

Leszek Kieltyka, Waldemar Jędrzejczyk

SZKIELETOWY SYSTEM EKSPERTOWY W PROCESIE PROGNOZOWANIA DOSKONAŁENIA PRODUKTU

1. Wstęp

Oceny szans przedsiębiorstwa na rynku można dokonać na podstawie kilkuset różnorodnych czynników, obejmujących wszystkie obszary jego funkcjonowania. Dokonanie takiej analizy zajmuje jednak wiele czasu i jest bardzo kosztowne. W praktyce stosuje się analizę pewnej grupy czynników, określanych często mianem czynników sukcesu. W jej wyniku można otrzymać informację wskazującą, na jakich obszarach i problemach powinno skoncentrować się kierownictwo firmy, aby osiągnąć przewagę konkurencyjną na rynku. Grupa czynników sukcesu danego przedsiębiorstwa powinna być określona przez ekspertów zewnętrznych (menedżerowie kooperujących przedsiębiorstw, firmy consultingowe, instytucje naukowe) oraz wewnętrznych (menedżerowie z wyższych szczebli zarządzania przedsiębiorstwem). Dane należy pozyskiwać ze źródeł zewnętrznych (publikacje rządowe, dane GUS, Internet, przedsiębiorstwa należące do otoczenia firmy: dostawcy, klienci, pracownicy, katalogi itp.) oraz wewnętrznych (m.in.: bilanse, faktury, raporty i rejestry sporządzane przez różne komórki organizacyjne przedsiębiorstwa).

Proces konstruowania prognoz wielkości czynników sukcesu przedsiębiorstwa na rynku należy postrzegać jako wycinek całościowego procesu analizy tych czynników, który obejmuje m.in.: analizę wartości aktualnych, odchyleń, dynamiki zmian, funkcji trendu, prognoz krótkoterminowych, średnioterminowych i długoterminowych, wzajemnych zależności oraz wpływu na procesy produkcyjne, kondycję finansową, poziom konkurencyjności.


W niniejszym opracowaniu skoncentrowano się głównie na procesie tworzenia modelu prognostycznego za pomocą systemu ekspertowego. Podstawowym celem artykułu jest ukazanie przydatności jednej z metod sztucznej inteligencji w prognozowaniu gospodarczym, m.in. poprzez przedstawienie uzyskanych wyników dokładności odwzorowania zjawiska z jej wykorzystaniem, na przykładzie analizy

problemu dotyczącego doskonalenia produktu. System ekspertowy tworzone za pomocą pakietu sztucznej inteligencji Sphinx. Wykorzystano moduły Neuronix, DeTree oraz PC-Shell, będące częścią tego pakietu.

2. Systemy ekspertowe do zadań prognostycznych

Systemy ekspertowe (SE) są to komputerowe programy konsultacyjne, które umożliwiają korzystanie z wiedzy i ułatwiają podejmowanie decyzji. Systemy ekspertowe mogą wspomagać bądź zastępować ekspertów w danej dziedzinie [Mulawka 1997, s. 20]. Mogą realizować zadania z wielu kategorii. Systemy ekspertowe w zależności od realizowanych zadań można podzielić m.in. na:

- interpretacyjne – tworzą opisy sytuacji na podstawie obserwacji,
- diagnostyczne – określają stan istniejący na podstawie obserwacji,
- prognostyczne – wnioskuje o przyszłości na podstawie zaistniałej sytuacji,
- kompletowania – konfigurują obiekty w warunkach ograniczeń,
- planowania – podejmują działania, aby osiągnąć zamierzony cel,
- monitorowania – porównują obserwacje z ograniczeniami,
- sterowania – sterują procesem/obiektem,
- poprawiania – podają sposób postępowania w przypadku złego funkcjonowania obiektu/systemu,
- naprawy – ustalają harmonogram działań przy dokonywaniu napraw uszkodzonych obiektów [Mulawka 1997, s. 26].




Rys. 1. System ekspertowy do zadań prognostycznych

Źródło: opracowanie na podstawie [Technologie informatyczne... 2005, s. 187].

Do budowy SE najlepiej przystosowane są systemy szkieletowe (np.: Acquire, Babylon, DecisionPro, EsieWin, Expert System Builder, Expert System Designer, ExSys, G2, Mobal, PS-Shell, XpertRule). System szkieletowy można traktować jako system ekspertowy z pustą bazą wiedzy [Mulawka 1997, s. 27]. Zapewnienie bazy wiedzy wiedzą z danej dziedziny zmienia system szkieletowy w konkretny system ekspertowy.

Systemy ekspertowe przeznaczone do zadań prognostycznych powinny składać się z następujących elementów bazy danych, bazy modeli, bazy wiedzy, modułu wnioskującego, modułu uczącego się oraz interfejsu (rys. 1).



Rys. 2. Mechanizmy prognozowania w systemie ekspertowym

Źródło: opracowanie na podstawie [Technologie informatyczne... 2005, s. 188].

Układ elementów składowych systemu ekspertowego oraz sposób ich wykorzystania w procesie prognozowania może być różny. Relacje pomiędzy modułami są zależne od rodzaju rozwiązywanego problemu oraz od stosowanego mechanizmu prognozowania. Modułem prognostycznym w systemie ekspertowym może być baza modeli, baza wiedzy, moduł wnioskowania lub moduł uczącego się (rys. 2).

3. Prognozowanie doskonalenia produktu

3.1. Doskonalenie produktu jako czynnik sukcesu przedsiębiorstwa na rynku

Jednym z czynników potencjalnego sukcesu przedsiębiorstwa produkcyjnego na rynku jest doskonalenie produktu [Jędrzejczyk 2004, s. 86]. Doskonalenie wiodącego produktu oceniano w skali od –2 do 2. Ocena określająca innowacje w zakresie produktu uwzględniała zmianę jakości technicznej wiodącego wyrobu oraz zmianę poziomu wartości dodanej. Macierz doskonalenia produktu przedstawiono w tab. 1.

Tabela 1. Macierz doskonalenia produktu

Jakość techniczna	Spadek poziomu jakości	Stąły poziom jakości	Wzrost poziomu jakości
Wartość dodana			
Niszczenie wartości dodanej	–2	–1	0
Wartość dodana stała	–1	0	1
Tworzenie wartości dodanej	0	1	2

Źródło: opracowanie własne.

3.2. Baza danych prognostycznych

Wyboru zmiennej prognozowanej i doboru zmiennych objaśniających dokonano na podstawie badań własnych. Głównym celem jednego z etapów badań była identyfikacja grupy czynników istotnych dla małych i średnich przedsiębiorstw produkcyjnych, systematycznie analizowanych przez kadrę zarządzającą, tzw. czynników sukcesu. Czynniki uwzględnione w analizowanym przypadku stanowią podgrupę tej grupy. Za zmienne objaśniające uznano piętnaście zmiennych przedstawionych w tab. 2. Osiem z nich ma charakter ilościowy, a siedem jakościowy. Zbiór wejściowy tworzy 576 przypadków. Składa się on z szesnastu klas (pojęciem klasy określone zostały dane pozyskane z jednego przedsiębiorstwa). Liczebność każdej klasy wynosi 36. Dane statystyczne mają charakter dynamiczno-przekrojowy. Dane reprezentujące zmienne związane z przedsiębiorstwem i jego mikrootoczeniem pochodzą z szesnastu przedsiębiorstw z grupy MŚP, zajmujących się produkcją sprzętu oświetleniowego i lamp elektrycznych, zlokalizowanych w Częstochowie. Dane reprezentujące zmienne związane z makrootoczeniem przedsiębiorstwa ściągnięto ze stron internetowych: <http://www.money.pl/pieniadze/> (kurs euro), <http://www.bzwbk.pl> (oprocentowanie kredytów dla przedsiębiorstw) i <http://euro.bankier.pl/research/macro> (skłonność do zakupów). Dane zestawione zostały z interwałem miesięcznym. Obejmują one okres od grudnia 2000 r. do grudnia 2003 r.

Tabela 2. Zestawienie zmiennych objaśniających

Lp.	Nazwa zmiennej	Rodzaj zmiennej
1	Cena jednostkowa wiodącego wyrobu	ilościowa
2	Jakość wiodącego wyrobu	jakościowa
3	Kapitał własny	ilościowa
4	Kurs euro	ilościowa
5	Kwalifikacje i doświadczenie pracowników	jakościowa
6	Kwalifikacje i doświadczenie właściciela firmy	jakościowa
7	Liczebność nabywców	jakościowa
8	Metody sprzedaży	jakościowa
9	Oprocentowanie kredytów dla przedsiębiorstw	ilościowa
10	Poziom intensywności konkurencji	jakościowa
11	Skłonność do zakupów	ilościowa
12	Stosunek pracowników do pracy	jakościowa
13	Wielkość produkcji wiodącego wyrobu	ilościowa
14	Wskaźnik udziału kapitałów własnych	ilościowa
15	Wynagrodzenia brutto	ilościowa

Źródło: opracowanie własne.

3.3. Budowa modelu prognostycznego za pomocą szkieletowego systemu ekspertowego

Bazę wiedzy systemu ekspertowego do zadań prognostycznych konstruowano za pomocą metody pozyskiwania wiedzy na podstawie przykładów. Zastosowano technikę indukcji drzew decyzyjnych.

Tworząc modele prognostyczne w postaci systemu ekspertowego za pomocą pakietu Sphinx, postępowano według następujących kroków:


- wyodrębnienie uczącego oraz testującego zbioru danych i utworzenie przy użyciu modułu Neuronix plików z rozszerzeniem *.lrn (uczący) i *.tst (testujący),
- generowanie na podstawie pliku uczącego drzewa decyzyjnego z wykorzystaniem modułu DeTreeX,
- ocena poprawności odwzorowania na podstawie pliku testującego z wykorzystaniem modułu DeTreeX,
- zapis utworzonego zbioru reguł do bazy wiedzy systemu ekspertowego PC-Shell.

Dzieląc zbiór danych wejściowych na zbiory: uczący, walidacyjny i testowy, wzięto pod uwagę ich dynamiczno-przekrojowy charakter. Testowano dwa warianty:

- 1) podział 576 przypadków według proporcji 1:1:1 (192:192:192) – zbiór uczący stanowiły przypadki z 2001 r., zbiór walidacyjny – przypadki z 2002 r., a zbiór testowy – przypadki z 2003 r.;
- 2) podział 576 przypadków według proporcji 4:1:1 (384:96:96) – zbiór uczący stanowiły przypadki z 2001 r. i 2002 r., zbiór walidacyjny – przypadki z okresu styczeń–czerwiec 2003 r., a zbiór testowy – przypadki z okresu lipiec–grudzień 2003 r.

Zbiory uczące posłużyły do generowania drzew decyzyjnych. Zbiory walidacyjne wykorzystano do testowania poprawności uogólnionej wiedzy reprezentowanej przez drzewo. Za pomocą zbiorów testowych oceniono dokładność tworzonych prognoz. Mniejsze błędy klasyfikacyjne dla wszystkich analizowanych przypadków uzyskano dla drugiego wariantu. Z tego względu w opracowaniu przedstawiono wyniki modelowania dla podziału zbioru danych wejściowych według proporcji 4:1:1. Opcje generowania drzewa decyzyjnego dobierano empirycznie. Wartość parametru „minimalna liczba przykładów tworzących liść drzewa” przyjmowano z przedziału od 1 do 50, a parametru „przycinanie drzewa decyzyjnego” – od 0 (nie przycinaj drzewa) do 50%. Wartości parametrów, dla których osiągnięto najlepsze wyniki uogólniania wiedzy, wynoszą odpowiednio: 1 i 30%.

Wygenerowana baza wiedzy dla suboptymalnego modelu prognostycznego (rys. 3) składa się ze 106 reguł. Największy wpływ na prognozowaną zmienną wywiera zmienna wielkość produkcji wiodącego wyrobu, stanowiąca korzeń wygenerowanego drzewa decyzyjnego. Duży wpływ wywierają również takie zmien-



Rys. 3. Okno prognostycznego systemu ekspertowego

Źródło: opracowanie własne na podstawie modułu PC-Shell.

ne, jak: kwalifikacje i doświadczenie pracowników, poziom intensywności konkurencji oraz stosunek pracowników do pracy, które znalazły się na następnym poziomie drzewa.

3.4. Ocena dokładności odwzorowania

Uzyskane wyniki dokładności odwzorowania badanego zjawiska poprzez suboptymalny model prognostyczny w postaci systemu ekspertowego zestawiono w tab. 3. Jakość odwzorowania oraz dokładność prognoz zjawiska o charakterze ja-

Tabela 3. Statystyki i błędy klasyfikacyjne w zbiorach: uczącym, walidacyjnym i testowym

		Zbiór	Uczący					Walidacyjny					Testowy				
		Stan	-2	-1	0	1	2	-2	-1	0	1	2	-2	-1	0	1	2
Statystyki	razem		0	13	56	184	131	0	6	6	29	55	0	0	6	34	56
	poprawnie		0	13	55	182	131	0	0	6	25	39	0	0	6	30	34
	błędnie		0	0	1	2	0	0	6	0	4	16	0	0	0	4	22
	-2		0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	-1		0	13	0	0	0	0	0	0	0	0	0	0	0	0	0
	0		0	0	55	1	0	0	0	6	0	0	0	0	6	0	4
	1		0	0	1	182	0	0	0	0	25	16	0	0	0	30	18
	2		0	0	0	1	60	0	6	0	4	39	0	0	0	4	34
Błędy klasyfikacji	dla stanów		0	0	1,8	1,1	0	0	100	0	13,8	29,1	0	0	0	11,8	39,3
	dla zbiorów		0,8					27,1					27,1				

Źródło: opracowanie własne na podstawie badań empirycznych.

kościowym oceniano na podstawie błędów klasyfikacji. Bazowano na ogólnym błędzie klasyfikacji postaci:

$$E = \frac{Z}{N} \cdot 100\%, \quad (1)$$

gdzie: Z – liczba wszystkich niepoprawnych określeń stanów (wartości nominalnych) prognozowanej zmiennej w danej grupie typologicznej, np.: w zbiorze uczącym, zbiorze walidacyjnym, zbiorze testowym, danej klasie, danym stanie,

N – liczba przypadków w danej grupie typologicznej.

Błąd ten wskazuje, jaka część wartości nominalnych prognozowanej zmiennej została źle określona. W przypadku niepoprawnych określeń wartości nominalnych brano również pod uwagę stopień ich odchylenia od danych empirycznych. W analizowanym zjawisku maksymalne odchylenie od empirycznej wartości nominalnej wynosiło dwa stany na trzy możliwe. Dodatkowo oceniano udział błędnie określonych wartości nominalnych w danej grupie typologicznej, określonych w odniesieniu do danych empirycznych w stanie dalszym niż sąsiedni. Oceny tej dokonowano według następującej zależności:

$$E_s = \frac{Z_s}{N} \cdot 100\%, \quad (2)$$

gdzie: Z_s – liczba niepoprawnych określeń stanów (wartości nominalnych) prognozowanej zmiennej w danej grupie typologicznej, określonych w stanie dalszym niż sąsiedni,

N – liczba przypadków w danej grupie typologicznej.

Analizując wartości błędów klasyfikacji dla zbioru uczącego i zbioru walidacyjnego, można stwierdzić, że uzyskano dobrą jakość odwzorowania analizowanego zjawiska – akceptowalne błędy klasyfikacji i niski udział błędnie określonych wartości nominalnych E_s (w zbiorze walidacyjnym $E_s = 6,3\%$, a w zbiorze testowym $E_s = 4,2\%$). Takie same wartości błędów klasyfikacji dla zbioru walidacyjnego i testowego wskazują na dobre własności generalizacyjne utworzonego modelu.

Istotny wpływ na błędy klasyfikacji ma struktura przypadków w zbiorach: uczącym, walidacyjnym i testowym. Analizowane zjawisko cechuje rozkład nierównomierny. Stanem dominującym jest wartość nominalna 1. Dla tego stanu błędy klasyfikacji w zbiorze walidacyjnym i testowym wykazują najmniejsze zróżnicowanie i są relatywnie niskie – odpowiednio 24% i 14,3%. Natomiast najmniej liczny stan jest wartość nominalna -1 (wartość nominalna -2 w ogóle nie występowała w zbiorze danych statystycznych). Dla tego stanu błędy klasyfikacji w zbiorze walidacyjnym i testowym wykazują największe zróżnicowanie i osiągają wysokie wartości – odpowiednio 100 i 0%.

4. Zakończenie

W opracowaniu przedstawiono próbę wykorzystania szkieletowego systemu ekspertowego w prognozowaniu gospodarczym. Modułem prognostycznym w opracowanym systemie ekspertowym jest baza wiedzy. Przedstawiona procedura tworzenia modelu prognostycznego umożliwia skrócenie czasu budowy i weryfikacji bazy wiedzy pod względem jej zupełności, niesprzeczności oraz eliminacji nadmiarowości informacji. Od jakości utworzonej bazy wiedzy przede wszystkim zależy prawidłowe funkcjonowanie systemu ekspertowego. Wraz z rozwojem systemów doradczych występuje konieczność tworzenia coraz większych baz wiedzy. Zastosowanie drzew decyzyjnych ułatwia proces generowania reguł. Generowanie reguł na podstawie drzew decyzyjnych umożliwia ich przejrzysty zapis i znacznie skraca czas potrzebny do wnioskowania. Przypadki są oceniane na podstawie wartości zmiennych objaśniających, zgodnie z kolejnością wynikającą ze struktury drzewa. Analizując wygenerowane drzewo decyzyjne, można również dokonać oceny istotności zmiennych objaśniających. Ocena taka może zostać wykorzystana do przeanalizowania wpływu poszczególnych zmiennych na rozpatrywane zjawisko.

Systemy ekspertowe stosuje się w zagadnieniach, które są słabo sformalizowane. W przypadku problemów, dla których istnieją algorytmy numeryczne, stosowanie SE nie jest celowe. Programy algorytmiczne są na ogół znacznie szybsze i doprowadzają do optymalnego rozwiązania, w przeciwieństwie do systemów ekspertowych, które najczęściej prowadzą do rozwiązań suboptymalnych (rozwiązanie niewiele różniące się od optymalnego, akceptowane przez użytkownika systemu). Do głównych przesłanek, które predestynują stosowanie systemów ekspertowych w prognozowaniu, należą:

- przewaga wiedzy w postaci heurystyk,
- przewaga wiedzy/danych o reprezentacji/typie symbolicznym.

Wykorzystując szkieletowy system ekspertowy do budowy modelu prognostycznego, uzyskano dobre wyniki odwzorowania badanego zjawiska gospodarczego i jego prognoz. Uzyskane wyniki mogą zachęcić prognostów do wykorzystywania systemów ekspertowych do prognozowania wielkości innych czynników sukcesu przedsiębiorstwa. Próby prognozowania wielkości niektórych czynników sukcesu z wykorzystaniem szkieletowego systemu ekspertowego mogą również zakończyć się niepowodzeniem. Wynika to z własności prognozowanych zjawisk. Należy więc zawsze zachować dużą ostrożność wobec uzyskanych wyników prognozowania.

Literatura

- Jędrzejczyk W., *Czynniki warunkujące sytuację decyzyjną w małych i średnich przedsiębiorstwach produkcyjnych*, „Współczesne Zarządzanie. Kwartalnik Środowisk Naukowych i Liderów Biznesu” 2004, nr 3.
- Mulawka J., *Systemy ekspertowe*, WNT, Warszawa 1997.
- Technologie informatyczne i prognozowanie w zarządzaniu. Wybrane zagadnienia*, red. L. Kiełtyka, J. Nazarko, Wydawnictwo Politechniki Białostockiej, Białystok 2005.

FRAME EXPERT SYSTEM IN PRODUCT IMPROVEMENT PROGNOSIS PROCESS

Summary

This paper presents the issues of factors conditioning enterprise's success on the market. Basic features of expert systems, particularly in reference to prognostic issues, are outlined in it. The process of prognostic model construction by means of frame expert system is presented in the paper on the example of problem analysis concerning product improvement. Sphinx package is used as a base.

Prof. zw. dr hab. inż. Leszek Kiełtyka jest kierownikiem Katedry Informatycznych Systemów Zarządzania na Wydziale Zarządzania Politechniki Częstochowskiej, e-mail: lekiel@zim.pcz.czyst.pl.

Dr inż. Waldemar Jędrzejczyk jest asystentem w Katedrze Informatycznych Systemów Zarządzania na Wydziale Zarządzania Politechniki Częstochowskiej, e-mail: waldekj@zim.pcz.czyst.pl.