

PRACE NAUKOWE

Uniwersytetu Ekonomicznego we Wrocławiu

RESEARCH PAPERS

of Wrocław University of Economics

254

Inwestycje finansowe i ubezpieczenia – tendencje światowe a rynek polski



Redaktorzy naukowi

Krzysztof Jajuga

Wanda Ronka-Chmielowiec



Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu
Wrocław 2012

Recenzenci: Diarmuid Bradley, Jan Czekaj, Marek Gruszczyński, Jacek Lisowski, Paweł Miłobędzki,
Włodzimierz Szkutnik, Mirosław Szreder, Adam Szyszka, Waldemar Tarczyński,
Stanisław Wieteska, Tomasz Wiśniewski

Redaktor Wydawnictwa: Aleksandra Śliwka

Redaktor techniczny: Barbara Łopusiewicz

Korektor: Barbara Cibis

Łamanie: Małgorzata Czupryńska

Projekt okładki: Beata Dębska

Publikacja jest dostępna w Internecie na stronach:

www.ibuk.pl, www.ebscohost.com,

The Central and Eastern European Online Library www.ceeol.com,

a także w adnotowanej bibliografii zagadnień ekonomicznych BazEkon

http://kangur.uek.krakow.pl/bazy_ae/bazekon/nowy/index.php

Informacje o naborze artykułów i zasadach recenzowania znajdują się
na stronie internetowej Wydawnictwa

www.wydawnictwo.ue.wroc.pl

Kopiowanie i powielanie w jakiegokolwiek formie
wymaga pisemnej zgody Wydawcy

© Copyright by Uniwersytet Ekonomiczny we Wrocławiu
Wrocław 2012

ISSN 1899-3192

ISBN 978-83-7695-293-2

Wersja pierwotna: publikacja drukowana

Druk: Drukarnia TOTEM

Spis treści

Wstęp	9
Barbara Będowska-Sójka: Zastosowanie zmienności zrealizowanej i modeli typu ARCH w wyznaczaniu wartości zagrożonej	11
Jacek Bialek: Zastosowanie statystycznych indeksów łańcuchowych do oceny przeciętnego zwrotu grupy OFE	23
Beata Bieszk-Stolorz, Iwona Markowicz: Zastosowanie modelu logitowego i modelu regresji Coxa w analizie zmian cen akcji spółek giełdowych w wyniku kryzysu finansowego	33
Katarzyna Byrka-Kita: Premia z tytułu kontroli na polskim rynku kapitałowym – wyniki badań	42
Krzysztof Echaust: Analiza przekroczeń wysokości depozytów zabezpieczających na podstawie kontraktów futures notowanych na GPW w Warszawie.	52
Magdalena Frasyniuk-Pietrzyk, Radosław Pietrzyk: Rentowność inwestycji na rynku regulowanym i w alternatywnym systemie obrotu w Polsce	61
Daniel Iskra: Wartość zagrożona instrumentu finansowego szacowana przedziałowo	74
Bogna Janik: Analiza stóp zwrotu z inwestycji w indeksy akcji spółek społecznie odpowiedzialnych	83
Paweł Kliber: Niestacjonarność aktywności transakcyjnej na Giełdzie Papierów Wartościowych w Warszawie	93
Krzysztof Kowalke: Ocena przydatności rekomendacji giełdowych opartych na metodzie DCF na przykładzie spółek budowlanych	103
Mieczysław Kowerski: Modele selekcji próby stóp dywidend spółek notowanych na Giełdzie Papierów Wartościowych w Warszawie	113
Dominik Krężolek: Granica efektywności portfeli inwestycyjnych a indeks ogona rozkładu stopy zwrotu – analiza empiryczna na przykładzie GPW w Warszawie	124
Monika Kubik-Kwiatkowska: Znaczenie raportów finansowych dla wyceny spółek notowanych na Giełdzie Papierów Wartościowych w Warszawie SA	133
Agnieszka Majewska: Wycena opcji menedżerskich – wybrane problemy ...	142
Sebastian Majewski: Pomiar nastroju inwestycyjnego jako metoda wspomagająca strategię inwestycyjne	152
Piotr Manikowski: Cykle ubezpieczeniowe w Europie Środkowej	162

Artur Mikulec: Metody oceny wyników inwestycyjnych przy braku normalności rozkładu stóp zwrotu	171
Joanna Olbryś: Tarcie w procesach transakcyjnych i jego konsekwencje	181
Andrzej Paliński: Spłata zadłużenia kredytowego w ujęciu teoriogrowym	190
Monika Papież, Stanisław Wanat: Modele autoregresji i wektorowej autoregresji w prognozowaniu podstawowych zmiennych charakteryzujących rynek ubezpieczeń działu II	199
Daniel Papla: Przykład zastosowania metod analizy wielowymiarowej w analizie zarażania rynków finansowych	209
Tomasz Pisula: Zastosowanie sztucznych sieci neuronowych do prognozowania upadłości przedsiębiorstw	219
Agnieszka Przybylska-Mazur: Wybrane reguły nastawione na cel a prognozowanie wskaźnika inflacji	235
Paweł Siarka: Wykorzystanie modeli scoringowych w bankowości komercyjnej	246
Rafał Siedlecki: Struktura kapitału w cyklu życia przedsiębiorstwa	262
Anna Sroczyńska-Baron: Wybór portfela akcji z wykorzystaniem narzędzi teorii gier	271
Michał Stachura, Barbara Wodecka: Zastosowania kopuli niesymetrycznych w modelowaniu ekonomicznym	281
Michał Stachura, Barbara Wodecka: Zastosowanie estymatora k -to-rekordowego do szacowania wartości narażonej na ryzyko	289
Piotr Staszewicz: Multi entry framework for financial and risk reporting	298
Anna Szymańska: Czynniki decydujące o wyborze ubezpieczyciela w przypadku ubezpieczeń komunikacyjnych AC	310
Sławomir Śmiech, Wojciech Zysk: Oceny ratingowe jako element konkurencyjności wybranych systemów gospodarczych – weryfikacja na przykładzie agencji Fitch	323
Rafał Tuzimek: Wpływ wypłat dywidendy na wartość akcji spółek notowanych na Giełdzie Papierów Wartościowych w Warszawie	333
Jacek Welc: Rewersja do średniej dynamiki przychodów oraz rentowności spółek a zmiany relatywnej dynamiki zysków	347
Ryszard Węgrzyn: Zastosowanie delty „wolnej od modelu” w hedgingu opcyjnym	356
Stanisław Wieteska: Wyładowania atmosferyczne jako element ryzyka w ubezpieczeniach majątkowo-osobowych w polskim obszarze klimatycznym	367
Alicja Wolny-Dominiak: Modelowanie liczby szkód w ubezpieczeniach komunikacyjnych w przypadku występowania dużej liczby zer	381

Summaries

Barbara Będowska-Sójka: Modeling value-at-risk when realized volatility and ARCH-type models are used.....	22
Jacek Bialek: The application of chain indices to evaluate the average rate of return of a group of Open Pension Funds.....	32
Beata Bieszk-Stolorz, Iwona Markowicz: The application of the logit model and the Cox regression model in the analysis of financial crisis related price changes of listed companies' shares	41
Katarzyna Byrka-Kita: Control premium on Polish capital market – empirical evidence	51
Krzysztof Echaust: Analysis of margin exceedances on the basis of futures contracts quoted on the Warsaw Stock Exchange.....	60
Magdalena Frasyniuk-Pietrzyk, Radosław Pietrzyk: Return on investment on a regulated market and multilateral trading facility in Poland	73
Daniel Iskra: Confidence interval for Value at Risk.....	82
Bogna Janik: Analysis of rates of return on investments in equity SRI indices	92
Paweł Kliber: Non-stationarity in transaction activity on the Warsaw Stock Exchange.....	102
Krzysztof Kowalke: Assessment of the usefulness of Stock Exchange recommendations based on the DCF method on the example of construction companies.....	112
Mieczysław Kowerski: The sample selection models of dividend yield of companies quoted on the Warsaw Stock Exchange.....	123
Dominik Krężolek: The efficient frontier of investment portfolios and the tail index of distribution of returns – an empirical analysis on the WSE	132
Monika Kubik-Kwiatkowska: Value relevance of financial reporting on the Warsaw Stock Exchange.....	141
Agnieszka Majewska: The value of employee stock options – selected problems.....	151
Sebastian Majewski: Measuring of investment sentiment as a method of supporting investment strategies.....	161
Piotr Manikowski: Insurance cycles in Central Europe.....	170
Artur Mikulec: Investment performance evaluation methods in the absence of normality of the rates of return.....	180
Joanna Olbryś: Friction in trading processes and its implications	189
Andrzej Paliński: The game theoretic approach to bank credit repayment....	198
Monika Papież, Stanisław Wanat: The application of autoregressive models and vector autoregressive models in forecasting basic variables on the non-life insurance market	208

Daniel Papla: Example of using multidimensional methods in analyzing the contagion on the financial markets	218
Tomasz Pisula: Application of artificial neural networks for forecasting corporate bankruptcy	234
Agnieszka Przybylska-Mazur: Selected targeting rules and forecasting inflation rate	245
Paweł Siarka: The use of scoring models in commercial banking.....	261
Rafał Siedlecki: The structure of capital in the company life cycle	270
Anna Sroczyńska-Baron: The choice of shares portfolio based on the theory of games.....	280
Michał Stachura, Barbara Wodecka: Asymmetric copulas applications in economic modelling.....	288
Michał Stachura, Barbara Wodecka: Value-at-Risk estimation using ‘ k -th record’ estimator	297
Piotr Staszewicz: Zapis poczwórny jako mechanizm pozwalający na integrację sprawozdawczości finansowej i ostrożnościowej	309
Anna Szymańska: Factors determining a choice of an insurer in case of motor hull insurance	322
Sławomir Śmiech, Wojciech Zysk: Assessments of rating as part of competitiveness of selected economies – verification on the example of Fitch agency	332
Rafał Tuzimek: Effect of dividend payments on the value of shares listed on the Warsaw Stock Exchange	346
Jacek Welc: Impact of mean-reversion of sales growth and profitability on the relative growth of corporate earnings	355
Ryszard Węgrzyn: Application of model free delta to option hedging	366
Stanisław Wieteska: Lightning as an element of risk in non-life insurance in the Polish area of climate.....	380
Alicja Wolny-Dominiak: Zero-inflated claim count modeling in automobile insurance. Case Study	390

Tomasz Pisula

Politechnika Rzeszowska

ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH DO PROGNOZOWANIA UPADŁOŚCI PRZEDSIĘBIORSTW

Streszczenie: W dobie pogłębiającego się kryzysu ekonomicznego bardzo wiele przedsiębiorstw jest zagrożonych ryzykiem upadłości. Efektywne przewidywanie upadłości jest jednym z ważniejszych zagadnień zarządzania ryzykiem. W ostatnich kilkunastu latach, z racji większej dostępności na rynku specjalistycznych pakietów oprogramowania, zaczęto intensywnie wykorzystywać modele sztucznej inteligencji do prognozowania upadłości firm. W publikacji przedstawiono możliwości wykorzystania sztucznych sieci neuronowych w klasyfikacji przedsiębiorstw zagrożonych upadłością. Na podstawie próby badawczej 207 polskich przedsiębiorstw, które ogłosiły upadłość od stycznia 2007 r. do grudnia 2010 r., przeprowadzono badania empiryczne porównujące skuteczność prognostyczną modeli neuronowych w porównaniu z klasycznymi modelami parametrycznymi (logitowym i analizy dyskryminacyjnej).

Słowa kluczowe: prognozowanie upadłości, sieci neuronowe, model logitowy, analiza dyskryminacyjna.

1. Wstęp

W ostatnich latach rośnie liczba polskich przedsiębiorstw zagrożonych ryzykiem upadłości. Jak wynika z analizy statystyk upadłościowych bazy Corporate Database, należącej do systemu informacyjnego EMIS (<http://www.securities.com>), od stycznia 2007 r. do grudnia 2010 r. ponad 360 polskich przedsiębiorstw ogłosiło upadłość. Przyczyny upadłości tak wielu przedsiębiorstw są wieloaspektowe i wielopłaszczyznowe. Najczęstszymi przyczynami upadłości na płaszczyźnie makroekonomicznej (zob. [Korol, Prusak 2009]) są: recesja w gospodarce, recesja w branży, poziom bezrobocia, kursy walut obcych, stawki podatków. Sektorowe przyczyny kryzysu przedsiębiorstw to: zatory płatnicze, wzrost stopnia konkurencji, napływ kapitału zagranicznego. Natomiast spośród wewnętrznych przyczyn upadłości należy wymienić jako najważniejsze: brak kapitału lub innych zasobów, błędne zarządzanie przedsiębiorstwem, błędną strategię rozwoju lub jej brak, niską efektywność gospo-

darowania, błędną politykę cenową, konflikty wewnętrzne itp. Upadłość jest zawsze zjawiskiem niekorzystnym, głównie w wymiarze ekonomicznym oraz społecznym, dlatego szczególnie ważne jest, aby odpowiednio wcześniej przewidywać potencjalne ryzyko zagrożenia upadłością. Do prognozowania upadłości przedsiębiorstw od lat z dużym powodzeniem stosuje się statystyczne modele parametryczne, takie jak modele liniowej analizy dyskryminacyjnej (LDA) oraz modele logitowe. W ostatnich latach, wraz z rozwojem możliwości obliczeniowych współczesnych komputerów, coraz częściej wykorzystywane są metody sztucznej inteligencji (szczególnie sztuczne sieci neuronowe) do przewidywania upadłości przedsiębiorstw. Metody wykorzystujące sieci neuronowe są alternatywą dla modeli parametrycznych, gdyż są stosunkowo łatwe do wykorzystania w praktyce z racji coraz większej dostępności do specjalistycznego oprogramowania (niejednokrotnie darmowego i oferującego automatyzację całego procesu ich wykorzystania) oraz mają dużą efektywność w klasyfikacji przedsiębiorstw zagrożonych upadłością.

W publikacji podjęto próbę praktycznego wykorzystania sieci neuronowych do prognozowania upadłości polskich przedsiębiorstw. Celem przeprowadzonych badań empirycznych jest zbadanie skuteczności wykorzystania sieci neuronowych jako efektywnych narzędzi w prognozowaniu upadłości.

Wcześniejsze badania innych autorów pokazują, że sieci neuronowe mają zbliżoną, a niekiedy lepszą efektywność klasyfikacyjną niż klasyczne modele analizy dyskryminacyjnej i logitowe. Celem badań empirycznych było zatem sprawdzenie również hipotezy, że efektywność modeli prognostycznych opartych na sztucznej inteligencji jest lepsza niż efektywność modeli parametrycznych (LDA i logitowego).

Praktyczne możliwości wykorzystania sztucznej inteligencji do prognozowania upadłości pokazano na przykładzie próby badawczej, obejmującej 81 polskich przedsiębiorstw, które ogłosiły upadłość od stycznia 2007 r. do grudnia 2010 r., oraz 126 przedsiębiorstw niezagrażonych upadłością. Przedsiębiorstwa objęte badaniem należały do różnych sektorów działalności, zgodnie z Polską Klasyfikacją Działalności (PKD). Dla każdego przedsiębiorstwa upadłego wytypowano 1-2 przedsiębiorstwa zdrowe, należące do tego samego sektora działalności. Przedsiębiorstwa zdrowe identyfikowano na podstawie wnikliwej analizy wskaźników finansowych określających ich kondycję finansową. Ostateczna próba badawcza obejmowała zatem 207 polskich przedsiębiorstw (81 upadłych i 126 zdrowych). Dla potrzeb analiz badawczych korzystano z danych pochodzących ze sprawozdań finansowych badanych przedsiębiorstw z roku bezpośrednio poprzedzającego okres upadłości lub z 2 lat przed okresem upadłości (w zależności od dostępności danych). Dane statystyczne pochodziły z systemu Emerging Markets Information Service (EMIS).

Wykorzystane w badaniach empirycznych sieci neuronowe (zob. szczegółową ich charakterystykę w punkcie 4 pracy) to sieci typu perceptron wielowarstwowy (MLP) z jedną warstwą neuronów ukrytych, ale mające różną liczbę neuronów ukrytych oraz wykorzystujące różne funkcje aktywacji neuronów w warstwach: ukrytej i wyjściowej. Wybór tego typu architektury sieci został podyktowany tym, że są to

najczęściej wykorzystywane w praktyce modele sieci neuronowych (zob. analiza literatury w punkcie 2 pracy), a do praktycznej implementacji sieci neuronowych wykorzystano moduł NN pakietu Statistica PL, który sieci o takiej właśnie architekturze oferował. W badaniach wykorzystano także własne procedury obliczeniowe w języku programowania Statistica Visual Basic.

2. Główne kierunki badań w prognozowaniu upadłości przedsiębiorstw

Wykorzystanie modeli statystycznych w problematyce przewidywania upadłości przedsiębiorstw zapoczątkowane zostało badaniami Beavera. Wyniki swoich analiz opublikował on w pracy (zob. [Beaver 1966]), w której zawarł swoje ponadtrzydziestoletnie doświadczenia z badań nad wskaźnikami finansowymi firm upadłych i zdrowych. Badania Beavera są pierwszą próbą formalnego statystycznego podejścia do wykorzystania wskaźników finansowych w analizie przewidywania ryzyka niewypłacalności finansowej i prognozowania zagrożenia upadłością firm.

Altman (zob. [Altman 1968]) na gruncie badań Beavera zapoczątkował natomiast najbardziej popularną grupę modeli prognozowania upadłości przedsiębiorstw, tzw. statystycznych modeli parametrycznych wykorzystujących jako główne determinanty upadłości wskaźniki stosowane w analizie finansowej przedsiębiorstw i rachunkowości. Model Altmana był pierwszym empirycznym badaniem nad możliwością wykorzystania wielowymiarowej analizy dyskryminacyjnej do klasyfikacji przedsiębiorstw zagrożonych upadłością.

Ohlson (zob. [Ohlson 1980]) zastosował w swoich badaniach podobnie jak Altman jako determinanty upadłości wskaźniki finansowe, wykorzystał natomiast po raz pierwszy w problemach klasyfikacji firm zagrożonych bankructwem model logitowy. Wymaga on mniejszej liczby restrykcyjnych założeń niż zastosowana przez Altmana metoda MDA (*Multivariate Discriminant Analysis*). W dalszych badaniach Żmijewski (zob. [Żmijewski 1984]) wprowadził i zaadaptował model probitowy do prognozowania zagrożenia upadłością przedsiębiorstw. Model Żmijewskiego wykorzystywał jako predyktory upadłości również wskaźniki finansowe firm, ale posługiwał się innym zbiorem potencjalnych zmiennych diagnostycznych niż Ohlson.

Aziz i Dar (zob. [Aziz, Dar 2006]) w swoim artykule zawarli bardzo wyczerpujące podsumowanie dotychczasowych głównych kierunków badań nad problematyką przewidywania upadłości przedsiębiorstw. Do prognozowania upadłości przedsiębiorstw wykorzystuje się różne techniki analityczne i modele teoretyczne. Stosowane modele prognostyczne można bardzo ogólnie podzielić na trzy główne klasy modeli:

- Modele statystyczne – wykorzystujące głównie metody wielowymiarowej statystycznej analizy porównawczej. Dominującą rolę w tej klasie odgrywiają modele wykorzystujące: wielowymiarową analizę dyskryminacyjną (*Multivariate Discriminant Analysis*), *linear probability models*, modele logitowe oraz probitowe

(zob. np. [Altman 1968; Altman i in. 1977; Skogsvik 1990; Theodossiou 1991; Stone, Rasp 1991]).

- Modele i metody wykorzystujące sztuczną inteligencję oraz systemy eksperckie. Do tej grupy metod przewidywania upadłości przedsiębiorstw należą głównie metody wykorzystujące: drzewa decyzyjne (*decision trees*), sieci neuronowe (*neural networks*), algorytmy genetyczne (*genetic algorithms*) czy też teorię zbiorów rozmytych (*rough sets*), zob. np. [Beynon, Peel 2001; Shin, Lee 2002].
- Modele teoretyczne – oparte na różnego rodzaju teoriach i teoretycznych podstawach, analizujące te czynniki, które wymuszają bankructwo firm. Do tego nurtu badań należą metody wykorzystujące głównie: teorię entropii (*entropy theory*) i *Balance Sheet Decomposition Measure* (BSDM), teorię ruiny (*Gambler's ruin theory*), teorię zarządzania pieniędzem (*cash management theory*) czy też teorię ryzyka kredytowego (*credit risk theories*), zob. np. [Wilcox 1973; Booth 1983].

W pracy [Aziz, Dar 2006] przeanalizowano 89 publikacji z lat 1968-2003, poruszających teoretyczne i praktyczne aspekty problematyki prognozowania upadłości przedsiębiorstw. Z analiz tych wynika, że najczęściej w badaniach stosowane są modele statystyczne (w 64% publikacji), w dalszej kolejności pod względem częstotliwości zastosowań znalazły się badania wykorzystujące sztuczną inteligencję i systemy eksperckie (analizowane w 25% publikacji), zastosowanie modeli teoretycznych stanowiło najmniej liczną grupę badań (tylko 11%) wszystkich przeanalizowanych publikacji. Najczęściej stosowanymi modelami w badaniach nad przewidywaniem upadłości przedsiębiorstw były modele wielowymiarowej analizy dyskryminacyjnej (stosowane w ponad 30% publikacji), w dalszej kolejności modele logitowe (w ponad 20% publikacji) i wykorzystanie sieci neuronowych (w 9% publikacji). Ogólna średnia efektywność predykcyjna dla modeli (łącznie dla przedsiębiorstw upadłych oraz zdrowych) jest dość duża i dla prawie wszystkich modeli (oprócz modeli wykorzystujących teorię zarządzania pieniędzem, dla których wynosiła tylko 64% poprawnych klasyfikacji), oscyluje w granicach 81-94% (szczególnie dla modeli wykorzystujących teorię ruiny – aż 94%, dla parametrycznych modeli: MDA 86% i logitowych 87%, a dla sieci neuronowych 88%, zob. [Aziz, Dar 2006]).

Sieci neuronowe należą zatem, obok statystycznych modeli parametrycznych, takich jak: modele analizy dyskryminacyjnej i modele logitowe, do najczęściej stosowanych narzędzi w praktyce prognozowania upadłości przedsiębiorstw, które charakteryzują się dużą jakością i efektywnością klasyfikacyjną. Jardin (zob. [Jardin 2010]) przeanalizował ponad 80 publikacji traktujących o zastosowaniach sieci neuronowych do prognozowania upadłości przedsiębiorstw (opublikowanych do roku 2009). Z przedstawionego w jego publikacji zestawienia wynika, że najczęściej stosowanymi sieciami neuronowymi są sieci typu perceptron wielowarstwowy (MLP – *Multilayer Perceptron*) o różnej architekturze i z różnymi algorytmami uczenia się sieci. Najczęściej są to algorytmy wstecznej propagacji błędu (*back-propagation*), ale stosuje się również inne algorytmy, jak: algorytmy genetyczne, gradientów sprzężonych czy też algorytm Levenberg–Marquardta. Rzadziej wykorzystuje się

sieci innych typów, takie jak: sieci typu Kohonena czy sieci o RBF o radialnych funkcjach bazowych. Odsetek poprawnych klasyfikacji analizowanych modeli sieci neuronowych dla populacji przedsiębiorstw zdrowych zawiera się w przedziale 75-100%, dla populacji bankrutów zaś – w przedziale 62-100% (zob. [Jardin 2010]).

Należy podkreślić także, że badania nad problemami upadłości przedsiębiorstw prowadzone były również przez polskich autorów. Trzeba zwrócić uwagę chociażby na znaczny wkład w rozwój omawianego nurtu badań opracowania na podstawie rodzimych danych statystycznych o upadłościach przedsiębiorstw różnorodnych modeli analizy dyskryminacyjnej (zob. np. prace [Prusak 2005; Hadasik 1998; Gajdka, Stos 1996]). Wykorzystanie sztucznej inteligencji, a szczególnie sieci neuronowych, w problemach prognozowania upadłości przedsiębiorstw pozostawało również w centrum zainteresowań polskich naukowców. Wymienić tutaj należy wieloletnie badania prof. Witkowskiej (zob. np. [Witkowska 2002]) oraz prace innych polskich autorów (zob. [Korol, Prusak 2009]).

3. Klasyfikacja przedsiębiorstw ze względu na ryzyko upadłości z wykorzystaniem sieci neuronowych – podstawowe zagadnienia metodologiczne

Sztuczne sieci neuronowe mają wiele różnych zastosowań ekonomicznych. Do najważniejszych należy zaliczyć możliwość wykorzystania sieci neuronowych w zagadnieniach regresyjnych oraz prognostycznych, a także w zagadnieniach klasyfikacyjnych obiektów wielocechowych. Z punktu widzenia oceny zagrożenia upadłością przedsiębiorstw istotne są zastosowania klasyfikacyjne sieci neuronowych, czyli możliwości grupowania przedsiębiorstw (charakteryzowanych wieloma czynnikami określającymi ich kondycję finansową) na 2 podstawowe grupy: przedsiębiorstw niezagrażonych upadłością i potencjalnych bankrutów. Obszerna teoria dotycząca sztucznych sieci neuronowych oraz ich charakterystyka są bardzo szeroko omawiane w literaturze, dlatego w publikacji ograniczono się do podania jedynie odwołań literaturowych, gdzie można znaleźć wyczerpujące informacje dotyczące tych zagadnień. Wieloaspektową i szczegółową charakterystykę sieci neuronowych można znaleźć m.in. w monografiach (zob. np. [Tadeusiewicz 1993, 1998; Witkowska 2002]).

Pierwszy istotny problem metodologiczny w modelowaniu z wykorzystaniem sieci neuronowych stanowi zagadnienie wyboru potencjalnych zmiennych diagnostycznych, których wartości będą pojawiać się na wejściu (w warstwie wejściowej) analizowanych sieci. Jako zmiennych wejściowych w modelach sieci neuronowych (wykorzystywanych do klasyfikacji przedsiębiorstw pod względem potencjalnego ryzyka ich upadłości) używa się różnych wskaźników finansowych, które opisują kondycję finansową badanych firm. Przy ustalaniu ostatecznego zestawu zmiennych wejściowych do analiz empirycznych stosuje się różnorodne metody statystyczne, takie jak: metody oparte na analizie współczynników korelacji (zarówno pomiędzy

zmiennymi diagnostycznymi, jak i zmiennych diagnostycznych z dychotomiczną zmienną zależną identyfikującą przedsiębiorstwa jako upadłe lub nie), metoda analizy składowych głównych, metoda analizy czynnikowej czy też metody sztucznej inteligencji, takie jak np. algorytmy genetyczne.

W publikacji jako zmienne diagnostyczne (zmienne wejściowe) w modelach sztucznych sieci neuronowych wykorzystanych do badań empirycznych (zob. pkt 4) zastosowano pierwotną listę 26 wskaźników finansowych (dokładna lista wszystkich wskaźników znajduje się w załączniku pracy), które bardzo często wykorzystuje się w analizie finansowej przedsiębiorstw (zob. np. [Bednarski 2001]).

Ważnym elementem każdej analizy klasyfikacyjnej, a szczególnie z wykorzystaniem sztucznych sieci neuronowych, jest walidacja i ocena jakości uzyskanych klasyfikacji pod względem ich poprawności i efektywności prognoz *ex post*. Istnieje bardzo wiele mierników oraz sposobów umożliwiających zbadanie skuteczności klasyfikacyjnej modeli. Do najczęściej spotykanych w praktyce i opisywanych w literaturze (zob. np. [Witkowska 2002; Prusak 2005; Korol, Prusak 2009]) należą: macierz klasyfikacji wraz ze współczynnikiem poprawnych klasyfikacji, współczynnik IS (iloraz szans) oraz graficzna ilustracja efektywności modeli za pomocą krzywych koncentracji CAP (*Cumulative Accuracy Profiles Curve*) lub ROC (*Relative Operating Characteristic Curve*).

Macierz klasyfikacji przedsiębiorstw jest tabelarycznym podsumowaniem dokładności klasyfikacyjnej badanego modelu. W tabeli z macierzą klasyfikacji podane są informacje o liczbie prawidłowych klasyfikacji: dla przedsiębiorstw upadłych (bankrutów) P_B oraz niezagrożonych upadłością (zdrowych) P_{NB} , o liczbie nieprawidłowych klasyfikacji: dla bankrutów NP_B oraz dla przedsiębiorstw niezagrożonych upadłością NP_{NB} , a także podsumowujące statystyki określające efektywność oraz błędy klasyfikacji badanych modeli.

Efektywność oraz błąd klasyfikacji dla przedsiębiorstw niebędących bankrutami określa procent ich poprawnych oraz niepoprawnych klasyfikacji opisany zależnością:

$$EFF_{NB} = \frac{P_{NB}}{P_{NB} + NP_{NB}} \cdot 100\%, \quad ERR_{NB} = 100\% - EFF_{NB} = \frac{NP_{NB}}{P_{NB} + NP_{NB}} \cdot 100\%. \quad (1)$$

Podobnie efektywność i błąd klasyfikacji dla przedsiębiorstw upadłych określa procent poprawnych klasyfikacji opisany zależnością:

$$EFF_B = \frac{P_B}{P_B + NP_B} \cdot 100\%, \quad ERR_B = 100\% - EFF_B = \frac{NP_B}{P_B + NP_B} \cdot 100\%. \quad (2)$$

Błąd ogólny ERR i efektywność ogólną klasyfikacji EFF dla danego modelu wyznacza się z analogicznych wzorów, na podstawie oceny poprawności klasyfikacji dla wszystkich przedsiębiorstw w próbie badawczej (zarówno upadłych, jak i zdrowych).

Iloraz szans służy do porównywania efektywności klasyfikacyjnej modeli (szczególnie modeli sieci neuronowych). Sprawność modelu wyrażona ilorazem szans określana jest jako iloraz liczby obiektów (przedsiębiorstw) poprawnie zakwalifikowanych do liczby obiektów w próbie badawczej niepoprawnie zakwalifikowanych:

$$IS = \frac{P_B \cdot P_{NB}}{NP_B \cdot NP_{NB}}. \quad (3)$$

Im wyższa wartość ilorazu szans, tym dany model należy uznać za lepszy pod względem praktycznych zastosowań. Wartości ilorazu szans większe od 1 oznaczają, że klasyfikacja na podstawie badanego modelu jest lepsza od zupełnie przypadkowej klasyfikacji.

4. Wykorzystanie sztucznej inteligencji do prognozowania upadłości polskich przedsiębiorstw

W celu zbadania możliwości wykorzystania sztucznych sieci neuronowych do prognozowania upadłości polskich przedsiębiorstw przeprowadzono badania empiryczne, których celem było zbadanie skuteczności i poprawności klasyfikacyjnej sieci neuronowych do identyfikacji przedsiębiorstw zagrożonych ryzykiem upadłości. Pobocznym celem badań było sprawdzenie hipotezy, że sieci neuronowe są często skuteczniejszym narzędziem do oceny upadłości niż klasyczne metody parametryczne: liniowa analiza dyskryminacyjna lub modele logitowe.

Badania empiryczne przebiegały następująco. Skuteczność sztucznych sieci neuronowych do przewidywania zagrożenia upadłością przedsiębiorstw zbadano na przykładzie 81 polskich przedsiębiorstw, które ogłosiły upadłość od 1 stycznia 2007 r. do 31 grudnia 2010 r. (dla których dostępne były pełne sprawozdania finansowe na jeden rok lub dwa lata przed okresem upadłości). Dla każdego analizowanego upadłego przedsiębiorstwa do badania wytypowano jedno lub dwa odpowiadające mu przedsiębiorstwa niezagrażone upadłością (zdrowe) i należące do tego samego sektora prowadzonej działalności (zgodnie z PKD). Kwalifikacja przedsiębiorstw do grupy przedsiębiorstw niezagrażonych upadłością (zdrowych) odbywała się na podstawie wnikliwej analizy i oceny wyznaczonych wartości wskaźników, określających ich kondycję finansową. Ostateczna grupa przedsiębiorstw zdrowych wytypowanych do badania obejmowała w sumie 126 przedsiębiorstwa należące do różnych branż i sektorów działalności. Łączna próba badawcza obejmowała zatem 81 przedsiębiorstw upadłych i 126 przedsiębiorstw zdrowych (łącznie 207 przypadków).

Badanie empiryczne skuteczności wykorzystania sieci neuronowych do prognozowania upadłości przedsiębiorstw przeprowadzono w czterech wariantach (wykorzystując różny zbiór zmiennych wejściowych). W wariacie pierwszym jako zmienne wejściowe wykorzystano pełny zestaw 26 wskaźników finansowych, których wartości obliczono na rok przed okresem upadłości. W drugim wariacie zbiór

zmiennych wejściowych stanowiło tylko 12 wybranych wskaźników: $X_1, X_3-X_7, X_9-X_{11}, X_{14}, X_{15}, X_{24}$, które były dostatecznie silnie skorelowane (korelacje istotne statystycznie) z dychotomiczną zmienną zależną Y , określającą, czy przedsiębiorstwo jest bankrutem, czy też nie ($Y = 1$ – przedsiębiorstwo upadłe, $Y = 0$ – przedsiębiorstwo zdrowe). W trzecim wariancie zbiór zmiennych wejściowych został zawężony tylko do 6 wskaźników: $X_1, X_5, X_6, X_{10}, X_{15}, X_{24}$, które były silnie skorelowane ze zmienną zależną Y oraz słabo skorelowane pomiędzy sobą. W ostatnim czwartym wariancie ograniczono się do podzbioru 3 zmiennych wejściowych: X_1, X_7, X_{15} , które były najczęściej wybierane jako istotne zmienne objaśniające w alternatywnych modelach parametrycznych: modelu logitowym oraz w modelu liniowej analizy dyskryminacyjnej.

Badanie skuteczności sztucznych sieci neuronowych w zagadnieniach klasyfikacyjnych przewidywania upadłości przedsiębiorstw przeprowadzono z wykorzystaniem modułu SANN (automatyczne sieci neuronowe) pakietu Statistica 8.0. Konstruowane sieci neuronowe były sieciami typu MLP (perceptron wielowarstwowy), posiadającymi tylko jedną warstwę neuronów ukrytych. Liczba neuronów w warstwie ukrytej była zmienna, zakres zmienności zależał od liczby zmiennych wejściowych w sieci, i zmieniała się w zakresie: 3-10 neuronów ukrytych (dla sieci z 3 zmiennymi), 3-20 neuronów ukrytych (dla sieci z 6 zmiennymi), 6-40 neuronów (dla sieci z 12 zmiennymi) oraz 10-50 neuronów ukrytych (dla sieci z 26 zmiennymi wejściowymi).

W procesie uczenia się tworzonych sieci neuronowych stosowano dwa warianty funkcji błędu: sumę kwadratów ERR_{SoS} oraz entropię wzajemną ERR_{CE} . Dla sieci z funkcją błędu w postaci sumy kwadratów jako funkcję aktywacji neuronów w warstwie ukrytej i wyjściowej stosowano jedną z czterech funkcji aktywacji: liniową, logistyczną, tangens hiperboliczny oraz wykładniczą. Dla sieci z funkcją błędu w postaci entropii wzajemnej jako funkcję aktywacji dla neuronów wyjściowych stosowano funkcję Softmax. Do uczenia sieci stosowano algorytm typu BFGS (Broyden-Fletcher-Goldfarb-Shanno).

W pierwszym etapie badań empirycznych nad skutecznością klasyfikacyjną sieci zastosowano wariant automatycznego poszukiwania najlepszych sieci. Podzbiór uczący (próba ucząca) dla każdej tworzonej i trenowanej sieci neuronowej (w danym wariancie zmiennych wejściowych) był analogiczny dla każdej sieci i obejmował losowo wybrany podzbiór 70% przedsiębiorstw. Próby walidacyjna i testowa były równoliczne i stanowiły po 15% (losowo wybranych) przedsiębiorstw. Wykorzystując kreator automatycznego poszukiwania najlepszych sieci, przeanalizowano 100 różnych wariantów sieci neuronowych typu MLP, z różną liczbą neuronów w warstwie ukrytej, o różnej postaci funkcji błędu oraz z różnymi funkcjami aktywacji neuronów. Do dalszej analizy wybrano z każdego wariantu po jednej najlepszej sieci, która ma najlepszą właściwość klasyfikacyjną (najmniejszy błąd klasyfikacji) dla próby walidacyjnej. Najlepsze sieci neuronowe uzyskane w każdym z wariantów zmiennych decyzyjnych przedstawia tab. 1.

Ponieważ próby uczące, testowe i walidacyjne wykorzystane do wstępnej selekcji sieci były identyczne dla danego zbioru zmiennych wejściowych, dlatego w drugim etapie zbadano skuteczność klasyfikacyjną sieci dla różnych wariantów prób uczących oraz testowych. W tym celu wylosowano 5 nowych prób, w których podzbiór uczący stanowiło 70% losowo wybranych przedsiębiorstw, a pozostałe 30% stanowiły próbę testową, i zbadano skuteczność klasyfikacyjną każdej sieci.

Tabela 1. Modele sieci neuronowych o najlepszych właściwościach klasyfikacyjnych uzyskane dla każdego wariantu zmiennych decyzyjnych

Typ sieci (id sieci)	Funkcja błędu uczenia	Funkcja aktywacji neuronów ukrytych	Funkcja aktywacji neuronów wyjściowych	Procent poprawnych klasyfikacji, próba ucząca (%)	Procent poprawnych klasyfikacji, próba testowa (%)	Procent poprawnych klasyfikacji, próba walidacyjna (%)
Wariant 1: 26 zmiennych w warstwie wejściowej (X_1 - X_{26})						
26-11-2 (1)	Entropia wzajemna ERR_{CE}	Wykładnicza	Softmax	84,1	80,6	83,9
Wariant 2: 12 zmiennych w warstwie wejściowej ($X_1, X_3, X_7, X_9, X_{11}, X_{14}, X_{15}, X_{24}$)						
12-12-2 (2)	Entropia wzajemna ERR_{CE}	Tanh	Softmax	92,4	83,9	87,1
Wariant 3: 6 zmiennych w warstwie wejściowej ($X_1, X_5, X_6, X_{10}, X_{15}, X_{24}$)						
6-3-2 (3)	Suma kwadratów ERR_{SOS}	Wykładnicza	Tanh	83,4	93,5	80,6
Wariant 4: 3 zmienne w warstwie wejściowej (X_1, X_7, X_{15})						
3-5-2 (4)	Entropia wzajemna ERR_{CE}	Liniowa	Softmax	82,1	77,4	83,9

Źródło: opracowanie własne.

Dla porównania skuteczności uzyskanych prognoz oszacowano w każdym wariantcie zmiennych wejściowych i dla każdej z 5 prób również alternatywne modele parametryczne: logitowy oraz liniowej analizy dyskryminacyjnej (LDA). Uzyskane oszacowania modeli oraz walidację jakości klasyfikacyjnej badanych modeli przedstawia tab. 2.

Dla pierwszej próby testowej spośród 4 badanych wariantów sieci neuronowych najlepsze właściwości klasyfikacyjne ma sieć 3, dla której iloraz szans jest bardzo duży i wynosi 113. Sieć ta ma wysokie wartości współczynnika poprawnych klasyfikacji zarówno dla przedsiębiorstw upadłych (85%), jak i dla przedsiębiorstw zdrowych (95%). Dobrymi własnościami klasyfikacyjnymi charakteryzują się także badana sieć 1 i 2 (o wartościach ilorazu szans odpowiednio 66 i 52). Najgorsze właściwości klasyfikacyjne z badanych sieci dla tej próby ma sieć 4, w porównaniu

Tabela 2. Efektywność klasyfikacyjna badanych modeli sieci neuronowych względem modeli parametrycznych dla 5 badanych prób testowych

	Badana sieć neuronowa (id sieci)				Model logitowy	Model liniowej analizy dyskryminacyjnej
	1	2	3	4		
Próba testowa 1						
Liczba poprawnych i błędnych klasyfikacji	P _{NB} =37 P _B =18 NP _{NB} =5 NP _B =2	P _{NB} =39 P _B =16 NP _{NB} =3 NP _B =4	P _{NB} =40 P _B =17 NP _{NB} =2 NP _B =3	P _{NB} =36 P _B =17 NP _{NB} =6 NP _B =3	$P(Y=1) = \frac{e^{2,27+2,3X_1-0,77X_{15}}}{1 + e^{2,27+2,3X_1-0,77X_{15}}}$	Funkcje klasyfikacyjne: B: $-1,53 + 0,29X_1 + 0,91X_{14} - 0,66X_{15}$ NB: $-1,49 + 0,67X_1 + 0,36X_{14} + 0,29X_{15}$
EFF (%)	88,7	88,7	91,9	85,5	80,6	87,1
Iloraz szans	66,6	52	113,3	34	28,8	41,9
Próba testowa 2						
Liczba poprawnych i błędnych klasyfikacji	P _{NB} =38 P _B =12 NP _{NB} =4 NP _B =8	P _{NB} =39 P _B =16 NP _{NB} =3 NP _B =4	P _{NB} =40 P _B =17 NP _{NB} =2 NP _B =3	P _{NB} =38 P _B =16 NP _{NB} =4 NP _B =4	$P(Y=1) = \frac{e^{1,69+2,02X_1-3,32X_7}}{1 + e^{1,69+2,02X_1-3,32X_7}}$	Funkcje klasyfikacyjne: B: $-1,69 + 0,26X_1 - 0,24X_6 - 1,11X_6 + 0,84X_{14}$ NB: $-1,41 + 0,56X_1 - 0,02X_6 + 0,13X_6 + 0,35X_{14}$
EFF (%)	80,6	88,7	91,9	87,1	87,1	87,1
Iloraz szans	14,2	52	113,3	38	39	46,6
Próba testowa 3						
Liczba poprawnych i błędnych klasyfikacji	P _{NB} =25 P _B =23 NP _{NB} =5 NP _B =9	P _{NB} =27 P _B =23 NP _{NB} =3 NP _B =9	P _{NB} =27 P _B =20 NP _{NB} =3 NP _B =12	P _{NB} =26 P _B =22 NP _{NB} =4 NP _B =10	$P(Y=1) = \frac{e^{2,16-2,66X_1-3,48X_{11}-6,49X_7}}{1 + e^{2,16-2,66X_1-3,48X_{11}-6,49X_7}}$	Funkcje klasyfikacyjne: B: $-1,66 + 1,69X_1 - 1,86X_{11} - 2,45X_7$ NB: $-2,88 + 3,16X_1 - 3,13X_{11} - 0,63X_7$
EFF (%)	77,4	80,6	75,8	77,4	77,4	79
Iloraz szans	12,8	23	15	14,3	17,2	16,6

		Próba testowa 4				Oszacowany model	Funkcje klasyfikacyjne:
Liczba poprawnych i błędnych klasyfikacji	$P_{NB}=31$ $P_B=20$ $NP_{NB}=2$ $NP_B=9$	$P_{NB}=32$ $P_B=20$ $NP_{NB}=1$ $NP_B=9$	$P_{NB}=32$ $P_B=19$ $NP_{NB}=1$ $NP_B=10$	$P_{NB}=32$ $P_B=19$ $NP_{NB}=1$ $NP_B=10$	$P_{NB}=32$ $P_B=20$ $NP_{NB}=1$ $NP_B=9$	$\frac{e^{-0,95-1,07X_1-3,01X_2+2,4X_3+2,4X_4}}{1+e^{-0,95-1,07X_1-3,01X_2+2,4X_3+2,4X_4}}$	B: $-1,36+0,47X_1-2,03X_2$ NB: $-1,66+1,01X_1-0,19X_2$
EFF (%)	82,3	83,9	82,2	82,2	83,9	83,9	$P_{NB}=32$ $P_B=20$ $NP_{NB}=1$ $NP_B=9$
Iloraz szans	34,4	71,1	60,8	60,8	71,1	71,1	
		Próba testowa 5				Oszacowany model	Funkcje klasyfikacyjne:
Liczba poprawnych i błędnych klasyfikacji	$P_{NB}=30$ $P_B=19$ $NP_{NB}=7$ $NP_B=6$	$P_{NB}=34$ $P_B=19$ $NP_{NB}=3$ $NP_B=6$	$P_{NB}=34$ $P_B=18$ $NP_{NB}=3$ $NP_B=7$	$P_{NB}=32$ $P_B=17$ $NP_{NB}=5$ $NP_B=8$	$P_{NB}=30$ $P_B=19$ $NP_{NB}=7$ $NP_B=6$	$\frac{e^{1,71-1,19X_1-1,57X_2-2,96X_3+2,96X_4}}{1+e^{1,71-1,19X_1-1,57X_2-2,96X_3+2,96X_4}}$	B: $-1,11+0,21X_1-0,47X_2-0,68X_3-0,26X_4$ NB: $-1,33+0,47X_1-0,06X_2+0,32X_3+0,22X_4$
EFF (%)	79	85,5	83,9	79	79	77,4	$P_{NB}=29$ $P_B=19$ $NP_{NB}=8$ $NP_B=6$
Iloraz szans	13,6	35,9	29,1	13,6	13,6	11,5	

Źródło: opracowanie własne.

z którą lepsze wyniki uzyskuje się z wykorzystaniem modelu analizy dyskryminacyjnej. Najgorsze wyniki z wszystkich analizowanych modeli ma model logitowy (z racji małej poprawności klasyfikacyjnej przedsiębiorstw zdrowych, wynoszącej tylko 76%).

W przypadku drugiej próby testowej również najlepsze wyniki ma 3 analizowana sieć neuronowa, dla której ogólna efektywność wynosi 92% (dla przedsiębiorstw upadłych i zdrowych odpowiednio 85 i 95%), a iloraz szans 113. Najgorsze wyniki ma 1 sieć (z racji małego odsetka poprawnych klasyfikacji dla przedsiębiorstw upadłych, wynoszącego tylko 60%).

Tylko 1 i 4 z badanych sieci neuronowych posiadała wyniki zbliżone do wyników dla modeli parametrycznych lub gorsze od nich. Dla trzeciej próby testowej jakość wszystkich badanych modeli znacznie spadła.

Najlepsze wyniki ma 2 sieć neuronowa (iloraz szans wynosi 23, a poprawność klasyfikacji na poziomie 72 i 90%, odpowiednio dla przedsiębiorstw upadłych i zdrowych). Dla tej próby modele parametryczne dają lepsze klasyfikacje od pozostałych analizowanych sieci neuronowych (1, 3 i 4), z których najgorsze wyniki miała sieć 1 (iloraz szans tylko 13, a procent poprawnych klasyfikacji – 71,9% dla bankrutów i 83,3% dla przedsiębiorstw zdrowych). W przypadku czwartej próby testowej modele parametryczne mają jedne z najlepszych właściwości klasyfikacyjnych i uzyskują wyniki analogiczne jak najlepsza 2 sieć neuronowa, mająca iloraz szans 71, a ogólny odsetek poprawnych klasyfikacji na poziomie 84% (69% dla bankrutów i 97% dla przedsiębiorstw niezagrożonych upadłością). Dla ostatniej piątej próby znowu najlepsze właściwości klasyfikacyjne ma 2 sieć neuronowa (iloraz szans 36, poprawność klasyfikacyjna dla bankrutów 76 i 92% dla przedsiębiorstw niezagrożonych). W tym przypadku modele parametryczne uzyskują gorsze wyniki praktycznie od wszystkich analizowanych sieci neuronowych.

Z analizy wyników poprawności klasyfikacyjnej badanych sieci neuronowych uzyskanych dla wszystkich prób testowych wynika, że najlepszymi modelami sieci neuronowej są sieci typu perceptron wielowarstwowy MLP w wariacie z 12 zmiennymi wejściowymi o architekturze sieci: 12-12-2 (CE, Tanh, Softmax). Nie wiele gorsze wyniki klasyfikacyjne uzyskuje się, wykorzystując sieć z 6 wybranymi wskaźnikami finansowymi jako zmienne wejściowe o architekturze sieci: 6-3-2 (SoS, Wykładnicza, Tanh).

5. Podsumowanie

Analiza empiryczna skuteczności klasyfikacyjnych sieci neuronowych w zagadnieniach przewidywania zagrożenia upadłością, przeprowadzona na próbie 207 wybranych polskich przedsiębiorstw (81 upadłych oraz 126 niezagrożonych upadłością), pokazuje, że modele sztucznych sieci neuronowych są skutecznym narzędziem wczesnego przewidywania upadłości przedsiębiorstw. Wyniki badania empirycznego pozwalają na sformułowanie kilku ważnych wniosków praktycznych:

- Jakość (poprawność) klasyfikacyjna sieci neuronowych dla każdej z pięciu losowo wybranych prób testowych była lepsza od wyników uzyskiwanych z zastosowaniem modeli parametrycznych. Tylko dla 4 próby testowej jakość klasyfikacyjna modeli parametrycznych okazała się porównywalna z wynikami uzyskanymi przez najlepszą sieć neuronową 12-12-2 (CE-Tanh-Softmax).
- Poprawność klasyfikacyjna sieci neuronowych istotnie zależy od przyjętych zmiennych diagnostycznych w warstwie wejściowej. Dla każdej próby testowej najlepsze wyniki uzyskiwano z wykorzystaniem sieci neuronowych: 12-12-2 i 6-3-2. Poprawnie skonstruowany zbiór czynników wejściowych wpływa bardzo istotnie na jakość klasyfikacji uzyskiwanych z zastosowaniem sieci neuronowych.
- Uzyskane wyniki potwierdzają wcześniejsze badania innych autorów (zob. punkt 2 – analiza literatury), że sieci neuronowe mają w większości wypadków lepszą efektywność klasyfikacyjną niż alternatywne modele parametryczne: logitowy i liniowej analizy dyskryminacyjnej. Są przy tym znacznie prostsze w użyciu, gdyż nie wymagają spełnienia aż tylu, często restrykcyjnych założeń, jak chociażby modele analizy dyskryminacyjnej. Łatwość zastosowania sprzyja również dostępność do coraz większej liczby, często darmowych pakietów analiz neuronowych.
- Poprawnie skonstruowane modele sztucznych sieci neuronowych są interesującą alternatywą dla modeli parametrycznych w zagadnieniach przewidywania zagrożenia upadłością przedsiębiorstw.
- Należy podkreślić, że sieci neuronowe mogą być również z powodzeniem wykorzystywane do prognoz *ex ante*. Moduł NN pakietu Statistica oferuje taką możliwość. Można z niej skorzystać w oknie dialogowym z wytrenowanymi sieciami, wybierając opcję predykcja i wprowadzając odpowiednie wartości wskaźników finansowych dla zmiennych wejściowych, np. dla przedsiębiorstwa, które nie należało ani do próby uczącej, ani do próby walidacyjnej.

Załącznik

Wykaz pierwotnie wytypowanych wskaźników finansowych wykorzystywanych jako zmienne wejściowe w analizowanych sieciach neuronowych:

- Wskaźniki płynności (wskaźniki opisujące płynność finansową badanych przedsiębiorstw):
 X_1 – płynności bieżącej: Aktywa obrotowe / Zobowiązania krótkoterminowe),
 X_2 – płynności szybkiej: (Aktywa obrotowe – Krótkoterminowe rozliczenia międzyokresowe – Zapasy) / Zobowiązania krótkoterminowe, X_3 – płynności KO/SB: (Aktywa obrotowe – Krótkoterminowe rozliczenia międzyokresowe – Zobowiązania krótkoterminowe) / Suma bilansowa, X_4 – natychmiastowej wymagalności: (Aktywa obrotowe – Zapasy – Należności krótkoterminowe) / Zobowiązania krótkoterminowe.
- Wskaźniki rentowności (zyskowności) – wskaźniki określające zdolność przedsiębiorstw do generowania zysku:
 X_5 – zyskowności: Zysk z działalności operacyjnej / Przychody netto ze sprzedaży, X_6 – rentowności: Zysk netto / (Kapitał własny – Zysk netto), X_7 – rentowności aktywów (ROA)[%]: Zysk netto / Suma bilansowa $\times 100\%$, X_8 – rentowności kapitału własnego (ROE)[%]: Zysk netto / Kapitał własny $\times 100\%$, X_9 – rentowności sprzedaży (brutto)[%]: Zysk brutto / Przychody netto ze sprzedaży $\times 100\%$, X_{10} – rentowności sprzedaży (netto)[%]: Zysk netto / Przychody netto ze sprzedaży $\times 100\%$.
- Wskaźniki zadłużenia (wyplącalności) – wskaźniki opisujące zadłużenie badanych przedsiębiorstw:
 X_{11} – ogólnego zadłużenia: (Zobowiązania krótkoterminowe + Zobowiązania długoterminowe) / Suma bilansowa, X_{12} – zadłużenia kapitałów własnych: Zobowiązania ogółem / Kapitał własny, X_{13} – zadłużenia: (Kapitał własny + Zobowiązania długoterminowe) / Aktywa trwałe, X_{14} – zadłużenia aktywów: Zobowiązania krótkoterminowe / Suma bilansowa, X_{15} – zadłużenia: Zysk brutto / Zobowiązania krótkoterminowe, X_{16} – zadłużenia: (Zysk netto + Amortyzacja) / Zobowiązania ogółem, X_{17} – zadłużenia długoterminowego: Zobowiązania długoterminowe / Kapitał własny.
- Wskaźniki sprawności (efektywności) – opisujące efektywność zarządzania oraz sprawność działania przedsiębiorstw:
 X_{18} – rotacji należności: Przychody netto ze sprzedaży / Należności krótkoterminowe, X_{19} – Przychody netto ze sprzedaży / Suma bilansowa, X_{20} – Koszty operacyjne (bez pozostałych kosztów operacyjnych) / Zapasy, X_{21} – rotacji aktywów trwałych: Przychody netto ze sprzedaży / Aktywa trwałe, X_{22} – rotacji zapasów: Przychody netto ze sprzedaży / Zapasy, X_{23} – Cykl środków pieniężnych: Należności krótkoterminowe / Przychody netto ze sprzedaży $\times 365$ + Zapasy/Koszty operacyjne $\times 365$ – Wartość średnia zobowiązań krótkoterminowych (bez funduszy specjalnych i krótkoterminowych zobowiązań finansowych) / Koszty operacyjne (bez pozostałych kosztów operacyjnych) $\times 365$.

- Pozostałe wskaźniki finansowe charakteryzujące strukturę kapitałowo-majątkową przedsiębiorstw:
 X_{24} – Kapitał własny / Suma bilansowa, X_{25} – Aktywa trwałe (bez długoterminowych rozliczeń międzyokresowych) / Suma bilansowa, X_{26} – Aktywa trwałe / Aktywa obrotowe.

Literatura

- Altman E.I., *Financial ratios, discriminant analysis and the prediction of corporate bankruptcy*, "Journal of Finance" 1968, no 23.
- Altman E.I., Haldeman R.C., Narayanan P., *ZETA analysis: A new model to identify bankruptcy risk of corporations*, "Journal of Banking and Finance" 1977, no 1.
- Aziz M.A., Dar H.A., *Predicting corporate bankruptcy: Where we stand?*, "Corporate Governance" 2006, no 6 (1).
- Beaver W.H., *Financial ratios as predictors of failure*, "Journal of Accounting Research" 1966, no 4.
- Bednarski L., *Analiza finansowa w przedsiębiorstwie*, Polskie Wydawnictwo Ekonomiczne, Warszawa 2001.
- Beynon M.J., Peel M.J., *Variable precision rough set theory and data discretisation: an application to corporate failure prediction*, "Omega" 2001, no 29.
- Booth P.J., *Decomposition measure and the prediction of financial failure*, "Journal of Business Finance & Accounting" 1983, no 10 (1).
- Gajdka J., Stos D., *Wykorzystanie analizy dyskryminacyjnej do badania podatności przedsiębiorstwa na bankructwo*, [w:] *Przedsiębiorstwo na rynku kapitałowym*, red. R. Borowiecki, Wydawnictwo AE, Kraków 1996.
- Hadasik D., *Upadłość przedsiębiorstw w Polsce i metody jej prognozowania*, Prace Naukowe Akademii Ekonomicznej nr 153, Wydawnictwo AE, Poznań 1998.
- Jardin P., *Predicting bankruptcy using neural networks and other classification methods: The influence of variable selection techniques on model accuracy*, "Neurocomputing" 2010, no 73.
- Korol T., Prusak B., *Upadłość przedsiębiorstw a wykorzystanie sztucznej inteligencji*, Wydawnictwo CeDeWu, Warszawa 2009.
- Ohlson J., *Financial ratios and the probabilistic prediction of bankruptcy*, "Journal of Accounting Research" 1980, no 18.
- Pogodzińska M., Sojak S., *Wykorzystanie analizy dyskryminacyjnej w przewidywaniu bankructwa przedsiębiorstw*, [w:] *AUNC, Ekonomia XXV*, Toruń 1995.
- Prusak B., *Nowoczesne metody prognozowania zagrożenia finansowego przedsiębiorstw*, Difin, Warszawa 2005.
- Shin K., Lee Y., *A genetic algorithm application in bankruptcy prediction modelling*, "Expert Systems With Applications" 2002, no 23 (3).
- Skogsvik K., *Current cost accounting ratios as predictors of business failure: the Swedish case*, "Journal of Business Finance and Accounting" 1990, no 17(1).
- Stone M., Rasp J., *Tradeoffs in the choice between logit and OLS for accounting choice studies*, "The Accounting Review" 1991, no 66 (1).
- Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa 1993.
- Tadeusiewicz R., *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*, Wydawnictwo PLJ, Warszawa 1998.
- Theodossiou P.T., *Alternative models for assessing the financial condition of business in Greece*, "Journal of Business Finance and Accounting" 1991, no 18(5).

- Wilcox J., *A prediction of business failure using accounting data*, "Journal of Accounting Research: Supplement on Empirical Research in Accounting" 1973.
- Witkowska D., *Sztuczne sieci neuronowe i metody statystyczne*, Wydawnictwo C.H. Beck, Warszawa 2002.
- Żmijewski M.E., *Methodological issues related to the estimation of financial distress prediction models*, "Journal of Accounting Research" 1984, no 22.

APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR FORECASTING CORPORATE BANKRUPTCY

Summary: In today's deepening economic crisis there are a lot of companies at risk of bankruptcy. Effective prediction of bankruptcy is one of the most important risk management issues. In recent years, because of greater availability of specialized software packages on the market, the models of artificial intelligence to predict the bankruptcy of companies have been extensively used. The article presents the possibility of using artificial neural networks for the classification of businesses at risk of bankruptcy. On the basis of the research sample of 207 Polish companies which declared bankruptcy in the period from January 2007 to December 2010 there was conducted the sector analysis of bankruptcy as well as there were carried out the empirical studies which compared the efficiency of neural models in relation to the classical parametric models (logit and discriminant analysis).

Keywords: bankruptcy prediction, neural networks, logit model, discriminant analysis.