

Tomasz Korol

Politechnika Gdańska

WERYFIKACJA SKUTECZNOŚCI PARAMETRYCZNYCH ORAZ NIEPARAMETRYCZNYCH MODELI PROGNOZOWANIA UPADŁOŚCI PRZEDSIĘBIORSTW

1. Wstęp

W ostatnim okresie jesteśmy świadkami, z jednej strony, intensywnego rozwoju modeli prognozowania upadłości przedsiębiorstw, a z drugiej strony – dynamicznego wzrostu wszystkich indeksów na warszawskiej Giełdzie Papierów Wartościowych. Jednak, jak wykazały badania przeprowadzone przez prof. E. Mączyńską, stopień wykorzystania tych modeli przez takie instytucje, jak: fundusze emerytalne, towarzystwa ubezpieczeniowe, rynek kapitałowy, rady nadzorcze czy też audytorów, jest zerowy bądź też niewielki [Mączyńska 2005, s. 92-96]. Indeks WIG przekroczył po raz pierwszy w historii GPW w Warszawie próg 50 000 punktów. Również indeksy WIG 20, WIRR, MIDWIG, TECHWIG z miesiąca na miesiąc pokonują kolejne progi wzrostu. Wzrosty na GPW przyciągają coraz więcej małych inwestorów. Inwestorzy zarówno mali (np. gospodarstwa domowe), jak i duzi (np. fundusze inwestycyjne) nie powinni jednak zapominać, że jak w każdej zbiorowości przedsiębiorstw, również w populacji spółek giełdowych zdarzają się firmy zagrożone upadłością.

W latach 2000-2002 łącznie wobec 41 spółek publicznych złożono w Polsce wnioski o upadłość lub o otwarcie postępowania układowego, przy czym liczba ta z roku na rok gwałtownie wzrastała [Appenzeller, Szarzec 2004, s. 121]. Biorąc pod uwagę, że w okresie tym na GPW w Warszawie notowanych było 230 spółek, wynika z tego, że aż 17,8% z tych przedsiębiorstw było zagrożonych upadłością. Odnosząc tę wartość do występującego wtedy w Polsce ogólnego natężenia zagrożenia firm upadkiem (117-149 bankrótów przypadało na 10 000 funkcjonujących przedsiębiorstw [Korol 2003, s. 79-89]), można stwierdzić, iż paradoksalnie do

przekonań o niskim ryzyku bankructwa spółek giełdowych, spółki te były bardziej narażone na upadłość niż pozostałe przedsiębiorstwa.

Artykuł ten ma na celu weryfikację skuteczności modeli parametrycznych, tj. logitowych, probitowych i analizy dyskryminacyjnej, oraz modeli nieparametrycznych, czyli sztucznych sieci neuronowych, w prognozowaniu upadłości przedsiębiorstw na przykładzie spółek giełdowych. Autor (na podstawie takiej samej populacji spółek akcyjnych notowanych na warszawskiej Giełdzie Papierów Wartościowych) opracował modele prognozowania upadłości spółek na rok i na dwa lata wstecz, wykorzystując wyżej wymienione techniki opracowywania modeli. Pozwoli to na:

- pokazanie inwestorom możliwości prognozowania zagrożenia kryzysem finansowym spółek aż z dwuletnim wyprzedzeniem czasowym. Tak wczesne przewidywanie kłopotów finansowych poszczególnych spółek jest niekwestionowaną zaletą dla inwestorów, dzięki czemu mogą oni znacznie ograniczyć straty wynikające ze spadku ceny akcji;
- wskazanie metody najskuteczniejszej wśród zbioru metod parametrycznych i nieparametrycznych. Do tej pory, mimo opracowanych przez naukowców licznych modeli prognozowania upadłości przedsiębiorstw, niewiele dotyczyło prognozowania upadłości spółek giełdowych. A gdy dotyczyły one tego rodzaju spółek kapitałowych, nie podejmowano próby weryfikacji skuteczności tych modeli na tle innych modeli z tych dwóch odmiennych grup metod badawczych (parametrycznych i nieparametrycznych). Jedynie porównywano ich skuteczność ze skutecznością modeli opracowanych przez innych naukowców bądź ograniczano się do porównań w ramach jednej z metod, np. modeli analizy dyskryminacyjnej (najbardziej popularnej w Polsce).

2. Założenia do analizy

W badaniach autor wykorzystał dane dotyczące 74 spółek notowanych na warszawskiej Giełdzie Papierów Wartościowych, które opublikowały swoje sprawozdania finansowe w Notoria Serwis „Wyniki finansowe spółek giełdowych” za okres między 1998 a 2003 rokiem. W ramach tej populacji przedsiębiorstw wyodrębniono:

- próbę uczącą – składającą się z 19 spółek zagrożonych bankructwem oraz porządkowanych im 19 spółek niezagrażonych upadkiem. Spółki te pochodziły z różnych sektorów, takich jak: budownictwo, przemysł metalowy, spożywczy, chemiczny, telekomunikacyjny itp. Przy czym zostały one w miarę możliwości dobrane parami, tj. potencjalnemu bankrutowi przypisano przedsiębiorstwo „zdrowe” z tej samej branży i o podobnej wielkości sumy bilansowej. Do celów badawczych opracowano dwie próby uczące z danymi – na rok i na dwa lata przed postawieniem spółki w stan upadłości;

- próbę testową – składającą się z 18 spółek zagrożonych upadłością oraz 18 firm „zdrowych”. W celu sprawdzenia skuteczności w prognozowaniu upadłości spółek giełdowych modeli logitowych, probitowych, wielowymiarowej analizy dyskryminacyjnej i sztucznych sieci neuronowych opracowanych z wykorzystaniem prób uczących, przygotowano dwie próby testowe z danymi – na rok i na dwa lata przed postawieniem spółki w stan upadłości. Przy czym próby te składały się z firm, które nie wchodziły w skład prób uczących modele.

Jakość klasyfikacji oceniono na podstawie skuteczności ogólnej modelu, a także błędów I i II rodzaju. Zastosowano następujące formuły:

- błąd I – $E_1 = D_1 / BR \cdot 100\%$, gdzie D_1 – liczba bankrutów zaklasyfikowanych przez model jako firmy „zdrowe”, BR – liczba bankrutów w próbie uczącej/testowej;
- błąd II – $E_2 = D_2 / NBR \cdot 100\%$, gdzie D_2 – liczba niebankrutów zaklasyfikowanych przez model jako firmy zagrożone upadłością, NBR – liczba niebankrutów w próbie uczącej/testowej;
- skuteczność ogólna modelu – $S = \{1 - [(D_1 + D_2) / (BR + NBR)]\} \cdot 100\%$.

Wszystkie spółki zostały opisane przez 15 wskaźników finansowych. Dodatkowo każda spółka została opisana zmienną wyjściową, tzn. zmienną dzielącą populację na dwie grupy przedsiębiorstw – na zagrożone i niezagrożone upadłością.

Dane wejściowe do modeli wyznaczono na podstawie macierzy korelacji, wybierając jedynie cechy, które są słabo skorelowane między sobą i silnie skorelowane ze zmienną grupującą, reprezentującą informację o zagrożeniu bądź też niezagrożeniu upadłością. Podejście to zapewniło dobór takich cech, które nie powielają informacji dostarczanych przez inne wskaźniki, a jednocześnie są dobrymi reprezentantami wskaźników nie wybranych jako diagnostyczne. Na tej podstawie wyznaczono cztery wskaźniki finansowe na rok i cztery na dwa lata przed upadłością spółek. Wybrane na podstawie macierzy korelacji najlepsze predyktory upadłości przedstawiono w tab. 1. Warto przy tym zwrócić uwagę, że do analizy na rok i na dwa lata przed upadłością zostały wybrane inne wskaźniki finansowe.

Tabela 1. Wskaźniki finansowe wykorzystane w modelach prognozowania upadłości spółek giełdowych na rok i na dwa lata przed upadłością

Wskaźnik	Na rok przed upadłością	Na dwa lata przed upadłością
X1	[aktywa obrotowe (bez krótkoterminowych rozliczeń m/o) – zapasy] / zobowiązania krótkoterminowe	zysk ze sprzedaży / wartość sumy bilansowej
X2	(zysk netto + amortyzacja) / zobowiązania ogółem	kapitał obrotowy / suma bilansowa
X3	koszty operacyjne (bez pozostałych kosztów operacyjnych) / wartość zobowiązań krótkoterminowych	(zysk netto + amortyzacja) / zobowiązania ogółem
X4	zysk brutto / zobowiązania krótkoterminowe	kapitał własny / suma bilansowa

* Kapitał obrotowy został obliczony jako różnica między aktywami obrotowymi bez krótkoterminowych rozliczeń m/o a zobowiązaniami krótkoterminowymi.


Źródło: opracowanie własne.

3. Analiza porównawcza skuteczności modeli prognozowania upadłości firm

Autor tego artykułu opracował dwa modele sztucznych sieci neuronowych prognozowania upadłości spółek giełdowych, które składały się z:

- 4 neuronów w warstwie wejściowej modelu. Neurony te stanowiły 4 wskaźniki finansowe wybrane na podstawie macierzy korelacji zmiennych. Autor nie wykorzystał większej ilości danych diagnostycznych, ponieważ, jak wykazały jego wcześniejsze badania, w przypadku spółek akcyjnych maksymalizacja liczby wskaźników finansowych w modelu sztucznej sieci neuronowej prowadzi do pogorszenia skuteczności takiego modelu [Korol – artykuł w recenzji];
- 6 neuronów w warstwie ukrytej; w warstwie tej model dokonywał obliczeń oraz analiz;
- 1 neuronu wyjściowego, który dokonywał klasyfikacji spółek giełdowych na zagrożone i niezagrożone upadłością, przy czym 0 oznaczało firmę bankrutą, 1 – firmę „zdrową”; próg graniczny klasyfikacji ustalono na poziomie 0,5.

Architekturę opracowanego modelu SSN wraz z wykorzystanymi wskaźnikami finansowymi przedstawia rys. 1.



Rys. 1. Architektura sieci neuronowej na rok i na dwa lata przed bankructwem

Źródło: opracowanie własne.

Kolejnym opracowanym przez autora modelem prognozowania bankructwa spółek był model parametryczny oparty na technice logitowej. Model ten ma następującą postać:

(roczne wyprzedzenie czasowe)

$$Z = -10,2014 + 6,479805 \cdot X_1 + 6,5 \cdot X_2 + 1,14 \cdot X_3 + 8,767 \cdot X_4,$$

(dwuletnie wyprzedzenie czasowe)

$$Z = -4 + 30 \cdot X_1 + 1,11617 \cdot X_2 + 2,6 \cdot X_3 + 3,12512 \cdot X_4.$$

Następnym modelem opracowanym przez autora był model wielowymiarowej analizy dyskryminacyjnej, który składał się z dwóch funkcji. Pierwsza funkcja została nazwana „funkcją bankrutów – Z_{BAN} ”. Miała ona za zadanie określić niebezpieczeństwo upadłości. Druga funkcja określona została mianem „funkcji niebankrutów – Z_{NON} ”. Z kolei ta funkcja określała zdolność przedsiębiorstwa do funkcjonowania, czyli była funkcją określającą „zdrowie” firm.

Funkcje te mają następujące postacie:

(roczne wyprzedzenie czasowe)

$$Z_{BAN} = -2,95855 + 3,20023 \cdot X_1 + (-7,73879) \cdot X_2 + 0,6318 \cdot X_3 + 0,37591 \cdot X_4,$$

$$Z_{NON} = -6,8088 + 3,17942 \cdot X_1 + (-5,45035) \cdot X_2 + 1,62317 \cdot X_3 + 1,51146 \cdot X_4,$$

(dwuletnie wyprzedzenie czasowe)

$$Z_{BAN} = -2,82403 + 5,89684 \cdot X_1 + 1,22819 \cdot X_2 + (-1,13046) \cdot X_3 + 10,42274 \cdot X_4,$$

$$Z_{NON} = -7,13954 + 27,48208 \cdot X_1 + (-0,67722) \cdot X_2 + (-0,61551) \cdot X_3 + 16,39725 \cdot X_4.$$

Model ten różni się od większości modeli analizy dyskryminacyjnej spotykanych w literaturze¹ nie tylko posiadaniem aż dwóch funkcji, ale również sposobem klasyfikacji przedsiębiorstw na zagrożone i niezagrożone upadłością. W zależności od większej wartości Z_{BAN} lub Z_{NON} spółka jest klasyfikowana do jednej z populacji („zdrowych”, „zagrożonych”) firm. Jeżeli $Z_{BAN} > Z_{NON}$, przedsiębiorstwo jest uważane za zagrożone upadłością, gdy $Z_{BAN} < Z_{NON}$, groźba taka nie istnieje, sytuacja finansowa firmy jest oceniona pozytywnie.

Kolejnym opracowanym modelem był model probitowy. Model charakteryzował się następującą funkcją:

(roczne wyprzedzenie czasowe)

$$Z = -6,10919 + 3,807899 \cdot X_1 + 5,671742 \cdot X_2 + 0,701721 \cdot X_3 + 5,448146 \cdot X_4,$$

(dwuletnie wyprzedzenie czasowe)

$$Z = -2,5577 + 17,22672 \cdot X_1 + 0,457882 \cdot X_2 + 1,380421 \cdot X_3 + 1,806184 \cdot X_4.$$

Skuteczność przedstawionych modeli została oszacowana na podstawie prób uczących, czyli populacji firm na podstawie której modele były uczone rozpoznawać bankrutów od niebankrutów, oraz prób testowych, czyli populacji przedsiębiorstw, której modele nie znały. Wyniki testów zostały przedstawione w tab. 2 i 3.

Tabela 2. Wyniki klasyfikacji spółek giełdowych z próby uczącej na rok i na dwa lata wstecz

Czas	Skuteczność	Metody			
		parametryczne			nieparametryczne
		logit	probit	analiza dyskryminacyjna	sztuczna sieć neuronowa
Na rok przed	Błąd I typu	5,26% (1)	5,26% (1)	5,26% (1)	0%
	Błąd II typu	5,26% (1)	5,26% (1)	10,52% (2)	0%
	Skuteczność	94,74%	94,74%	92,11%	100%
Na dwa lata przed	Błąd I typu	15,79% (3)	10,52% (2)	10,52% (2)	0%
	Błąd II typu	10,52% (2)	10,52% (2)	21,05% (4)	0%
	Skuteczność	86,85%	89,48%	84,21%	100%

Źródło: opracowanie własne.

¹ Nie tylko dla spółek giełdowych.

Na podstawie prób uczących można zauważyć, iż najwyższą skuteczność prognozowania upadłości przedsiębiorstw osiągnęły modele sztucznej sieci neuronowej. Zarówno na rok, jak i na dwa lata wstecz modele te nie wygenerowały żadnych błędów, tym samym trafność prognozy wyniosła 100%. W przypadku sztucznych sieci neuronowych jest to jednak zjawisko normalne, że w procesie uczenia modeli osiągają one maksymalne zdolności predykcyjne. Dlatego też bardziej istotne z punktu widzenia wiarygodności wyników są badania skuteczności modeli sztucznych sieci neuronowych na podstawie prób testowych nieznanymi modelom.

Wśród modeli parametrycznych na rok wstecz najwyższą skutecznością charakteryzował się model probitowy i logitowy. Ich skuteczność była wyższa od modelu analizy dyskryminacyjnej o 2,63 punktu procentowego. Natomiast w analizie spółek na dwa lata wstecz model probitowy osiągnął skuteczność wyższą o 5,27 punktu procentowego od modelu AD oraz o 2,63 punktu procentowego od modelu logitowego.

Tabela 3. Wyniki klasyfikacji spółek giełdowych z próby testowej na rok i na dwa lata przed upadłością spółek

Czas	Skuteczność	Metody			
		parametryczne			nieparametryczne
		logit	probit	analiza dyskryminacyjna	sztuczna sieć neuronowa
Na rok przed	Błąd I typu	0%	0%	0%	0%
	Błąd II typu	5,55% (1)	5,55% (1)	22,22% (4)	5,55% (1)
	Skuteczność	97,23%	97,23%	88,89%	97,23%
Na dwa lata przed	Błąd I typu	11,11% (2)	0%	0%	11,11% (2)
	Błąd II typu	16,66% (3)	16,66% (3)	22,22% (4)	11,11% (2)
	Skuteczność	86,12%	91,67%	88,89%	88,89%

Źródło: opracowanie własne.

Otrzymane wyniki prób testowych wskazują, że w analizie spółek na rok przed ich upadłością trzy modele – logitowy, probitowy oraz sztucznej sieci neuronowej – osiągnęły taką samą skuteczność, tj. 97,23%. Skuteczność prognozy modelu wielowymiarowej analizy dyskryminacyjnej była niższa od tych modeli aż o 8,34 punktu procentowego. Jest to znacznie gorszy wynik od pozostałych modeli, co jest paradoksem, jeśli się weźmie pod uwagę powszechność wykorzystania modeli analizy dyskryminacyjnej w Polsce.

W analizie spółek na dwa lata wstecz model probitowy charakteryzował się najwyższą skutecznością. Trafność jego prognoz była na poziomie 91,67%. Przy czym warto również zauważyć, iż model ten nie popełnił żadnego błędu I typu, czyli błędu polegającego na zaklasyfikowaniu spółki bankruta jako firmy „zdrowej”. Błędy te, z punktu widzenia banków, inwestorów itp., są znacznie kosztowniejsze niż błędy II typu, które polegają na zaklasyfikowaniu spółki „zdrowej” do przedsiębiorstw zagrożonych upadłością. Na drugim miejscu pod względem poziomu skuteczności znalazł się model sztucznej sieci neuronowej oraz analizy dyskryminacyjnej. Oba modele osiągnęły skuteczność wynoszącą 88,89%. Należy

jednak zaznaczyć, że o ile skuteczność tych modeli jest taka sama, to model analizy dyskryminacyjnej nie wygenerował żadnych błędów I typu, podczas gdy model sztucznej sieci neuronowej w dwóch przypadkach błędnie zaklasyfikował spółkę bankrutą jako firmę „zdrową”. Tym samym błąd I typu wyniósł 11,11%. Najmniejszą skutecznością prognozowania upadłości spółek giełdowych na dwa lata wstecz charakteryzował się model logitowy, którego trafność prognozy wyniosła 86,12%.

4. Wnioski

Wnioski płynące z wyników badań są istotne. Przeprowadzone przez autora badania wykazały, że choć modele analizy dyskryminacyjnej są najpopularniejsze na świecie i w Polsce, ich skuteczność w prognozowaniu upadłości spółek giełdowych notowanych na warszawskiej Giełdzie Papierów Wartościowych jest wyraźnie gorsza od skuteczności modeli probitowych, logitowych i sztucznych sieci neuronowych. Dzięki tym badaniom na takiej samej populacji² dokonano weryfikacji skuteczności modeli opartych na czterech różnych technikach. Wyniki jednoznacznie wykazały, że modele probitowe charakteryzują się najwyższą zdolnością predykcji zagrożenia upadłością przedsiębiorstw w przypadku wydłużenia okresu prognozy zarówno na próbie uczącej³, jak i testowej. W analizach krótkookresowych prób testowych model probitowy, logitowy i sztucznej sieci neuronowej charakteryzowały się taką samą skutecznością. Z tego też względu można zasugerować, iż w przypadku oceny zagrożenia upadłością spółek giełdowych przy wykorzystaniu samych tylko wskaźników finansowych⁴ najwydajniejszą metodą jest metoda probitowa⁵.

Literatura

- Appenzeller D., Szarzec K., *Prognozowanie zagrożenia upadłością polskich spółek giełdowych*, „Rynek Terminowy” 2004 nr 1.
- Korol T., Prusak B., *Upadłość przedsiębiorstw a wykorzystanie sztucznej inteligencji*, CeDeWu, Warszawa 2005.
- Korol T., *Wpływ maksymalizacji danych wejściowych na skuteczność modeli parametrycznych i nieparametrycznych prognozowania upadłości przedsiębiorstw*, „Bank i Kredyt” (artykuł w recenzji).
- Korol T., *Zjawisko upadłości przedsiębiorstw w Polsce w okresie transformacji gospodarczej*, „Gospodarka w Praktyce i Teorii”, Wydawnictwo Katedry Ekonomii Uniwersytetu Łódzkiego 2003 nr 1 (12).
- Mączyńska E. (red.), *Ekonomiczne aspekty upadłości przedsiębiorstw w Polsce*, Materiały i Prace Instytutu Funkcjonowania Gospodarki Narodowej, T. XCII, SGH, Warszawa 2005.

² Co jest istotne dla wiarygodności otrzymanych wyników.

³ Z wyjątkiem sztucznych sieci neuronowych, o których pisał autor.

⁴ System wczesnego ostrzegania przed upadłością firm może zostać rozbudowany o zmienne nieekonomiczne, jak np. region funkcjonowania spółki. W takich przypadkach należy wskazać model sztucznej sieci neuronowej jako narzędzie optymalne. Więcej na temat takich systemów w [Korol 2005].

⁵ Dla zachowania tej samej metody do badań spółek na rok i na dwa lata przed upadłością. Mieszanie technik w zależności od okresu analizy nie sprzyja przejrzystości stawianej prognozy, zwiększa też czasochłonność jej przeprowadzenia.

VERIFICATION OF EFFECTIVENESS OF PARAMETRIC AND NONPARAMETRIC BANKRUPTCY PREDICTION MODELS

Summary

This article is on bankruptcy prediction of the stock equity companies with the use of different parametric and nonparametric techniques. The author created 8 models for analyzing the companies one year and two years prior to their financial failure. Models presented in the article allow to predict with a high probability bankruptcy.