

Research of Possibility of Bankruptcy Diagnostics Applying Neural Network

Ojaras Purvinis, Povilas Šukys, Rūta Virbickaitė

Kauno technologijos universitetas
Panevėžio institutas
Klaipėdos g. 1, LT–35209, Panevėžys

This paper analyses the possibilities of prediction of the enterprise bankruptcy, applying neural network. The prediction results of the failed enterprises are compared to the prediction results of the profitable enterprises. In this way we can see the peculiarities and reliability of neural network usage for the bankruptcy diagnosis.

Lithuanian enterprises work in different conditions than other foreign enterprises, but all introduced models were based only on foreign enterprises, so their applicability for the diagnostics of bankruptcy remains disputable. Estimations of enterprises for the bankruptcy in definite time, calculated from “Z” scores of different authors, are different so they have to be analysed taking into account of their changing tendencies.

This article discusses the application of neural networks to analyse the possibility of enterprise bankruptcy. The classification of neural networks, estimation of the number of hidden layers and their size, the methods of training are described in special scientific literature.

Perceptrone neural network was constructed of 3 layers. To train it the backpropagation method was used. The algorithms of training and the programmes to implement them require a lot of samples of enterprises – over ten times more than inputs of the enterprise state. To train the network following indicators were used: the indicator of net profitability of assets, coefficient of short-term solvency; debt ratio; ratio of short-term liquidity of the years 1998-2001. The authors had data of 13 enterprises, so they increased the number by including the same enterprises in the list several times. In this way 284 enterprises were obtained: 161 failed and 123 profitable.

By training various networks with different inputs it was researched what indicators of the enterprise were the best to forecast the bankruptcy. Therefore the neural network was trained in the optimisation mode. The programme used different combinations of inputs and checked 408 different versions of the neural networks. As a result, all the used inputs could forecast bankruptcy, except the profitability of assets of the year 2000 and the short-term liquidity ratio of the year 1998.

According to the small amount of enterprises (8 profitable and 5 insolvent) and their 4 financial ratios used to train the neural network, the percentage of the right diagnosis is 84. But when increased the number of enterprises to 284 (written the same enterprises a few times in the same list), the results of right diagnosis rose to 92 per cents. It is good result of the method of

the neural network prognosis. The research is being continued.

Keywords: *bankruptcy diagnosis, financial indicators of enterprise, neural networks.*

Preface

Unfavourable business environment, unexpected and unfavourable events, the risky decisions of enterprise managers for short or for long periods may make enterprise insolvent and lead it towards bankruptcy. The number of insolvent enterprises has been rising in recent years. About 50 enterprises become insolvent every month. The process of bankruptcy is being executed in more than 1200 enterprises (Bankrutavusių imonių statistika, 2004).

International institutions such as European Commission, The European Bank for Reconstruction and Development, World Trade Organisation note the low competitive ability of Lithuanian enterprises and ask to quicken the bankruptcy process of insolvent enterprises and to liquidate them. New system is starting in Lithuania to help prospectless enterprises quickly leave the market or to help renew enterprises which have temporal difficulties: Department of Bankruptcy Management has been founded at the Ministry of Economy; The New Bankruptcy Law and The Law of Reorganization and Foundation are adopted. However the efficiency of the system depends on the bankruptcy prevention of particular enterprise as well as analysis of economical – financial state, risk diagnosis and estimation.

To describe the economic-financial state of the enterprise one can use a lot of (up to 100) indicators from financial statements (balance, profit – loss, money flow, etc.). Financial analysts considered the characteristics of Lithuanian financial accountability and suggested to use four main groups of indicators: profitability (there are about 12 indicators of it), short-term and long-term solvency (there are about 18 of it), efficiency of activity (about 36) and capital market (about 15) (Mackevičius et al, 1999). But to use them all for bankruptcy diagnosis is too complicated and not purposeful. Indicators, which help to diagnose the state of enterprise, must describe all kinds of enterprise performance, all kinds of usage of enterprise resources, and contain only the main but not all possible indicators (Sakalas et al, 2003). The main feature of bankruptcy according to Russian analysts (Kuroseva, 2002; Ripol-Saragosi, 2002) is the ratio of debts and assets

of enterprise based on the market prices. However they don't reject to use other relative indicators to estimate the possibility of bankruptcy.

The search of complex indicator or their set to estimate the possibility of enterprise bankruptcy was started in the 20th century and it hasn't been finished yet (Amershi, 2000; Gibson, 1987). From methodological side W.Beaver's research (Beaver, 1966) was particularly valuable, and based on the comparative analysis of indicators of profitable and insolvent enterprises. Later E.Altman, E.B. Deakin, G. Forster, A.Kovaliov, T.Poddig and other researchers (Altman, 1968; Deakin, 1972; Forster, 1978; Kovaliov, 1994; Poddig, 1995) used methods of discriminant functions. However these models don't estimate dynamically financial state of enterprise, i.e. its change tendency. Estimation of the possibility of enterprise bankruptcy still remains very actual problem (Crames, 2003; Maksimovic, 1998; Newton; 2003, Rutkauskas, 2001; Tvaronavičienė, 2001; Barniv et al, 2002; Rose-Green et al, 2002; Parker

et al, 2002; Kuruppu et al, 2003).

The authors of this article used the neural network to analyse the possibility of enterprise bankruptcy. Neural networks are widely used in different fields of science and practice (Bishop, 1996; Navakauskas, 2000; Simpson, 1990; Apanavičienė ir kt., 2003). They are used to model complicated non-linear phenomena, when analytic and regression expressions are unknown. In economics neural networks are used by credit companies for fraud detection, to forecast the rate of stocks, to optimise market nets, to model international economical competition, to identify insolvent enterprises, to forecast inflation (Calderon, 2002; Buscema, 2000; Larkin, 1999; McIntyre-Bhatty, 2000). Some research are known to apply neural network to identify failed enterprises (Poddig, 1995; Pompe, 1997; Yang, 1999).

But the application of neural networks is limited by the number of enterprises, which must be considerably higher than the number of the indicators, which estimate the state of enterprise.

Table 1

Characteristic Indicators of Enterprise Financial State

Index of Financial State	Enterprise State and Name	Year				
		1997	1998	1999	2000	2001
Net Profitability of Assets	<u>Profitable:</u>					
	JSC „Kalnapilis”	0,41	0,51	0,45	0,53	0,52
	JSC „Panevezio statybos trestas”	0,00	0,00	0,00	0,00	0,00
	JSC „Vabalas”	0,18	0,29	0,52	0,51	0,59
	<u>Failed:</u>					
	JSC „Panevezio baldai”	0,00	0,00	0,00	-0,02	-0,49
JSC „Austata”	0,00	0,00	-0,16	-0,57	0,44	
JSC „Biofarma”	-1,85	-2,15	-2,23	-2,70	-3,08	
Short-Term Solvency ratio	<u>Profitable:</u>					
	JSC „Kalnapilis”	0,97	1,38	0,78	4,03	7,46
	JSC „Panevezio statybos trestas”	2,24	0,18	1,79	1,77	14,9
	JSC „Vabalas”	1,41	2,90	10,4	5,68	16,2
	<u>Failed:</u>					
	JSC „Panevezio baldai”	1,93	1,51	1,44	0,92	0,92
JSC „Austata”	2,49	2,02	1,04	0,47	0,18	
JSC „Biofarma”	0,25	0,16	0,19	0,09	0,08	
Debt Ratio	<u>Profitable:</u>					
	JSC „Kalnapilis”	0,27	0,14	0,21	0,06	0,05
	JSC „Panevezio statybos trestas”	0,25	3,17	0,03	0,34	0,04
	JSC „Vabalas”	0,60	0,29	0,08	0,14	0,25
	<u>Failed:</u>					
	JSC „Panevezio baldai”	0,36	0,47	0,58	0,62	0,68
JSC „Austata”	0,29	0,32	0,53	1,03	0,54	
JSC „Biofarma”	1,56	1,74	1,79	2,10	2,46	
Short-term Liquidity Ratio	<u>Profitable:</u>					
	JSC „Kalnapilis”	0,43	0,46	0,18	2,36	5,34
	JSC „Panevezio statybos trestas”	1,49	-0,20	1,59	1,46	13,3
	JSC „Vabalas”	0,89	2,05	6,67	3,86	8,07
	<u>Failed:</u>					
	JSC „Panevezio baldai”	1,07	0,90	0,79	0,43	0,61
JSC „Austata”	1,84	1,63	0,85	0,35	0,08	
JSC „Biofarma”	-0,39	0,02	0,08	0,07	0,07	

The aim of the paper – to evaluate the applicability of neural network usage for the diagnostics of enterprise bankruptcy based on data of financial state indicators of few failed and profitable enterprises.

The object – the applicability and reliability of neural network usage for bankruptcy prediction.

The method – comparative analysis of enterprise financial state based on relative indicators, prognosis of

bankruptcy possibility and estimation of it developing and applying a neural network and well-known discriminant models.

Financial data of 5 failed and 8 profitable enterprises during 5 years were used for this research.

Indetermination of enterprise financial state, estimated with relative indicators

The limitation of relative indicators is described in literature, especially estimating enterprises, which have various kind of business and their accounting is different from others, indicator values are too big or too small or their performance is seasonal (Obi, 1998). The problem is that the indicators estimating the financial state of the same enterprise sometimes are very different in different periods of time. However, some relative indicators of failed companies are sometimes similar to the indicators of profitable enterprises or even better.

For example, from the enterprise indicators shown

in Table 1 we could see that net profitability of assets of the profitable JSC “Panevėžio statybos trestas” are the same in some years as of the failed JSC “Panevėžio baldai” or JSC “Austata”. Their short-term solvency ratio, debt ratio and short-term liquidity ratio of the definite time were sometimes even better than the same ratios of profitable enterprises.

No doubt that using one integrated indicator would make it easier to estimate enterprise state. In this case “Z score” in fact is discriminant function, has advantages compared with others.

Applying results of discriminant models to estimate possibility of bankruptcy

As an example here is given application of an integrated “Z score” to estimate the possibility of enterprise bankruptcy (Table 2) according to following discriminant models of the below mentioned well-known foreign authors:

Table 2

Results of Enterprise State Estimation According to Discriminant Models of Different Authors

Model	Enterprise	Z score 1997	Possibility of bankruptcy	Z score 2001	Possibility of bankruptcy
Profitable enterprises					
Altman's	Kalnapilis	3,26	Very low	5,71	Very low
	Panevėžio statybos trestas	37,3	Very low	9,27	Very low
	Vabalas	2,52	High	2,72	Low
Taffler and Tisshaw's	Kalnapilis	1,97	Low	4,43	Low
	Panevėžio statybos trestas	8,78	Low	4,87	Low
	Vabalas	-1,66	Very high	6,82	Very low
Springate	Kalnapilis	1,25	Low	1,22	Low
	Panevėžio statybos trestas	0,95	Low	0,93	Low
	Vabalas	1,03	Low	1,05	Low
Insolvent enterprises					
Altman's	Panevėžio baldai	0,48	Very high	0,31	Very high
	Austata	2,27	High	0,82	Very high
	Biofarma	-0,26	Very high	-11,78	Very high
Taffler and Tisshaw's	Panevėžio baldai	-1,64	Very high	-1,37	Very high
	Austata	-0,45	Very high	0,22	High
	Biofarma	-4,26	Very high	-1,08	Very high
Springate	Panevėžio baldai	0,95	Low	0,75	Very high
	Austata	0,62	Very high	0,55	Very high
	Biofarma	0,76	Very high	0,52	Very high

Altman (Altman, 1968)

$$Z=1.2A+1.4B+3.3C+0.6D+0.999E \quad (1)$$

where A – capital/ assets;
 B – inappropriate balance/ assets;
 C – profit before taxes/ assets;
 D – stock value in the market/ liability;
 E – sales/ assets.

When $Z < 2.68$, bankruptcy is possible.

Taffler and Tisshaw (Taffler, 1977)

$$Z=0.53K_1+0.13K_2+0.18K_3+0.16K_4, \quad (2)$$

where K_1 – revenue/ short-term liability

K_2 – working capital/ amount of liability;

K_3 – short-term liability/ assets;

K_4 – sales/ assets.

When $Z > 0.3$, the possibility of bankruptcy is low.

Springate (Springate, 1978)

$$Z=1,03A+3,07B+0,66C+0,4D, \quad (3)$$

where A – capital/ assets;
 B – profit before taxes/ assets;
 C – profit before taxes/ liability;
 D – sales/ assets.

When $Z < 0.862$, bankruptcy is possible.

Lithuanian enterprises work in different conditions than other foreign enterprises, but all introduced models were based only on foreign enterprises, so their acceptability for the diagnostics of bankruptcy remains disputable. Estimations of profitable enterprises (Table 2) for the bankruptcy in definite time, calculated from “Z” scores of different authors, are different. The estimations of bankruptcy possibility become equal only when enterprises are close to bankruptcy. So various indicators have to be analysed from the point of their changing tendencies.

Modern up-to-date changes in business environment often result in a non-linear change in the financial state of the enterprise that cannot be always modelled by linear discriminating models. The modeling, prognostic and other problems of non-linear dependences might be solved using the neural networks.

Theoretical Conception of Neuron and Neural Network Models

The mathematical model of single neuron is analogous to biological neuron. The neuron model (Osovskii, 2002) connects independent inputs (incoming signals) X_0, X_1, \dots, X_n with output (outgoing signal) Y (Fig.1).

Firstly the weighted sum of independent inputs is calculated:

$$I = \sum w_i X_i \quad (4)$$

And from this sum the outgoing signal $Y = f(I)$ is received with a special activation function $f(I)$. The function $f(I)$ equals 1 when the weighted sum I exceeds some step (activation) value I_0 .




Fig.1. Scheme of Neuron Model

One of the simplest activation functions is:

$$Y = f(I) = \begin{cases} 1, & \text{if } I > I_0 \\ 0, & \text{if } I \leq I_0 \end{cases} \quad (5)$$

However the function (5) isn't continuous, so other activation functions of better smoothness are used. Weights w_i and activation step I_0 are chosen when training the neural network.

The neural network is made of these interconnected neurons (units) (Fig.2). This net is used to solve the problems of modelling non-linear dependencies, classi-

fication, prognosis, etc.




Fig.2. Scheme of Neural Network

The classification of neural networks, estimation number of hidden layers and their size, the methods of training are described in special scientific literature (Haykin, 1999; Osovskii, 2002; Artificial, 2004; Rojas, 1996).

Results of Diagnosis with Neural Network

There are a lot of programs modelling neural networks such as Matlab with its packages as well as free programmes, for instance “Alyuda Forecaster”. This one like others consists of two parts. The first part is add-on to programme “Excel”, the second – standalone programme. Neural network learns by means of appropriately changing the internal connection weights w_i . This is called the weight adaptation and takes place during so-called training phase, by using given input and output values (Kruglov et al, 2002).

Perceptrone neural network (Kruglov et al, 2002) was constructed of 3 layers. To train it the back propagation method was used (Widrow, 1990). The algorithms of training and the programmes to implement them require a lot of samples of enterprises – over ten times more than inputs of the enterprise state (Kruglov et al, 2002). To train the network the following indicators were used: the indicator of net profitability of assets, coefficient of short-term solvency; debt ratio; ratio of short-term liquidity of the years 1998-2001. The authors had data of only 13 enterprises, so they increased the number by including the same enterprises in the list several times. In this way 284 enterprises were obtained: 161 failed and 123 profitable.

To train the net we gave to the input the data of all enterprises except one used for test of the forecast. This procedure was repeated 13 times, because we had 13 enterprises. The net was trained in this way: the estimation of profitable enterprise was set to 0, and failed enterprise – to 1.

Thus, the information (weights and activation steps) saved in the net let us recognize failed enterprises from profitable ones, i.e. identify enterprises in the aspect of bankruptcy.

By training various networks with different inputs it

was researched what indicators of the enterprise were the best to forecast the bankruptcy. Therefore the neural network was trained in the optimisation mode. The programme used different combinations of inputs, algorithms and checked 408 different versions of the neural networks. As a result, all the used inputs could forecast bankruptcy, except the profitability of assets of the year 2000 and the short-term liquidity ratio of the year 1998 (Table 3).

Table 3

Estimation of the Indicator Importance for Bankruptcy Forecast

Index	Year	Used as input (A), not used (N)
Net Profitability of Assets	1998	A
	1999	A
	2000	N
	2001	A
Short-Term Solvency Ratio	1998	A
	1999	A
	2000	A
	2001	A
Debt ratio	1998	A
	1999	A
	2000	A
	2001	A
Short-term Liquidity Ratio	1998	N
	1999	A
	2000	A
	2001	A

The trained neural network was used in this way: data of enterprise, which was not used to train the neural network, was input into the computer programme, modelling the trained neural network. Thus, the neural network worked on financial data of unknown enterprise and gave the numerical bankruptcy estimation of this enterprise.

Comparing the forecast with the factual state of the enterprise one can estimate the reliability of the forecast (when the result is 1 – enterprise is failed, when 0 – not failed) (Table 4).

We would like to draw attention, that the prognosis of enterprise “Vabalas” is non-defined, because the neural network gave prognosis value 0.52 between 1 and 0, so we can't define if it is failed or profitable. Also the forecast of enterprise “Tulpe” is very different from 0 and 1, because its prognosis value is 3.6 times bigger than the code (value 1) of bankruptcy. On the other hand this value is bigger than the values (0) of profitable enterprises. Consequently this prognosis is right – the bankruptcy estimation value is much higher than others, or at least non-defined. The percentage of right forecasts is 92.

To compare these results, the other original list of 13 enterprises was used where we wrote each enterprise once. In this case we had only 12 enterprises to train the net. Checking the bankruptcy forecast for each enterprise, which wasn't used to train the net, more mistakes of bankruptcy forecast appeared, i.e. was received more

non-defined values, and for one enterprise “Vabalas” was even given wrong forecast. It could be explained by not only the algorithm features of neural network, but by greater number of profitable enterprises (8) used to train the net than failed enterprises (5). In this case the number of right prognosis was 84 per cents. It is good result of the method of the neural network prognosis. The research is being continued.

Table 4

Prognosis with Trained Neural Network

Enterprise	Estimation of bankruptcy		Estimation of forecast
	factual	forecast	
„Agota“	0	-0,1	Right
„Arguva“	1	1,4	Right
„Austata“	1	1,1	Right
„Biofarma“	1	1,1	Right
„Dvarcioniu keramika“	0	0,02	Right
Kaisiadoriu autobusu parkas	0	-0,03	Right
“Panevezio baldai”	1	1,0	Right
Panevezio statybos trestas	0	0,32	Right
“Robis”	0	-0,02	Right
“Silas”	0	0,00	Right
“Simas”	0	0,00	Right
“Tulpe”	1	3,6	Right
“Vabalas”	0	0,52	Non-defined

Conclusions:

1. Usage of complex model “Z score” computed on the base of financial ratios for bankruptcy diagnosis is complicated. Applying it was obtained only static rating of bankruptcy possibility. Because of it one should analyse the performance of enterprise over a period of time.
2. Training the neural network with 8 profitable enterprises and 5 failed enterprises using 4 financial ratios of the years 1998-2001 for estimation of their state was received that the number of right prognosis was 84 per cents. When increased the number of enterprises more than 20 times, the percentage of right prognosis reached the number 92 per cents. This indicates that in both cases the neural networks are effective tool to forecast bankruptcy.

References

1. Altman E. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy // Journal of Finance, 1967 Sept, p.589-609.
2. Amershi, A.H. The occurrence of Fibonacci numbers in time series of financial accounting ratios: Anomalies or indicators of firm survival, bankruptcy and fraud? An exploratory study / A.H.Amershi; E.H.Feroz // Managerial Finance, 2000, Vol. 26, No 11, p. 5-20.
3. Artificial Neural Networks. <http://hem.hj.se/~de96klda/NeuralNetworks.htm>, [2004.04.23].
4. Apanavičienė R. Statybos projektų valdymo efektyvumo modeliavimas, taikant dirbtinius neuroninius tinklus / R. Apanavičienė, A. Juodis // Inžinerinė ekonomika, Nr. 3 (34),

- 2003, p.7-16.
5. Barniv R. Predicting Bankruptcy Resolution / R.Barniv, A.Aganwal, R. Leach // Journal of Business Finance and Accounting, April/May, 2002, Vol. 53, p.497-521.
 6. Beaver W.H. Financial Ratios as Predictors of Failure //Journal of Accounting Research, 1966, No 4, p.71-111.
 7. Bishop C.M. Neural Networks for Pattern Recognition. Oxford University Press, 1996.
 8. Buscema M. Feedforward networks in financial predictions: the future that modifies the present / M.Buscema, P.L.Sacco // Expert Systems, 2000, Vol. 17, No. 3, p.149-170.
 9. Calderon T.G. A roadmap for future neural networks research in auditing and risk assessment / T.G.Calderon, J.J.Chen // International Journal of Accounting Information Systems, 2002, Vol 3, p. 203-236.
 10. Crames M.J. The Fundamentals of Bankruptcy and Corporate Reorganization. Nordstrom, 2003.
 11. Cyri Pat Obi. Verslo finansų pagrindai. Kaunas: Technologija, 1998, p.299.
 12. Deakin E.B., 1972. A Discriminant Analysis of Predictors of Failure //Journal of Accounting Research, 1972, No 10, p.167-179.
 13. Forster G. Financial Statement Analysis. New Jersey: Prentice-Hall, 1978, p.543.
 14. Haykin S. Neural Networks: A Comprehensive Foundation. Prentice-Hall, Upper Saddle River, 1999.
 15. Hebb D. Organization of Behavior. New York: John Wiley and Sons, 1994.
 16. Gibson Ch. How Chartered Financial Analysts View Financial Ratios // Financial Analysts Journal. 1987, May/June, vol. 43, no. 3, p. 73-76.
 17. Ковалев А. П. Финансовый анализ и диагностика банкротства. Москва: Экономическая Академия, 1994, с.43-45.
 18. Poddig Thorsen. Bankruptcy Prediction: A Comparison with Discriminant Analysis // Neural Networks in the Capital Markets. Chichester: John Wiley&Sons, 1995, p.379.
 19. Круглов В. В. Искусственные нейронные сети / В. В. Круглов, В. В. Борисов // М.: Горячая линия-телеком, 2002, с.382.
 20. Курошева Г. М. Теория антикризисного управления предприятием. // Санкт-Петербург: Речь, 2002, с.372.
 21. Kuruppu N. The efficacy of liquidation and bankruptcy prediction models for assessing going concern / Kuruppu Nirosh, Laswad Fawzi, Oyelere Peter // Managerial auditing Journal. 2003, No 6, p. 577-590.
 22. Larkin A.B. Clustering of Binary Market Research Data / A.B.Larkin, K.Oldham // Neural Comput&Applic, 1999, No 8, p.303-308.
 23. Mackevičius J. Įmonių bankroto prognozavimo analizės metodikų tyrimas, remiantis finansinių ataskaitų duomenimis / J.Mackevičius, D.Poškaitė //Ekonomika.. T.49, 1999, p.51-64.
 24. Maksimovic V. Asset Efficiency and Reallocation Decisions of Bankrupt Firms / Vojislav Maksimovic, Gordon Phillips // The Journal of Finance. October, 1998, p.1495-1533.
 25. McIntyre-Bhatty Y.T. Neural network analysis and the characteristics of market sentiment in the financial markets // Expert systems, 2000, Vol. 17, No. 4, p.191-198.
 26. Navakauskas D. SSA priemonės. Dirbtinių neuronų tinklai. VGTU: Technika, 2000.
 27. Newton W. Corporate Bankruptcy. Nordstrom, 2003.
 28. Осовский С. Нейронные сети для обработки информации. // М.: Финансы и статистика, 2002, с.344.
 29. Parker Susan. Corporate Governance and corporate failure: a survival analysis / Parker Susan, F.Peters Gary, F.Howard Turet-sky // Corporate Governance: International Journal of Business in Society, 2002, No 2, p.4-12.
 30. Pompe P.M. Using Machine Learning, Neural Networks, and Statistics to Predict Corporate Bankruptcy / P.M.Pompe, A.J.Feelders // Microcomputers in Civil Engineering. July, 1997, p.267-277.
 31. Риполь-Сарагоси Ф.Б. Основы финансового и управленческого анализа.// Москва, "Книга сервис", 2002, с.224.
 32. Rojas R. Neural Networks – A Systematic Introduction. Springer-Verlag, 1996.
 33. Rose-Green Ena. Strategic Bankruptcies and Price Reactions to Bankruptcy Filings / Rose-Green E, Dawkins M. C. // Journal of Business Finance & Accounting., 29 (9/10), 2002, p.1319-1335.
 34. Rutkauskas A. V. Finansų analizės problemos esant neapibrėžties galimybei // Ekonomika, T. 54, 2001, p.108-125.
 35. Sakalas A. Įmonės krizių vadyba / A.Sakalas, A.Savanevičienė / Kaunas: Technologija, 2003, p.199.
 36. Simpson P.K. Artificial Neural Systems: Foundations, Paradigms, Applications, and Implementations. Pergamon Press, 1990.
 37. Shawe-Taylor John. Neural Network Learning: Theoretical Foundations // AI magazine, 2001, 22(2), p.99-100.
 38. Springate G. Predicting the Possibility of Failure in a Canadian Firm / Unpublished M.B.A. Research Projekt, Simon Fraser University, January 1978.
 39. Taffler R.J. Going, going, gone – four factors which predict /R.J.Taffler, H.Tisshaw // Accountancy, March 1977, p.50-54.
 40. Tvaronavičienė M. Įmonių bankroto proceso ekonominio efektyvumo didinimo kryptys // Ekonomika, 2001, T. 54, p.35-143.
 41. Widrow B. 30 years of Neural networks: Perceptron, Madaline and Backpropagation / B.Widrow B.,M.A.Lehr // Proc.of the IEEE, 1990, Vol 78, No 9, p.1415–1442.
 42. Yang Z.R. Probabilistic Neural Networks in Bankruptcy Prediction / Z.R.Yang, M.B.Platt, Platt H.D // Journal of Business Research, 1999, No 44, p.67-74.
- Ojaras Purvinis, Povilas Šukys, Rūta Virbickaitė
- Bankroto diagnostikos galimybės tyrimas taikant neuronų tinklus**
- Santrauka
- Nepalankiai pakitusi verslo aplinka, nenumatyti ir nepageidaujami įvykiai bei rizikingi įmonės vadovų sprendimai trumpesniai ar ilgesniai laikotarpiui gali sudaryti nemokios įmonės būklę bei sukelti bankroto grėsmę. Pastaraisiais metais nemokių įmonių skaičius Lietuvoje gana sparčiai auga, šalyje vidutiniškai per mėnesį bankrutuoja apie 50 įmonių, bankroto procedūros vykdomos daugiau nei 1200 įmonėse (Bankrutuojančių įmonių statistika, 2004).
- Įmonės ūkinei-finansinei būklei apibūdinti gali būti panaudota daugybė (iki šimto) rodiklių, kurie apskaičiuojami iš finansinių (balanso, pelno nuostolio, pinigų srautų ir kt.) ataskaitų. Tačiau naudoti juos visus bankroto galimybei įvertinti yra pernelyg komplikantuota, dažniausiai ir netikslinga. Apibendrintam įmonės būklės vertinimui patogesnis būtų koks tai vienas kompleksinis rodiklis. Tokio rodiklio ar jų sistemos paieška užsienyje pradėta dar XX a. trečiajame dešimtmetyje ir tęsiama iki šiol. Metodologiniu požiūriu ypač vertingi W. Biverio 1966 m. tyrimai, atlikti remiantis pelningų ir bankrutavusių įmonių finansinių rodiklių tendijų lyginamąja analize (Beaver, 1966), bei vėlesni E. Altmano, E.B. Deakino, G. Forsterio, A. Kovaliovo, T.Poddig (Altman, 1968; Deakin, 1972; Forster, 1978; Kovaliov, 1994; Poddig, 1995) ir kitų tyrimai, naudojant diskriminantinės analizės metodus. Tačiau diskriminantiniai modeliai visapusiškai neįvertina įmonės finansinės būklės ir jos kitimo tendencijos. Įmonių bankroto galimybės vertinimas lieka aktualus ir toliau plačiai nagrinėjama problema (Crames, 2003; Maksimovic, 1998; Newton, 2003; Rutkauskas, 2001; Tvaronavičienė, 2001; Barniv et al, 2002; Rose-Green et al, 2002; Parker et al, 2002; Kuruppu et al, 2003)
- Mes siūlome bankroto galimybę tirti naudojant neuronų tinklų metodą. Dirbtiniai neuronų tinklai taikomi modeliuoti gana sudėtingoms netiesinėms priklausomybėms, kurių analizės ir regresinės išraiškos nežinomos. Jie vis plačiau naudojami įvairiose mokslo ir praktikos srityse (Bishop, 1996; Navakauskas, 2000; Simpson, 1990; Apanavičienė ir kt., 2003). Ekonomikoje neuronų tinklai naudojami tikrinti apgavystės galimumą, vertybinių popierių kursui prognozuoti, parduotuvių tinklams optimizuoti, rinkodaros tyrimuose tarptautinei ekonominei konkurencijai modeliuoti (Calderon, 2002; Buscema, 2000; Larkin, 1999; McIntyre-Bhatty, 2000). Žinomi bandymai neu-

ronų tinklų metodą taikyti bankrutuojančioms firmoms identifikuoti (Poddig, 1995; Pompe, 1997; Yang, 1999). Tačiau šio metodo taikymą riboja tai, kad reikia remtis duomenimis iš keliasdešimt kartų didesnio skaičiaus įmonių, nei jų būklę apibūdinančių rodiklių.

Šio tyrimo tikslas – įvertinti neuronų tinklų metodo taikymo įmonių bankroto diagnostikai tinkamumą remiantis mažo skaičiaus bankrutavusių ir sėkmingai veikiančių įmonių finansinės būklės duomenimis.

Tyrimo objektas – neuronų tinklų metodo taikymo mažos imties įmonių bankroto diagnostikai ypatumai ir patikimumas.

Tyrimo metodas – įmonių finansinės būklės lyginamoji analizė remiantis santykiniais rodikliais bei bankroto galimybės vertinimas taikant diskriminantinius modelius ir neuronų tinklus.

Tyrimui panaudoti 5 bankrutavusių ir 8 sėkmingai Lietuvoje veikiančių įvairių gamybos šakų įmonių finansinių ataskaitų duomenys už 5 metus. Naudoti 4 įmonės finansinę būklę vertinantys grynjojo turto pelningumo, trumpalaikio mokumo, įsiskolinimo ir greito likvidumo rodikliai. Nustatyta (1 lentelė), kad tos pačios įmonės šie santykiniai rodikliai kai kuriais metais labai skiriasi. Be to, kai kurių bankrutuojančių įmonių rodikliai būna panašūs į sėkmingai veikiančiųjų arba už juos netgi geresni. Sėkmingai veikiančių įmonių bankroto tikimybės nagrinėjamo laikotarpio pradžioje vertinimai kompleksiniais rodikliais (2 lentelė), gautais remiantis skirtingų autorių – Altmano (Altman, 1968), Tafflerio ir Tisšovo (Taffler et al., 1977) ir Springate (Springate, 1978) „Z“ tipo diskriminantiniais modeliais, taip pat yra skirtingi. Kad įvertinti bankroto grėsmę, vėl reikia analizuoti minimų kompleksinių rodiklių kitimo tendencijas.

Lietuvos įmonės veikia kitose sąlygose, negu tos kitų valstybių įmonės, kurių pagrindu buvo sukurti aukščiau minėti diskriminantiniai modeliai, todėl jų priimtumas bankroto diagnostikai išlieka abejotinas. Dažnai šuoliškai kintanti verslo aplinka lemia netiesialinijį įmonės finansinės būklės kitimą, o minėti „Z“ modeliai yra tiesiniai.. Šiuo atveju netiesinėms finansinės būklės priklausomybėms modeliuoti ir bankrotui prognozuoti tikslingiau naudoti neuronų tinklus.

Dabartiniu metu yra gana daug dirbtinius neuronų tinklus modeliuojančių programų, pradedant nuo tokių populiarių paketų, kaip Matlab priedai ir baigiant laikinai nemokamomis programomis, pvz., „Alyuda Forecaster“. Pastaroji, kaip ir kai kurios kitos programos, sudaryta iš dviejų dalių. Viena jų yra priedas prie programos „Excel“, o kita – savarankiška. Svarbus etapas veiksmingam neuronų tinklui sudaryti yra jo apmokymas naudojant turimas veiksmų vertes (Круглов и др., 2002).

Perceptroninis neuronų tinklas buvo sukonstruotas iš 3 sluoksnių, jam apmokyti naudotas atgalinio sklidimo metodas (Widrow, 1990). Tinklo apmokymo algoritmai ir juos realizuojančios programos reikalauja nemažai įmonių pavyzdžių – nuo kelių iki keliasdešimt kartų daugiau, nei įmonės pavyzdžio būklę apibūdinančių rodiklių (įrašo laukų) (Круглов и др., 2002). Tinklo apmokymui naudojome jau minėtus 4 santykinis rodiklius. Kadangi turėjome nedidelio įmonių skaičiaus – tik 13, jų skaičius buvo dirbtinai padidintas į sąrašą įtraukiant po keletą kartų. Taip gautas 284 įmonių sąrašas, kuriame buvo 161 bankrutuojanti ir 123 nebankrutuojančios įmonės. Tinklui apmokyti buvo pateikiami duomenys iš vienodo abiejų rūšių įmonių skaičiaus, iš sąrašo išbraukius pačią vieną įmonės, naudojamos jos bankroto prognozei (prognozės kontrolei), rodiklius. Ši procedūra buvo kartojama tiek kartų, kiek buvo įmonių, t. y. 13 kartų. Tinklas buvo apmokytas taip, kad veikiančios įmonės identifikavimo įvertis būtų lygus 0, o bankrutuojančios – 1. Tokiu būdu, tinklo atmintyje liko žinios (svoriai ir aktyvavimo slenksčiai), leidžiančios atskirti

bankrutuojančias nuo sėkmingai veikiančių, t. y. identifikuoti įmones bankroto galimybės požiūriu.

Apmokant neuronų tinklą, kartu buvo tirta, kurie įmonės būklę charakterizuojantys rodikliai (veiksniai) geriausiai apsprendžia įvykusį bankrotą. Tuo tikslu neuronų tinklo programa buvo paleista tinklų optimizavimo režime. Programa, naudodama įvairias rodiklių kombinacijas ir įvairius algoritmus ištyrė 408 neuronų tinklų variantus. Gauta (3 lentelė), kad visi tirti rodikliai buvo bankrotą apsprendžiantys veiksniai, išskyrus 2000 m grynjojo turto pelningumo ir 1998 m – greito likvidumo rodiklius.

Apmokytas neuronų tinklas buvo naudotas šitaip. Į kompiuterio programą, modeliuojančią neuronų tinklą, (įėjimo sluoksni) buvo įvesti duomenys įmonės, kuri nebuvo naudota apmokant tinklą. Tuo būdu tinklas operavo nežinomos įmonės finansinę būklę charakterizuojančiais duomenimis ir išėjimo sluoksnyje teikė skaitmeninius bankroto įverčius, kuriuos, lyginant su faktiniu tos įmonės įverčiu galima spręsti apie prognozės teisingumą (4 lentelė).

Pastebėsime, kad vienos įmonės, pavadinimu „Vabalas“ prognozė reikia laikyti neapibrėžta, kadangi neuroninis tinklas pateikė prognozės požymio vertę tarp 0 ir 1, t. y. 0,52, šią įmonę negalima priskirti nei prie bankrutuojančių, nei prie nebankrutuojančių. Taip pat ir įmonės „Tulpė“ bankroto prognozės įvertis išsiskiria iš kitų, nes požymio prognozė 3,6 karto didesnė už bankroto požymį. Bet iš kitos pusės, tas įvertis dar didesnis už nebankrutuojančiųjų įmonių bankroto įverčius. Vadinasi, šią prognozė reikia laikyti arba teisinga – įmonės bankroto požymis žymiai stipriau išreikštas nei kitų, arba laikyti neapibrėžta prognoze. Bendras teisingų prognozių skaičius sudarė 92%.

Palyginimui analogiški tyrimai buvo atlikti su įmonių sąrašu, kuriame duomenys (įrašų laukai) apie kiekvieną įmonę buvo įrašyti tik po vieną kartą. Vadinasi, šiuo atveju neuronų tinklo apmokymui buvo pateikiama tik po 12 įmonių. Tikrinant tinklo teikiamą bankroto prognozė vienai įmonei, kuri nebuvo naudota mokyme, gauta daugiau diagnozės klaidų, t. y. gauta daugiau neapibrėžtų vertinimų, o vienai įmonei „Vabalas“ (ji nėra bankrutuojanti) duota neteisinga prognozė. Matyt, tai paaiškinama ne tik neuronų tinklų algoritmo ypatybėmis, bet ir tuo, kad antruoju atveju apmokymui buvo naudojamas didesnis kiekis (8) nebankrutuojančių, nei bankrutuojančių (5) įmonių. Šiuo atveju teisingų prognozių skaičius sudarė 84%. Tai taip pat yra neblogas prognozavimo neuronų tinklais rodiklis. Aptarta tema mūsų tyrimai tęsiami.

Išvados

1. Santykinų rodiklių, taip pat jų pagrindu sudaryti kompleksinių „Z“ tipo modelių naudojimas bankroto diagnostikai yra komplikuoatas. Juos taikant gaunami statiniai bankroto galimybės įverčiai, neatsižvelgiant į tų rodiklių kitimo tendencijas.
2. Remiantis mažos imties įmonių skaičiaus (8 veikiančių ir 5 bankrutuojančių) ir jų būklę charakterizuojančiais 4 santykiniais rodikliais apmokytų neuronų tinklu gauta, kad bendras teisingų prognozių skaičius sudarė 84%, o jų skaičių dirbtinai (pakartotinai įtraukus į sąrašą) padidinus daugiau nei 20 kartų, teisingų prognozių skaičius pasiekė 92%. Tai rodo, kad abiem tyrimo atvejais neuronų tinklai yra gana efektyvi bankroto diagnostikos priemonė.

Raktažodžiai: *bankroto diagnostika, įmonės finansiniai rodikliai, neuronų tinklai.*

The article has been reviewed.

Received in December, 2004; accepted in February, 2005.

DOI: 10.5755/j01.ee.41.1.11279