

Metodyka prognozowania stanu ekonomiczno-finansowego małych i średnich przedsiębiorstw

Andrzej Burda

Wyższa Szkoła Zarządzania i Administracji w Zamościu

Zdzisław S. Hippe

Wyższa Szkoła Informatyki i Zarządzania w Rzeszowie

Streszczenie: *W artykule przedstawiono koncepcję nowej metodyki prognozowania stanu ekonomiczno-finansowego małych i średnich przedsiębiorstw opartej na specyficznym sposobie wykorzystania metod uczenia maszynowego. Procedura bazuje na kontrolowanym usprawnianiu danych źródłowych opisujących badane obiekty gospodarcze. Do tego celu wykorzystano zespoły sztucznych sieci neuronowych o architekturze perceptronu dwuwarstwowego. W dalszej kolejności do opisu reguł klasyfikacji firm utworzono i usprawniono modele za pomocą różnych algorytmów uczenia maszynowego. Wiarygodność proponowanej metodyki potwierdza ponad 80-procentowa dokładność klasyfikacji małych i średnich przedsiębiorstw z regionu podkarpackiego uzyskana w trakcie wyczerpujących testów na danych pochodzących z lat 1999–2007.*

Wstęp

Obecnie o sile gospodarczej krajów wysoko rozwiniętych nie decydują duże koncerny, lecz małe i średnie przedsiębiorstwa, zwane dalej MŚP, zatrudniające do 250 osób¹. MŚP stanowią 99,8% firm funkcjonujących w sektorach pozafinansowych UE. Są one miejscem pracy ponad 67% wszystkich osób zatrudnionych w sektorze prywatnym [Schmiemann 2008]. Ich upadłość w każdym przypadku stanowi bardzo duże zagrożenie bezrobociem na obszarze funkcjonowania, szczególnie w regionach słabo zurbanizowanych. Z tego względu poszukiwanie niezawodnych i efektywnych metod oceny ich stanu ma duże znaczenie dla nich samych, ale także spełnia ważną funkcję społeczną.

1. Cel i zakres badań

Dane ekonomiczno-finansowe MŚP w przeciwieństwie do firm dużych, notowanych na giełdach papierów wartościowych, nie są publicznie dostępne, a ponadto – jak się można spodziewać – mogą zawierać wewnętrzne usterki wynikające z przypadkowych błędów wprowadzonych przez osoby kierujące obsługą finansową lub z zamierzonych działań w procesie tzw. kreatywnej księgowości [Nowak 1998]. Może być to jedną z ważniejszych przyczyn niezadowalających wyników prognozowania stanów tych przedsiębiorstw, co zdaje się wskazywać analiza dostępnej literatury [Pongsat, Ramage, Lawrence 2004], [Mączyńska, Zawadzki 2006], [Rutkowska 2006] oraz wyniki wstępnych badań prowadzonych z zastosowaniem standardowych metod statystycznych [Burda 2009]. Z tego względu podjęliśmy próbę nowego podejścia do prognozowania stanu MŚP z zastosowaniem wybranych metod uczenia maszynowego w celu opracowania modeli, które mogłyby być wykorzystane do przewidywania stanów (*bankrut, nie-bankrut*) badanych firm.

¹ Kryteria podziału przedsiębiorstw ze względu na ich wielkość reguluje ustawa z 2 lipca 2004 r. o swobodzie działalności gospodarczej (DzU z 2004 r., nr 173, poz. 1808 ze zm.).

2. Nowa metodyka oceny stanu MŚP

Nowa metodyka oceny stanu MŚP bazuje na trzech kolejnych krokach:

- 1) usprawnianiu źródłowego zbioru danych za pomocą Zespołu Sztucznych Sieci Neuronowych (ZSSN) [Burda, Kuczmowska, Hippe 2007],
- 2) poszukiwaniu zestawu reguł wstępnej prognozy (surowy model uczenia opisujący właściwości badanych obiektów). W tym celu wybrano algorytmy uczenia maszynowego: TVR [Hippe, Knap 2003], GTS [Hippe 1999] oraz nowy algorytm generowania reguł decyzji *via* sieci przekonań Bayesa (B-NET) [Hippe, Grzymała-Busse, Mroczek 2006],
- 3) poprawie wstępnych reguł decyzji (uzyskanych w kroku poprzednim). W tym celu wykorzystano specjalne narzędzie [Paja 2008] usprawniania reguł, aby uzyskać ostateczny, *quasi*-optymalny zestaw reguł decyzji. Reguły te traktowane są jako modele uczenia do klasyfikacji bieżących i/lub przyszłych stanów badanych MŚP.

3. Opis eksperymentu

3.1. Opis bazy informacyjnej

Baza informacyjna użyta do badań to zbiór 196 przypadków MŚP, z czego 98 firm to firmy w stanie upadłości bądź będące w stanie likwidacji (kategoria *bankrut*), a pozostałe to te kontynuujące swoją działalność (*nie-bankrut*). Każdy z obiektów został opisany 7 atrybutami (tab. 1) – wskaźnikami ekonomiczno-finansowymi. Ich wartości obliczono, zgodnie ze stosownymi procedurami opisanymi w [Kowerski 2006], na podstawie danych zawartych w sprawozdaniach finansowych i o zatrudnieniu dostarczanych przez MŚP do urzędów statystycznych.

Tab. 1. Atrybuty opisujące stan ekonomiczno-finansowy MŚP

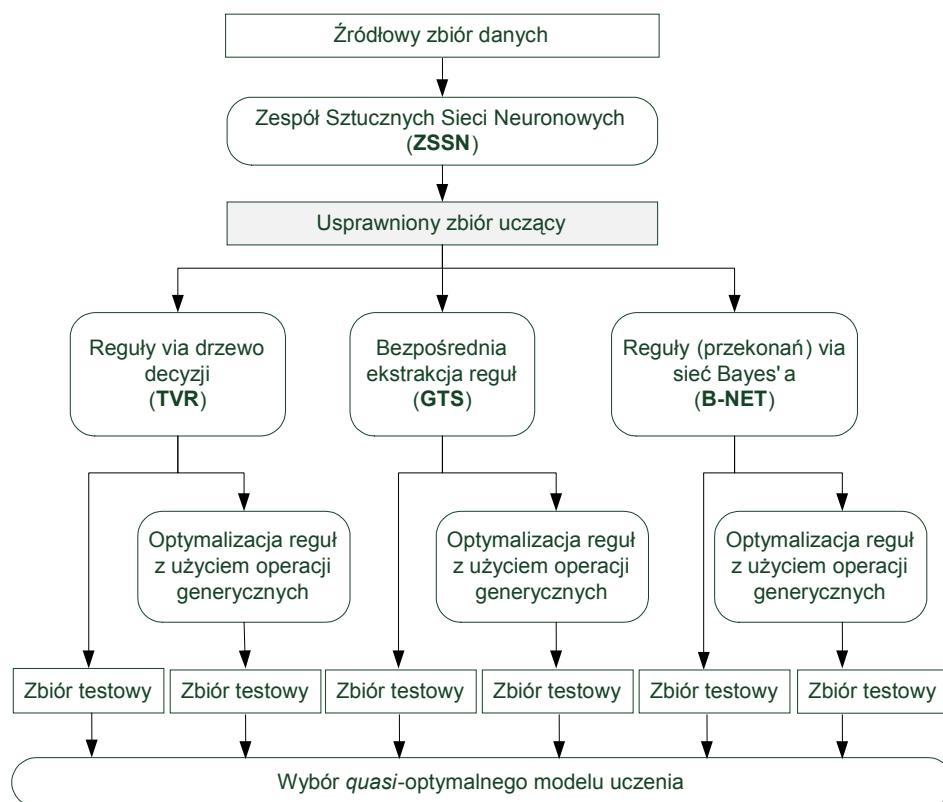
Lp.	Nazwa atrybutu	Typ atrybutu
1.	Udział zapasów w aktywach ogółem	Sytuacja majątkowa przedsiębiorstwa
2.	Udział kapitału obrotowego w finansowaniu majątku ogółem	Sytuacja majątkowo-kapitałowa
3.	Niedobór kapitału obrotowego netto	Płynność finansowa
4.	Wskaźnik globalnego obrotu aktywami (produktywność majątku)	Efektywność wykorzystania zasobów
5.	Wynik finansowy brutto	Rentowność działalności
6.	Stopa zmian sprzedaży	Pozycja rynkowa
7.	Stopa zmian zatrudnienia	Potencjał produkcyjny

3.2. Opis badań

Badania przeprowadzono zgodnie z opisaną w p. 3 metodyką i schematycznie przedstawioną na rys. 1. Każdy krok w rzeczywistości był powtarzany siedem razy z powodu stosowania siedmiokrotnej walidacji krzyżowej.

3.3. Informacje uzupełniające

W celu usprawnienia surowych danych bazy informacyjnej (pierwszy etap procedury) zastosowano zespół dziewięciu sieci neuronowych, perceptronów dwuwarstwowych (MLP). Sieci uczone za pomocą algorytmu wstecznej propagacji błędów. Początkowa liczba neuronów w warstwie ukrytej wynosiła siedem. Aby uniknąć nadmiernego dopasowania się sieci do danych (efekt przeuczenia), wprowadzono mechanizm regularyzacji Weigenda [Lula, Tadeusiewicz 2001].



Rys. 1. Schemat metodyki oceny i prognozowania stanu MŚP

4. Wyniki badań i wnioski

Wyniki przeprowadzonego eksperymentu, zebrane w tab. 2, wspierają nasze wcześniejsze obserwacje [Burda, Kuczmowska, Hippe 2007], że w badaniach z wykorzystaniem danych ekonomiczno-finansowych MŚP korzystanie z zespołów sztucznych sieci neuronowych wydaje się korzystne w celu filtrowania wielu usterek powstałych m.in. wskutek kreatywnej księgowości. Innym źródłem trudności, czyli błędów w ocenie badanych obiektów, mogą być celowe kłamstwa (agresywna księgowość), potencjalnie częste w przypadku małych i średnich przedsiębiorstw.

Tab. 2. Wyniki klasyfikacji MŚP za pomocą opracowanych modeli uczenia

	Zbiór źródłowy			Usprawniony zbiór uczący					
				Reguły wstępne			Reguły finalne		
	TVR	GTS	B-NET	TVR	GTS	B-NET	TVR	GTS	B-NET
Liczba reguł (min. – maks.)	13–21	55–69	9–23	4–13	26–42	19–30	10–18	19–32	16–28
Błąd klasyfikacji [%]	25,00	23,98	30,10	20,41	22,45	25,51	19,90	20,92	19,90
Błąd fałszywie pozytywnej klasyfikacji [%]	26,75	25,57	34,43	19,92	23,68	36,22	19,08	21,91	25,69
Błąd fałszywie negatywnej klasyfikacji [%]	23,80	21,07	24,09	19,79	19,80	14,39	19,79	19,55	13,84

W wyniku przeprowadzonego eksperymentu okazało się, że trzy różne modele uczenia (TVR, GTS i B-NET) w efekcie finalnym obciążone są porównywalnym błędem klasyfikacji. Model uczenia uzyskany za pomocą algorytmu TVR wydaje się jednak najbardziej korzystny ze względu na równy udział wszystkich rodzajów błędów. Uzyskana tą drogą dokładność klasyfikacji przekracza 80% i wydaje się wysoka, jeśli weźmiemy pod

uwagę metodykę badań przyjętą w zakresie oceny jakości modeli, a mianowicie n -krotną walidację krzyżową. Dla *quasi*-zoptymalizowanego modelu TVR został wygenerowany następujący zestaw reguł:

REGULA 1

JEZELI Udział kapitału obrotowego w finansowaniu majątku ogółem $< -0,415$
TO Stan JEST bankrut

REGULA 2

JEZELI Stopa zmian zatrudnienia $< -0,27$
TO Stan JEST bankrut

REGULA 3

JEZELI Stopa zmian sprzedaży $< -0,475$
TO Stan JEST bankrut

REGULA 4

JEZELI Udział kapitału obrotowego w finansowaniu majątku ogółem $\geq -0,415$
ORAZ Stopa zmian sprzedaży $\geq -0,475$
ORAZ Stopa zmian zatrudnienia $\geq -0,27$
TO Stan JEST nie-bankrut

Ten bardzo prosty zbiór reguł (tylko jedna reguła dla kategorii *nie-bankrut*, a trzy reguły ostrzegania o możliwości upadłości) sprawdzony na dostępnych danych dał całkiem zadowalające rezultaty. Aby uzyskać lepszy wgląd w skuteczność tego typu modeli oceny stanu MŚP, proponowana metodyka zostanie gruntownie przetestowana na innych bazach informacyjnych.

Literatura

- BURDA A. (2009): *Wielokryterialna ocena modeli prognozowania stanu ekonomiczno-finansowego małych i średnich przedsiębiorstw*, „Barometr Regionalny”, nr 15.
- BURDA A., KUCZMOWSKA B., HIPPE Z.S. (2007): *Ensembles of Artificial Neural Networks for Predicting Economic Situation of Small and Medium Enterprises*, [w:] M. Kurzynski, E. Puchala, M. Wozniak, A. Zolnierek (red.), *Computer Recognition Systems 2*, Springer, Berlin–Heidelberg.
- HIPPE Z.S. (1999): *Data Mining and Knowledge Discovery in Business: Past, Present, and Future*, [w:] W. Abramowicz, M. Orłowska (red.), *Business Information Systems '99*, Springer-Verlag, London.
- HIPPE Z.S., GRZYMAŁA-BUSSE J.W., MROCEK T. (2006): *Belief Networks vs. Relief Rules: Basic Theory and Practical Issues*, [w:] D. Zuba, A. Parczewski (red.), *Chemometrics. Methods and Applications*, Institute of Forensic Research Publishers, Kraków.
- HIPPE Z.S., KNAP M. (2003): *Badania nad generowaniem pewnych oraz możliwych drzew decyzji*, „Zeszyty Naukowe Wydziału ETI Politechniki Gdańskiej, Technologie informacyjne”, nr 1.
- KOWERSKI M. (2006): *Koncepcja badań sektora małych i średnich przedsiębiorstw w projekcie „System przeciwdziałania bezrobociu na obszarach słabo zurbanizowanych”*, „Barometr Regionalny”, nr 6.
- LULA P., TADEUSIEWICZ R. (red.) (2001): *Statistica Neural Networks™*, StatSoft Polska, Kraków.
- MĄCZYŃSKA E., ZAWADZKI E. (2006): *Dyskryminacyjne modele predykcji bankructwa przedsiębiorstw*, „Ekonomista” nr 2.
- NOWAK M. (1998): *Praktyczna ocena kondycji finansowej przedsiębiorstwa*, Fundacja Rozwoju Rachunkowości w Polsce, Warszawa.
- PAJA W. (2008): *Development of the Optimal Learning Models Using Secondary Sources of Knowledge*, Ph.D. Thesis, AGH University of Science and Technology, Kraków.
- PONGSATAT S., RAMAGE J., LAWRENCE H. (2004): *Bankruptcy Prediction for Large and Small Firms in Asia: A Comparison of Ohlson and Altman*, „Journal of Accounting and Corporate Governance” nr 2.
- RUTKOWSKA J. (2006): *Ocena przydatności metod prognozowania bankructwa w warunkach polskich*, „Zeszyty Naukowe Akademii Ekonomicznej w Krakowie”, nr 683.
- SCHMIEMANN M. (2008): *Enterprises by size class-overview of SMEs in the EU*, http://epp.eurostat.ec.europa.eu/cache/ITY_OFFPUB/KS-SF-08-031/EN/KS-SF-08-031-EN.PDF.