

Dr Roman Simiński

Wyższa Szkoła Zarządzania i Marketingu w Sosnowcu
Instytut Informatyki i Matematyki

TECHNOLOGIE SZTUCZNEJ INTELIGENCJI W SYSTEMACH ZARZĄDZANIA

Ekonomiczne systemy informatyczne wykorzystują metody sztucznej inteligencji do rozwiązywania problemów normalnie wymagających ekspertów. W niniejszym opracowaniu przedstawiono wybrane zagadnienia wykorzystania systemów sztucznej inteligencji w zastosowaniach biznesowych. Prace rozpoczyna prezentacja wykorzystania metod reprezentacji wiedzy do jej kodyfikacji. Rozważane są podstawowe właściwości systemów ekspertowych, sieci neuronowych oraz metod uczenia maszynowego z uwzględnieniem potrzeb i wymagań systemów biznesowych. Następnie zaprezentowana została koncepcja systemu hybrydowego, jako środowiska realizacji elastycznych systemów wspomagania decyzji w zakresie systemów biznesowych.

1. Wstęp

Sztuczna inteligencja (SI) jako dziedzina naukowa budzi od wielu lat wiele emocji. Systemy komputerowe zdolne do inteligentnego rozwiązywania problemów, podejmujące samodzielnie decyzje, czy wręcz myślące i ... buntujące się – wizja taka była intensywnie eksploatowana przez autorów z nurtu literatury fantastyczno-naukowej. A jak jest w rzeczywistości? Coraz częściej zarówno nieduże autonomiczne, jak i kompleksowe, zintegrowane systemy informatyczne, wyposażane są w wyspecjalizowane podsystemy inteligentne, wykorzystujące metody SI. Jednym ze szczególnie interesujących zastosowań systemów SI są systemy ekonomiczne, finansowe, określane dalej wspólnym, ogólnym mianem BIS (ang. *Business Information Systems*). Dzieje się tak ze względu na różnorodność i złożoność występujących w tej dziedzinie problemów, często trudnych do rozwiązania przy użyciu metod klasycznych, bądź zyskujących nowy wymiar dzięki zastosowaniu sztucznej inteligencji. Tematem niniejszego opracowania jest zwięzły opis najistotniejszych metod sztucznej inteligencji, ukierunkowany na zastosowania w zakresie BIS.

2. Systemy wykorzystujące bazy wiedzy

Wiedza z danej dziedziny stanowi podstawę do skonstruowania systemu komputerowego mającego rozwiązywać problemy z danej dziedziny. To trywialne stwierdzenie niesie jednak istotną informację o tym, że odpowiednio zebrana, usystematyzowana i skodyfikowana wiedza stanowi ważny kapitał

organizacji decydujących się na zautomatyzowanie określonych procesów z wykorzystaniem systemów informatycznych. Wiedza dziedzinowa konieczna jest zarówno przy opracowywaniu klasycznych, ewidencyjnych systemów informatycznych, jednak nabiera szczególnego znaczenia przy budowie systemów mających nosić miano systemów inteligentnych. W ramach badań nad metodami sztucznej inteligencji rozwijane są systemy wykorzystujące do rozwiązywania problemów wiedzę dziedzinową gromadzoną w bazach wiedzy oraz mechanizmy wnioskowania. Systemy takie nazywane są potocznie systemami z bazą wiedzy. Postać systemów z bazą wiedzy przejęła pewna klasa utylitarnych systemów sztucznej inteligencji – systemy ekspertowe.

Zadaniem systemów ekspertowych jest rozwiązywanie trudnoalgorytmizowalnych problemów wymagających zastosowania wiedzy dziedzinowej. Jak nazwa wskazuje, systemy ekspertowe mogą być postrzegane jako systemy zdolne zastąpić ekspertów z danej dziedziny. W praktyce systemy ekspertowe raczej wspomagają pracę człowieka przyjmując formę systemów doradczych czy też systemów wspomagania decyzji. Istotną cechą systemów ekspertowych jest ich zdolność do rozwiązywania szerokiej klasy zadań z wybranej dziedziny, co jest możliwe dzięki elastycznej konstrukcji bazy wiedzy systemu, mogącej obejmować obszerną problematykę związaną z wybranym zagadnieniem, umożliwiającą zarazem uzyskiwanie rozwiązań cząstkowych w przypadkach, gdy kompleksowa analiza nie jest konieczna.

Proces realizacji systemów ekspertowych różni się od procesu realizacji klasycznych systemów informatycznych [17][18]. W przypadku tych ostatnich, kompleksowo rozumiany proces realizacji systemu jest przedmiotem inżynierii programowania. W przypadku systemów ekspertowych mówi się o inżynierii wiedzy. Przyjmijmy dla potrzeb tej pracy następującą definicję pojęcia inżynierii wiedzy:


Inżynieria wiedzy (ang. *knowledge engineering*) to dziedzina sztucznej inteligencji zajmująca się projektowaniem i realizacją baz wiedzy systemów ekspertowych oraz doбором i strojeniem wykorzystywanych metod wnioskowania.

Jednym z kluczowych elementów inżynierii wiedzy jest akwizycja wiedzy. Przyjmijmy następującą jej definicję:

Akwizycja wiedzy (ang. *knowledge acquisition, knowledge elicitation*) to proces pozyskiwania, gromadzenia i strukturalizowania wiedzy dziedzinowej niezbędnej do realizacji baz wiedzy systemu ekspertowego.

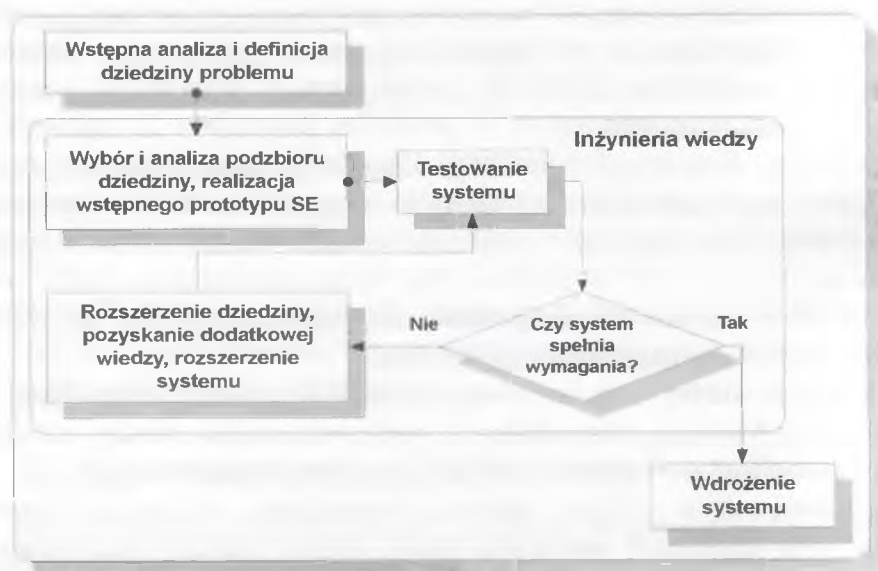
Kluczową rolę w realizacji systemu ekspertowego odgrywają eksperci dziedzinowi, stanowiący najczęściej źródło wiedzy. Chociaż coraz większą rolę odrywają systemy automatycznego pozyskiwania wiedzy z danych, eksperci dziedzinowi pozostają i tak podstawowym ogniwem przy testowa-

niu i ocenie systemu. Rysunek nr 1 przedstawia przebieg realizacji systemu ekspertowego z uwzględnieniem roli twórców systemu.




Rys. 1. Realizacja dziedzinowego systemu ekspertowego.

Przebieg realizacji systemu ekspertowego najczęściej ma charakter iteracyjno-przyrostowy. Obrazuje to najlepiej spiralny model cyklu rozwoju systemu znany z inżynierii programowania lub model tzw. piłeczki basebalowej [16]. Rysunek nr 2 przedstawia jeden z możliwych przebiegów iteracyjnego cyklu realizacji systemu ekspertowego.



Rys. 2. Inkrementacyjny model cyklu rozwojowego systemu ekspertowego.

Działanie systemu ekspertowego polega na realizacji procesu wnioskowania, który w świetle znanych faktów prowadzi do potwierdzenia postawionych hipotez, czy wyprowadzenia nowych konkluzji. Proces ten uwiarygadniany jest wyjaśnieniami ilustrującymi np. ścieżkę rozumowania przeprowadzonego przez system czy celowość zadawanych pytań [3].



Rys. 3. Przepływ danych w procesie wnioskowania.

Systemy ekspertowe umożliwiają również wnioskowanie w warunkach wiedzy niekompletnej, niepewnej – wykorzystując takie rozwiązania jak *metoda współczynników pewności CF* (ang. *Certain Factor*), metody probabilistyczne np. w oparciu o sieci Bayesa (również z wykorzystaniem podejścia Dempstera-Shafera) [14], czy *logikę rozmytą* [15].

Systemy ekspertowe stanowić mogą zasadniczy element systemów wspomagania decyzji ekonomicznych. Dzięki kodyfikacji wiedzy najwyższej klasy specjalistów, oferują one zwykle wysoki poziom ekspertyzy, przeprowadzanej według jednolitych, dobrze określonych zasad. Osiąga się dzięki temu zwiększenie dostępności profesjonalnych ekspertyz, przy znacznej redukcji kosztów oraz zachowaniu niezmiennego w czasie i niezależnego od warunków toku rozumowania.

Najczęściej spotykane zastosowania to obserwowanie trendów, analizy ryzyka – ubezpieczeniowego, kredytowego, planowanie i kontrola inwestycji, monitorowanie stanu finansowego przedsiębiorstw.

Należy podkreślić, że stosowalność systemów ekspertowych w systemach zarządzania nie ma jedynie wymiaru eksperymentalnego. Za względu na wybitnie użyteczny charakter tych systemów, są one praktycznie wykorzystywane już stosunkowo długo. Tabela nr 1 zawiera zestawienie przykładowych systemów ekspertowych w zastosowaniach ekonomicznych.

Tabela 1. Wybrane systemy ekspertowe w zastosowaniach ekonomicznych

Nazwa systemu	Przeznaczenie	Autorzy	Narzędzie
INVEST	Doradztwo w dziedzinie finansów – inwestycje	Uniwersytet w Karlsruhe (1988)	DONALD
LENDING ADVISOR	Wspomaganie decyzji kredytowych	Stanford Research Institute (1987)	Syntel
UNDERWRITIN G ADVISOR	Ocena ryzyka w zakresie ubezpieczeń	Syntelligence (1987)	-----
AUDITOR	Wspomaganie rewizji ksiąg finansowych	Uniwersytet w Illinois (1985)	AL/X
FINEX	Analizy finansowe	George Mason University	Prolog
PEP	Planowanie promocji towaru	Carnige Mellon University	EMYCIN
CLUE	Analiza polis ubezpieczeniowych	I.S.T.G.	NEXPERT Objects
ACS	Zarządzanie kadrami	Japan Airlines	ES/Kernel
ISAF	Monitoring stanu finansowego	AITECH (1993)	PC-Shell

3. Sieci neuronowe

Sztuczne sieci neuronowe powstały w oparciu o badania dotyczące mechanizmów funkcjonowania ludzkiego mózgu. Idea sieci, na wysokim poziomie abstrakcji stosunkowo prosta, polega na symulowaniu struktury mózgu oraz jego działania poprzez odpowiednio zrealizowaną sieć elementów pierwotnych zwanych *neuronami*. Praktyczne realizacje systemów neuronowych są jednak dość odległe od pierwowzoru. Neurony, realizowane sprzętowo lub programowo, są zdolne do generowania odpowiednich sygnałów wyjściowych w zależności od określonych sygnałów wejściowych. Sieć odpowiednio połączonych neuronów jest zwykle poddawana procesowi uczenia, którego celem jest ustalenie odpowiednich parametrów charakterystycznych dla neuronów. Danymi wejściowymi dla sieci są zwykle liczby charakteryzujące modelowany problem, danymi wyjściowymi, odpowiednio zakodowanymi, mogą być np. decyzje czy klasyfikacje reprezentowane liczbowo.

Podstawowym obszarem zastosowań sieci neuronowych są takie problemy, dla których nie tylko trudno podać algorytm ich rozwiązania, lecz nie

można nawet podać żadnych zadawalających reguł. Warunkiem jest jednak posiadanie odpowiedniej ilości danych, opisujących zarówno typowe dane wejściowe sieci, jak i dane wyjściowe. Odpowiednio nauczoną sieć cechuje zdolność do przetwarzania informacji niekompletnych, obarczonych błędami, rozmytych, czy możliwość generowania rezultatów przybliżonych.

W systemach BIS podstawowym obszarem zastosowania są wszelkiego rodzaju analizy danych, mających charakter numeryczny. Jako przykłady można podać prognozowanie rozwoju przedsiębiorstw, zmian rynku, popytu na produkcję, analizę i prognozowanie wyników finansowych przeprowadzaną na podstawie odpowiednio wyliczonych wskaźników, ocenę prawidłowości struktury wydatków. Systemy wykorzystujące sieci neuronowe potrafią np. rozpoznać na podstawie danych bilansowych czy przedsiębiorstwo się rozwija, znajduje się w stanie stagnacji czy regresji.

Sieci neuronowe odznaczają się zdolnością do kojarzenia faktów i dokonywania generalizacji. Odpowiednio przygotowana (wyuczona) sieć neuronowa potrafi generować trafne decyzje z uwzględnieniem czegoś na kształt intuicji. Szczególnie istotne jest to, że sieć neuronowa może nauczyć się np. prognozowania nawet w takiej dziedzinie, w której nic nie wiadomo o naturze rządzących nią związków przyczynowo-skutkowych.

4. Eksploracja baz danych

BIS są nierozzerwalnie związane z bazami danych, w których składowane są zwykle duże ilości informacji charakteryzujących daną organizację. Bazy te są kopalnią wiedzy o wielu istotnych zależnościach, związkach i relacjach ekonomicznych. Niestety, informacja ta nie jest dana wprost, jest rozproszona w bazach danych. Jedną z dziedzin SI jest odkrywanie wiedzy w bazach danych. Oprócz istniejących metod czysto statystycznych, wykorzystywane są np. metody bazujące na *zbiorach przybliżonych* [11][21], metodach *maszynowego uczenia*, takich jak metody Quinlana czy Michalskiego [1][9], czy sieciach neuronowych.

Celem stosowania tych metod jest najczęściej generacja pewnych podziałów, klasyfikacji, które mogą przyjmować formę reguł decyzyjnych, odwzorowujących związki pomiędzy atrybutami wskazanymi jako decyzyjne a innymi atrybutami w bazie danych. Tak wyznaczone reguły decyzyjne generowane przez systemy eksploracji baz danych stanowią bardzo często materiał wejściowy dla budowy baz wiedzy systemów ekspertowych [4], zatem odgrywają również ważną rolę w *inżynierii wiedzy*.

Odkrywanie wiedzy w bazach danych może mieć szczególnie istotne znaczenie w procesie modelowania makroekonomicznego, odnajdywania związków i relacji, wyznaczania trendów, jak również w trakcie czynności

audytorskich, kiedy to mogą służyć do detekcji i charakterystyki sytuacji błędnych czy wręcz kryminogennych.

5. Algorytmy genetyczne i strategie ewolucyjne

Inspiracje naturą w SI nie ograniczają się jedynie do sieci neuronowych. Jednym z kierunków rozwoju tej dyscypliny naukowej są algorytmy genetyczne (AG), których podstawą jest koncepcja znajdowania najlepszego rozwiązania drogą ewolucyjnego doboru wśród rozwiązań dobrych. Ten dobór odbywa się drogą stosowania odpowiednich operatorów genetycznych i testowaniu odpowiedniej funkcji celu, zwanej funkcją przystosowania, oceniającej jakość proponowanego rozwiązania.

Podstawowym zagadnieniem jest właściwa reprezentacja wielkości reprezentujących problem, stanowiących populację wejściową oraz określenia funkcji celu, która w ostatecznym rozrachunku decyduje o wyborze rozwiązania najlepszego. Podstawową cechą opisywanych metod jest zdolność do generowania rozwiązań dobrych, często zbliżonych do optymalnych nawet w sytuacjach, gdy owo optimum nie jest znane. Ma to miejsce np. w przypadku tzw. problemów NP-zupełnych, dla których czas rozwiązania narasta wykładniczo wraz ze wzrostem rozmiaru danych, co zwykle prowadzi do niemożności uzyskania rozwiązania dokładnego w skończonym czasie, przy użyciu metod analitycznych. Przykładem mogą być, klasyczne już, problemy transportowe, takie jak np. problem komiwojażera czy pięciu listonoszy.

Jedną z podstawowych zalet AG jest to, że nie trzeba znać precyzyjnego algorytmu rozwiązania problemu. Należy natomiast dobrze określić populację wejściową (reprezentującą zwykle możliwe rozwiązania problemu), sprecyzować odpowiednie operatory genetyczne oraz funkcję przystosowania.

Systemy wykorzystujące omawiane powyżej podejścia są szczególnie użyteczne do modelowania i symulacji makroekonomicznych. Stąd w powszechnie wykorzystywanych systemach zarządzania nie są, czy też nie będą zapewne podstawową czy też najpopularniejszą metodą SI. Stanowią one jednak ważny element *systemów hybrydowych*.

6. Systemy hybrydowe

Jednym z kierunków rozwoju systemów sztucznej inteligencji jest konsolidacja różnych jej dokonań, ukierunkowana na integrację systemów eksperckich, sztucznych sieci neuronowych, systemów indukcyjnych oraz dokonań opartych o algorytmy genetyczne, zbiory przybliżone czy logikę rozmytą. Takie złożone, inteligentne systemy informatyczne zwane są potocznie systemami hybrydowymi. Celem wykorzystania systemów hybry-

dowych jest uzyskanie potencjału sztucznej inteligencji niedostępnego dla każdej z jej metod rozpatrywanej z osobna [15][18].

Wczesne dokonania ukierunkowane były na wykorzystanie mieszanych metod reprezentacji wiedzy, np. *Cake* [13], *Krypton* [2]. Podstawowym ich celem była konsolidacja najsilniejszych metod reprezentacji wiedzy i wnioskowania, przy czym głównym nurtem było łączenie właściwości systemów ramowych, regułowych i reprezentacji logicznych. Współczesne systemy, oprócz kontynuacji tego kierunku, dążą do szerszego wykorzystania dokonań sztucznej inteligencji. Przykładem może być szkieletowy system ekspercki *Nexpert* firmy *Neuron Data* wykorzystujący regułowo-obiektową reprezentację wiedzy, rozbudowany, wielowariantowy mechanizm wnioskowania, oraz silny moduł akwizycji wiedzy. Inne znane pakiety narzędziowe to *KEE* (*Knowledge Engineering Environment*) firmy *IntelliCorp*, *KES* (*Knowledge Engineering System*) firmy *Software Architecture*, *ART* firmy *Interface Corp.*, czy polski system *PC-Shell* firmy *AITECH* [5].

Systemy hybrydowe wydają się być szczególnie użyteczne z punktu widzenia problemów zarządzania. Spowodowane jest to dużym potencjałem tych systemów, zdolnych do rozwiązywania złożonych, niejednorodnych problemów. Jednym z ciekawszych, praktycznych przykładów wykorzystania systemów hybrydowych są analizy finansowe [6][7][8]. Charakterystyczną cechą tych zastosowań jest konieczność inteligentnego przetwarzania dużej ilości danych numerycznych, które trudno opisać precyzyjnym modelem analitycznym. W wielu przypadkach trudno również podać precyzyjne związki przyczynowo-skutkowe, które można zapisać w postaci reguł w bazie wiedzy systemu eksperckiego. Z drugiej jednak strony, istnieje szereg jawnie wyrażonych reguł ekonomicznych, zarówno natury ogólnej, jak i bardzo szczegółowych.

7. Podsumowanie

Przedstawiona praca zawiera skrócony opis wybranych metod sztucznej inteligencji, ukierunkowany na wskazanie istniejących, jak i przyszłych zastosowań w obrębie systemów zarządzania. Jako szczególnie użyteczne w tej dziedzinie wskazano systemy hybrydowe – narzędzia o wysokim stopniu uniwersalności, gotowe do realizacji wielu różnorodnych problemów występujących w BIS.

Podsumowując: wydaje się, że rozwój inteligentnych podsystemów w obrębie systemów zarządzania jest jedynie kwestią czasu. Dotyczy, czy też dotyczy on będzie, zarówno elementów przeznaczonych dla decydentów (np. w obrębie Systemów Informowania Kierownictwa), menedżerów, finansistów, jak również elementów wspomagających działanie pracowników

produkcyjnych (sterowanie produkcją), czy utrzymania ruchu (diagnostyka awarii, monitoring stanu technicznego urządzeń). Systemy inteligentne będą nie tylko wspomagały podejmowanie decyzji makroekonomicznych, będą również optymalizowały zagadnienia lokalne, np. proces zarządzania stanami magazynowymi, doboru parametrów optymalnego rozkroju materiałów, czy sterowania procesem załadunku produktów na środki transportu oraz doboru stosownych dla nich tras. Sztuczna inteligencja oraz dokonania w dziedzinie robotyki być może już wkrótce umożliwią przybliżenie chwili, kiedy to pomysły pisarzy z nurtu fantastyki naukowej zaczną powoli stawać się rzeczywistością.

Bibliografia:

1. T. Arciszewski, *Machine Learning in Engineering Design*, Materiały Międzynarodowej Konferencji Intelligent Information Systems, Warszawa 1994.
2. R. Brachman, V. Gilbert, H. Lavesque, *An essential hybrid reasoning system: Knowledge and symbol level accounts of KRYPTON*, IJCAI 1985.
3. P. Jackson, *Introduction to Expert Systems*, Addison-Wesley Publishing Company 1986.
4. M. Michalewicz, S.T. Wierzchoń, M.A. Kłopotek, *Knowledge Acquisition, Representation & Manipulation in Decision Support Systems*, Materiały Międzynarodowej Konferencji Intelligent Information Systems, Warszawa 1993.
5. K. Michalik, *PC-Shell dla Winows wer. 2.1 – Przewodnik inżyniera wiedzy*, AITECH, Katowice 1996.
6. K. Michalik, Z. Twardowski, *Financial Analysis Using a Hybrid Expert Systems*, Materiały Konferencji ECAP'94 Workshop „AI in Finance and Business”, Amsterdam 1994.
7. K. Michalik, Z. Twardowski, *Hybrid Expert Systems for Data Analysis*, Materiały Konferencji International Symposium on Applied Stochastic Models and Data Analysis (ASMDA), Dublin 1995.
8. K. Michalik, Z. Twardowski, *Intelligent Systems for Financial Analysis*, Materiały Konferencji SPICIS'94 International Conf. on Intelligent Systems, Singapoure 1994.
9. R. S. Michalski, *Seeking Knowledge in the Flood of Facts*, Materiały Międzynarodowej Konferencji Intelligent Information Systems, Warszawa 1994.
10. N.J. Nilsson, *Principies of Artificial Intelligence*, Tioga Publishing Company, 1980.

11. Z. Pawlak, *Rough Sets – Theoretical Aspects on Reasoning about Data*, Kluwer Academic Publ. 1991.
12. H. Reichgelt, *Knowledge Representation: An AI Perspective*, Ablex Publishing Corporation, New Jersey 1991.
13. C. Rich, *The layered architecture of system for reasoning about programs*, IJCAI 1985.
14. R. Simiński, M. Boryczka, A. Wakulicz-Deja, *Implementation of Probabilistic Inference Engine – Some Technical Issues*, Materiały Międzynarodowej Konferencji IDEA'97 – Intelligent Design in Engineering Applications, Aachen Niemcy 1997.
15. R. Simiński, *Hybrid System as the Way of Integration Methods of AI*, Materiały Konferencji WIS '96, Dęblin 1996.
16. R. Siminski, *Obiektowe podejście do projektowania systemów informatycznych moda czy konieczność?*, Prace Wydziału Techniki UŚ 29, Systemy Informacji Naukowo-Technicznej, Katowice 1996.
17. R. Siminski, *Praktyczne aspekty realizacji systemów ekspertowych w środowisku systemu PC-Shell*, Materiały III-ej Konferencji Naukowej Inżynieria Wiedzy i Systemy Ekspertowe, Wrocław 1997.
18. R. Siminski, *Some Practical Issues On Constructing Hybrid Decision Support System*, Materiały Międzynarodowej Konferencji EUFIT'98, Aachen, Niemcy 1998.
19. R. Siminski, A. Wakulicz-Deja, *Principles and Practice in Knowledge Bases Verification*, Materiały Międzynarodowej Konferencji Intelligent Information Systems VII, Malbork 1998.
20. L. Zadeh, *Fuzzy sets and their applications to cognitive and decision process*, Academic Press, New York 1975.
21. W. Ziarko, N. Shan, *Machine Learning Throught Data Classification and Reduction*, Materiały Międzynarodowej Konferencji Intelligent Information Systems, Warszawa 1994.