywana przy życiu nawet jeżeli jej wyniki są krytyczne. Możliwa jest również odwrotna sytuacja, kiedy firma o nienajgorszej kondycji ekonomicznej składa do sądu wniosek o ogłoszenie upadłości, ponieważ jest to zgodne z interesem jej właściciela.

Zadaniem systemu ekspertowego, podobnie jak zadaniem rewidenta oceniającego kondycję firmy, nie jest ustalenie czy firma zostanie w przyszłym roku prawnie ogłoszona bankrutem, lecz wydanie opinii na temat tego, czy bieżąca ekonomiczna sytuacja firmy świadczy o tym, że powinna ona zaprzestać kontynuacji działalności. Biorąc to pod uwagę uznano, że model badanego systemu nie powinien być oparty na pierwotnych danych źródłowych, informujących jedynie o tym jak zawarte w zbiorze firmy zostały sklasyfikowane z prawnego punktu widzenia, lecz powinien odzwierciedlać faktyczny, występujący w zbiorze danych, podział firm na klaster firm zdrowych i firm o słabej kondycji ekonomicznej.

Zgodnie z powyższym dokonano przekształcenia pierwotnego zbioru danych poprzez wyznaczenie klastrów próbek pomiarowych w pełnej, 55-wymiarowej, przestrzeni wejściowej badanego systemu. W celu zlokalizowania położenia poszczególnych klastrów wykorzystano rozmytą metodę c-środków (Piegat, 1999). Po przeprowadzeniu procesu klasteryzacji uzyskano zbiór złożony z 215 firm o złej kondycji ekonomicznej, 696 firm o dobrej kondycji oraz 180 firm o kondycji trudnej do ustalenia.

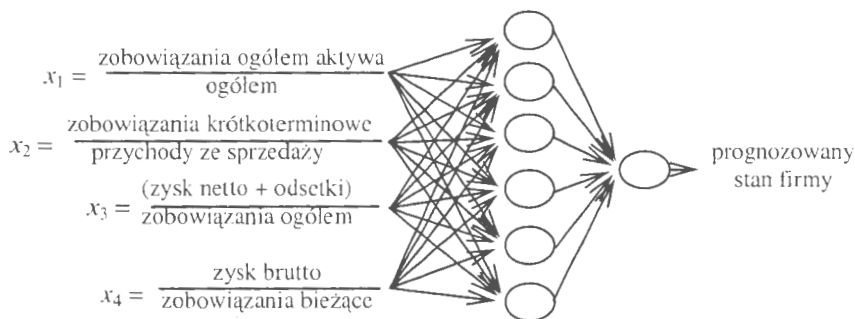
Kolejnym krokiem na drodze do budowy bazy wiedzy omawianego systemu było zredukowanie liczby czynników uznawanych przez różnych ekspertów za determinanty kondycji ekonomicznej firmy jedynie do kilku najbardziej istotnych. Do wykonania tego zadania wykorzystano metodę hierarchiczną (Sugeno, Yasukawa, 1993). Jako, że metoda ta polega na połączeniu badania istotności

potencjalnych zmiennych objaśniających z procesem modelowania, więc w wyniku jej zastosowania uzyskano model badanego systemu zawierający najbardziej istotne zmienne objaśniające.

Do budowy modeli pomocniczych konstruowanych na kolejnych etapach metody hierarchicznej wykorzystane zostały sieci neuronowe o następujących parametrach (Haykin, 1999; Reed, Marks, 1999): jednokierunkowym przepływie sygnałów, architekturze połączeń neuronów kolejnych warstw typu: każdy z każdym, jedną warstwą ukrytą zawierającą 6-10 neuronów o sigmoidalnych funkcjach aktywacji, jednym, również sigmoidalnym, neuronie wyjściowym. Algorytmem wykorzystanym do uczenia sieci neuronowych był algorytm wstecznej propagacji błędów z członem momentum i zmiennymi stopami uczenia. W procesie uczenia każdego kolejnego modelu wykorzystywano 80% losowo wybranych próbek pomiarowych, pozostałe 20% pozostawiając dla celów weryfikacyjnych. Proces uczenia każdego z modeli prowadzony był dziesięciokrotnie, przy wykorzystaniu różnych, losowo wybranych startowych wartości wag. Spośród 10-ciu nauczonych modeli do dalszych badań wybierany był każdorazowo model o najmniejszym średnim błędzie bezwzględnym i jednocześnie wysokiej zdolności aproksymacyjnej.

**Tablica 2.** Zestawienie błędów modeli tworzonych w kolejnych etapach procesu modelowania

Nazwa zmiennej dodanej do modelu	błąd uczący %	błąd testowy %
$x_1$ – zobow. ogółem/aktywa ogółem	15,98%	15,62%
$x_2$ – zobow. krótkoterminowe/przychody ze sprzed.	10,41%	10,30%
$x_3$ – (zysk netto + odsetki)/zobow. ogółem	7,79%	7,80%
$x_4$ – zysk brutto/zobow. bieżące	3,47%	3,56%




**Rysunek 1.** Model neuronowy analizowanego systemu

Zestawienie zmiennych dodawanych do tworzonego modelu w kolejnych etapach procesu modelowania wraz z zestawieniem błędów uczących i testowych kolejno tworzonych modeli przedstawia tab. 2. Z zestawienia tego wynika, że ostateczny model neuronowy (rys. 1) zawierał zmienne: *zobowiązania ogółem/aktywa ogółem*, *zobowiązania krótkoterminowe/przychody ze sprzedaży*, *(zysk netto + odsetki)/zobowiązania ogółem* oraz *zysk brutto/zobowiązania bieżące* i charakteryzował się wartością błędu równą 3,47%.

### 3. Indukcja reguł rozmytych z modelu neuronowego

Jedną z podstawowych cech systemu ekspertowego, odróżniającą go od innych klas systemów jest to, że pozwala on na uzasadnienie generowanej przez siebie opinii, na przykład poprzez wskazanie zestawu reguł, które zostały uruchomione w procesie wnioskowania. Opisany w poprzednim punkcie model nie mógł zostać bezpośrednio zastosowany w procesie tłumaczenia generowanych decyzji, ponieważ, tak jak każdy inny model neuronowy, był on przedstawicielem klasy modeli „black-box”, czyli modeli o bezpośrednio nieidentyfikowalnych procesach wewnętrznych. W rzeczywistości wiedza o charakterze zależności występujących w systemie była zaszyta wewnątrz modelu, a do jej wydobycia na zewnątrz konieczne było jedynie przekształcenie modelu neuronowego w model regułowy. W celu zwiększenia precyzji sądów generowanych przez model, opracowano nie klasyczny model regułowy zawierający reguły typu: *jeśli  $x=a$  to  $y=b$* , lecz model zawierający reguły rozmyte typu: *jeśli  $x$  około  $A$  to  $y$  około  $B$* .



**Rysunek 2.** Funkcje przynależności wyznaczone dla poszczególnych zmiennych wejściowych modelu

W celu przekształcenia opisanego w poprzednim punkcie modelu neuronowego w model rozmyty przedział zmienności każdej zmiennej wejściowej

występującej w modelu został podzielony na pięć obszarów, które opisano trójkątnymi funkcjami przynależności, o charakterystykach zaprezentowanych na rys.2.

Punkty podparcia utworzonych funkcji przynależności zostały następnie wykorzystane w przesłankach kolejnych reguł. Pojedyncze przesłanki formułowane były przy pomocy spójnika „około”, np.  $x_1$  około 0.25,  $x_3$  około 0.75, natomiast ich łączenia dokonywano przy wykorzystaniu spójnika „I”, np.  $x_1$  około 0.25 I  $x_2$  około 0.75. Część przesłankowa każdej reguły składała się z czterech przesłanek, odpowiadającym funkcjom przynależności kolejnych zmiennych wejściowych modelu. Po opracowaniu części przesłankowej wszystkich możliwych reguł, przystąpiono do ustalania ich konkluzji. Zadanie to wykonano podając na wejścia modelu neuronowego wektory własne reguł i odczytując wygenerowane przez model wartości wyjściowe. W efekcie powstał zbiór 625 reguł, o singletonowych funkcjach przynależności konkluzji, z których kilka przykładowych zaprezentowanych zostało poniżej:


- jeżeli ( $x_1$  około 0) i ( $x_2$  około 0.5) i ( $x_3$  około 0.25) i ( $x_4$  około 1)  
to  $y$  około 0.5
- jeżeli ( $x_1$  około 0.75) i ( $x_2$  około 0) i ( $x_3$  około 0) i ( $x_4$  około 0.75)  
to  $y$  około 0.8
- jeżeli ( $x_1$  około 0.5) i ( $x_2$  około 0.5) i ( $x_3$  około 0.5) i ( $x_4$  około 0)  
to  $y$  około 0.6
- jeżeli ( $x_1$  około 0) i ( $x_2$  około 0.25) i ( $x_3$  około 0) i ( $x_4$  około 1)  
to  $y$  około 0.2

Pierwotna baza reguł miała jedną podstawową wadę bardzo ograniczającą jej praktyczną użyteczność. Wadą tą było oparcie części przesłankowej reguł na znormalizowanych wartościach zmiennych wejściowych, przez co reguły stawały się zupełnie niezrozumiałe dla użytkowników systemu. Teoretycznie wskazaną wadę można było wyeliminować wykorzystując jeden z dwóch sposobów. Po pierwsze można było zbudować bazę reguł w oparciu o pierwotne, nieznormalizowane wartości zmiennych wejściowych, po drugie można było zdenormalizować przesłanki reguł zawartych w pierwotnej bazie reguł. Pomimo, że pierwsze rozwiązanie byłoby mniej pracochłonne, to jednak nie mogło ono zostać zastosowane w prowadzonych badaniach z uwagi na wykorzystanie modelu neuronowego w procesie obliczania konkluzji reguł. Prawidłowe działanie modelu neuronowego jest bowiem w dużej mierze zależne od wprowadzanych do niego wartości wejściowych, które powinny pochodzić z przedziału liczbowego wykorzystywanego w procesie uczenia, czyli w przypadku opisywanego modelu z przedziału (0, 1).

Z uwagi na powyższe w celu ułatwienia użytkownikowi zrozumienia reguł rządzących analizowanym problemem, przed wprowadzeniem bazy reguł do

tworzonego systemu ekspertowego przesłanki zawartych w niej reguł poddano procesowi denormalizacji. Proces denormalizacji przeprowadzono przy wykorzystaniu funkcji logarymicznej, uzyskując wartości przedstawione na rys. 3. Oczywiście funkcja logarymiczna mogła zostać bezpośrednio wykorzystana do obliczenia rzeczywistych wartości jedynie dla liczb: 0.25, 0.5, 0.75 i 1. Jeżeli chodzi natomiast o występującą w przesłankach niektórych reguł liczbę 0, dla której nie istnieje wartość funkcji logarymicznej, to została ona wyznaczona na podstawie szerokości przedziału rzeczywistego odpowiadającego przedziałowi znormalizowanemu (0.25; 0.5).

Należy w tym miejscu zwrócić uwagę na jeden bardzo ważny aspekt, który pojawił się w wyniku procesu denormalizacji. Wykorzystanie funkcji wykładniczej do normalizacji zmiennych powoduje, że wartości pochodzące z pierwotnego zbioru danych zostają przekształcone do przedziału (0, 1). W przypadku kiedy w trakcie eksploatacji systemu na jego wejściach pojawiają się wartości leżące nawet bardzo daleko poza krańcami pierwotnego przedziału zmienności danej zmiennej, to i tak po dokonaniu procesu normalizacji przy wykorzystaniu funkcji wykładniczej zostaną one wtłoczone do przedziału (0, 1). Z kolei, jeżeli w trakcie eksploatacji systemu wykorzystywane będą zdenormalizowane przedziały zmienności, to może okazać się, że wartości zmiennych wprowadzone przez użytkownika znajdują się poza krańcami przedziałów zmienności, a więc nie będą pokryte żadną z reguł. Uwzględniając taką możliwość dokonano przekształcenia brzegowych funkcji przynależności każdej zmiennej z funkcji trójkątnych w funkcje trapezowe, zewnętrznie nieograniczone (rys. 3).



**Rysunek 3.** Funkcje przynależności wyznaczone dla poszczególnych zmiennych wejściowych modelu po przeprowadzeniu procesu denormalizacji

Działanie takie nie wymuszało zmiany reguł zawartych w systemie, ponieważ z uwagi na fakt że i tak nie było możliwości zbadania zachowania się systemu w obszarach nie odzwierciedlonych w próbkach uczących, dla każdej wartości danej zmiennej znajdującej się poza krańcami przedziału zmienności stosowana była ta sama reguła brzegowa.

Przekształcenie brzegowych funkcji przynależności zostało więc wykonane nie w celach obliczeniowych, lecz przede wszystkim po to aby w jeszcze większym stopniu ułatwić użytkownikowi zrozumienie prezentowanych mu reguł. W tym celu wszystkie przesłanki oparte na brzegowych funkcjach przynależności zostały zapisane w formie warunkowej, pozwalającej na zaprezentowanie użytkownikowi innego obrazu przesłanki w przypadku kiedy podałby on wartość spoza przedziału zmienności zmiennej uwzględnionej w przesłance (np.  $x_1 > 1$ ), a innego w przypadku podania przez niego wartości mieszczącej się w przedziale zmienności danej zmiennej (np.  $x_1$  około 1).

Kilka przykładowych reguł powstałych po przeprowadzeniu procesu denormalizacji przesłanek zostało zaprezentowanych poniżej:

- jeżeli ( $x_1$  około 1.54) i ( $x_2$  około 0.82) i ( $x_3$  około 0.06) i ( $x_4$  około 0.4)  
to  $y$  około 0.00%
- jeżeli ( $x_1$  około 1.54) i ( $x_2$  około 0.41) i ( $x_3 > 0.46$ ) i ( $x_4$  około 0.2)  
to  $y$  około 38.17%
- jeżeli ( $x_1$  około 0.77) i ( $x_2 > 1.22$ ) i ( $x_3$  około 0.15) i ( $x_4$  około 0.4)  
to  $y$  około 92.12%
- jeżeli ( $x_1$  około 0.32) i ( $x_2 > 1.22$ ) i ( $x_3$  około 0.15) i ( $x_4 > 0.59$ )  
to  $y$  około 81.96%

#### **4. Zakończenie**

W niniejszym artykule zostały przedstawione badania, których celem była budowa bazy wiedzy systemu ekspertowego do prognozowania bankructw przedsiębiorstw. Ciekawym aspektem przedstawionych badań był fakt, że reguły rządzące analizowanym systemem nie mogły zostać zidentyfikowane w procesie prowadzenia bezpośrednich wywiadów z ekspertami dziedzinowymi, lecz musiały zostać wyizolowane ze zbioru przykładów przedstawiających działanie systemu. W celu wykonania tego zadania zgromadzony zbiór przykładów został najpierw uogólniony przy pomocy modelu neuronowego, a następnie przekształcony na zbiór reguł rozmytych tłumaczących działanie modelu neuronowego użytkownikowi systemu.

## Literatura

- Demuth H., Beale M. (2000) *Neural Network Toolbox User's Guide*. The Math Works Inc., Natick MA USA.
- Haykin S. (1999) *Neural Networks A Comprehensive Foundation*. Prentice-Hall Inc., New Jersey.
- Mulawka J.J. (1996) *Systemy ekspertowe*. WNT, Warszawa.
- Piegat A. (1999) *Fuzzy Modelling and Control*. Physica-Verlag, New York.
- Reed R.D., Marks II R.J. (1999) *Neural Smithing – Supervised Learning in Feedforward Artificial Neural Networks*. The MIT Press, Massachusetts.
- Sugeno M., Yasukawa T. (1993) A Fuzzy-Logic-Based Approach to Qualitative Modelling. *IEEE Transaction on Fuzzy Systems*, 1, 1.



IBS PAN *Seria*

45187

Bibl. podręczna

**ISSN 0208-8028**

**ISBN 83-85847-92-8**

---

---

**W celu uzyskania bliższych informacji i zakupu dodatkowych egzemplarzy  
prosimy o kontakt z Instytutem Badań Systemowych PAN  
ul. Newelska 6, 01-447 Warszawa  
tel. 837-35-78 w. 241 e-mail: [biblioteka@ibspan.waw.pl](mailto:biblioteka@ibspan.waw.pl)**