



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

**ROZWÓJ I ZASTOSOWANIA  
METOD ILOŚCIOWYCH  
I TECHNIK INFORMATYCZNYCH  
WSPOMAGAJĄCYCH PROCESY  
DECYZYJNE**

**Redakcja:**

**Jan Studziński**  
**Ludostław Drelichowski**  
**Olgierd Hryniewicz**

**ROZWÓJ I ZASTOSOWANIA  
METOD ILOŚCIOWYCH  
I TECHNIK INFORMATYCZNYCH  
WSPOMAGAJĄCYCH PROCESY  
DECYZYJNE**

Redakcja:

Jan Studziński

Ludosław Drelichowski

Olgierd Hryniewicz

Wydanie tej publikacji było możliwe dzięki pomocy finansowej  
MINISTERSTWA NAUKI I SZKOLNICTWA WYŻSZEGO.

Książka zawiera wybór artykułów poświęconych omówieniu aktualnego stanu badań w kraju w zakresie rozwoju i zastosowań metod, modeli, technik i systemów informatycznych w procesach podejmowania decyzji. Kilka artykułów przedstawia rezultaty projektów badawczych finansowanych przez Ministerstwo Nauki i Szkolnictwa Wyższego i realizowanych przez polskie instytucje badawcze.

Recenzenci:

Prof. Olgierd Hryniewicz

Prof. Andrzej Straszak

Dr hab. Jan Studziński

Komputerowa edycja tekstu: Anna Gostyńska

© Instytut Badań Systemowych, Warszawa 2006

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

Sekcja Informacji Naukowej i Wydawnictw  
e-mail: [biblioteka@ibspan.waw.pl](mailto:biblioteka@ibspan.waw.pl)

**ISBN 83-894-7506-5**

**9788389475060**

**ISSN 0208-8029**



**ROZWÓJ I ZASTOSOWANIA  
METOD ILOŚCIOWYCH I TECHNIK  
INFORMATYCZNYCH  
WSPOMAGAJĄCYCH PROCESY  
DECYZYJNE**

Instytut Badań Systemowych • Polska Akademia Nauk  
**Seria: Badania Systemowe**  
**Tom 49**

---

Redaktor Naukowy:  
**Prof. Jakub Gutenbaum**

Warszawa 2006



## WYBRANE METODY POZYSKIWANIA WIEDZY TECHNOLOGICZNEJ

*Izabela ROJEK*

Instytut Mechaniki Środowiska i Informatyki Stosowanej,  
Uniwersytet Kazimierza Wielkiego w Bydgoszczy  
<izarojek@ukw.edu.pl>

**Streszczenie:** *Pozyskiwanie wiedzy z baz danych jest obecnie jedną z najintensywniej rozwijanych dziedzin. Jest to nieuniknione, gdyż tradycyjne systemy bazodanowe nie są w stanie efektywnie zarządzać ogromną ilością informacji, dostępną obecnie również w przedsiębiorstwach. Tradycyjny model przetwarzania danych jest satysfakcjonujący w przypadku bieżącej obsługi działalności przedsiębiorstwa (np. rejestracja zamówień, obsługa sprzedaży). Niestety ten klasyczny model przetwarzania danych nie wspomaga procesów analizy danych oraz aplikacji wspomagających podejmowanie decyzji. W referacie przedstawiono fragment badań dotyczących zastosowania wybranych metod pozyskiwania wiedzy technologicznej: sieć neuronową i metodę indukcji drzew decyzyjnych. W ten sposób pozyskana wiedza posłużyła do doboru narzędzi dla operacji technologicznej.*

**Słowa kluczowe:** Akwizycja wiedzy, sieć neuronowa, metoda indukcji drzew decyzyjnych, system ekspertowy, dobór narzędzi.

### 1. Wprowadzenie

Wiedza jako zasób w organizacji traktowana jest jako informacja połączona z doświadczeniem i użyta w określonym kontekście. Zasoby wiedzy organizacji to jej aktywa intelektualne, będące sumą wiedzy pojedynczych pracowników oraz zespołów pracowników, które organizacja wykorzystuje w swych działaniach. Zasoby wiedzy obejmują również dane i informacje, na bazie, których budowana jest wiedza indywidualna i zbiorowa. Podlegają one ciągłym zmianom, które są przejawem procesu uczenia się organizacji. Wiedzę możemy podzielić na jawną i ukrytą. Wiedza jawna to obrazy, słowa, dane. Prowadzi ona do fachowości, jest łatwa w wyrażaniu i łatwa do skopiowania. Natomiast wiedza ukryta to doświadczenie, know-how, intuicja. Jest ona trudna w artykulacji, do transferowania i skopiowania, ale daje dużą przewagę konkurencyjną (Probst, 2002)

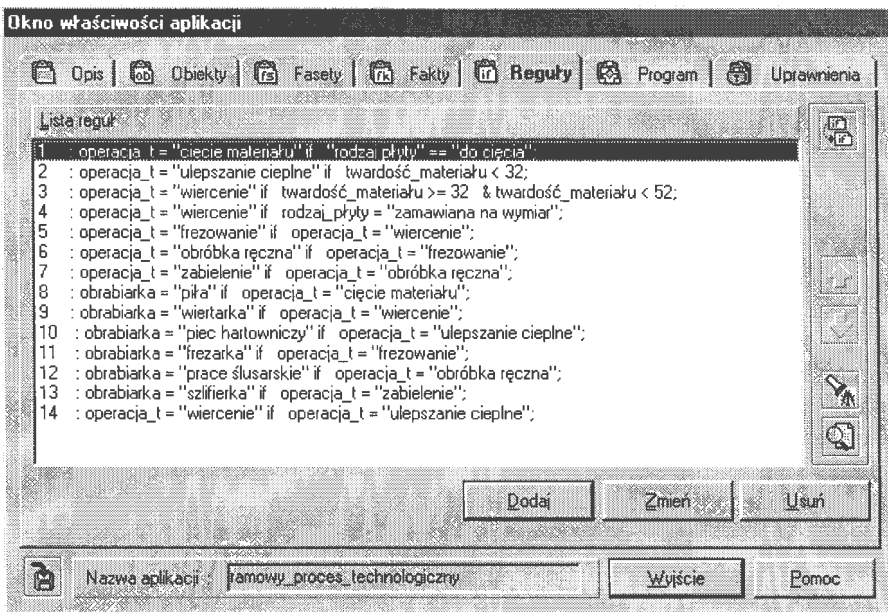
Stąd wiedza ukryta cieszy się ogromnym zainteresowaniem naukowców, którzy stosując różne metody i techniki informatyczne próbują przenieść ją do systemów informatycznych w celu dalszego jej wykorzystania.

Autorka dokonała próby przeniesienia wiedzy ukrytej do systemu informatycznego przy zastosowaniu metody tradycyjnej, sztucznych sieci neuronowych oraz metody indukcji drzew decyzyjnych.

## 2. Pozyskiwanie wiedzy technologicznej metodą tradycyjną

Pozyskiwanie danych i wiedzy dla systemu przeprowadzono zarówno metodami tradycyjnymi jak i sformalizowanymi. Dane dotyczące materiałów, środków produkcji pozyskiwane były z norm, katalogów, literatury, dokumentacji przedsiębiorstwa oraz baz danych istniejących już w przedsiębiorstwie.

Tradycyjna metoda akwizycji wiedzy polegała na obserwacji technologa i rozmowie z nim. W tej metodzie kluczową rolę odgrywał inżynier wiedzy, który obserwował pracę eksperta rozwiązującego problem, analizował wiedzę na podstawie instrukcji eksperta i realnych przykładów rozwiązanych przez eksperta oraz gromadził wiedzę na podstawie analogii. Dalej wiedzę przekazaną przez specjalistów inżynier wiedzy selekcjonował i organizował w taki sposób np. w postaci reguł systemu ekspertowego, aby mogła być ona przechowywana i efektywnie wykorzystywana przy pomocy komputera (Rysunek 1). Metoda tradycyjna została użyta w stopniu minimalnym, do określenia reguł doboru operacji technologicznych w ramowym procesie technologicznym.

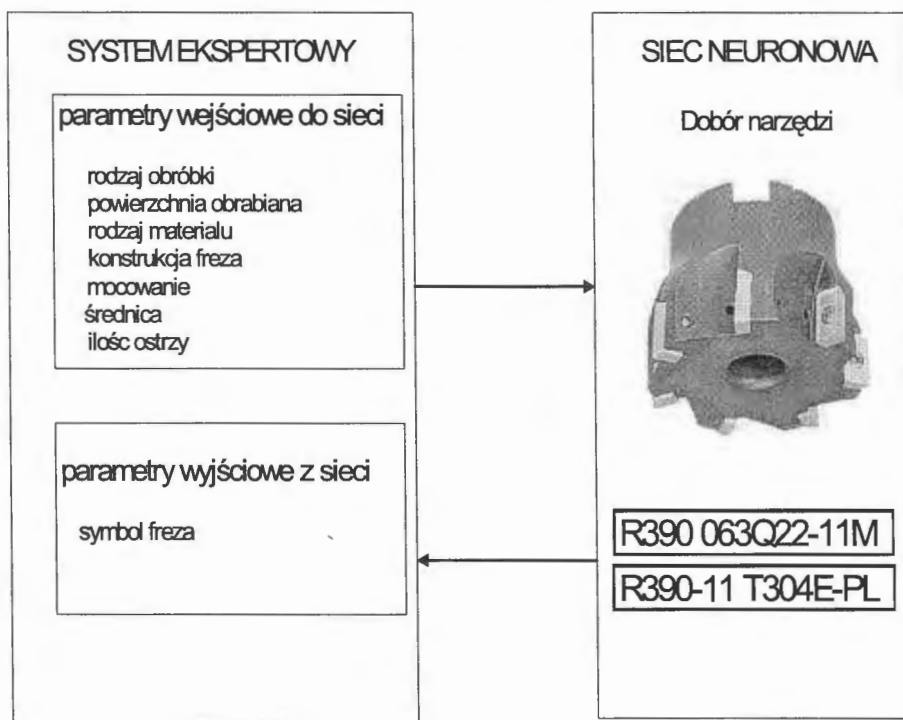


Rysunek 1. Wprowadzanie reguł metodą tradycyjną do systemu ekspertowego.

Akwizycja wiedzy do bazy wiedzy systemu ekspertowego była przeprowadzana przy użyciu systemu wspomagania inżynierii wiedzy CAKE, który przeznaczony jest do wspomagania procesu realizacji aplikacji systemu ekspertowego, uwzględniającego pozyskiwanie wiedzy od ekspertów, jej systematyzowanie oraz zapis zgodnie z przyjętym formalizmem opisu bazy wiedzy.

### 3. Pozyskiwanie wiedzy technologicznej przy użyciu sieci neuronowej

Pośród technik sformalizowanych wykorzystane zostały sieci neuronowe, których użyto do automatycznego pozyskiwania wiedzy i doświadczenia z baz danych przedsiębiorstwa bez udziału ekspertów ludzi. W przypadku użycia sieci neuronowej upraszcza się proces pozyskiwania wiedzy. Inżynier wiedzy nie musi ręcznie wpisywać reguł do systemu ekspertowego. Nauczona sieć po wprowadzeniu parametrów wejściowych daje na wyjściu wynik, który następnie może być dalej przetwarzany przez system ekspertowy. Sieć neuronowa została użyta do pozyskania wiedzy dotyczącej doboru narzędzi do operacji technologicznej.



Rysunek 2. Parametry wejściowe i wyjściowe sieci neuronowej do akwizycji wiedzy dotyczącej doboru narzędzi (Rojek, 2005).



Narzędzie było dobierane przy użyciu jednokierunkowej wielowarstwowej sieci neuronowej ze wsteczną propagacją błędów (Rutkowska i in., 1997). Wejścia sieci zawierały warunki technologiczne doboru narzędzi. Wyjścia sieci stanowiły zbiór wartości określających wyniki otrzymane w trakcie doboru narzędzi dla danych warunków. W przypadku operacji frezowania dane wejściowe do sieci neuronowej obejmują: odmianę frezowania, rodzaj powierzchni obrabianej, rodzaj i twardość materiału obrabianego, wymaganą chropowatość powierzchni, rodzaj konstrukcji i mocowania freza, średnicę freza, ilość ostrzy oraz długość całkowitą freza. Dane wyjściowe z sieci neuronowej zawierają symbol freza (Rysunek 2). Szczegółowo sieć neuronowa do pozyskiwania wiedzy do doboru narzędzi została omówiona w pracy (Rojek, 2005).

Dane dotyczące narzędzia uzyskane w wyniku działania sieci neuronowej przekazywane były do systemu ekspertowego, przy pomocy którego technolog określał parametry obróbki i parametry nastawne obrabiarki.

#### **4. Pozyskiwanie wiedzy technologicznej przy użyciu metody indukcji drzew decyzyjnych**

Pozyskiwanie wiedzy przy wykorzystaniu metody indukcji drzew decyzyjnych jest przykładem metody maszynowego uczenia. Maszynowe uczenie się obejmuje problematykę konstruowania systemów, które polepszają swoje działanie wraz z analizą doświadczenia reprezentowanego przez zbiór przykładów uczących (Cichosz, 2000). W ostatnich latach metody maszynowego uczenia się stosowane są z powodzeniem w wielu praktycznych problemach oraz stają się częścią zaawansowanych systemów informatycznych – w szczególności dotyczy to odkrywania wiedzy w bazach danych oraz tzw. eksploracji danych. Dotychczas zaproponowano wiele różnorodnych metod maszynowego uczenia się. W referacie została opisana i zastosowana metoda uczenia nadzorowanego tworzącego symboliczną reprezentację wiedzy (algorytm indukcji drzew decyzyjnych). W przypadku pozyskiwania wiedzy drzewa decyzyjne wykazały się większą przydatnością i prostotą pozyskiwania wiedzy niż sieci neuronowe, ze względu na możliwość przedstawiania danych w postaci symbolicznej, którym można przypisać interpretacje. Postać ta jest czytelna i zrozumiała dla człowieka. Natomiast w przypadku sieci neuronowych podczas procesu uczenia się nie wypracowuje się w sposób jawny symbolicznej reprezentacji wiedzy. Powstają natomiast wewnętrzne zapisy informacji, które nie są jednak tak łatwo i bezpośrednio interpretowalne lub zrozumiałe dla człowieka.

Metoda indukcji drzew decyzyjnych pozwala na przybliżenie funkcji klasyfikacyjnych o dyskretnych wartościach wyjściowych odnoszących się do pewnych pojęć, klas decyzyjnych. Na bazie przykładów dobranych narzędzi do operacji technologicznych zawartych w bazie danych, wyselekcjonowanych przez ekspertów technologów system uczy się dobierać narzędzia obróbkowe.

W metodzie indukcji drzew decyzyjnych budowane jest drzewo decyzyjne, które pozwala na dokonanie klasyfikacji całego zbioru przykładów uczących na jednorodne klasy. Drzewa decyzyjne wygenerowane z przykładów uczących są często wykorzystywane do klasyfikowania nowych obiektów, tzn. określenia ich przydziału do klasy decyzyjnej. W takim zastosowaniu drzewa pełnią funkcję klasyfikatorów (Krawiec i in., 2004).

Ocena przydatności drzew do klasyfikowania nowych obiektów dokonana została przez ocenę trafności klasyfikowania w odniesieniu do zbioru przykładów testowych. Jednak podczas generowania jak najlepszych drzew- klasyfikatorów można napotkać trudności, zwłaszcza, jeśli rzeczywiste dane zawierają sprzeczne, lub niekompletne opisy przykładów uczących. W algorytmach indukcji drzew, takich jak C4.5, Assistant lub CART, wprowadzono różne rozszerzenia, które mają na celu polepszenie zdolności klasyfikacyjnych drzew w takich sytuacjach. Do najważniejszych z nich należą rozszerzenia związane z przecuciem i z metodą uproszczenia rozmiarów drzew (tzw. przycinanie).

W algorytmach uczenia się drzew decyzyjnych poszczególne gałęzie są rozbudowywane tak głęboko, aż przykłady w węźle zostaną zaklasyfikowane do pojedynczej klasy decyzyjnej. Powyższy sposób postępowania zakłada niejawnie, że przykłady uczące się są zdefiniowane poprawnie. Oznacza to m.in., że nie występują przykłady sprzeczne lub szum informacyjny.

Ponadto liczba przykładów uczących może być zbyt małą dla stworzenia reprezentatywnej próbki pewnych pojęć decyzyjnych.

W takich sytuacjach podczas indukcji drzew decyzyjnych możemy mieć do czynienia ze zjawiskiem przecięcia klasyfikatora, nazywanym także nadmiernym dopasowaniem do zbioru uczącego. Zjawiska nadmiernego dopasowania drzewa do danych uczących można unikać lub minimalizować jego wpływ na zdolność klasyfikowania poprzez właściwą redukcję rozmiarów drzewa, czyli przycinanie.

System DeTreex, użyty do implementacji systemu oferuje możliwość ingerencji w opcje generowanego drzewa decyzyjnego. Mamy do wyboru dwie opcje: minimalna liczba przykładów tworzących liść drzewa oraz przycinanie drzewa decyzyjnego. Opcja przycinania drzewa decyzyjnego zapobiega nadmiernemu dopasowaniu się danych. Możliwe jest również podanie wartości jak mocno ma być przycięte drzewo. Wartość tę podajemy w procentach. W przedstawionym przykładzie wykorzystano metodę przycinania pełnego drzewa (o 25%) oraz ustalono minimalną liczebność zbioru przykładów przed podziałem w węźle na 2.

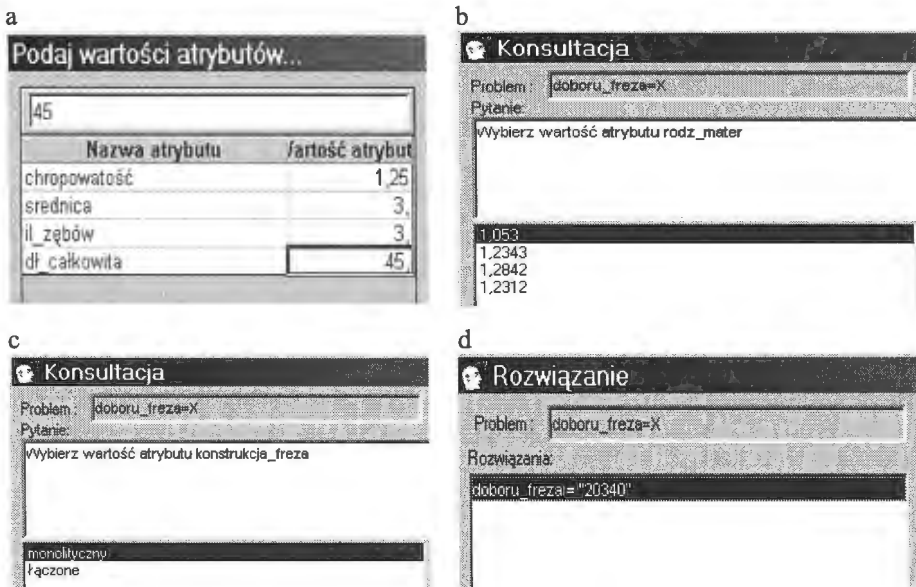
Drzewo jest wykorzystane do klasyfikacji narzędzi w następujący sposób: rozpoczynając od korzenia drzewa sprawdzana jest wartość atrybutu związanego z bieżącym węzłem (np. rodzaj materiału obrabianego); następnie przesuujemy się do kolejnego wierzchołka wzdłuż gałęzi odpowiadającej wartości atrybutu (np. rodzaj materiału obrabianego = 1,053); proces jest powtarzany dla poddrzew związanych z tym wierzchołkiem, dopóki nie osiągniemy liścia wskazującego klasę

(np. symbol freza = 20340). Na podstawie drzewa decyzyjnego tworzone są reguły decyzyjne, które są następnie użyte w systemie ekspertowym do doboru narzędzi spoza zbioru przykładów uczących. Reguły zostały zapisane w bazie wiedzy systemu ekspertowego. Baza ta została utworzona przy użyciu systemu pozyskiwania wiedzy DeTree i zawiera deklaratywno-proceduralną wiedzę w postaci faset i reguł decyzyjnych.

## 5. Przykład wykorzystania pozyskanej wiedzy do doboru frezów

Wykorzystując system ekspertowy PC-Shell oraz reguły decyzyjne utworzone z drzewa decyzyjnego zaimplementowano aplikację mającą wspomagać technologię w doborze frezów dla operacji frezowania.

Narzędzie było dobierane przy użyciu jednokierunkowej wielowarstwowej sieci neuronowej ze wsteczną propagacją błędów (Rutkowska i in., 1997). Wejścia sieci zawierały warunki technologiczne doboru narzędzi. Wyjścia sieci stanowiły zbiór wartości określających wyniki otrzymane w trakcie doboru narzędzi dla danych warunków. W przypadku operacji frezowania dane wejściowe do sieci neuronowej obejmują: odmianę frezowania, rodzaj powierzchni obrabianej, rodzaj i twardość materiału obrabianego, wymaganą chropowatość powierzchni, rodzaj konstrukcji i mocowania freza, średnicę freza, ilość ostrzy oraz długość całkowitą freza.



Rysunek 1. a) Ekran wprowadzania wartości atrybutów, b) i c) ekran wyboru atrybutów, d) ekran wyników aplikacji – symbol freza

Dane wyjściowe z sieci neuronowej zawierają symbol freza (Rysunek 2). Szczegółowo sieć neuronowa do pozyskiwania wiedzy do doboru narzędzi została omówiona w pracy (Rojek, 2005).

Narzędzie było dobierane przy użyciu jednokierunkowej wielowarstwowej sieci neuronowej ze wsteczną propagacją błędów (Rutkowska i in., 1997). Wejścia sieci zawierały warunki technologiczne doboru narzędzi. Wyjścia sieci stanowiły zbiór wartości określających wyniki otrzymane w trakcie doboru narzędzi dla danych warunków. W przypadku operacji frezowania dane wyjściowe do sieci neuronowej obejmują: odmianę frezowania, rodzaj powierzchni obrabianej, rodzaj i twardość materiału obrabianego, wymaganą chropowatość powierzchni, rodzaj konstrukcji i mocowania freza, średnicę freza, ilość ostrzy oraz długość całkowitą freza. Dane wyjściowe z sieci neuronowej zawierają symbol freza (Rysunek 2). Szczegółowo sieć neuronowa do pozyskiwania wiedzy do doboru narzędzi została omówiona w pracy (Rojek, 2005).

Poprawne działanie aplikacji doboru frezów wykazało poprawność wygenerowanych reguł decyzyjnych, a te z kolei wykazały poprawność utworzonego drzewa decyzyjnego.

## **6. Podsumowanie**

Odkrywanie wiedzy technologicznej, w dużej mierze heurystycznej wynikającej z doświadczenia technologa, a ukrytej w bazach danych gotowych procesów technologicznych możliwe jest dzięki łączeniu różnych metod odkrywania wiedzy, które rozszerzają możliwości ujmowania semantyki procesu technologicznego. Opracowywany system pozyskiwania wiedzy technologicznej pozwala na pozyskanie danych, wiedzy i doświadczenia technologa w sposób komplementarny. Wykorzystano zarówno do tego celu bazy danych istniejące w przedsiębiorstwie, reguły wnioskowania systemu ekspertowego oraz metodę maszynowego uczenia.

W referacie przedstawiono proste klasyfikatory w postaci drzewa decyzyjnego, czy sieci jednokierunkowej wielowarstwowej. Dalsze badania będą rowijane w kierunku tworzenia złożonych klasyfikatorów związanych z drzewami decyzyjnymi.

Kompleksowe podejście w akwizycji wiedzy jest istotnym osiągnięciem w stosunku do tradycyjnych systemów ekspertowych opartych wyłącznie na wiedzy pozyskanej od ekspertów ludzi.

Jest to szczególnie istotne w sytuacjach, gdy wiedza taka nie jest dostępna, bądź jest trudna do sformalizowania, niepełna i niepewna.

## Literatura

- Cichosz P. (2000) *Systemy uczące się*. WNT, Warszawa.
- Krawiec K., Stefanowski J. (2004) *Uczenie maszynowe i sieci neuronowe*. Wydawnictwo Politechniki Poznańskiej, Poznań.
- Probst G., Raub S., Romhardt K. (2002) *Zarządzanie wiedzą w organizacji*. Oficyna ekonomiczna, Kraków.
- Rojek I. (2005) *Application of artificial intelligence methods in knowledge management in the intelligent database environment*. W: *Zastosowania Informatyki w nauce, technice i zarządzaniu*. Seria Badania Systemowe, 41: 117-127, IBS PAN, Warszawa.
- Rutkowska D., Piliński M., Rutkowski L. (1997) *Sieci neuronowe, algorytmy genetyczne i logika rozmyta*. WN PWN, Warszawa.

### SELECTED METHODS OF ACQUISITION OF MANUFACTURING KNOWLEDGE

**Abstract:** *Currently, knowledge acquisition from databases is one of the most intensive developing domains. It is inevitable since traditional database systems cannot effectively manage large amounts of information accessible in the enterprises. Traditional model of data processing is sufficient in the case of current activity of the enterprise (e.g. order registration, service purchase). Unfortunately, this classical model of data processing does not aid processes of data analysis and the systems aiding decision taking.*

*In this paper, a part of research concerning application of selected methods of manufacturing knowledge acquisition: neural networks and the method of induction of decision trees is presented. In this way, the acquired knowledge was used for selection of tools in manufacturing operation.*

**Keywords:** Knowledge acquisition, neural network, method of induction of decision trees, expert system, tools selection.

Jan Studziński, Ludosław Drelichowski, Olgierd Hryniewicz  
(Redakcja)

**ROZWÓJ I ZASTOSOWANIA METOD ILOŚCIOWYCH  
I TECHNIK INFORMATYCZNYCH WSPOMAGAJĄCYCH  
PROCESY DECYZYJNE**

Monografia zawiera wybór artykułów dotyczących informatyzacji procesów zarządzania, prezentując aktualny stan rozwoju informatyki stosowanej w Polsce i na świecie. Zamieszczone artykuły opisują metody, modele, techniki i systemy informatyczne stosowane do wspomaganie procesów podejmowania decyzji, a także omawiają zastosowania narzędzi informatycznych w różnych sektorach gospodarki. Kilka prac przedstawia wyniki projektów badawczych Ministerstwa Nauki i Szkolnictwa Wyższego, dotyczących rozwoju metod informatycznych i ich zastosowań.

**ISBN 83-894-7506-5**  
**9788389475060**  
**ISSN 0208-8029**

---

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