

Anna MANOWSKA

Politechnika Śląska, Wydział Górnictwa i Geologii

## METODY PROGNOZOWANIA

**Streszczenie.** W artykule omówiono klasyczne i nowoczesne metody prognozowania, które służą ograniczeniu ryzyka związanego z niepewnością i niepełną wiedzą o przyszłości. Komputerowe wspomaganie ludzkiej działalności występuje w wielu dziedzinach, jednakże najwyraźniej i najefektywniej rozwija się w zarządzaniu i sterowaniu procesami technologicznymi. Rozwój sztucznej inteligencji wiąże się z włączeniem ich do tworzonych systemów informacyjnych. W artykule podjęto próbę oceny teorii i narzędzi sztucznej inteligencji pod kątem prognozowania procesów zachodzących w przedsiębiorstwie.

## FORECASTING METHODS

**Summary.** In the paper the classical and up-to-date methods have been presented. They are used to cut down the risk that is connected with uncertainty and incomplete knowledge about the future. Computer-aided human activity has taken place in many fields, but has developed in management and control of technological processes in the most noticeably and efficiently way. The artificial intelligence approach is more and more used in information systems. It has been undertaken the attempt of the assessment of artificial intelligence theories and tools from a point of view of forecasting the processes that have taken places in the enterprises.

### 1. Wprowadzenie

Przedsiębiorstwo należy do systemów złożonych, jest ono konglomeratem struktur personalnych, materialnych, finansowych, informacyjnych. Struktury te są wzajemnie ze sobą powiązane poprzez skomplikowane więzy przyczynowo-skutkowe [2]. Ze względu na złożoność i spójność systemu ekonomicznego skuteczna metoda analizy firmy powinna

oceniać przedsiębiorstwo w sposób całościowy z uwzględnieniem informacji ilościowych i jakościowych, czynników statycznych i dynamicznych [2].

W dobrze zarządzanym przedsiębiorstwie dzisiaj pracuje się na sukcesy jutra, niestety, wiedza o przyszłości jest niepełna i niepewna. Tę niepewność, a także ryzyko z tym związane można ograniczyć prowadząc badania nad przyszłością, w których szczególnie miejsce zajmuje prognozowanie [6].

## 2. Klasyczne metody prognozowania

Prognozowanie to przewidywanie przyszłych zdarzeń z wykorzystaniem metod naukowych, którego celem jest zmniejszenie ryzyka w procesie podejmowania decyzji (decyzje zalecające). Przez prognozę danego zjawiska rozumie się wskazanie najbardziej prawdopodobnej drogi rozwoju tego zjawiska zgodnie z wiedzą o dotychczasowym przebiegu zjawiska oraz obecnym jego stanie.

Przyjmuje się zatem, że prognozowanie:

- to działania racjonalne posługujące się metodami naukowymi,
- odnosi się do określonej, zazwyczaj niezbyt odległej przyszłości.

Metody prognozowania technicznego mają trzy cechy charakterystyczne i do pewnego stopnia zależne od siebie [1]:

- Zostały one rozwinięte, by umożliwić dialog „człowiek – technika” i są podatne na wiedzę człowieka, jego zdolności do abstrakcyjnego myślenia, do fachowej i wartościującej opinii oraz syntezy.
- Są to metody cząstkowe, obejmujące tylko ułamek całkowitego procesu prognozowania technicznego.
- Są to środki pomocnicze przy podejmowaniu decyzji, które powinny opierać się na informacjach szerszych niż te, które można otrzymać tylko za pomocą metod prognostycznych.

Wyróżnia się dwa trendy w prognozowaniu. Pierwszy kierunek to wykorzystywanie coraz bardziej zaawansowanych metod prognozowania, jednak ich ograniczenie polega na tym, że odnoszą się do zjawisk z historią. Drugi kierunek, to rozwinięcie metod heurystycznych, w których centralne miejsce zajmują eksperci, a aparat matematyczny dotyczy weryfikacji zgodności sądów, miary rozproszenia, jak również możliwych wyjątków. Każda z tych metod wspomagana jest systemami informatyczno-informacyjnymi [6].

### 3. Nowoczesne metody prognozowania

Dynamiczny rozwój rynku informatycznego i technologii mikroprocesorowej spowodował wzrost zaangażowania wykorzystania komputerów w metodach prognostycznych. W latach 70. żywiono nadzieję, że znaczny postęp w analizie ekonomicznej zostanie dokonany dzięki nowej technice – symulacji komputerowej. Metoda symulacyjna polegała na badaniu przedsiębiorstwa w sposób pośredni – za pomocą numerycznego modelu systemu ekonomicznego [2]. Oczywiście, w znacznym stopniu w symulacjach wykorzystywano klasyczne metody prognozowania, gdzie tworzenie prognozy opierało się na historii zjawiska. Duża liczba danych wejściowych i skomplikowane algorytmy prognostyczne stworzyły potrzebę zwiększenia mocy obliczeniowych komputerów w celu znacznego skrócenia czasu obliczeń. Procesy zachodzące w przedsiębiorstwie trudno jest w pełni rozpoznać bądź też informacja na temat zjawisk nie jest kompletna. Nawet metody eksperckie, które bazują na wiedzy, intuicji eksperta muszą być wspomagane systemami informatyczno-informacyjnymi, ponieważ jest prawie niemożliwe zebranie w jedno miejsce, w tym samym czasie dużej liczby ekspertów, natomiast można korzystać z wiedzy i doświadczeń opisanych w publikacjach [6]. Z tych przyczyn powstały nowoczesne metody prognozowania, do których zalicza się:

- a) sztuczne sieci neuronowe;
- b) systemy eksperckie;
- c) zbiory rozmyte;
- d) metody algorytmów genetycznych.


### 4. Sztuczne sieci neuronowe

W ostatnich latach obserwować można dynamiczny rozwój zastosowań metod sztucznej inteligencji, w szczególności sztucznych sieci neuronowych. Główne kierunki badań dotyczą:

- wyszukiwania informacji,
- inteligentnych agentów,
- profilowania i interpretacji zachowań użytkowników,
- pozyskiwania wiedzy z Internetu,
- generacji adaptacyjnych dedykowanych serwisów WWW.

Przyczyną tak dużego sukcesu tych narzędzi jest ich uniwersalność, zdolność przetwarzania niepewnych i niekompletnych danych, które występują w wielu zagadnieniach praktycznych. Sieć neuronowa umożliwia analizę i modelowanie zjawisk i procesów bez

konieczności pełnego zrozumienia charakteru wewnętrznych zjawisk i przemian. Efektem jest potoczne określenie sieci neuronowej mianem czarnej skrzynki, do której wprowadza się dane i uzyskuje wyniki, bez wiedzy o tym, co dzieje się w środku.




Rys. 1. Przykładowa sieć neuronowa

Fig.1. Artificial Neural Networks

Źródło: <http://pbryzi.fm.interia.pl/W/SN.htm>.

Idea sztucznych sieci neuronowych (ANN Artificial Neural Networks – rys. 1) wywodzi się z obserwacji, że mózg zwierząt i ludzi prowadzi „obliczenia” w zupełnie inny sposób niż robią to komputery. Bazując więc na sposobie przetwarzania informacji w organizmach żywych stworzono model tego procesu, którego najmniejszy element jest zwany neuronem, a pożądane struktury są tworzone przez łączenie neuronów w sieci – rys. 2.



Rys. 2. Schemat neuronu

Fig. 2. Stages of neuron

Aby jednak móc rozwiązać dowolne zadania klasyfikacji, jest konieczne nie tylko zwiększenie liczby neuronów, ale także stosowanie sieci neuronowych wielowarstwowych. Liczba warstw powinna być teoretycznie nieskończenie duża, ale jak się okazuje, sieci trójwarstwowe w zupełności wystarczają do rozwiązania większości problemów. Najważniejszą cechą ANN jest ich zdolność uczenia się na podstawie doprowadzonych wzorców treningowych. Te reguły uczenia się determinują optymalne wagi tak, aby minimalizować pewien wskaźnik jakości. Mechanizm uczenia zastosowany w ANN zmienia wagi w poszczególnych neuronach sieci i dostosowuje sieć do tego, by uzyskiwać pożądaną odpowiedź, zapisaną w przedstawionym wzorcu treningowym. Podczas tego procesu uczenia obliczany jest sygnał błędu, jest to różnica między aktualnym sygnałem wejściowym i sygnałem pożądanym, zapisanym we wzorcu treningowym. Struktura ANN musi być dobrana do konkretnego zastosowania. Dotyczy to liczby wejść i wyjść, liczby warstw oraz liczby neuronów w poszczególnych warstwach. Niestety, nie ma metod analitycznych, które pozwoliłyby na oszacowanie tych wielkości i dobór struktury sieci bliskiej optymalnej, i trzeba posługiwać się metodami prób i błędów.

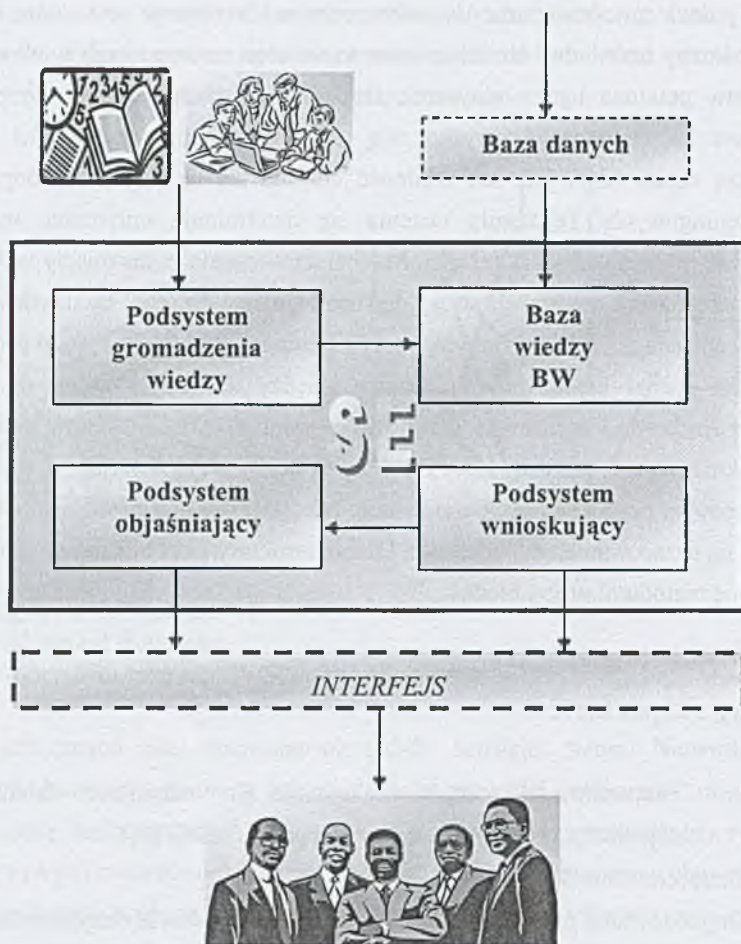
## 5. Systemy ekspertowe

Systemy ekspertowe wkroczyły praktycznie do wszystkich dziedzin twórczej działalności ludzkiej, służąc wykonywaniu następujących funkcji [3]:

- interpretowania danych,
- prognozowania prawdopodobnych zdarzeń na podstawie danych sytuacji,
- diagnozowania,
- projektowania,
- planowania,
- monitorowania,
- programowania sposobów uniknięcia błędnych operacji,
- naprawiania zgodnie z przypisanym algorytmem,
- szkolenia i sterowania.

Tak szeroki zakres funkcji wspomaganych przez system ekspercki pozwolił na opracowanie i wdrożenie tych systemów w informatyce, elektronice, technice kosmicznej, meteorologii, matematyce, ekonomii itp.

Przez systemy ekspertowe rozumie się programy komputerowe, które rozwiązują specjalistyczne problemy z pewnej dziedziny, spełniając funkcje eksperta. Na podstawie zgromadzonej wiedzy potrafią również wnioskować i podejmować decyzje.



Rys. 3. Schemat blokowy systemu ekspertowego  
 Fig. 3. Block diagram of expert system  
 Źródło: Opracowanie własne na podstawie [4].

System ekspertowy składa się z następujących, niezależnych fizycznie, lecz współpracujących ze sobą, elementów (rys. 3) [3]:

- Bazy wiedzy – znajdują się w niej wszelkie informacje z zakresu wybranej dziedziny: wiedza faktograficzna (fakty), wiedza o wnioskowaniu (zbiór reguł), wiedza o sposobach rozwiązywania problemu (metawiedza) – musi być ona zapisana w postaci sformalizowanej, zrozumiałej dla mechanizmu wnioskującego i pozwalającej na prześledzenie sposobu dojścia systemu do rozwiązania.

- Maszyny wnioskującej – na podstawie zgromadzonej wiedzy wyszukuje rozwiązanie postawionego problemu – jest ona oddzielona od bazy wiedzy, dzięki czemu działa tak samo w systemach ekspertowych dla dowolnej dziedziny, jak i w szkieletowych systemach ekspertowych; algorytm wyszukiwania zawiera szereg strategii przeszukiwań, heurystyk i metod wnioskowania – strategie wyznaczają kolejne kroki przeszukiwań, heurystyki pomagają zoptymalizować przestrzeń poszukiwań, a metody decydują, w jaki sposób zachodzi proces myślenia (wnioskowane wstecz, w przód czy inne).
- Procedury objaśniania – objaśniają strategię wnioskowania, sposób dojścia do rozwiązania i pokazują dokładniejsze dane o rozwiązaniu.
- Interfejs do porozumiewania się z użytkownikiem – umożliwia komunikację człowieka z systemem (pracę interaktywną) – służy do zasięgania informacji u użytkownika, przedstawiania wygenerowanego wyniku oraz udzielania wyjaśnień na temat procesu wnioskowania – konstrukcja i wygląd interfejsu zależą od języka programowania, za pomocą którego stworzono system ekspertowy, oraz systemu operacyjnego, w którym on działa.
- Moduły zdobywania i modyfikacji wiedzy – pozyskiwanie wiedzy pozwala na automatyczne ulepszanie systemu.

Sposób reprezentacji wiedzy stanowi jeden z podstawowych zagadnień w dziedzinie sztucznej inteligencji. Wiedza w bazie wiedzy powinna być zapisana w sposób jawny i jasny dla użytkownika, tak aby mogła być przeglądana i rozumiana bez specjalistycznego przygotowania. Kolejny bardzo ważny aspekt systemów eksperckich to dobór liczby ekspertów, badanie zgodności oraz ich ocena. Jako najbardziej efektywne i twórcze uważa się zespoły sześciuosobowe. Zauważa się, że w metodach sztucznej inteligencji jest powrót do klasycznych metod prognostycznych, gdzie do oceny umiejętności eksperta wykorzystuje się metody pobudzającego nadzoru. Nowoczesne technologie informatyczne pozwalają na korzystanie z wiedzy ekspertów wykorzystując więzi informatyczne. Oszacowanie wiedzy eksperta powinno następować po zapoznaniu się z jego publikacjami. Po stwierdzeniu, że jest to osoba, która powinna rozwiązać dany problem powinno się wyjść z inicjatywą stworzenia własnego zespołu poprzez wskazanie osób kompetentnych. Inną metodą jest korzystanie z doświadczeń menadżerów działających na „wielkich” rynkach. Oczywiście grupy ekspertów powinny być interdyscyplinarne, a więzi występujące w zespole powinny być partnerskie.

## 6. Zbiory rozmyte

Metody sztucznej inteligencji służą próbie opisywania rzeczywistości w sposób naśladowujący rozumowanie człowieka. Ich twórcy starają się przezwyciężyć wady tradycyjnych algorytmów komputerowych, zawodzących często w sytuacjach, w których człowiek jest w stanie rozwiązać postawiony problem bez większych trudności. Sztuczna inteligencja nie może więc przejść do porządku dziennego nad naturalnym brakiem precyzji zjawisk i przedmiotów świata realnego [4]. Jak bowiem zdefiniować: duży, znacznie wyższe, czy też bardzo ryzykowne? Ten rodzaj braku precyzji zwykle jest nazywany rozmyciem [4]. Zbiór rozmyty  $A$  jest definiowany jako funkcja, która dla każdego elementu z  $X$  określa, w jakim stopniu należy on do zbioru  $A$ . Teoria zbiorów rozmytych zyskuje sobie coraz większe uznanie. W górnictwie występuje wiele wielkości czy też cech górotworu oraz zjawisk niedokładnie rozpoznanych lub wiele związków, których nie da się dokładnie opisać, więc teoria zbiorów rozmytych mogłaby znaleźć tu zastosowanie [5].

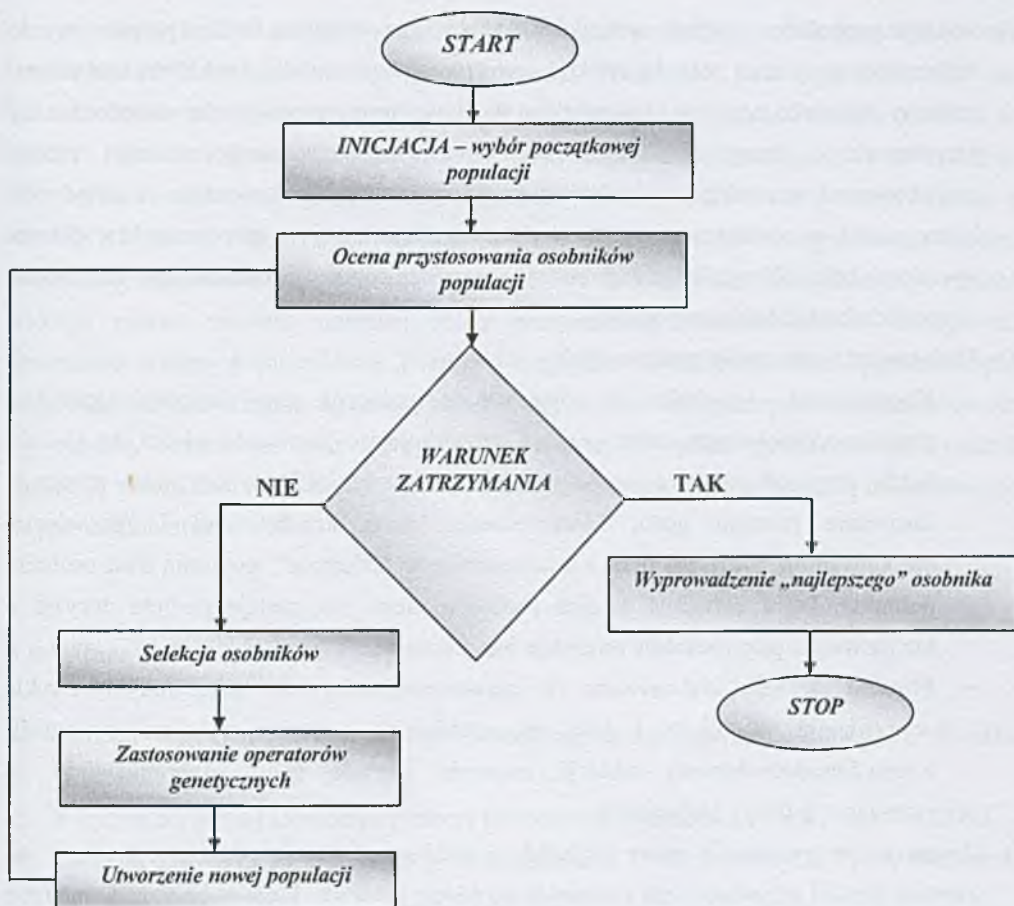
## 7. Algorytmy genetyczne

Algorytmy genetyczne to metody rozwiązywania problemów wzorowane na naturalnej ewolucji. Są to procedury przeszukiwania zbioru rozwiązań oparte na mechanizmach doboru naturalnego i dziedziczenia, korzystają z ewolucyjnej zasady przeżycia osobników najlepiej przystosowanych. Algorytmy genetyczne często współpracują lub wspomagają sieci neuronowe, obie metody mogą również współdziałać, tworząc układ hybrydowy służący do rozwiązania określonego zadania.

Cechami charakterystycznymi algorytmów genetycznych są:

- reprezentacja osobnika jako łańcucha binarnego (geny to 0 lub 1, świadczy to o kodowaniu problemu na poziomie genotypu) o stałej długości (ilości bitów),
- operatorami genetycznymi są: proste krzyżowanie i prosta mutacja, operacje te są prowadzone na poziomie genotypu,
- stałe prawdopodobieństwo operatorów genetycznych,
- parametrem algorytmu jest prawdopodobieństwo zajścia krzyżowania,
- osobnik jest przekształcany z genotypu do fenotypu i dopiero oceniany (to istotna cecha, gdyż mała zmiana na poziomie genotypu może spowodować duże zmiany na poziomie fenotypu).





Rys. 4. Schemat blokowy klasycznego algorytmu genetycznego

Fig. 4. Block diagram of genetic algorithm

Działanie algorytmu polega na realizacji następujących kroków:

- Inicjacja – populacja bazowa zostaje wypełniona losowo wygenerowanymi osobnikami.
- Ocena przystosowania – dla każdego osobnika obliczana jest wartość funkcji przystosowania.
- Sprawdzenie warunku zatrzymania – warunkiem tym może być: wykonanie określonej liczby generacji lub odnalezienie osobnika o odpowiednio dużej wartości funkcji przystosowania. Zatrzymanie algorytmu może również nastąpić wtedy, gdy jego dalsze działanie nie poprawia już uzyskanej lepszej wartości. Jeśli warunek jest spełniony algorytm wyprowadza najlepszego osobnika. Jeśli nie jest spełniony, pętla 4-5-6-3 wykonywana jest ponownie.

- d) Selekcja osobników – wybór osobników z największą wartością funkcji przystosowania. Najbardziej popularną metodą selekcji jest tzw. metoda ruletki (każdemu osobnikowi możemy wydzielić wycinek koła ruletki o wielkości proporcjonalnej do wartości funkcji przystosowania danego osobnika. Całe koło odpowiada sumie wartości funkcji przystosowania wszystkich osobników w populacji. Selekcja chromosomu to jakby obrót kołem ruletki, w wyniku czego zostaje wybrany osobnik lepiej przystosowany (z większym wycinkiem koła). W wyniku selekcji zostaje utworzona populacja rodzicielska o liczebności równej liczebności bieżącej populacji.
- e) Zastosowanie operatorów genetycznych:
- Krzyżowanie – osobniki są kojarzone w rozłączne pary (losowo, zgodnie z prawdopodobieństwem krzyżowania – przyjmuje się je zwykle od 0,5 do 1) i dla każdej pary podejmowana jest decyzja o krzyżowaniu: jeśli jest pozytywna- następuje losowanie (pozycji genu, która określa punkt krzyżowania) i "przecięcie" chromosomów rodziców oraz ich naprzemienne "sklejenie"; powstają dwa osobniki potomne, które zastępują swoich rodziców. Jeśli nie zostaje podjęta decyzja o krzyżowaniu, para rodziców pozostaje bez zmian.
  - Mutacja – jest wykonywana z prawdopodobieństwem szacowanym zwykle w przedziale  $<0, 0.1>$  i jest to perturbacja genotypu – operator mutacji z prawdopodobieństwem mutacji zamienia wartość genu w chromosomie na przeciwną: z 0 na 1 i odwrotnie.
- f) Utworzone w ten sposób nowe osobniki są poddawane ocenie poprzez obliczenie ich wartości funkcji przystosowania i stanowią populację potomną, która w następnej generacji (iteracji) staje się populacją bazową. Pętla 4-5-6-3 jest wykonywana dopóty, dopóki nie zostanie spełniony warunek zatrzymania.
- g) Wyprowadzenie najlepszego osobnika – podane wyniku działania algorytmu, czyli rozwiązania. Najlepszym rozwiązaniem jest osobnik z największą wartością funkcji przystosowania.

## 8. Wnioski

W prognozowaniu spotyka się dwa zasadnicze problemy: pierwszy z nich to brak informacji na temat danego zjawiska bądź też informacja jest nieprecyzyjna, a drugi problem – to nadmiar informacji wynikający ze złożoności zdarzenia. Skomplikowane algorytmy matematyczne powodują wzrost zaangażowania technologii informatycznej, co owocuje szybkim postępem technicznym. Łatwość dostępu do metod rozwiązywania problemów, a z

drugiej strony brak czasu na poszukiwanie rozwiązań powodują, że nie znajdują obecnie zastosowania klasyczne metody prognozowania. Większość tych ograniczeń nie jest przeszkodą dla metod prognozowania opartych na sztucznej inteligencji. Jednakże znajdują się obszary ograniczonej stosowalności podstawowych technik inteligentnych, gdyż nie spełniają one kryteriów uniwersalnej, kompleksowej metody analizy ekonomicznej firmy. Metody te nie są zdolne do zapisu istotnych danych o systemie w postaci zintegrowanego modelu informacyjnego, nie są tym samym w stanie wykreować środowiska analitycznego, w ramach którego można dokonać rzetelnej oceny ekonomicznej przedsiębiorstwa. Dlatego też stworzono systemy polimorficzne, które pod względem struktury są jednolite, jednakże pod względem funkcjonalnym mają cechy składowych technik inteligentnych: sieci neuronowych → systemy ekspertowe oraz algorytmy genetyczne. W wyniku połączenia tych technik powstaje narzędzie, które wykorzystywane jest do prognozowania procesów zachodzących w przedsiębiorstwie.

## Literatura

1. Siciński A., Gzula J.: Problemy metodologii prognozowania, Książka i Wiedza, Warszawa 1976.
2. Węgrzyn S.: Nano i kwantowe systemy informatyki, Politechnika Śląska, Gliwice 2003.
3. Zieliński J.S.: Inteligentne systemy w zarządzaniu. Teoria i praktyka, PWN, Warszawa 2000.
4. Kowalik S.: Nowoczesne metody optymalizacyjne w zastosowaniach górniczych i ekonomicznych., Politechnika Śląska, Gliwice 2004.
5. Radościński E.: Inteligentne techniki hybrydowe w analizie ekonomicznej, Politechnika Wrocławska, Wrocław 1998.
6. Przybyła H.: Przedsiębiorstwo i jego otoczenie. Praca zbiorowa pod redakcją Dźwigoł H. pt. „Restrukturyzacja przedsiębiorstwa w warunkach gospodarki rynkowej”. Instytut Promocji Małych i Średnich Przedsiębiorstw PROMOTOR. Katowice-Chorzów 2004.

## Abstract

Today modern forecasting methods are more and more current, because people need not to have complete knowledge about events. Nowadays, when the market is competitive, all businesses have to forecast and use informatics technology in order to possess information about future requirements of the market.