

Dr inż. Tomasz Korol

Wydział Zarządzania i Ekonomii
Politechnika Gdańska

Prognozowanie upadłości firm przy wykorzystaniu miękkich technik obliczeniowych

Wstęp

Artykuł ten poświęcony jest zagadnieniu prognozowania zagrożenia upadłością firm. Obecny globalny kryzys finansowy dowiódł, że nawet najlepsze międzynarodowe koncerny powinny nieustannie monitorować sytuację finansową swoją i firm, z którymi współpracują. Proces globalizacji doprowadził do powstania skomplikowanej sieci zależności w otoczeniu przedsiębiorstw. W warunkach gospodarki rynkowej oznacza to wzrost złożoności i niepewności zjawisk wpływających na kondycję finansowo-ekonomiczną jednostek gospodarczych. Żadne przedsiębiorstwo, nawet w okresie prosperity, nie może być pewne swojej przyszłości. Globalny kryzys finansowy, który rozpoczął się w drugiej połowie 2008 r., spowodował, iż liczba zagrożonych podmiotów gospodarczych na świecie znacząco wzrosła. Według danych statystycznych międzynarodowej firmy Euler Hermes liczba zagrożonych upadłością firm w USA wzrosła o 54%, w Hiszpanii aż o 118%, a w Wielkiej Brytanii o 56%¹. Obecny światowy kryzys finansowy spowodował, że również i w Polsce liczba upadłości znacząco wzrosła. Według szacunków firmy Euler Hermes w 2009 r. w Polsce nastąpił wzrost liczby upadłych firm o 55%². Natomiast według czasopisma „Puls Biznesu”, ze względu na to, iż w postępowanie upadłościowe w naszym kraju zajmuje nawet trzy lata, prawdziwa fala bankructw dotknie Polskę dopiero w 2010 r. Przewidują oni nawet trzykrotny wzrost liczby upadłości w 2010 r. w porównaniu z rokiem 2009³. Ogólny wzrost zagrożenia upadłością firm na świecie spowodował wzrost świadomości menedżerów firm konieczności implementacji metod wczesnego ostrzegania firmy przed ryzykiem bankructwa.

W obecnej sytuacji, kiedy firmy działają w niesłychanie dynamicznym otoczeniu charakteryzującym się olbrzymią złożonością i niepewnością zjawisk, kluczowym zagadnieniem jest ustalanie obszarów występowania ryzyka, bieżąca kontrola sytuacji ekonomiczno-finansowej oraz skuteczne prognozowanie zagrożeń upadłością, aby z wyprzedzeniem na nie reagować. Stąd też dzisiaj analitycy już nie stoją przed dylematem, czy prognozować ewentualne zagrożenie upadłością firm, lecz jaką metodę wykorzystać do oceny sytuacji finansowej, aby zminimalizować błąd prognozy. Celem tego artykułu jest weryfikacja przydatności wybranych metod miękkich technik obliczeniowych w prognozowaniu upadłości firm na przykładzie spółek notowanych na Giełdzie Papierów Wartościowych w Warszawie.

Metody prognozowania upadłości przedsiębiorstw

To, czy dane przedsiębiorstwo będzie w stanie regulować swoje zobowiązania finansowe, a więc czy przetrwa na rynku, jest przedmiotem zainteresowania wielu podmiotów rynkowych, a w szczegól-

¹ www.eulerhermes.pl/pl/pl/media/0907_eh_upadlosci_swiat.pdf/0907_eh_upadlosci_swiat.pdf.

² *Bankructwa firm – problem polskiej gospodarki*, www.eulerhermes.pl/pl/pl/dokumenty/091021_eh_upadl_iiikw09.pdf/091021_eh_upadl_iiikw09.pdf.

³ *Bankructw będzie trzy razy więcej*, 31.12.2009, http://www.pb.pl/2/a/2009/12/31/Plajt_będzie_trzy_razy_wiecej.

ności dostawców, kredytodawców oraz właścicieli. Ze względu na pracochłonność pełnej analizy kondycji finansowej przedsiębiorstwa usiłowano opracować metody umożliwiające postawienie natychmiastowej i pewnej diagnozy dotyczącej sytuacji finansowej firmy, oparte na możliwie najmniejszej liczbie parametrów. Tego rodzaju potrzeba była przyczyną powstania modeli prognozowania upadłości. W literaturze zachodniej modele te pokategoryzowane są na dwie główne grupy: modele grupy metod statystycznych oraz modele metod miękkich technik obliczeniowych, które wchodzą w skład odrębnej gałęzi nauki określanej angielskim terminem *computational intelligence*, co można przetłumaczyć jako inteligencja obliczeniowa (pod tym terminem rozumiane jest rozwiązywanie różnych problemów przy pomocy sztucznej inteligencji z wykorzystaniem komputerów wykonujących obliczenia numeryczne). Badania M. Aziza i H. Dara⁴ nad częstością wykorzystania poszczególnych metod w prognozowaniu upadłości przedsiębiorstw na całym świecie wykazały, że w 64% przypadków badań do prognozowania zagrożenia bankrutem firm wykorzystano metody statystyczne, w 25% badań – metody miękkich technik obliczeniowych i w 11% przypadków wykorzystano innego rodzaju modele⁵. Wśród metod statystycznych najpopularniejszą metodą jest metoda wielowymiarowej analizy dyskryminacyjnej, natomiast w grupie miękkich technik obliczeniowych najczęściej wykorzystywana jest metoda sztucznych sieci neuronowych.

Autor tego artykułu we wcześniejszych swoich badaniach wykazał, że sztuczne sieci neuronowe charakteryzują się lepszymi wynikami w ocenie zagrożenia przedsiębiorstw upadłością niż tradycyjna analiza dyskryminacyjna⁶, dlatego też w artykule tym skupiono się na weryfikacji skuteczności wybranych metod miękkich technik obliczeniowych.

W przeciwieństwie do modeli metod statystycznych metody miękkich technik obliczeniowych efektywnie radzą sobie z nieprecyzyjnie zdefiniowanymi problemami, niepełnymi danymi, niedokładnością, brakiem precyzji i niepewnością. Zagadnienie prognozowania upadłości firm posiada wszystkie z wyżej wymienionych cech. Dodatkowo, metody te doskonale nadają się do zastosowania w systemach, których zadaniem jest dopasowanie pewnych wewnętrznych parametrów do zmiennych warunków otoczenia w sposób dynamiczny (tzw. systemy uczące się). Miękkie techniki obliczeniowe obejmują zestaw technik, których działanie ukierunkowane jest na to, aby możliwe było efektywne wnioskowanie na podstawie nieprecyzyjnych przesłanek – techniki te naśladują tym samym działanie ludzkiego mózgu. Różnica pomiędzy tradycyjnymi metodami obliczeniowymi a metodami „miękkimi” polega na odniesieniu do zagadnień takich, jak precyzja, pewność i dokładność. Elementy te są podstawą metod statystycznych, podczas gdy punktem wyjścia dla np. logiki rozmytej jest teza, że precyzja i pewność niosą ze sobą koszty, a obliczenia, wnioskowanie i podejmowanie decyzji powinny wykorzystywać tolerancję dla niedokładności i niepewności, gdziekolwiek tylko jest to możliwe. Miękkie techniki obliczeniowe, w przeciwieństwie do metod statystycznych, tolerują zatem niedokładność danych, niepewność i aproksymację. Istotą systemów opartych na inteligencji obliczeniowej jest przetwarzanie i interpretacja danych o bardzo różnorodnym charakterze. Ich wspólną cechą jest to, że przetwarzają one informacje w przypadkach trudnych do przedstawienia w postaci algorytmów i czynią to w powiązaniu z symboliczną reprezentacją wiedzy. Mogą to być relacje dotyczące jakiegoś obiektu znanego tylko na podstawie skończonej liczby pomiarów stanu wyjścia i wejścia. Mogą to być również dane wiążące najbardziej prawdopodobną diagnozę z szeregiem zaobserwowanych symptomów w ciągach uczących. Potrafią formułować reguły wnioskowania i generalizować wiedzę o sytuacjach, kiedy oczekuje się od nich predykcji bądź zaklasyfikowania obiektu do jednej z zaobserwowanych wcześniej kategorii⁷.

⁴ M. Aziz, H. Dar, *Predicting corporate bankruptcy – where we stand?* „Corporate Governance Journal” 2006, vol. 6, nr 1, s. 18–33.

⁵ Wyniki badań M. Aziza i H. Dara nad częstością wykorzystania poszczególnych metod w prognozowaniu upadłości firm, są zbliżone z wynikami badań literaturowych przeprowadzonych przez autora tego artykułu (autor przestudiował przeszło 400 różnych badań przeprowadzonych na świecie w latach 1960–2008).

⁶ Więcej na temat tych badań: T. Korol, *Modele prognozowania upadłości przedsiębiorstw – analiza porównawcza wyników sztucznych sieci neuronowych z tradycyjną analizą dyskryminacyjną*, „Gospodarka w Praktyce i Teorii” 2005, nr 2(17).

⁷ L. Rutkowski, *Metody i techniki sztucznej inteligencji*, PWN, Warszawa 2005, s. 10.

Do badań autor wybrał następujące metody miękkich technik obliczeniowych: rekurencyjną sztuczną sieć neuronową (SSN REC), jednokierunkową wielowarstwową sztuczną sieć neuronową (SSN MLP), sztuczną sieć neuronową opartą na algorytmach genetycznych (SSN GA), sztuczną sieć neuronową o radialnych funkcjach bazowych (SSN RBF), mapę samoorganizującą się (SOM), model wektorów nośnych (SVM) oraz model logiki rozmytej (FL). Należy zaznaczyć, iż jest to pierwsza próba weryfikacji skuteczności tak szerokiego wachlarza metod miękkich technik obliczeniowych w prognozowaniu upadłości firm w Polsce.

Założenia do badań

W badaniach autor wykorzystał dane dotyczące 185 spółek akcyjnych notowanych na Giełdzie Papierów Wartościowych w Warszawie w latach 2000–2005 (wyjątek stanowiły 2 spółki z roku 2007). Spółki te były firmami z sektora usług i produkcji. W badaniach pominięto przedsiębiorstwa z sektora finansowego (banki i firmy ubezpieczeniowe) ze względu na zbyt odmienną charakterystykę tego typu spółek. Warto przy tym nadmienić, iż opracowana populacja przedsiębiorstw stanowiła praktycznie w całości populację spółek produkcyjnych i usługowych notowanych na WGPW w analizowanym okresie. Dlatego też, z jednej strony, nie było możliwości zwiększenia populacji firm objętych badaniami, z drugiej zaś, zapewniło to odpowiednią reprezentatywność opracowanej populacji firm. W ramach tej populacji przedsiębiorstw wyodrębniono:

- próbę uczącą – składającą się z 53 firm. Przy czym, 25 z nich były to spółki zagrożone bankructwem, tj. złożono wobec nich wnioski o upadłość lub zarząd danej spółki rozważał taką możliwość w obliczu trudnej sytuacji finansowej firmy (5 w 2000 r., 16 w 2001 r., 3 w 2002 r., a 1 w 2005 r.). Pozostałe 28 spółek były to firmy o dobrej kondycji finansowo-ekonomicznej. Badane 53 spółki pochodziły z różnych sektorów, takich jak: budownictwo, przemysł metalowy, spożywczy, chemiczny, telekomunikacyjny. Należy zaznaczyć, że zostały one w miarę możliwości dobrane parami, tj. potencjalnemu bankrutowi przypisano przedsiębiorstwo „zdrowe” z tej samej branży oraz o podobnej wielkości sumy bilansowej. Dla celów badawczych opracowano daną próbę uczącą z danymi – na rok, na dwa i na trzy lata przed postawieniem spółki w stan upadłości;
- próbę testową „jeden” – składającą się z 54 firm: 25 spółek zagrożonych upadłością (2 wnioski o upadłość złożono w 2001 r., 18 w 2002 r., 1 w 2004 r., 2 w 2005 r., a 2 w 2007 r.) oraz 29 firm „zdrowych”. W celu sprawdzenia skuteczności w prognozowaniu upadłości spółek giełdowych opracowanych modeli w oparciu o próbę uczącą przygotowano tą próbę testową z danymi – na rok, na dwa i na trzy lata przed postawieniem spółki w stan upadłości, przy czym próba ta składała się z firm, które nie wchodziły w skład próby uczącej system.
- próbę testową „dwa” – w skład której weszły wszystkie spółki z próby testowej „jeden” oraz dodatkowo 78 firm niezagrażonych upadłością. Taki zabieg pozwolił autorowi na przetestowanie poszczególnych modeli, które zostały opracowane na podstawie próby uczącej z proporcją bankrutów (25 spółek) do niebankrutów (28 spółek) zbliżoną do stosunku 50%/50%, w warunkach zbliżonych do rzeczywistych, tj. przy proporcji bankrutów (25 firm) do niebankrutów (107 firm) 18,9%/81,1%. Dzięki temu próba testowa „dwa” umożliwi weryfikację walorów predykcyjnych modeli wczesnego ostrzegania firm na rok, na dwa i na trzy lata, nie tylko w sztucznych warunkach utrzymania proporcji „złych” i „zdrowych” firm 50%/50%.

Autor w swoich badaniach wykorzystał 14 wskaźników jako niezależne zmienne wejściowe modeli, o wyborze których zdecydowały:

- względy merytoryczne – starano się dobrać te wskaźniki, których przydatność do prognozowania upadłości przedsiębiorstw wykazały dziesięcioletnie badania autora tego artykułu nad prognozowaniem tego zjawiska,
- względy praktyczne – dostępność odpowiednich danych statystycznych.

Tab. 1. Wskaźniki finansowo-ekonomiczne wykorzystane w badaniach

Symbol wskaźnika	Rodzaj wskaźnika oraz sposób jego obliczania
WSKAŹNIKI RENTOWNOŚCI	
ZS / SB = X1	zysk ze sprzedaży / wartość sumy bilansowej
ZO / PS = X2	zysk z działalności operacyjnej / przychody netto ze sprzedaży
WSKAŹNIKI PŁYNNOŚCI FINANSOWEJ	
AO / ZK = X3	aktywa obrotowe (bez krótkoterminowych rozliczeń m/o) / zobowiązania krótkoterminowe
(AO - Z) / ZK = X4	[aktywa obrotowe (bez krótkoterminowych rozliczeń m/o) - zapasy] / zobowiązania krótkoterminowe
KP / SB = X5	kapitał obrotowy / suma bilansowa
WSKAŹNIKI ZADŁUŻENIA	
ZK / SB = X6	zobowiązania krótkoterminowe / suma bilansowa
KW / ZOB = X7	kapitał własny / zobowiązania ogółem
(ZN + A) / ZOB = X8	(zysk netto + amortyzacja) / zobowiązania ogółem
ZB / ZK = X10	zysk brutto / zobowiązania krótkoterminowe
(KW+ZD.DL) / AT = X11	(kapitał własny + zobowiązania długoterminowe) / aktywa trwałe
WSKAŹNIK SPRAWNOŚCI	
KO / ZK = X9	koszty operacyjne (bez pozostałych kosztów operacyjnych) / wartość zobowiązań krótkoterminowych
PS / SB = X12	przychody ze sprzedaży / suma bilansowa
PS / N = X13	przychody ze sprzedaży / należności krótkoterminowe
INNE MIERNIKI FINANSOWE	
Log SB = X14	logarytm dziesiętny z aktywów ogółem

Źródło: Opracowanie własne

Dodatkowo dla każdego wskaźnika finansowego (tab. 1) policzono tempo zmiany wartości dla wszystkich analizowanych lat, czyli tempo zmiany między: pierwszym a drugim, drugim a trzecim oraz trzecim a czwartym rokiem przed upadłością.

Ponadto każde przedsiębiorstwo zostało opisane zero-jedynkową zmienną wyjściową – zmienną grupującą populację na dwie grupy przedsiębiorstw – na zagrożone (wartość zmiennej = zero) i niezagrożone upadłością (wartość zmiennej = jeden).

Jakość klasyfikacji modeli wczesnego ostrzegania oceniono na podstawie skuteczności ogólnej, a także błędów I i II rodzaju. I tak, 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 – $S = \{1 - [(D_1 + D_2) / (BR + NBR)]\} \cdot 100\%$.

Modele prognozowania upadłości firm

Autor opracował modele miękkich technik obliczeniowych do oceny spółek na rok, na dwa i na trzy lata przed ich upadłością z wykorzystaniem trzech różnych zbiorów zmiennych objaśniających, tj. wskaźników finansowych firm. Założeniem pierwszego zbioru zmiennych była weryfikacja skuteczności modeli prognozowania upadłości firm przy minimalizacji liczby tych zmiennych. Dane wejściowe do modelu 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 niezagrażeniu upadłością. Podejście to zapewniło dobór takich cech, które nie powielają informacji dostarczanych przez inne wskaźniki, a jednocześnie są dobrymi reprezentantami wskaźników niewybranych jako diagnostyczne. Na tej podstawie wyznaczono następujące wskaźniki finansowe:

- do analizy na rok przed upadkiem: X3_1, X8_1, X9_1, X10_1;
- do analizy na dwa lata przed bankructwem: X1_2, X3_2, X5_2, X7_2, X8_2;
- do analizy na trzy lata przed upadłością: X1_3, X3_3, X8_3, X9_3, X10_3.

Założeniem drugiego zbioru zmiennych objaśniających było wykorzystanie całego wachlarza obliczonych w badaniach wskaźników finansowych, czyli zastosowanie wszystkich 14 wskaźników przedstawionych w tab. 1 jako dane wejściowe modeli.

Zadaniem trzeciego zbioru zmiennych wejściowych była weryfikacja skuteczności modeli prognozowania upadłości firm przy założeniu maksymalizacji ilości informacji dostarczanych modelom. W tym celu na wejściu poszczególnych modeli podawano wartości wszystkich 14 wskaźników finansowych z analizowanego i poprzedniego roku. Innymi słowy, w analizie spółek na rok przed upadłością w modelu wykorzystano wartości 14 wskaźników na rok i na dwa lata wstecz, w analizie spółek na dwa lata wstecz wykorzystano wartości 14 wskaźników z dwóch i z trzech lat wstecz⁸. Dzięki takiemu zabiegowi uzyskano łącznie 28 zmiennych wejściowych na rok i 28 zmiennych diagnostycznych na dwa lata wstecz.

Powyższe podejście badawcze zakładające wykorzystanie trzech różnych zbiorów zmiennych diagnostycznych dotyczy wszystkich modeli miękkich technik obliczeniowych z wyjątkiem:

- modelu logiki rozmytej – w którym ze względu na jego specyfikę wykorzystano zbiór zmiennych zakładający minimalizację danych wejściowych oraz opracowany dodatkowo na potrzeby tego modelu zbiór zawierający tempo zmiany wartości wskaźników ze zbioru zawierającego 4–5 wskaźników finansowych między analizowanymi latami, tj. między pierwszym a drugim rokiem przed upadłością do analizy spółek na rok wstecz, między drugim i trzecim rokiem przed upadłością do oceny firm na dwa lata wstecz oraz między trzecim a czwartym rokiem przed bankructwem do analizy przedsiębiorstw na trzy lata wstecz,
- modelu wektorów nośnych – w którym ze względu na jego właściwości wykorzystano tylko zbiór zawierający 14 i 28 zmiennych objaśniających.

Zadaniem opracowanych modeli jest klasyfikacja przedsiębiorstw do jednej z dwóch grup firm, tj. zagrożonych oraz niezagrażonych upadłością. Stąd wyjście tych modeli w każdym z opisywanych wyżej przypadków zawiera jeden lub dwa neurony przyjmujące w procesie uczenia sieci wartości odpowiednio 0 lub 1. Należy jednak zauważyć, że wartości wyjść generowane przez testowany model w praktyce nie są równe wartościom zadanych w próbie uczącej, lecz przyjmują wartości z przedziału (0,1). Autor przyjął próg graniczny na poziomie 0,5, tzn. że przedsiębiorstwa dla których wyjście modelu przyjmuje wartości mniejsze niż 0,5 klasyfikowane są jako zagrożone upadłością. Natomiast wartości wyjścia modelu powyżej 0,5 oznaczają, że firmy te są spółkami „zdrowymi”.

⁸ Ze względu na niepełne dane w przypadku niektórych wskaźników na cztery lata wstecz, autor nie mógł zastosować tego podejścia w analizie spółek na trzy lata przed upadłością, w którym wzięto by wartości wskaźników z trzeciego i czwartego roku przed bankructwem firm.

Ze względu na dużą liczbę opracowanych modeli (52), autor nie przedstawi graficznie ich architektury. Modele zostaną scharakteryzowane pisemnie z wykorzystaniem następujących oznaczeń: **n** – **k** – **o**, gdzie:

n – liczba neuronów w warstwie wejściowej,

k – liczba neuronów w warstwie ukrytej,

o – liczba neuronów w warstwie wyjściowej.

I tak, stosując się do powyższych założeń do badań, opracowano następujące modele:

- sztucznej sieci neuronowej wielowarstwowej jednokierunkowej (SSN MLP):
 - na rok wstecz (4 zmienne objaśniające): 4 – 9 – 2,
 - na dwa lata wstecz (5 zmiennych objaśniających): 5 – 10 – 2,
 - na trzy lata wstecz (5 zmiennych objaśniających): 5 – 5 – 2,
 - na rok wstecz (14 zmiennych objaśniających): 14 – 13 – 2,
 - na dwa lata wstecz (14 zmiennych objaśniających): 14 – 8 – 2,
 - na trzy lata wstecz (14 zmiennych objaśniających): 14 – 9 – 2,
 - na rok wstecz (28 zmiennych objaśniających): 28 – 20 – 2,
 - na dwa lata wstecz (28 zmiennych objaśniających): 28 – 8 – 2;
- sztucznej sieci neuronowej o radialnych funkcjach bazowych (SSN RBF):
 - na rok wstecz (4 zmienne objaśniające): 4 – 14 – 2,
 - na dwa lata wstecz (5 zmiennych objaśniających): 5 – 16 – 2,
 - na trzy lata wstecz (5 zmiennych objaśniających): 5 – 15 – 2,
 - na rok wstecz (14 zmiennych objaśniających): 14 – 12 – 2,
 - na dwa lata wstecz (14 zmiennych objaśniających): 14 – 15 – 2,
 - na trzy lata wstecz (14 zmiennych objaśniających): 14 – 15 – 2,
 - na rok wstecz (28 zmiennych objaśniających): 28 – 15 – 2,
 - na dwa lata wstecz (28 zmiennych objaśniających): 28 – 15 – 2;
- sztucznej sieci neuronowej rekurencyjnej (SSN REC):
 - na rok wstecz (4 zmienne objaśniające): 4 – 4 – 1,
 - na dwa lata wstecz (5 zmiennych objaśniających): 5 – 5 – 1,
 - na trzy lata wstecz (5 zmiennych objaśniających): 5 – 5 – 1,
 - na rok wstecz (14 zmiennych objaśniających): 14 – 14 – 1,
 - na dwa lata wstecz (14 zmiennych objaśniających): 14 – 14 – 1,
 - na trzy lata wstecz (14 zmiennych objaśniających): 14 – 14 – 1,
 - na rok wstecz (28 zmiennych objaśniających): 28 – 28 – 1,
 - na dwa lata wstecz (28 zmiennych objaśniających): 28 – 28 – 1;
- mapy samoorganizującej się (SOM):
 - na rok wstecz (4 zmienne objaśniające): 4 – 2,
 - na dwa lata wstecz (5 zmiennych objaśniających): 5 – 2,
 - na trzy lata wstecz (5 zmiennych objaśniających): 5 – 2,
 - na rok wstecz (14 zmiennych objaśniających): 14 – 2,
 - na dwa lata wstecz (14 zmiennych objaśniających): 14 – 2,
 - na trzy lata wstecz (14 zmiennych objaśniających): 14 – 2,
 - na rok wstecz (28 zmiennych objaśniających): 28 – 2,
 - na dwa lata wstecz (28 zmiennych objaśniających): 28 – 2;
- sztucznej sieci neuronowej opartej na algorytmach genetycznych (SSN GA) – model ten został oparty na strukturze perceptronu wielowarstwowego, w którym we wszystkich analizowanych latach w procesie uczenia został wykorzystany algorytm genetyczny o następujących parametrach – liczba pokoleń 100, wielkość populacji 50. Model ten miał następującą architekturę:
 - na rok wstecz (4 zmienne objaśniające): 4 – 4 – 1,
 - na dwa lata wstecz (5 zmiennych objaśniających): 5 – 5 – 1,
 - na trzy lata wstecz (5 zmiennych objaśniających): 5 – 5 – 1,



- na rok wstecz (14 zmiennych objaśniających): 14 – 14 – 1,
- na dwa lata wstecz (14 zmiennych objaśniających): 14 – 14 – 1,
- na trzy lata wstecz (14 zmiennych objaśniających): 14 – 14 – 1,
- na rok wstecz (28 zmiennych objaśniających): 28 – 28 – 1,
- na dwa lata wstecz (28 zmiennych objaśniających): 28 – 28 – 1;
- wektorów nośnych (SVM) – we wszystkich analizowanych latach model wektorów nośnych oszacowany został przy użyciu wektorów nośnych o radialnej funkcji bazowej (RBF). Model ten różnił się liczbą predyktorów i wektorów w poszczególnych wariantach badań:
 - na rok wstecz: 14 predyktorów (wskaźników finansowych), liczba wektorów nośnych – 47,
 - na dwa lata wstecz: 14 predyktorów, liczba wektorów nośnych – 39,
 - na trzy lata wstecz: 14 predyktorów, liczba wektorów nośnych – 49,
 - na rok wstecz: 28 predyktorów, liczba wektorów nośnych – 37,
 - na dwa lata wstecz: 28 predyktorów, liczba wektorów nośnych – 48;
- logiki rozmytej (FL):
 - na rok wstecz (podejście statyczne): X3, X8, X9, X10,
 - na dwa lata wstecz (podejście statyczne): X1, X3, X5, X7, X8,
 - na trzy lata wstecz (podejście statyczne): X1, X3, X8, X9, X10,
 - na rok wstecz (podejście dynamiczno-statyczne): X3, X8, X9, X10, X3V,
 - na dwa lata wstecz (podejście dynamiczno-statyczne): X1, X3, X7, X8, X3V,
 - na trzy lata wstecz (podejście dynamiczno-statyczne): X1, X3, X8, X9, X9V.

Model logiki rozmytej opracowywany jest na podstawie wiedzy i doświadczenia eksperta. Należy zaznaczyć, iż jest to pierwsza próba wykorzystania logiki rozmytej do prognozowania upadłości firm w Polsce oraz jedna z pierwszych na świecie. Ośrodkiem decyzyjnym opracowanego modelu logiki rozmytej jest napisana przez autora tego artykułu baza reguł o postaci: JEŻELI – TO⁹, w której zapisana jest wiedza ekspercka konieczna do skutecznej, merytorycznie prawidłowej, interpretacji wartości wskaźników finansowych będących wejściem modelu. Wyjściem modelu jest zmienna przedstawiająca prognozę sytuacji finansowej badanej firmy. Zmienna ta przyjmuje wartości od 0 do 1, przy czym przyjęto, iż wartość graniczna rozdzielająca firmy na zagrożone i niezagrożone upadłością wynosi 0,5¹⁰.

W modelu logiki rozmytej dla każdego wejścia, czyli wskaźnika finansowego, autor określił dwa zbiory rozmyte (będące podzbiórami dziedziny zbioru wartości danego wejścia): ZŁY („less”) i DOBRZY („more”¹¹); oraz odpowiadające im funkcje przynależności. Zbiory rozmyte oraz kształt funkcji przynależności zostały arbitralnie wyznaczone przez autora. Ocena wskaźnika (jako „dobry”, czy też „zły”) oparta została na analizie statystycznej. Autor policzył wartość pierwszego i trzeciego kwartyla dla każdego wskaźnika finansowego, osobno dla spółek o dobrej kondycji finansowej i osobno dla firm zagrożonych upadłością na rok, na dwa i na trzy lata wstecz. Wartość trzeciego kwartyla dla spółek-bankrutów posłużyła jako wartość krytyczna (wskaźnik został uznany jako „zły” poniżej tej wartości krytycznej).

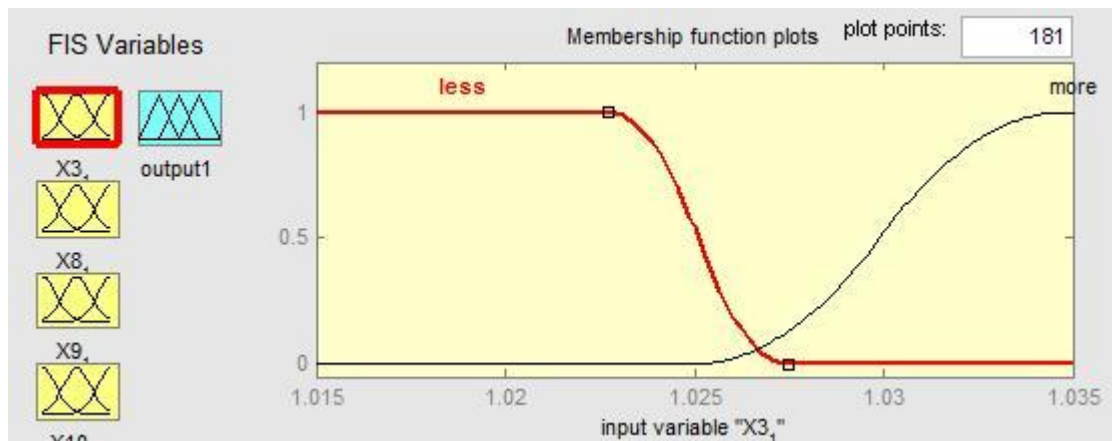
Poniżej przedstawiono przykład zdefiniowanych zbiorów rozmytych wraz z funkcjami przynależności dla wskaźnika X3 w analizie spółek na rok przed upadłością (rys. 1) oraz dla wskaźnika X7 w analizie spółek na dwa lata wstecz (rys. 2).

⁹ Ze względu na ograniczony rozmiar artykułu autor nie ma możliwości przedstawienia w nim opracowanych reguł funkcjonowania modelu logiki rozmytej dla wszystkich lat objętych analizą (zainteresowanym czytelnikom autor udostępni te reguły e-mailem – e-mail kontaktowy: tomasz.korol@zie.pg.gda.pl).

¹⁰ Podobnie jak w modelach sztucznych sieci neuronowych wartości zmiennej wyjściowej poniżej 0,5 oznaczają firmy zagrożone upadłością, a powyżej 0,5 przedstawiają przedsiębiorstwa niezagrożone bankrutem.

¹¹ Ze względu na wykorzystywanie angielskiej wersji oprogramowania służącego do opracowania modelu logiki rozmytej w modelu autor wykorzystał terminy angielskie, w których przyjął, że „zły” = „less” oraz „dobry” = „more”.

Rys. 1. Zbiory rozmyte dla wskaźnika X3 wraz z funkcjami przynależności




Źródło: Opracowanie własne (program Matlab)

Dla przedstawionego powyżej wskaźnika X3 (wskaźnik ten reprezentuje płynność bieżącą firm) wartością graniczną pomiędzy sytuacją pozytywną i negatywną jest wartość 1,025. Wszystkie wartości mniejsze od 1,023 są bezwzględnie negatywne, czyli należą do podzbioru rozmytego „ZŁY” (na rysunku przedstawione jako „less”) ze stopniem przynależności wynoszącym 1 oraz do podzbioru „DOBRY” (przedstawionym na rysunku jako „more”) ze stopniem przynależności równym 0. Natomiast wszystkie wartości większe od 1,035 są bezwzględnie pozytywne, tj. należą do podzbioru rozmytego „ZŁY” ze stopniem przynależności wynoszącym 0 oraz do podzbioru „DOBRY” ze stopniem przynależności równym 1. Wartości zawierające się w przedziale od 1,023 do 1,035 należą do obydwu podzbiorów rozmytych z różnymi wartościami funkcji przynależności, np. dla wartości wskaźnika X3_1 równej 1,03, wartość funkcji przynależności do zbioru „ZŁY” wynosi 0, a do zbioru „DOBRY” wynosi 0,5. Przy tak zdefiniowanych podzbiórach granica pomiędzy wartościami uważanymi za pozytywne i negatywne ulega rozmyciu, tj. pewna wartość wskaźnika jest „częściowo dobra” i „częściowo zła”. Takiej możliwości nie ma w przypadku stosowania logiki klasycznej, czyli dwuwartościowej, w której dana wartość wskaźnika jest „dobra” albo „zła”. Dlatego też stosowanie logiki klasycznej w ocenie sytuacji finansowo-ekonomicznej firm wpływa negatywnie na skuteczność stawianych prognoz. Taka sytuacja ma miejsce szczególnie dla wartości znajdujących się blisko granicy podzbiorów, gdzie nieznaczne przekroczenie wartości krytycznej wskaźnika decyduje o końcowej jego ocenie (jako całkowicie pozytywnej bądź też negatywnej), co nie jest zgodne z prawdą, ponieważ obydwie wartości wskaźnika odzwierciedlają niemal tę samą sytuację w przedsiębiorstwie.

Drugim przedstawionym przykładem są zbiory rozmyte dla wskaźnika X7 (wskaźnik ten przedstawia stosunek kapitału własnego do zobowiązań ogółem) z modelu logiki rozmytej prognozowania upadłości firm na dwa lata wstecz. Wartość graniczna dla tego wskaźnika pomiędzy sytuacją pozytywną i negatywną wynosi 0,8. Na rys. 2 widać, że wartości mniejsze od 0,797 są bezwzględnie negatywne, czyli należą do podzbioru rozmytego „ZŁY” („less”) ze stopniem przynależności wynoszącym 1 oraz do podzbioru „DOBRY” („more”) ze stopniem przynależności równym 0, natomiast wszystkie wartości większe od 0,805 są bezwzględnie pozytywne, tj. należą do podzbioru rozmytego „ZŁY” ze stopniem przynależności wynoszącym 0 oraz do podzbioru „DOBRY” ze stopniem przynależności równym 1. Wartości zawierające się w przedziale od 0,797 do 0,805 należą do obydwu podzbiorów rozmytych z różnymi wartościami funkcji przynależności.

Rys. 2. Zbiory rozmyte dla wskaźnika X7 wraz z funkcjami przynależności



Źródło: Opracowanie własne (program Matlab)

Wyniki testów wszystkich opisanych modeli prognozowania upadłości opracowanych przez autora zostały przedstawione w tab. 2, 3 i 4¹². Oceniając wpływ liczby wskaźników finansowych w modelu na jego skuteczność na podstawie otrzymanych wyników widać, że:

- w modelu sztucznej sieci neuronowej wielowarstwowej jednokierunkowej (SSN MLP) zwiększenie liczby wskaźników do 28 zapewniło najwyższą skuteczność w analizie na rok wstecz, zarówno na próbie testowej „jeden” (88,88% skuteczność), jak i próbie testowej „dwa” (75%). Natomiast wraz z wydłużaniem okresu prognozy do dwóch i do trzech lat wstecz widać, że optymalnym zbiorem zmiennych diagnostycznych wśród trzech opracowanych (4–5 wskaźników, 14 wskaźników, 28 wskaźników) był zbiór składający się z 14 wskaźników finansowych. Na próbie testowej „jeden” model ten osiągnął skuteczność na poziomie 74,07% na dwa lata wstecz i skuteczność 75,92% na trzy lata wstecz. Z kolei na próbie testowej „dwa” skuteczności te wynosiły: 67,42% i 63,63%;
- w modelu rekurencyjnym sztucznej sieci neuronowej (SSN REC) optymalnym zbiorem wskaźników finansowych był zbiór składający się z 14 zmiennych – zarówno w krótkim okresie analizy (na rok wstecz), jak i w długim okresie prognozy (na dwa i na trzy lata wstecz). Z tab. 2 wynika, że jedynie na próbie testowej „jeden” na rok wstecz 28 wskaźników finansowych wygenerowało najlepszą skuteczność modelu (94,44%). W pozostałych przypadkach wykorzystanie 14 wskaźników finansowych zapewniło lepszą jakość prognozy. W próbie testowej „jeden” na dwa lata wstecz, mimo iż skuteczność przy wykorzystaniu 14 i 28 zmiennych jest taka sama i wynosi 75,92%, to kosztowniejszy błąd I rodzaju jest wyższy o 4 p.p. w przypadku wykorzystania większej liczby wskaźników finansowych. Natomiast w okresie trzyletniego wyprzedzenia model składający się z 14 wskaźników uzyskał wyższą skuteczność o 18,52 p.p. w porównaniu z modelem opartym na 5 wskaźnikach finansowych. Z kolei w próbie testowej „dwa” na rok i na dwa lata wstecz najwyższą skuteczność model SSN REC osiągnął właśnie przy wykorzystaniu 14 zmiennych (77,27% w obu latach analizy). Na trzy lata wstecz, model ten uzyskał większą skuteczność przy wykorzystaniu tylko 5 wskaźników. Jednocześnie jednak warto zauważyć, że model taki wygenerował 100-procentowy błąd I typu – innymi słowy można powiedzieć, że model taki w ogóle nie jest w stanie rozpoznać

¹² W tabelach tych autor przedstawił wyniki testów na próbie testowej „jeden” i „dwa”. Autor nie przedstawił wyników prób uczących, ze względu na specyfikę tych modeli. Modele sztucznej sieci neuronowej w większości przypadków osiągają 100% skuteczność w procesie uczenia, dlatego ważniejsze są wyniki na próbach testowych, czyli próbach z przedsiębiorstwami, których modele te nie znają.

przyszłych bankrutów. Z tego też względu należy przyjąć, że również w analizie na trzy lata wstecz, model oparty na 14 wskaźnikach był modelem najlepszym;

- w przypadku wykorzystania algorytmów genetycznych w procesie uczenia modelu sztucznej sieci neuronowej (SSN GA), zwiększenie liczby wskaźników finansowych w modelu nie dało jednoznacznej odpowiedzi. Otóż z tab. 3 widać, że w próbie testowej „jeden”, w analizie na rok i na trzy lata wstecz, najwyższą skuteczność uzyskano w modelu z wykorzystaniem tylko 4 wskaźników finansowych (90,74% i 70,37%). Z kolei na dwa lata wstecz, najwyższą skuteczność uzyskano w modelu składającym się z 14 zmiennych wejściowych. Natomiast wyniki uzyskane na próbie testowej „dwa” są odmienne – na rok wstecz najwyższą skuteczność wygenerował model 14-wskaźnikowy (73,48%), na dwa lata wstecz - model 28-wskaźnikowy (68,93%), a na trzy lata wstecz – model 5-wskaźnikowy (60,60%);
- w modelu sztucznej sieci neuronowej o radialnych funkcjach bazowych (SSN RBF) widać, że w prognozie na rok i na dwa lata wstecz najlepszą jakością charakteryzował się model składający się z 14 wskaźników finansowych. Na próbie testowej „jeden” model ten uzyskał skuteczność 87,03% na rok i 74,07% na dwa lata wstecz; natomiast na próbie testowej „dwa” – 74,24% na rok i 64,39% na dwa lata wstecz¹³. Natomiast w analizie na trzy lata wstecz oba modele (5-wskaźnikowy, jak i 14-wskaźnikowy) na próbie testowej „jeden” i „dwa” wykazały się brakiem użyteczności, generując wysokie błędy I typu na poziomie 60–64%;
- w przypadku wykorzystania modelu mapy samoorganizującej się (SOM) widać, że w krótkim okresie analizy, tj. w prognozie na rok wstecz, model uzyskuje najlepszą skuteczność przy wykorzystaniu 14 zmiennych diagnostycznych (tab. 4) – 85,18% w próbie testowej „jeden” i 62,87% w próbie testowej „dwa”. Natomiast w analizie na dwa i na trzy lata wstecz wykorzystanie tylko 5 wskaźników finansowych zapewniło najwyższą skuteczność modelu (74,07% na dwa lata wstecz i 66,66% na trzy lata wstecz w próbie testowej „jeden” oraz 53,78% na dwa lata wstecz i 56,06% na trzy lata wstecz w próbie testowej „dwa”);
- w sytuacji wykorzystania modelu wektorów nośnych w prognozowaniu upadłości firm widać, że zastosowanie 14 wskaźników w całym okresie prognozy zapewniło najlepszą skuteczność modelu. I tak, na próbie testowej „jeden” model ten uzyskał skuteczność: 90,74% na rok wstecz, 87,04% na dwa lata wstecz i 74,07% na trzy lata wstecz; a na próbie testowej „dwa”: 75% na rok wstecz, 62,87%¹⁴ na dwa i na trzy lata wstecz.

Podsumowując, można powiedzieć, że w przypadku modeli miękkich technik obliczeniowych nie można wyciągnąć jednoznacznych wniosków na temat wpływu liczby wskaźników finansowych na ich skuteczność. Widać jednak, że w większości przypadków wykorzystanie 14 wskaźników finansowych zapewniało najwyższą jakość prognozy. Nie jest to więc ani wariant minimalizujący (4–5 wskaźników), ani też maksymalizujący (28 wskaźników) liczbę danych wejściowych do modelu.

¹³ W analizie na dwa lata wstecz, na próbie testowej „dwa” skuteczność modelu składającego się z 28 wskaźników była wyższa tylko o 2,27 p.p., ale model ten wygenerował większy błąd I rodzaju aż o 12 p.p. w porównaniu z modelem składającym się z 14 wskaźników. Dlatego też autor uznał, że model oparty na 14 wskaźnikach w tym przypadku jest modelem lepszym.

¹⁴ Podobnie jak w przypadku modelu SSN RBF w analizie na dwa lata wstecz na próbie testowej „dwa” skuteczność modelu składającego się z 28 wskaźników była wyższa od modelu opartego na 14 wskaźnikach, ale model ten charakteryzuje się większym błędem I rodzaju aż o 20 p.p. Z tego też względu uznano, że model 14-wskaźnikowy jest modelem lepszym.

Tab. 2. Skuteczności modelu sztucznej sieci neuronowej wielowarstwowej jednokierunkowej (SSN MLP) oraz modelu sztucznej sieci neuronowej rekurencyjnej (SSN REC) w dwóch próbach testowych na rok, na dwa i na trzy lata przed upadłością¹⁵

Rodzaj próby		Modele prognozowania upadłości											
		SSN MLP (4–5 wskaźników)		SSN MLP (14 wskaźników)		SSN MLP (28 wskaźników)		SSN REC (4–5 wskaźników)		SSN REC (14 wskaźników)		SSN REC (28 wskaźników)	
Próba testowa „jeden” 25:29	Na rok	E1	16% (4)	E1	16% (4)	E1	8% (2)	E1	12% (3)	E1	8% (2)	E1	0% (0)
		E2	10,34% (3)	E2	13,79% (4)	E2	13,79% (4)	E2	10,34% (3)	E2	10,34% (3)	E2	10,34% (3)
		S	87,03%	S	85,18%	S	88,88%	S	88,88%	S	90,74%	S	94,44%
	Na dwa lata	E1	24% (6)	E1	24% (6)	E1	32% (8)	E1	8% (2)	E1	32% (8)	E1	36% (9)
		E2	37,93% (11)	E2	27,58% (8)	E2	24,13% (7)	E2	34,48% (10)	E2	17,24% (5)	E2	13,79% (4)
		S	68,51%	S	74,07%	S	72,22%	S	77,77%	S	75,92%	S	75,92%
	Na trzy lata	E1	44% (11)	E1	32% (8)			E1	100% (25)	E1	48% (12)		
		E2	13,79% (4)	E2	17,24% (5)			E2	0% (0)	E2	10,34% (3)		
		S	72,22%	S	75,92%			S	53,70%	S	72,22%		
Próba testowa „dwa” 25:107	Na rok	E1	16% (4)	E1	16% (4)	E1	8% (2)	E1	12% (3)	E1	8% (2)	E1	0% (0)
		E2	29,90% (32)	E2	28,03% (30)	E2	28,97% (31)	E2	9,34% (10)	E2	26,16% (28)	E2	34,57% (37)
		S	72,72%	S	74,24%	S	75%	S	90,15%	S	77,27%	S	71,96%
	Na dwa lata	E1	24% (6)	E1	24% (6)	E1	32% (8)	E1	8% (2)	E1	32% (8)	E1	36% (9)
		E2	37,38% (40)	E2	34,57% (37)	E2	32,71% (35)	E2	43,92% (47)	E2	20,56% (22)	E2	30,84% (33)
		S	65,15%	S	67,42%	S	67,42%	S	62,87%	S	77,27%	S	68,18%
	Na trzy lata	E1	44% (11)	E1	32% (8)			E1	100% (25)	E1	48% (12)		
		E2	33,64% (36)	E2	37,38% (40)			E2	3,73% (4)	E2	26,16% (28)		
		S	64,39%	S	63,63%			S	78,03%	S	69,69%		

¹⁵ W nawiasach podano liczbę błędnie zaklasyfikowanych przedsiębiorstw.

Tab. 3. Skuteczności modelu sztucznej sieci neuronowej opartej na algorytmach genetycznych (SSN GA) oraz modelu sztucznej sieci neuronowej o radialnych funkcjach bazowych (SSN RBF) w dwóch próbach testowych na rok, na dwa i na trzy lata przed upadłością¹⁶

Rodzaj próby		Modele prognozowania upadłości											
		SSN GA (4–5 wskaźników)		SSN GA (14 wskaźników)		SSN GA (28 wskaźników)		SSN RBF (4–5 wskaźników)		SSN RBF (14 wskaźników)		SSN RBF (28 wskaźników)	
Próba testowa „jeden” 25:29	Na rok	E1	8% (2)	E1	12%(3)	E1	16%(4)	E1	20% (5)	E1	20% (5)	E1	4% (1)
		E2	10,34% (3)	E2	13,79% (4)	E2	13,79% (4)	E2	20,68% (6)	E2	6,89% (2)	E2	31,03% (9)
		S	90,74%	S	87,03%	S	85,18%	S	79,62%	S	87,03%	S	81,48%
	Na dwa lata	E1	36% (9)	E1	28% (7)	E1	28% (7)	E1	24% (6)	E1	20% (5)	E1	32% (8)
		E2	44,82% (13)	E2	34,48% (10)	E2	13,79% (4)	E2	41,37% (12)	E2	31,03% (9)	E2	24,13% (7)
		S	59,25%	S	68,51%	S	79,62%	S	66,66%	S	74,07%	S	72,22%
	Na trzy lata	E1	40% (10)	E1	52% (13)			E1	64% (16)	E1	60% (15)		
		E2	20,68% (6)	E2	27,58% (8)			E2	17,24% (5)	E2	44,82% (13)		
		S	70,37%	S	61,11%			S	61,11%	S	48,14%		
Próba testowa „dwa” 25:107	Na rok	E1	8% (2)	E1	12%(3)	E1	16% (4)	E1	20% (5)	E1	20% (5)	E1	4% (1)
		E2	31,77% (34)	E2	29,9% (32)	E2	34,57% (37)	E2	40,18% (43)	E2	27,1% (29)	E2	44,85% (48)
		S	72,72%	S	73,48%	S	68,93%	S	63,63%	S	74,24%	S	62,87%
	Na dwa lata	E1	36% (9)	E1	28% (7)	E1	28% (7)	E1	24% (6)	E1	20% (5)	E1	32% (8)
		E2	45,79% (49)	E2	43,92% (47)	E2	31,77% (34)	E2	48,59% (52)	E2	39,25% (42)	E2	33,64% (36)
		S	56,06%	S	59,09%	S	68,93%	S	56,06%	S	64,39%	S	66,66%
	Na trzy lata	E1	40% (10)	E1	52% (13)			E1	64% (16)	E1	60% (15)		
		E2	39,25% (42)	E2	39,25% (42)			E2	21,49% (23)	E2	40,18% (43)		
		S	60,60%	S	58,33%			S	70,45%	S	56,06%		

¹⁶ W nawiasach podano liczbę błędnie zaklasyfikowanych przedsiębiorstw.

Tab. 4. Skuteczności modelu mapy samoorganizującej się (SOM), modelu wektorów nośnych (SVM) oraz modelu logiki rozmytej (FL) w dwóch próbach testowych na rok, na dwa i na trzy lata przed upadłością¹⁷

Rodzaj próby		Modele prognozowania upadłości													
		SOM (4–5 wskaźników)		SOM (14 wskaźników)		SOM (28 wskaźników)		SVM (14 wskaźników)		SVM (28 wskaźników)		FL (4–5wskaźników)		FL (dyn.-stat.)	
Próba testowa „jeden” 25:29	Na rok	E1	0% (0)	E1	0% (0)	E1	4% (1)	E1	8% (2)	E1	12% (3)	E1	16% (4)	E1	16% (4)
		E2	58,62% (17)	E2	27,58% (8)	E2	65,51% (19)	E2	10,34% (3)	E2	10,34% (3)	E2	10,34% (3)	E2	6,89% (2)
		S	71,18%	S	85,18%	S	62,96%	S	90,74%	S	88,88%	S	87,03%	S	88,88%
	Na dwa lata	E1	8% (2)	E1	8% (2)	E1	8% (2)	E1	4% (1)	E1	24% (6)	E1	4% (1)	E1	8% (2)
		E2	41,37% (12)	E2	65,51% (19)	E2	55,17% (16)	E2	20,68% (6)	E2	10,34% (3)	E2	27,58% (8)	E2	24,13% (7)
		S	74,07%	S	61,11%	S	66,66%	S	87,04%	S	83,33%	S	83,33%	S	83,33%
	Na trzy lata	E1	36% (9)	E1	32% (8)			E1	44% (11)			E1	24% (6)	E1	20% (5)
		E2	31,03% (9)	E2	55,17% (16)			E2	13,79% (3)			E2	27,58% (8)	E2	17,24% (5)
		S	66,66%	S	55,55%			S	74,07%			S	74,07%	S	81,48%
Próba testowa „dwa” 25:107	Na rok	E1	0% (0)	E1	0% (0)	E1	4% (1)	E1	8% (2)	E1	12% (3)	E1	16% (4)	E1	16% (4)
		E2	73,83% (79)	E2	45,79% (49)	E2	73,83% (79)	E2	28,97% (31)	E2	30,84% (33)	E2	28,97% (31)	E2	19,62% (21)
		S	40,15%	S	62,87%	S	39,39%	S	75%	S	72,72%	S	73,48%	S	81,06%
	Na dwa lata	E1	8% (2)	E1	8% (2)	E1	8% (2)	E1	4% (1)	E1	24% (6)	E1	4% (1)	E1	8% (2)
		E2	55,14% (59)	E2	69,15% (74)	E2	62,61% (67)	E2	44,85% (48)	E2	30,84% (33)	E2	42,05% (45)	E2	41,12% (44)
		S	53,78%	S	42,42%	S	47,72%	S	62,87%	S	70,45%	S	65,15%	S	65,15%
	Na trzy lata	E1	36% (9)	E1	32% (8)			E1	44% (11)			E1	24% (6)	E1	20% (5)
		E2	45,79% (49)	E2	60,74% (65)			E2	35,51% (38)			E2	47,66% (51)	E2	39,25% (42)
		S	56,06%	S	44,69%			S	62,87%			S	56,81%	S	64,39%

¹⁷ W nawiasach podano liczbę błędnie zaklasyfikowanych przedsiębiorstw.



Kolejnym ważnym aspektem tych badań jest wskazanie najskuteczniejszego modelu prognozowania upadłości firm w grupie modeli miękkich technik obliczeniowych. Z tab. 2, 3 i 4 wynika, że bardzo wysoki (powyżej 50%) błąd I rodzaju eliminuje model SSN REC oraz model SSN RBF z rozważań na temat najlepszego modelu. Patrząc na wyniki bardziej istotnej próby testowej z punktu widzenia możliwości wykorzystania modeli w praktyce gospodarczej, czyli próby testowej „dwa” o nierównej proporcji bankrutów do niebankrutów, widać, że:

- model logiki rozmytej, opracowany przy wykorzystaniu ujęcia dynamiczno-statycznego wskaźników finansowych, uzyskał w analizie spółek:
 - na rok wstecz, skuteczność na poziomie 81,06% i była ona większa od skuteczności:
 - ✓ (najlepszego) modelu SSN MLP o 6,06 p.p.,
 - ✓ (najlepszego) modelu SSN GA o 7,58 p.p.,
 - ✓ (najlepszego) modelu SOM o 18,19 p.p.,
 - ✓ (najlepszego) modelu SVM o 6,06 p.p.,
 - na dwa lata wstecz, skuteczność na poziomie 65,15% i była ona:
 - ✓ gorsza od skuteczności (najlepszego) modelu SSN MLP o 2,27 p.p., ale błąd I typu modelu logiki rozmytej był o 16 p.p. mniejszy od błędu I typu modelu SSN MLP (8% vs 24%),
 - ✓ gorsza od skuteczności (najlepszego) modelu SSN GA o 3,78 p.p., ale błąd I typu modelu logiki rozmytej był o 20 p.p. mniejszy od błędu I typu modelu SSN GA (8% vs 28%),
 - ✓ lepsza od skuteczności (najlepszego) modelu SOM o 11,37 p.p.,
 - ✓ gorsza od skuteczności (najlepszego) modelu SVM o 5,3 p.p., ale błąd I typu modelu logiki rozmytej był o 16 punktów procentowych mniejszy od błędu I typu modelu SVM (8% vs 24%),
 - na trzy lata wstecz, skuteczność na poziomie 64,39% i była ona:
 - ✓ równa skuteczności (najlepszego) modelu SSN MLP, ale błąd I typu modelu logiki rozmytej był o 24 p.p. mniejszy od błędu I typu modelu SSN MLP (20% vs 44%),
 - ✓ lepsza od skuteczności (najlepszego) modelu SSN GA o 3,79 p.p.,
 - ✓ lepsza od skuteczności (najlepszego) modelu SOM o 8,33 p.p.,
 - ✓ lepsza od skuteczności (najlepszego) modelu SVM o 1,52 p.p.,
- model logiki rozmytej, opracowany przy wykorzystaniu ujęcia dynamiczno-statycznego wskaźników finansowych, charakteryzował się najmniejszymi błędami I typu w długim okresie prognozy,
- model logiki rozmytej charakteryzuje się największą przejrzystością sposobu wnioskowania i generowania prognozy dotyczącej zagrożenia upadłością firm.

Warto również zwrócić przy tym uwagę, jak pozytywnie wpłynęło dodanie do modelu logiki rozmytej ujęcia dynamicznego jednego ze wskaźników finansowych w każdym roku analizy. W próbie testowej „jeden” wpłynęło to na zwiększenie skuteczności modelu z 87,03% do 88,88% w analizie spółek na rok wstecz oraz z 74,07% do 81,48% w analizie firm na trzy lata przed upadłością. Natomiast w próbie testowej „dwa” ujęcie dynamiczne spowodowało zwiększenie skuteczności modelu z 73,48% do 81,06% w analizie przedsiębiorstw na rok wstecz oraz z 56,81% do 64,39% w analizie spółek na trzy lata wstecz. W obu próbach testowych w przypadku analizy na dwa lata wstecz nie zanotowano zmiany skuteczności.

Wnioski

Wnioski płynące z przeprowadzonych przez autora badań są istotne. Dzięki tym badaniom na takiej samej populacji firm¹⁸ dokonano weryfikacji skuteczności modeli opracowanych siedmioma różnymi technikami badawczymi. Wyniki jednoznacznie wykazały, że w przypadku wykorzystania

¹⁸ Co jest istotne dla wiarygodności otrzymanych wyników.



proporcji bankrutów do niebankrutów zbliżonej do rzeczywistych uwarunkowań model logiki rozmytej charakteryzuje się wyższą zdolnością predykcji niż pozostałe modele sztucznej inteligencji. Warto również zwrócić uwagę, iż taki model ekspercki otwiera szerokie możliwości wykorzystania różnych zmiennych, które mogą zwiększyć skuteczność prognoz upadłości. Model logiki rozmytej pozwala swobodnie modyfikować strukturę modelu (kryteria, funkcje przynależności, używane zmienne itp.) w przeciwieństwie do modelu sztucznych sieci neuronowej, o którym często potocznie mówi się, że działa on na zasadzie „czarnej skrzynki”, czyli badacz ma niewielkie możliwości modyfikacji wnętrza modelu.

Badania te są pierwszą próbą wykorzystania logiki rozmytej do przewidywania upadłości przedsiębiorstw w Polsce i jedną z pierwszych na świecie.

Literatura

Aziz M., Dar H., *Predicting corporate bankruptcy – where we stand?* „Corporate Governance Journal” 2006, vol. 6, nr 1.

Bankructwa firm – problem polskiej gospodarki, www.eulerhermes.pl/pl/pl/dokumenty/091021_eh_upadl_iiikw09.pdf/091021_eh_upadl_iiikw09.pdf.

Korol T., *Modele prognozowania upadłości przedsiębiorstw – analiza porównawcza wyników sztucznych sieci neuronowych z tradycyjną analizą dyskryminacyjną*, „Gospodarka w Praktyce i Teorii” 2005, nr 2(17).

Rutkowski L., *Metody i techniki sztucznej inteligencji*, PWN, Warszawa 2005.

www.eulerhermes.pl/pl/pl/media/0907_eh_upadlosci_swiat.pdf/0907_eh_upadlosci_swiat.pdf.