

Henryk Marjak

IDENTYFIKOWANIE SYTUACJI FINANSOWEJ PRZEDSIĘBIORSTW TWORZĄCYCH MWIG40 ZA POMOCĄ SIECI NEURONOWYCH

FINANCIAL IDENTIFICATION OF COMPANIES MAKE mWIG40 BY NEURAL NETWORKS

Zakład Analizy Systemowej, Zachodniopomorski Uniwersytet Technologiczny w Szczecinie
ul. Klemensa Janickiego 31, 71-270 Szczecin, e-mail: Henryk.Marjak@zut.edu.pl

Summary. In the paper were presented researches constructing of model to estimating financial distress of enterprises based on artificial neural nets. Parameters of neural nets were optimized by scaled conjugate gradient and resilient backpropagation algorithms. The tested models have enabled the correct classification of more than 80% of the elements. In proposed models financial distress was developed based on information from yearly reports of medium enterprises quoted on WGPW (Warsaw Stock Exchange).

Słowa kluczowe: bankructwo, klasyfikacja, sieci neuronowe.
Key words: bankruptcy, classification, neural nets.

WSTĘP

Rozwój technologii informacyjno-komunikacyjnych (ICT) umożliwił elastyczniejsze budowanie modeli prognozowania sytuacji finansowej przedsiębiorstw. Spośród klasycznych modeli predykcji bankructwa, nazywanych również systemami wczesnego ostrzegania, obejmującymi wskaźniki finansowe, wymienić należy modele Beaver'a (1968), Altmana (1968) oraz Altmana i in. (1977). Ich przydatność do zaliczania podmiotów do bankrutów lub nie była zróżnicowana. Badacze stosowali takie techniki klasyfikacyjne, jak wielowymiarowa analiza dyskryminacyjna lub analiza logit/probit, badając dwie grupy firm – zdrowe i zagrożone. Na tej podstawie tworzono model klasyfikacyjny, który następnie stosowano do prognozowania nowych przypadków. Wyniki uzyskane za pomocą takich modeli były korzystne, jeżeli warunki środowiska ekonomicznego dla próbek w trakcie prognozy pokrywały się z warunkami ekonomicznymi panującymi wówczas, gdy model był tworzony.

Pierwsze badania nad zastosowaniem sieci neuronowych do oceny zdolności kredytowej również przeprowadził E.I. Altman (1994). D. West (2000) opracował algorytmy sieci neuronowych, za których pomocą uzyskał lepsze wyniki niż oceny zdolności kredytowej za pomocą np. drzew decyzyjnych. Warto zwrócić uwagę, że sieci neuronowe dają dobre wyniki w badaniu przedsiębiorstw działających w trudnych warunkach ekonomicznych, tj. bez rozwiniętej infrastruktury, z wysokimi kosztami transakcyjnymi i ograniczeniami prawnymi.

Z porównania tradycyjnych metod statystycznych z metodami alternatywnymi wynika zróżnicowanie, na które zwracają uwagę F.M. Liou i C.H. Yang (2008), zależne od pewnych uprzedzeń badaczy. Badania przeglądowe S. Balcaena i H. Oogghe (2004) pokazują, że

analiza porównawcza 28 prac kończyła się konkluzjami, że w 15 przypadkach sieci neuronowe były „zdecydowanie najlepsze”, „warunkowo najlepsze” lub „nieco lepsze”.

Celem artykułu jest skonstruowanie takiego modelu, który umożliwi trafną ocenę sytuacji finansowej przedsiębiorstwa, a w rezultacie podjęcie optymalnych decyzji inwestycyjnych i dotyczących współpracy z ocenianym przedsiębiorstwem.

MATERIAŁ I METODY

Perceptron wielowarstwowy to adaptacyjna i zasadniczo nieliniowa maszyna licząca, zbudowana w efekcie połączenia prostych elementów przetwarzających, nazywanych neuronami. Liczba elementów i wzorzec połączeń między nimi definiują strukturę sieci neuronowych. Sygnały przepływające przez połączenia skalowane są przez odpowiednie parametry, nazywane wagami synaptycznymi. Każdy element przetwarzający ma kilka połączeń wejściowych i tylko jedno wyjściowe.

Dane, które poddano klasyfikacji, pozyskano z raportów kwartalnych spółek giełdowych wchodzących w skład indeksu mWIG40 (MIDWIG) z lat 2005–2008 – 640 wektorów; mWIG40 to jeden z indeksów notowanych na Warszawskiej GPW, w którego skład wchodzi 40 spółek różnych branż, charakteryzujących się średnim obrotem. Jest on kontynuacją wcześniej notowanego indeksu MIDWIG – do zmiany nazwy doszło 17 marca 2007 roku. Średnia wartość aktywów i wartości księgowej spółek wchodzących w skład mWIG40 (dane z 2010 r.) wynosiła odpowiednio 5 355 107 tys. zł i 1 406 031 tys. zł, przy czym minimalna wartość aktywów wynosiła 109 112 tys. zł, a maksymalna – 64 428 407 tys. zł.

Proces kończący się zastosowaniem i skutecznym wykorzystaniem sieci neuronowej powinien być poprzedzony pracami przygotowawczymi i procesem, który ogólnie można nazwać uczeniem sieci neuronowej. Realizację procesu badania sieci neuronowej można podzielić na następujące etapy:

- określenie badanej wielkości,
- gromadzenie danych, szeregów liczbowych opisujących badane zjawisko,
- analiza danych, wstępne ich przetworzenie (*preprocessing*),
- wyodrębnienie zbiorów uczącego i testowego,
- wybór architektury sieci i metody uczenia,
- uczenie sieci neuronowej,
- weryfikacja modelu,
- zastosowanie modelu.

W artykule zastosowano dwa algorytmy uczenia: gradientów sprzężonych z regularyzacją (SCG) oraz Rprop. Dla obu tych metod proces uczenia można uogólnić przez wyróżnienie kilku etapów: analiza sieci neuronowej dla aktualnego wektora wejściowego, utworzenie sieci propagacji wstecznej, zastąpienie funkcji aktywacji ich pochodnymi, na kolejnym etapie podanie na wyjściu różnic między odpowiednimi wartościami uzyskanymi i wymaganymi, adaptacja wag na podstawie poprzednich etapów, kontynuacja uczenia dla wszystkich wektorów uczących do czasu spełnienia warunku zatrzymania.

Warunek zatrzymania to albo uzyskanie założonego błędu, np. MSE (błąd średniokwadratowy), albo wykonanie zaplanowanej liczby cykli uczenia:

$$MSE = \frac{1}{n-p} \sum_{i=0}^{n-1} (t_i - \sigma_i)^2,$$

gdzie:

t_i – wartości rzeczywiste,

σ_i – wartości otrzymane,

n – liczba próbek uczących,

p – liczba szacowanych parametrów (wagi).

Metoda gradientów sprzężonych z regularyzacją SCG – *scaled conjugate gradient* (Moller 1993) jest odmianą zwykłej metody gradientów sprzężonych. Metody te nazywane są metodami drugiego stopnia. Określenie drugi stopień oznacza używanie drugiej pochodnej funkcji celu. Techniki te znajdują szybszą trasę do minimum niż techniki wykorzystujące pierwszą pochodną. Lepsze możliwości optymalizacyjne uzyskiwane są wyższym kosztem obliczeniowym.

W standardowej propagacji błędu zakłada się obliczenia w kierunku zmniejszającego się gradientu funkcji błędu. W metodach gradientów sprzężonych wykorzystywane są obliczenia sprzężone z poprzednim etapem obliczeniowym. W metodzie gradientów sprzężonych z regularyzacją obowiązują następujące zależności:

$$s_k = E''(w_k) \cdot p_k \approx \frac{E'(w_k + \sigma_k p_k) - E'(w_k)}{\sigma_k}, 0 < \sigma_k \ll 1,$$

$$s_k = \frac{E'(w_k + \sigma_k p_k) - E'(w_k)}{\sigma_k} + \lambda_k p_k,$$

$$w_{i+1} = w_i + \alpha_i p_i,$$

gdzie:

w_k – wektor wag,

$E(w_k)$ – funkcja błędu,

k – etap iteracji,

p_j – nowy kierunek sprzężenia,

σ_k – wartość kroku w kierunku sprzężenia,

λ_k – parametr regularyzacji.

Metoda gradientów sprzężonych z regularyzacją jest znacznie szybsza w dochodzeniu do określonej wartości błędu niż podstawowe metody gradientów sprzężonych, jednak zależność ta związana jest z dłuższym czasem obliczeń. Mówiąc zatem o prędkości uczenia, nie mamy na myśli czasu wykorzystania procesora, ale liczbę epok uczenia koniecznych do osiągnięcia minimum błędu.

Nazwa algorytmu RPROP (Riedmiller 1992) pochodzi od ang. Resilient Backpropagation. Podstawowym założeniem tej metody jest eliminacja szkodliwego wpływu wielkości pochodnych cząstkowych, dlatego rozważa się tylko znak pochodnej, na którego podstawie określany jest kierunek zmian wag. Wielkość zmian wag jest wyznaczana za pomocą następującego czynnika:

$$\Delta w_{ij}^{(t)} = \begin{cases} -\Delta_{ij}^{(t)}, & \text{gdy } \frac{\partial E^{(t)}}{\partial w_{ij}} > 0, \\ +\Delta_{ij}^{(t)}, & \text{gdy } \frac{\partial E^{(t)}}{\partial w_{ij}} < 0, \\ 0 & \text{w innym przypadku,} \end{cases}$$

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \cdot \Delta_{ij}^{(t-1)}, & \text{gdy } \frac{\partial E^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t)}}{\partial w_{ij}} > 0, \\ \eta^- \cdot \Delta_{ij}^{(t-1)}, & \text{gdy } \frac{\partial E^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t)}}{\partial w_{ij}} < 0, \\ \Delta_{ij}^{(t-1)} & \text{w innym przypadku,} \end{cases}$$

gdzie:

$\frac{\partial E^{(t)}}{\partial w_{ij}}$ – gradient po wszystkich wzorcach uczących,

η^+, η^- – maksymalna i minimalna wartość współczynnika uczenia.

Algorytm RPROP znacznie przyspiesza proces uczenia w obszarach, gdzie nachylenie funkcji błędu jest niewielkie. Podstawą tej metody jest ciągły wzrost współczynnika uczenia, gdy dla dwóch kolejnych kroków znaki gradientu są takie same, a także zmniejszenie wartości współczynnika, gdy znaki te są różne.

Budowę modelu oparto na istniejących modelach prognozowania bankructwa, czyli

a) modelu wczesnego ostrzegania Beaver (1968):

$$P_{ij} = f(\text{CASH}_i, \text{NIN}_i, \text{LEV}_i, \text{WC}_i, \text{LIQ}_i, \text{NCRE}_i);$$

b) modelu wczesnego ostrzegania Altmana (1968):

$$P_{ij} = f(\text{WC}_i, \text{CP}_i, \text{ROA}_i, \text{CAP}_i, \text{ACT}_i);$$

c) zmodyfikowanego modelu wczesnego ostrzegania Altmana (1977):

$$P_{ij} = f(\text{ROA}_i, \text{S}_{\text{ROA}}, \text{DS}_i, \text{CP}_i, \text{LIQ}_i, \text{CAP}_i, \text{SIZE}_i);$$

d) modelu Garcia (1997):

$$P_{ij} = f(\text{QLIQ}_i, \text{ATD}_i, \text{INT}_i, \text{AMO}_i, \text{EAR}_i),$$

gdzie:

CASH_i – nadwyżka finansowa (wynik finansowy netto + amortyzacja) / zobowiązania ogółem,

NIN_i – wynik finansowy netto / aktywa ogółem,

LEV_i – zobowiązania ogółem / aktywa ogółem (wskaźnik zadłużenia ogólnego),

WC_i – kapitał obrotowy / aktywa ogółem,

LIQ_i – aktywa bieżące / zobowiązania krótkoterminowe,

NCRE_i – (aktywa płynne – zobowiązania krótkoterminowe) / (wydatki na działalność operacyjną – amortyzacja),

CP_i – zysk zatrzymany/aktywa ogółem,

ROA_i – (zysk przed opodatkowaniem i spłatą odsetek) / aktywa ogółem,
 CAP_i – rynkowa wartość kapitału akcyjnego / księgową wartość zadłużenia,
 ACT_i – przychody ze sprzedaży / aktywa ogółem (rotacja aktywów),
 $SROA$ – błąd standardowy oszacowania ROA ,
 DS_i – zyski bez uwzględnienia odsetek i przed opodatkowaniem / odsetki ogółem,
 $SIZE_i$ – transformacja logarytmiczna aktywów ogółem,
 $QLIQ_i$ – aktywa płynne / płatności bieżące,
 ATD_i – aktywa ogółem / zobowiązania ogółem,
 INT_i – odsetki / sprzedaż,
 AMO_i – amortyzacja / aktywa amortyzowane,
 EAR_i – zyski przed opodatkowaniem / zobowiązania ogółem.

Ocenę klasyfikatorów przeprowadzono przez porównanie macierzy pomyłek (*confusion matrix*), w szczególności współczynnika pomyłek dla zbioru testowego, charakterystyk operacyjnych odbiornika ROC (Receiver Operating Characteristics) oraz minimalizowanych w trakcie uczenia błędów (MSE z regularyzacją i ekonomizacją). Klasyfikatory, w których zastosowano obie metody uczenia (SCG i Rprop), porównano za pomocą k -krotnego testu krzyżowego (*k-fold cross validation*).

Macierz pomyłek to tabela zawierająca liczbę wierszy i kolumn odpowiadającą klasom decyzyjnym. Wiersze odpowiadają oryginalnym klasom decyzyjnym, a kolumny – przewidywanym klasom decyzyjnym (tab. 1).

Tabela 1. Macierz pomyłek

		Przewidywane klasy	
		pozytywne	negatywne
Oryginalne klasy	Pozytywne	TP	FN
	Negatywne	FP	TN

W macierzy pomyłek poszczególne symbole oznaczają:

- TP (*true positive*) – liczba poprawnie sklasyfikowanych pozytywnych przypadków;
- TN (*true negative*) – liczba poprawnie sklasyfikowanych negatywnych przypadków;
- FP (*false positive*) – liczba błędnie sklasyfikowanych pozytywnych przypadków;
- FN (*false negative*) – liczba błędnie sklasyfikowanych negatywnych przypadków.

Na podstawie wartości TP, TN, FP, FN można określić: czułość (*sensitivity*), czyli $TP/(TP + FN)$, oraz specyficzność (*specifity*), tj. $TN/(TN + FP)$. Charakterystyka odbiornika ROC określa zależności między czułością a specyficznością, określając jakość klasyfikatora. Im pole wyznaczone przez krzywe bliższe jest wartości 1, tym klasyfikator ma lepsze właściwości klasyfikacyjne.

Porównanie klasyfikatorów za pomocą k -krotnego testu krzyżowego polega na podziale zbioru danych na k części. Model trenowany jest na $k - 1$ częściach, następnie testowany na pozostałej części. Procedura powtarzana jest k -krotnie i dzięki temu każda z części jest użyta do testowania. W naszych rozważaniach przyjęto $k = 10$. Uzyskane w ten sposób wyniki sprawdzono za pomocą odpowiednich testów statystycznych.

WYNIKI I DYSKUSJA

Zgodnie z wcześniejszymi założeniami zbior danych podzielono na $k = 10$ części – 9 z nich służyło do trenowania, a jedna do testowania. Wektory wejściowe zawierały takie wskaźniki, jak rentowności – ROA, ROE; zadłużenia – LEV; aktywności – ACT.

Współczynnik ROE (rentowność kapitału własnego) to procentowo wyrażony stosunek zysku netto do kapitału własnego. Określa, jaka część zysku netto była finansowana środkami własnymi. Przyjmuje się, że im wyższa jest wartość ROE, tym większe możliwości uzyskania nadwyżek finansowych.

Kryterium klasyfikacyjnym była zmiana współczynnika C/Z w następnym badanym okresie. Współczynnik ten określa stosunek ceny jednej akcji do przypadającego na nią zysku. Wysoka wartość C/Z może oznaczać zawyżoną wycenę akcji danej spółki w stosunku do osiągniętych zysków, niska wartość – dobrą okazję do zainwestowania, przy czym należy pamiętać, że ujemna wartość C/Z świadczy o tym, że spółka nie przyniosła zysku w badanym okresie. Zaleca się konfrontowanie tego wskaźnika z C/Z ze wskaźnikiem dla branży, którą reprezentuje badana spółka.

Jakość klasyfikacji oceniono za pomocą współczynnika pomyłek oraz błędu MSE obliczonych dla każdej z części testowych. W tabeli 2 przedstawiono statystyki opisowe wymienionych błędów.

Tabela 2. Statystyki opisowe błędów dla danych testowych

Miara błędu	Średnia	Minimum	Maksimum	Dolny kwartył	Górny kwartył	Odchylenie standardowe
Pomyłki (SCG)	0,4073	0,3530	0,5091	0,3816	0,4204	0,0361
Pomyłki (RP)	0,4093	0,3591	0,5132	0,3867	0,4173	0,0377
MSE (SCG)	0,2670	0,2006	0,3409	0,2462	0,2899	0,0302
MSE (RP)	0,2546	0,1968	0,3228	0,2406	0,2688	0,0261

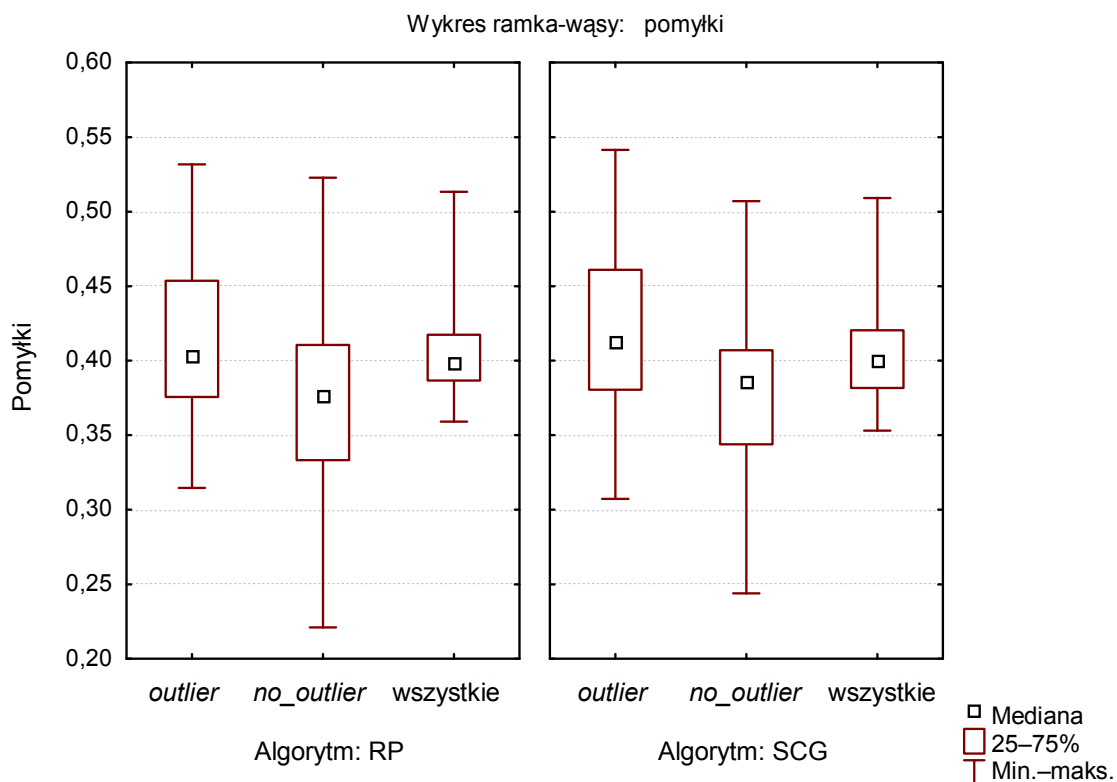
Z analizy błędów wynika, że dla algorytmu uczenia SCG uzyskano najmniejsze wartości współczynnika pomyłek – 0,3530. Maksymalna wartość współczynnika pomyłek była również niższa w przypadku algorytmu SCG (pomyłki (SCG) = 0,5091 niż pomyłki (RP) = 0,5132). Wartości odchylenia standardowego współczynników pomyłek świadczą o mniejszym rozproszeniu tych wartości w przypadku algorytmu SCG. Statystyki opisowe optymalizowanego błędu MSE-reg wskazują na lepszą jakość modeli uczonych za pomocą RPROP (średnia MSE (RP) = 0,1968 niż MSE (SCG) = 0,2670).

Następnie zbiór danych podzielono na dwa podzbiory zawierające dane odstające – *outlier*, i nieodstające – *no_outlier*, według formuły $x_i \pm 3 \cdot$ odchylenie standardowe. Wyniki przedstawiono w tabeli 3.

Po odrzuceniu danych odstających lepsze wyniki uzyskano dla RPROP (średnia pomyłki (RP) = 0,3790). Wyniki dla zbioru złożonego z wartości odstających wskazują na wagę odpowiedniego przygotowania danych przez eliminację wartości odstających. Innym podejściem może być zastosowanie algorytmów uczenia, które mogłyby poradzić sobie z tym problemem (rys. 1).

Tabela 3. Statystyki opisowe błędów dla danych testowych (*outlier* i *no_outlier*)

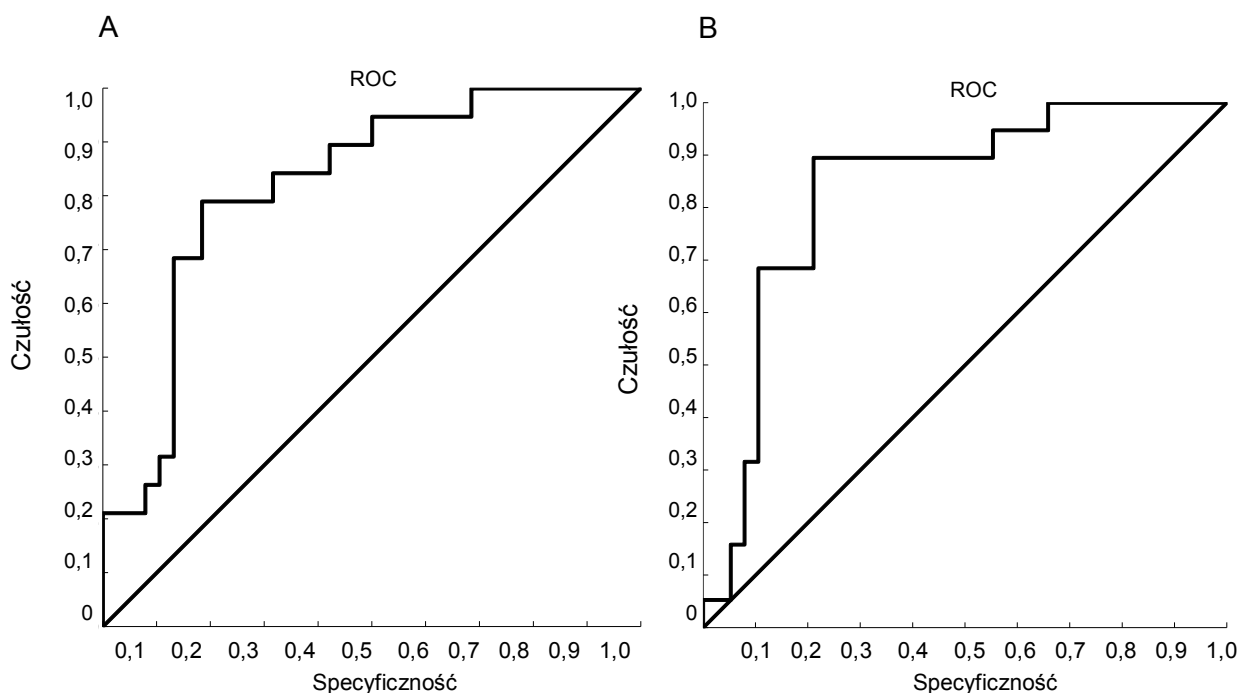
	Miara błędu	Średnia	Minimum	Maksimum	Dolny kwartyl	Górny kwartyl	Odchylenie standardowe
<i>No_outlier</i>	pomyłki (SCG)	0,3815	0,2438	0,5070	0,3438	0,4070	0,0670
	pomyłki (RP)	0,3790	0,2210	0,5228	0,3333	0,4105	0,0740
	MSE (SCG)	0,2384	0,1862	0,4354	0,2145	0,2510	0,0395
	MSE (RP)	0,2067	0,1817	0,2456	0,1937	0,2221	0,0166
<i>Outlier</i>	pomyłki (SCG)	0,4160	0,3073	0,5414	0,3804	0,4609	0,0584
	pomyłki (RP)	0,4133	0,3146	0,5317	0,3756	0,4536	0,0570
	MSE (SCG)	0,3794	0,2554	0,5811	0,3497	0,4092	0,0520
	MSE (RP)	0,3651	0,2785	0,4804	0,3394	0,3845	0,0436



Rys. 1. Porównanie wartości pomyłek dla wszystkich zbiorów danych

Z analizy miar położenia wynika, że potencjalnie lepszą zdolność klasyfikacyjną miał model uczony z wykorzystaniem algorytmu Rprop. Najlepsze wyniki uzyskano dla modeli z siedmioma (SCG (7)) i ośmioma (Rprop (8)) neuronami ukrytymi. Dla tych modeli przeprowadzono analizę zdolności klasyfikacyjnych za pomocą charakterystyk ROC i macierzy pomyłek. Charakterystyki ROC dla najlepszych optymalizowanych modeli wskazują na podobne zdolności klasyfikacyjne obu modeli: Rprop (8) – rysunek 2 A, i SCG (7) – rysunek 2 B.

Analiza macierzy pomyłek pokazuje, że oba modele w takim samym stopniu właściwie identyfikowały sytuację badanych jednostek – 80,7% zostało właściwie zakwalifikowanych do założonych grup (tab. 4).



Rys 2. Charakterystyki ROC dla Rprop i SCG – najlepsze modele

Tabela 4. Macierze pomyłek dla Rprop i SCG – najlepsze modele

A

Oryginalne klasy	1	15	7	68,2%
	2	4	31	88,6%
		78,9%	81,6%	80,7%
		1	2	
		Przewidywane klasy		

B

Oryginalne klasy	1	16	8	66,7%
	2	3	30	90,9%
		84,2%	78,9%	80,7%
		1	2	
		Przewidywane klasy		

Różnice między modelami dotyczą skuteczności właściwego przypisywania do poszczególnych klas. Model Rprop (8) lepiej klasyfikował wektory odpowiadające gorszej wartości współczynnika C/Z niż średnia rynkowa – skuteczność 81,6% (tab. 4A). Za pomocą modelu SCG (7) uzyskano lepsze wyniki dla wektorów odpowiadających lepszej wartości współczynnika C/Z niż średnia rynkowa – 84,2% zostało zakwalifikowanych do odpowiedniej klasy (tab. 4B).

PODSUMOWANIE

W artykule skupiono się na porównaniu dwóch algorytmów uczenia: gradientów sprzężonych z regularyzacją i Rprop. Dla zbadanych zbiorów nie stwierdzono istotnego statystycznie zróżnicowania jakości klasyfikatorów (10-krotny test krzyżowy) optymalizowanych tymi dwoma metodami.

Z przeprowadzonych badań wynika, że modele nieliniowe, takie jak sieci neuronowe, mogą być dobrą alternatywą dla klasycznych modeli liniowych. Badane modele umożliwiały właściwą klasyfikację ponad 80% elementów, a niewielkie różnice pomiędzy modelami przyniosła analiza kwalifikowania do poszczególnych klas.

Modele statystyczne identyfikacji sytuacji finansowej przedsiębiorstw są bardzo skuteczne wówczas, gdy prognozy dotyczą jednostek podobnych do tych, na których podstawie zostały zbudowane. Ponieważ były budowane na podstawie danych z przedsiębiorstw amerykańskich, trudno je zastosować do polskich przedsiębiorstw. Modele te mogą charakteryzować się wyższą sprawnością w odniesieniu do przedsiębiorstw działających w stabilnej (do niedawna) gospodarce amerykańskiej niż w polskich przedsiębiorstwach działających w mniej przewidywalnych warunkach.

PIŚMIENNICTWO

- Altman I.E.** 1968. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *J. Finance* 23 (4), 589–609.
- Altman E.I., Haldeman E., Narayanan P.** 1977. Zeta analysis: a new model to identify bankruptcy risk of corporations. *J. Banking and Finance* 1, 29–54.
- Altman E.I., Marco G., Varetto F.** 1994. Corporate distress diagnosis: comparison using linear discriminant analysis and neural networks (the Italian Experience). *J. Banking and Finance* 18, 505–529.
- Balcaen S., Ooghe H.** 2004. Alternative methodologies in studies on business failure: do they produce better results than the classic statistical methods? Working Paper Series 16. Gent, Vlerick Leuven Gent Management School.
- Beaver W.H.** 1968. Alternative accounting measures as predictor of failure. *The Accounting Rev.*, Autumn, 112–22.
- Becerra V.M., Galvão R.K.H., Abou-Seada M.** 2005. Neural and Wavelet Network Models for Financial Distress Classification. *Data Mining and Knowledge Discovery* 11, 35–55.
- Garcia D., Arques A., Calvo-Flores A.** 1997. Un modelo discriminante para evaluar el riesgo bancario en los créditos a empresas. *Revista Española de Financiación y Contabilidad* 24 (82), 175–200.
- Liou F.M., Yang C.H.** 2008. Predicting business failure under the existence of fraudulent financial reporting. *International J. Accounting and Information Management* 16 (1), 74–86.
- Moller M.F.** 1993. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks* 6, 525–533.
- Riedmiller M., Braun H.** 1992. A fast adaptive learning algorithm. Technical Report. Germany, University Karlsruhe.
- West D.** 2000. Neural Network Credit Scoring Models. *Computers & Operations Research* 27, 1131–1152.

