

ANALIZA JAKOŚCI PREDYKCJI STANU EKONOMICZNO- FINANSOWEGO MAŁYCH I ŚREDNICH PRZEDSIĘBIORSTW PRZY POMOCY ZESPOŁÓW SZTUCZNYCH SIECI NEURONOWYCH

Andrzej Burda, Barbara Kuczmowska
Wyższa Szkoła Zarządzania i Administracji

1. Wstęp

Jednym z ważniejszych aspektów analizy finansowej przedsiębiorstwa jest przewidywanie bankructwa firmy. Nieustanne badania, trwające od końca lat 60-tych [5], wprowadzone na nową tory poprzez wykorzystanie wielowymiarowej analizy dyskryminacyjnej (MDA) [1], zaowocowały wieloma cennymi pracami, które koncentrowały się głównie na uzyskaniu optymalnego modelu bankructwa, czy też szerzej- stanu ekonomiczno-finansowego firmy.

Badania prowadzono nie tylko metodami statystycznymi: MDA [2], przy pomocy modeli logitowych [13] czy dyskryminacji metodą k-najbliższych sąsiadów [17]. Od początków lat 90-tych coraz częściej sięgano po metody zaliczane do grupy metod sztucznej inteligencji obliczeniowej takich jak: drzewa decyzyjne [11], sieci przekonania Bayesa [16] i sztuczne sieci neuronowe [12].

Przewagę modeli neuronowych nad innymi modelami statystycznymi można odnotować m.in. w pracach: [9], [15], [18], [10], [20] i [4]. Należy jednak zaznaczyć, że prezentowane w nich modele budowane były na małej liczbie przypadków uczących. Jeśli dokonamy porównań modeli utworzonych na dużej liczbie obserwacji [3], to nie daje się zauważyć istotnych różnic w jakości klasyfika-

cji pomiędzy modelami neuronowymi a zbudowanymi przy pomocy alternatywnych metod.

Zaskakująco dobre rezultaty modeli budowanych przy małej liczbie obserwacji i dużej liczbie atrybutów opisujących nie powinny dziwić, ze względu na dużą łatwość uczenia się sztucznych sieci neuronowych w takich warunkach. Niestety, dochodzi wtedy do zjawiska „przeuczenia” sieci, nadmiernego jej dopasowania do przypadków uczących, a przez to do utraty zdolności do generalizacji problemu. W tego typu pracach mało przekonujące lub całkowicie pomijane są testy na niezależnym zbiorze danych [19].

2. Opis modelu

Neuronowy model oceny stanu ekonomiczno-finansowego małych i średnich przedsiębiorstw, zbudowany na potrzeby projektu, składa się z zespołu 10 sztucznych sieci neuronowych. Szczegółowy opis przyjętego kryterium klasyfikacji, topologii i metod uczenia sieci zawarty jest w: [6], [7] i [8]. Model zbudowano jako model predykcyjny o horyzoncie prognozy 1 roku.

W tym miejscu należy jednak zaznaczyć, że szczególną uwagę zwracano na liczebności przypadków uczących oraz ich stosunek do liczby atrybutów opisujących. Aby utworzony model nie utracił zdolności do generalizacji, liczba przypadków uczących spełniała warunek określony wzorem (1):

$$(1) \quad L^U = 2^N$$

Dysponując określoną liczbą przypadków uczących L^U , spełnienie warunku (1), wymagało starannego doboru wymiaru przestrzeni wejść N , czyli liczby atrybutów opisujących. Redukcję wymiaru prowadzono 2-etapowo: z wykorzystaniem analizy korelacji rangowej Spearmana oraz analizy wrażliwości sieci. Dodatkowo, zadbane o spełnienie jeszcze jednego warunku, którego empiryczne uzasadnienie można znaleźć w literaturze przedmiotu [14], aby liczba połączeń wagowych pomiędzy neuronami w sieci nie przekraczała 10% użytych przypadków uczących.

Modele budowane były osobno dla województwa lubelskiego i podkarpackiego, przy uwzględnieniu podziału na 5 wiodących, w obu regionach,

1 Polska Klasyfikacja Działalności (PKD) jest umownie przyjętym, hierarchicznie usystematyzowanym podziałem rodzajów działalności społeczno-gospodarczej.

sekcji gospodarki oraz ich podsekcji, działów i grup (zgodnie z PKD¹). O poziomie podziału decydowała liczebność obserwacji w grupach, ze względu na uwarunkowania opisane w punkcie 1. Razem, dla roku 2006, zbudowano 15 modeli dla woj. lubelskiego i 23 dla woj. podkarpackiego.

Proces pozyskiwania wiedzy nt. przewidywanego stanu ekonomiczno-finansowego firmy (Rys.1.) na koniec następnego roku, wymaga skorzystania z ostatnich sprawozdań finansowych firmy (F-01 i SP) oraz sprawozdania o zatrudnieniu (Z-06). Dane z tych sprawozdań wprowadzone na portal przez analityka firmy, przetwarzane są do postaci wskaźników (x_1, x_2, \dots, x_{32}). Do danych tych dołączane są dane mezo- i makro-ekonomiczne regionów (z_1, z_2, \dots, z_{15}). Wprowadza je administrator portalu. Następnie system, na podstawie danych, klasyfikuje firmę zgodnie z odpowiednim PKD i wybiera właściwy dla niej model predykcyjny. Uruchomienie modelu następuje na odpowiednim podzbiore zbioru X i Z.

Model zespołu sztucznych sieci neuronowych (ENN) generuje na wyjściu, jako obraz klasyfikacji, stosunek liczby głosów S (liczba pozytywnych

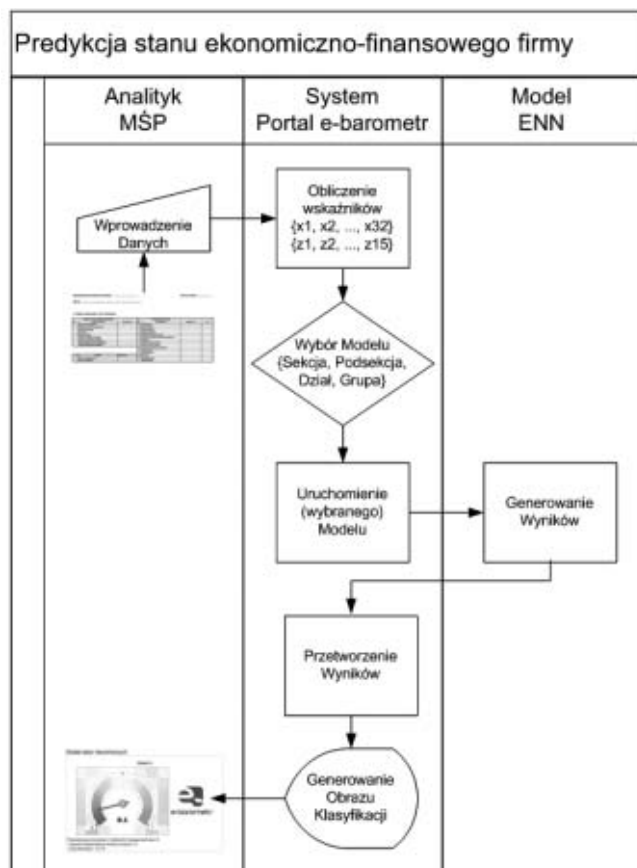
odpowiedzi sieci składowych na sygnał wejściowy do liczby sieci w zespole). Gdy stosunek ten jest mniejszy od 0,5 model sygnalizuje, że stan ekonomiczno-finansowy firmy w horyzoncie jednego roku będzie zły. Dobry stan sygnalizowany jest przy $S \geq 0,5$. W przypadku, gdy $S = 0,5$ (pięć sieci klasyfikuje stan jako dobry, a 5 jako zły) przyjmuje się, że stan firmy jest nieokreślony. Oznacza to, że przy obecnych wskaźnikach firmy, jednoznaczne określenie klasy wiązałoby się z dużym prawdopodobieństwem błędu. Wynik klasyfikacji modelu ENN, odpowiednio przetworzony przez system trafia na ekran analityka w postaci graficznej (e-barometr) jak i opisowej. Wielkość wychylenia strzałki barometru w prawo lub w lewo, proporcjonalna do stosunku głosów sieci składowych ENN, wyraża stopień pewności klasyfikacji.

3. Opis warunków testowania

Testowanie modelu, odbyło się wg analogicznej procedury, która opisana została w rozdziale 2. i pokazana na Rys.1. Ze względu na ograniczoną liczbę obserwacji w niezależnym zbiorze testowym za rok 2006 (do uczenia modeli wykorzystywano obserwacje z lat 1999-2005), szczególnie w odniesieniu do klasy firm o złym stanie ekonomiczno-finansowym, testowanie ograniczono do modeli budowanych na poziomie sekcji. W związku z tym, dla każdego regionu ocenie poddano po 5 modeli dla:

- sekcji D - Przetwórstwo przemysłowe;
- sekcji F - Budownictwo;
- sekcji G - Handel hurtowy i detaliczny, naprawa pojazdów samochodowych, motocykli oraz artykułów użytku osobistego i domowego;
- sekcji I - Transport, gospodarka magazynowa i łączność;
- sekcji K - Obsługa nieruchomości, wynajem i usługi związane z prowadzeniem działalności gospodarczej.

Dla każdego zespołu sieci wyznaczono błąd klasyfikacji (liczbę przypadków błędnie sklasyfikowanych do liczby wszystkich przypadków w podzbiore firm dla określonej sekcji) z podziałem na błędy: I rodzaju (błędna klasyfikacja firm o dobrej kondycji) i II rodzaju (błędna klasyfikacja firm o złej kondycji). Należy w tym miejscu zaznaczyć, że ze



Rys. 1. Proces predykcji stanu ekonomiczno-finansowego firmy na portalu <http://e-barometr.pl>

Tablica 1. Statystyki klasyfikacyjne dla woj. lubelskiego

Seksja	Podzbiór	Obserwacje						
		Liczebność				Udział [%]		
		Wszystkie	Poprawne	Niepoprawne	Nieznane	Poprawne	Niepoprawne	Nieznane
D	St.1.U1*	940	611	309	20	65,0	32,9	2,1
	St.0.U	140	94	44	2	67,1	31,4	1,4
	St.1.T	189	142	47	0	75,1	24,9	0,0
	St.0.T	12	9	3	0	75,0	25,0	0,0
E	St.1.U	414	260	136	18	62,8	32,9	4,3
	St.0.U	64	43	19	2	67,2	29,7	3,1
	St.1.T	78	56	21	1	71,8	26,9	1,3
	St.0.T	3	1	1	1	33,3	33,3	33,3
F	St.1.U	2177	1562	569	46	71,8	26,1	2,1
	St.0.U	324	239	79	6	73,8	24,4	1,9
	St.1.T	467	355	103	9	76,0	22,1	1,9
	St.0.T	30	21	8	1	70,0	26,7	3,3
K	St.1.U	198	144	49	5	72,7	24,7	2,5
	St.0.U	33	25	8	0	75,8	24,2	0,0
	St.1.T	50	40	9	1	80,0	18,0	2,0
	St.0.T	4	3	0	1	75,0	0,0	25,0
I	St.1.U	475	312	135	28	65,7	28,4	5,9
	St.0.U	26	17	4	5	65,4	15,4	19,2
	St.1.T	89	64	20	5	71,9	22,5	5,6
	St.0.T	1	1	0	0	100,0	0,0	0,0

*Podzbiór firm o dobrym (dobry- 1, zły- 0) stanie (St.) ekonomiczno-finansowym wykorzystany jako zbiór uczący (uczący- U, testowy- T).

względem kosztu, groźniejszy jest drugi rodzaj błędu.

4. Wyniki testów


Wyniki przeprowadzonych testów, dla obu województw, w rozbiciu na sekcje, stany ekonomiczno-finansowe i sposoby ich wykorzystania w procesie budowy modelu, zebrano w tablicach 1. i 2. Tablica 3. zawiera globalne statystyki porównawcze modeli dla województw jak i dla całego połączonego obszaru poddanego badaniom.

Wykresy przedstawione na Rys. 2-4, ukazują zależności pomiędzy błędami klasyfikacji uzyskanymi na zbiorze uczącym i niezależnym zbiorze testowym.


5. Wnioski

Ogólny błąd prognozy dla całego badanego obszaru, obliczony na zbiorze testowym 20,9%², przy błędzie 24,9% uzyskanym dla zbioru uczącego, należy uznać za pozytywny symptom świad-

czący o zachowaniu zdolności generalizacji modelu. Wielkości te, odniesione do wyników modeli



Rys. 2. Błędy klasyfikacji dla woj. lubelskiego



Rys. 3. Błędy klasyfikacji dla woj. podkarpackiego

² Błędy obliczone na podstawie danych z Tablicy 3.

Tablica 2. Statystyki klasyfikacyjne dla woj. podkarpackiego

Sekcja	Podzbiór	Obserwacje						
		Liczebność				Udział [%]		
		Wszystkie	Poprawne	Niepoprawne	Nieznane	Poprawne	Niepoprawne	Nieznane
D	St.1.U	1057	658	344	55	62,3	32,5	5,2
	St.0.U	165	97	57	11	58,8	34,5	6,7
	St.1.T	217	169	42	6	77,9	19,4	2,8
	St.0.T	17	11	5	1	64,7	29,4	5,9
E	St.1.U	368	224	127	17	60,9	34,5	4,6
	St.0.U	58	39	15	4	67,2	25,9	6,9
	St.1.T	75	54	16	5	72,0	21,3	6,7
	St.0.T	5	2	2	1	40,0	40,0	20,0
F	St.1.U	2093	1467	561	65	70,1	26,8	3,1
	St.0.U	255	181	69	5	71,0	27,1	2,0
	St.1.T	452	336	93	23	74,3	20,6	5,1
	St.0.T	27	19	7	1	70,4	25,9	3,7
K	St.1.U	104	96	4	4	92,3	3,8	3,8
	St.0.U	464	436	12	16	94,0	2,6	3,4
	St.1.T	32	29	2	1	90,6	6,3	3,1
	St.0.T	2	1	1	0	50,0	50,0	0,0
I	St.1.U	960	858	51	51	89,4	5,3	5,3
	St.0.U	72	63	3	6	87,5	4,2	8,3
	St.1.T	74	64	3	7	86,5	4,1	9,5
	St.0.T	1	1	0	0	100,0	0,0	0,0


Tablica 3. Globalne statystyki klasyfikacyjne dla woj. lubelskiego i podkarpackiego

Sekcja	Podzbiór	Obserwacje						
		Liczebność				Udział [%]		
		Wszystkie	Poprawne	Niepoprawne	Nieznane	Poprawne	Niepoprawne	Nieznane
woj. lubelskie	St.1.U	4204	2889	1198	117	68,7	28,5	2,8
	St.0.U	587	418	154	15	71,2	26,2	2,6
	St.1.T	873	657	200	16	75,3	22,9	1,8
	St.0.T	50	35	12	3	70,0	24,0	6,0
woj. podkarpackie	St.1.U	4582	3303	1087	192	72,1	23,7	4,2
	St.0.U	1014	816	156	42	80,5	15,4	4,1
	St.1.T	850	652	156	42	76,7	18,4	4,9
	St.0.T	52	34	15	3	65,4	28,8	5,8
Razem	St.1.U	8786	6192	2285	309	70,5	26,0	3,5
	St.0.U	1601	1234	310	57	77,1	19,4	3,6
	St.1.T	1723	1309	356	58	76,0	20,7	3,4
	St.0.T	102	69	27	6	67,6	26,5	5,9


opisanych w literaturze, nie odbiegają swoją jakością od tych, które otrzymano przy zastosowaniu podobnych rygorów o jakich mowa była w punkcie 1. i 2. Należy jednak zaznaczyć, że porównania dodatkowo utrudnia fakt, że uzyskane w ramach projektu modele, tworzono dla małych i średnich przedsiębiorstw, a jako kryterium klasyfikacji przyjęto ocenę ich stanu ekonomiczno-finansowego. Znane nam modele, utworzone zarówno dla go-

spodarki polskiej, jak i innych krajów świata, odnoszą się do dużych przedsiębiorstw, najczęściej notowanych na giełdach papierów wartościowych, a jako kryterium klasyfikacji firm przyjmowano bankructwo lub możliwość przetrwania firmy na rynku.

Niepokoić jednak może fakt, że niższy błąd II rodzaju dla zbioru uczącego (Rys.4.), wzrósł o 5%, przy analogicznym spadku błędów I rodzaju.



Rys. 4. Globalne błędy klasyfikacji dla woj. lubelskiego i podkarpackiego



Rys. 5. Udział procentowy błędów klasyfikacji i przypadków nierozpoznanych (sekcja F, woj. podkarpackie)

Przyczyn zapewne jest wiele, ale jedną z nich mogło być gwałtowne polepszenie kondycji małych i średnich przedsiębiorstw na badanym obszarze w okresie objętym testem. Jeśli w latach 1999-2005 firmy o złej kondycji stanowi 15% wszystkich badanych, to w roku 2006 (zbiór testowy) tylko 5%. Wpływ na to miały głównie wyniki uzyskane dla firm z woj. podkarpackiego, gdzie ten udział spadł jeszcze bardziej z 18% do 5%.

Potwierdza to również obserwacja, że na tle woj. podkarpackiego, modele uzyskane dla woj. lubelskiego prezentują się zdecydowanie lepiej. Oba rodzaje błędów uległy bardzo korzystnemu zmniejszeniu dla zbioru testowego w odniesieniu do zbioru uczącego. Błąd klasyfikacji II rodzaju dla zbioru testowego zmalał z 26% (dla zbioru uczącego) do 24%. Ten pozytywny obraz możemy zaobserwować dla modeli zbudowanych dla wszystkich sekcji, choć doskonałe wyniki dla sekcji K i I, ze względu na niewystarczającą liczebność podzbiorów, nie można uznać za statystycznie istotne.

Należy również zaznaczyć, że w przypadku, gdy wielkość błędów, a w szczególności błędów II rodzaju, nie jest akceptowalna dla potrzeb prowadzonej analizy, to kontrolując na

e-barometrze stopień pewności można go zminimalizować. Zmienność błędów w zależności od stopnia pewności, dla wybranej ze względu na odpowiednią liczebność podzbioru danych sekcji F, pokazano Rys.5.

Jeśli założymy akceptowalny błąd II rodzaju na poziomie 15%, to oczekiwany stopień pewności generowany przez model musi być mniejszy lub równy od 0,2. W oczywisty sposób pociąga to za sobą wzrost udziału nierozpoznanych przypadków z 3,7% do 15%.

Literatura:

1. Altman E. I.: Financial ratios, discriminant analysis and the prediction of corporate bankruptcy, *Journal of Finance* 23(1968)589-609.
2. Altman E. I.: Predicting financial distress of companies: revisiting the Z-score and ZETA® models (2000), <http://www.stern.nyu.edu/~ealtman/Zscores.pdf>.
3. Altman E. I., Marco G., Varetto F.: Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks, *Journal of Banking & Finance* 18(1994)505-529.
4. Back B., Laitinen T., Sere K.: Neural networks and bankruptcy prediction: Funds flows, accrual ratios, and accounting data, *Advances in Accounting* 14(1996)23-37.
5. Beaver W. H.: Financial Ratios as Predictors of Failure Empirical Research in Accounting: Selected Studies, *Supplement to Journal of Accounting Research* 4(1966)71-111.
6. Burda A.: Prognozowanie kondycji ekonomiczno-finansowej przedsiębiorstw z wykorzystaniem sztucznych sieci neuronowych, *Barometr Regionalny* 6(2006)67-75.
7. Burda A., Kuczmowska B., Hippe Z. S.: Ensembles of Artificial Neural Networks for Predicting Economic Situation of Small and Medium Enterprises In: Kurzynski, M.; Puchala, E.; Wozniak, M.; Zolnierek, A. (Eds.) *Computer Recognition Systems 2*, Springer, Berlin / Heidelberg 2007:808-815.
8. Burda A., Kuczmowska B., Hippe Z. S.: Zespoły sztucznych sieci neuronowych do przewidywania stanu ekonomicznego małych i średnich przedsiębiorstw, *Zamojskie Studia i Materiały* 23(2007):113-126.
9. Coats, P. K. & L. F. Fant : A neural network approach to forecasting distress, *The Journal of Business Forecasting* (Winter 1991), 9-12.
10. Fletcher D., Goss E.: Forecasting with neural networks.

- An application using bankruptcy data, *Information & Management*. 24(1993)159-167.
11. McKee T., Greenstein M.: Predicting Bankruptcy Using Recursive Partitioning and a Realistically Proportioned Data Set, *Journal of Forecasting* 19(2000)219-230.
 12. Odom M., Sharda R.: A neural network model for bankruptcy prediction, *International Joint Conference on Neural Networks, San Diego, cz. II*(1990)163-168.
 13. Ohlson J. A.: Financial Ratios and the Probabilistic Prediction of Bankruptcy, *Journal of Accounting Research* 18(1980)109-131.
 14. Osowski S.: *Sieci neuronowe*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1994, s. 75-79.
 15. Salchenberger, L., Cinar E., Lash N.: Neural networks: A new tool for predicting thrift failures, *Decision Sciences*, Vol. 23, No. 4(1992)899-916.
 16. Sarkar S., Sriram R. S.: Bayesian Models for Early Warning of Bank Failures, *Management Science* 47(2001)1457-1475.
 17. Tam K. Y., Kiang M.: Predicting Bank Failures- A Neural Network Approach, *Applied Artificial Intelligence* 4(1990)265-282.
 18. Tam K., Kiang M.: Managerial applications of neural networks: The case of bank failure predictions, *Management Science* 38:7(July 1992), 926-947.
 19. Trigueiros D., Taffler R.: Neural networks and empirical research in accounting, *Accounting and Business Research* 26:4(1996)347-355.
 20. Wilson R. L., Sharda R.: Bankruptcy prediction using neural networks, *Decision Support Systems* 11(1994)545-557.