

Józef Pocięcha

Uniwersytet Ekonomiczny w Krakowie

MODELE PROGNOZOWANIA BANKRUCTWA W SYSTEMIE WCZESNEGO OSTRZEGANIA PRZEDSIĘBIORSTW

Streszczenie: Prognozy ostrzegawcze i systemy wczesnego ostrzegania ze swojej natury mają charakter dynamiczny. Modele prognozowania bankructwa są z reguły modelami klasyfikacyjnymi, a więc mają charakter statyczny. Z tego względu nie są one spójnym elementem systemów wczesnego ostrzegania. W pracy dokonano przeglądu podstawowych metod prognozowania bankructwa, przedstawiono miary sprawności prognoz oparte na modelach klasyfikacyjnych oraz wskazano źródła możliwych błędów w prognozowaniu bankructwa firm. W pracy podkreślono konieczność uwzględniania koniunktury gospodarczej jako podstawowej determinanty ryzyka bankructwa. W końcowej części wskazano możliwości dynamicznego ujęcia modeli predykcji bankructwa, w modelach sztucznych sieci neuronowych, modelach logitowych i modelach SEM.

Słowa kluczowe: prognoza ostrzegawcza, prognozowanie bankructwa, koniunktura gospodarcza.

1. Wstęp

Profesor Zdzisław Hellwig, tak jak i dla wielu innych dziedzin badań statystycznych, był pomysłodawcą koncepcji i inicjatorem badań nad prognozami ostrzegawczymi w gospodarce. W uwagach ogólnych do pracy [8, s. 6] zwraca uwagę, że problemy te w literaturze polskiej postawione zostały po raz pierwszy i nie ma na ten temat odpowiedniej literatury. W pracy tej podaje intuicyjne pojęcie prognozy ostrzegawczej. „takim terminem określać się będzie przypuszczenie, że przyszły stan analizowanego (czy też prognozowanego) zjawiska będzie niższy (mniejszy) od stanu obecnego” [8, s. 15]. Profesor Hellwig podaje również formalną definicję prognozy ostrzegawczej, opartą na kolejnych wyrazach szeregu czasowego lub alternatywnie na wartości funkcji filtrującej [8, s. 17]. Podaje on również dwie propozycje procedur wczesnego ostrzegania: metody punktów charakterystycznych oraz wyznaczania dla danego szeregu czasowego funkcji filtrującej [8, s. 20-23]. Metody te są oparte na procedurach statystycznej kontroli jakości (SKJ). Można więc zauważyć, że metody SKJ zyskują nowe interesujące pole zastosowań jako podstawa metodologiczna budowy systemów wczesnego ostrzegania.

Idee budowy prognoz ostrzegawczych zapoczątkowane przez Profesora Hellwiga rozwinięte zostały w pracach śp. Profesor Urszuli Siedleckiej, a ich całościowa koncepcja zawarta została w pracy [24]. Podaje ona m.in. następującą definicję prognozy ostrzegawczej. „Prognozą ostrzegawczą nazywa się przypuszczenie sformułowane na podstawie informacji dostarczonych przez szereg czasowy, że w przyszłym momencie T_0 stan analizowanego zjawiska gospodarczego będzie niższy niż w momencie $T_0 - 1$ ” [24, s. 66]. Przyjmując, że prognoza ostrzegawcza jest z natury rzeczy prognozą długookresową, makroekonomiczną oraz dotyczącą w istocie prognozowania spadku koniunktury gospodarczej, formułuje ona pojęcie niepomyślnej sytuacji gospodarczej (NSG). „Niepomyślna sytuacja gospodarza może być określona jako naruszenie równowagi dynamicznej systemu, rozumiane jako zakłócenie pożądanego przebiegu rozwoju społeczno-gospodarczego” [24, s. 63]. Innym podstawowym pojęciem wprowadzonym przez U. Siedlecką jest definicja systemu wczesnego ostrzegania. „Jest to system informacyjno-ostrzegawczy emitujący sygnały ostrzegawcze o wystąpieniu w niektórych obszarach zagrożenia niepomyślną sytuacją, dostarczający przy tym użytkownikowi istotnych, syntetycznych informacji niezbędnych do analizowania sytuacji gospodarczej” [24, s. 103].

Systemy wczesnego ostrzegania niekoniecznie muszą obejmować jedynie problemy makroekonomiczne, lecz także, a może przede wszystkim, mikroekonomiczną sferę gospodarki z jej podstawowymi jednostkami, jakimi są przedsiębiorstwa i gospodarstwa domowe. Systemy wczesnego ostrzegania odgrywają ważną rolę w zarządzaniu strategicznym w przedsiębiorstwie. Ich podstawowym zadaniem jest sygnalizowanie wszelkich zagrożeń wewnątrz przedsiębiorstwa lub w jego otoczeniu. Podstawowym zagrożeniem dla funkcjonowania przedsiębiorstwa jest zagrożenie jego upadłością. W systemach wczesnego ostrzegania przedsiębiorstw kluczową rolę odgrywają modele i metody prognozowania bankructwa.

Celem niniejszej pracy jest dokonanie przeglądu modeli prognozowania bankructwa, ocena ich efektywności i ograniczeń oraz przedstawienie problemów związanych z uwzględnieniem wpływu otoczenia gospodarczego na ryzyko upadłości przedsiębiorstw. Syntetycznym miernikiem zewnętrznych warunków działania przedsiębiorstwa jest stan koniunktury gospodarczej. Przy dobrej koniunkturze nawet słabe przedsiębiorstwa mogą przetrwać, a przy złej koniunkturze także dobre mogą upaść. Oddzielnym problemem metodologicznym jest zagadnienie dynamizacji modeli prognozowania bankructwa, co jest wymogiem przynależności do systemu wczesnego ostrzegania. W pracy sformułowano pewne sugestie dotyczące możliwości rozwiązania przedstawionych problemów.

2. Metody prognozowania bankructwa

Bankructwo jest nieodłącznym elementem gospodarki rynkowej. Stanowi ono system samooczyszczania się gospodarki, przez eliminację firm nieefektywnych ekonomicznie lub nie znajdujących swojego miejsca na rynku. Możliwość jego prognozo-

wania pozwala na ewentualne podjęcie przez zarząd firmy działań naprawczych, które nie dopuszczają do zrealizowania się tego negatywnego dla firmy scenariusza. Jednocześnie fakt bankructwa firmy pociąga za sobą negatywne konsekwencje, będące społecznymi kosztami bankructwa. Jest to przede wszystkim utrata pracy lub przynajmniej części zarobków przez załogę zbankrutowanej firmy. Wiąże się także ze stratami właścicieli lub udziałowców zbankrutowanej firmy. Jest także porażką zarządu firmy, jeśli tylko nie jest to celowe doprowadzenie firmy do upadłości. Wszystkie te negatywne konsekwencje bankructwa powodują, że wiedza o zagrożeniach egzystencji firmy jest wiedzą pilnie poszukiwaną przez praktykę gospodarczą.

Zagadnienie prognozowania upadłości firmy rozpatrywane jest zazwyczaj z różnych punktów widzenia. Najważniejsze z nich to punkty widzenia [19]:

- 1) kierownictwa firmy – jako jednej z najważniejszych przesłanek dla podejmowania decyzji gospodarczych,
- 2) banku – w procesie podejmowania decyzji o udzieleniu kredytu,
- 3) biegłego rewidenta – w procesie rewizji sprawozdania finansowego,
- 4) inwestora i analityka finansowego – w procesie podejmowania decyzji inwestycyjnych na rynku kapitałowym,
- 5) instytucji rządowych i organizacji gospodarczych – zainteresowanych oceną stanu gospodarki.

Wygodnym narzędziem oszacowania prawdopodobieństwa bankructwa jest zbudowanie statystycznego modelu predykcji bankructwa firmy. Zdecydowaną większość procedur i modeli prognozowania bankructwa można zaliczyć do szeroko rozumianych metod klasyfikacji danych [18].

W teorii i praktyce prognozowania bankructwa sformułowano wiele typów modeli predykcji bankructwa. Ich wyczerpującą klasyfikację przedstawił T.E. McKee [14]. Wymienia on następujące typy procedur i modeli:

- jednowymiarowe modele wskaźnikowe,
- wielowymiarową analizę dyskryminacyjną,
- liniowe modele prawdopodobieństwa,
- modele logitowe i probitowe,
- drzewa decyzyjne,
- modele hazardu,
- systemy eksperckie,
- programowanie matematyczne,
- sieci neuronowe,
- zastosowania teorii zbiorów rozmytych i zbiorów zgrubnych.

Wśród nich najstarsze są jednowymiarowe modele wskaźnikowe, wywodzące się bezpośrednio z analizy finansowej. Natomiast najbardziej popularnymi narzędziami prognozowania bankructwa są modele wielowymiarowej analizy dyskryminacyjnej, opartej głównie na liniowej funkcji dyskryminacyjnej Fishera. Spośród obszernej literatury w tym zakresie wskazano tutaj na prace inicjujące zastosowania liniowej funkcji dyskryminacyjnej w świecie [1] oraz w Polsce [4; 13]. Najbardziej

reprezentatywne w Polsce, zdaniem autora, są: [7; 9; 10]. Metodami dyskryminacyjnym prawie dorównują popularnością modele logitowe prognozowania bankructwa, zapoczątkowane pracą [17], a w Polsce [25], najbardziej reprezentatywne zaś są [5; 6; 26]. A współczesnymi metodami nieparametrycznymi są modele sztucznych sieci neuronowych zapoczątkowane pracami [3; 16; 23], w Polsce zaś [15], a za najbardziej reprezentatywne należy uznać [12; 22].

3. Sprawność modeli prognozowania bankructwa

Wobec wielu możliwości zastosowania ilościowych metod predykcji bankructwa powstaje problem, które metody zastosować i jaka jest ich sprawność prognostyczna. Jako kryterium sprawności prognostycznej metod wymienionych w poprzednim punkcie można przyjąć następujące miary zdolności do poprawnej klasyfikacji na zbiorze uczącym:

1) sprawność I rodzaju (SP I) – czyli udział (procent) firm, które zbankrutowały, prawidłowo zakwalifikowany przez model do zbioru bankrutów,

2) błąd I rodzaju (B I) – procent bankrutów, którzy zostali nieprawidłowo zakwalifikowani do zbioru firm kontynuujących działalność,

3) sprawność II rodzaju (SP II) – procent firm kontynuujących swoją działalność (niebankrutów), prawidłowo rozpoznanych przez model,

4) błąd II rodzaju (B II) – procent firm, które kontynuują działalność, nieprawidłowo zakwalifikowanych do zbioru bankrutów,

5) sprawność ogólna (SP) – procent prawidłowo zaklasyfikowanych firm,

6) błąd ogólny (B) – procent nieprawidłowo zaklasyfikowanych firm.

W tabeli 1 przedstawiono wyniki badania zdolności do poprawnej klasyfikacji na zbiorze uczącym, w postaci macierzy sprawności klasyfikacji, podane przez autorów wybranych modeli prognozowania bankructwa.

Przy losowaniu prób z populacji bankrutów i niebankrutów dzieli się je zazwyczaj na dwie części, jeden to zbiór uczący, na podstawie którego konstruuje się model i szacuje jego parametry, a drugi traktuje się jako zbiór testowy, na podstawie którego bada się zdolność prognostyczną modelu. Wielu autorów podaje zarówno zdolności do poprawnej klasyfikacji na zbiorze uczącym, jak i zdolności prognostyczne na zbiorze testowym. Istotne jednak jest, aby model możliwie trafnie prognozował przynależność do grupy bankrutów lub niebankrutów obiektu wielowymiarowego (firmy) spoza zbioru uczącego lub testowego, gdyż dopiero wtedy można ocenić praktyczną zdolność predykcyjną modelu bankructwa.

Wyniki testowania zdolności predykcyjnych wybranych polskich modeli prognostycznych, na rok przed upadłością, na zbiorze 31 przedsiębiorstw, dla danych finansowych z lat 2002-2007 przedstawione zostały w pracy [20]. Jak wynika z danych przedstawionych w tej pracy, nie można jednoznacznie stwierdzić, jaki typ modeli prognostycznych daje najlepsze rezultaty. Pewni autorzy preferują sieci neuronowe, twierdząc, że są one najbardziej elastyczne i mają największą zdolność do

Tabela 1. Macierz sprawności klasyfikacji (w %)

Model	SP I	B I	SP II	B II	SP	B
Gajdka i Stos [4] (D)	93,3	6,7	76,0	24,0	78,6	21,4
Hadasik [7] (D)	95,4	4,6	90,9	9,1	93,2	6,8
Hołda [10] (D)	87,8	12,2	91,9	8,1	89,9	10,1
Pociecha [19] (D)	93,3	6,7	91,7	8,3	92,5	7,5
Hołda [10] (L)	89,2	10,8	94,6	5,4	91,9	8,1
Wędzki [26] (L)	90,3	9,7	87,0	13,0	89,0	11,0
Hołda [10] (S)	91,9	8,1	95,9	4,1	93,9	6,1
Korol i Prusak [12] (S)	97,4	2,6	94,9	5,1	96,2	3,8

Symbol (D) oznacza model dyskryminacyjny, (L) – logitowy, (S) – sieci neuronowe.

Źródło: autorzy wymienieni w pierwszej kolumnie tabeli.

poprawnej klasyfikacji. Są jednak również dowody na to, że klasyczna liniowa funkcja dyskryminacyjna może dawać lepsze rezultaty niż zbyt skomplikowana sieć neuronowa. Podsumowując, można stwierdzić, że precyzja prognozy bankructwa nie zależy od typu modelu prognostycznego. Drogą poprawy precyzji prognoz bankructwa jest uwzględnienie czynników zewnętrznych oddziałujących na kondycję finansową przedsiębiorstwa. Dotychczasowe modele prognostyczne w zasadzie nie brały pod uwagę ich oddziaływania, gdyż uwzględniały jedynie wskaźniki finansowe z przeszłości, czyli czynniki określające sytuację finansową wewnątrz przedsiębiorstwa.

4. Źródła błędów w prognozowaniu bankructwa

Wobec braku rozstrzygnięć, jakiego typu modele są najodpowiedniejsze do celów prognozowania bankructwa, należy sobie postawić fundamentalne pytanie: jakie są źródła błędów popełnianych w procesie prognozowania bankructwa?

Jednym z nich jest wartościowy charakter wskaźników finansowych. Weźmy na przykład rentowność majątku (ROA), która jest stosunkiem zysku netto do wartości majątku. Rentowność jest różnicą pomiędzy efektami a nakładami. Nakłady mierzy się kosztami, a koszty kalkuluje się, stosując pewne procedury rachunku kosztów. Podobnie wartość majątku zależy od sposobu liczenia amortyzacji, gdzie też mamy możliwości stosowania różnych rozwiązań. Oczywiście istnieją krajowe i międzynarodowe standardy rachunkowości, ale daleko jeszcze do ujednoczenia sposobu pomiaru wielkości finansowych, szczególnie w skali międzynarodowej. Precyzja pomiaru wskaźników finansowych jako zmiennych klasyfikujących do zbioru bankrutów lub niebankrutów nie jest więc zbyt wysoka.

Drugie możliwe źródło błędów to metoda doboru prób. W klasycznym ujęciu np. metody dyskryminacyjnej, próby z badanych populacji są wybierane drogą lo-

sową, a ponieważ populacje przedsiębiorstw nie są na ogół zbyt liczne, wymagałoby to losowania niezależnego. W praktyce doboru prób nie przeprowadza się żadnego losowania. Z rejestru sądowego przedsiębiorstw upadłych bierze się na ogół wszystkie firmy upadłe w badanym okresie, czyli nie mamy do czynienia z próbą, a z populacją. Do niej nielosową metodą parowania dobiera się przedsiębiorstwa dobrze funkcjonujące o podobnych parametrach co przedsiębiorstwa upadłe. Nie można więc mówić o doborze losowym, w sensie klasycznym, a więc także o błędzie próbkowania. Testowany błąd klasyfikacji nie wynika z tego, że operujemy próbami losowymi.

Istotnym elementem błędów w prognozowaniu bankructwa jest tzw. bankructwo z przyczyn strategicznych. Zarządcy lub właściciele firmy dobrze prosperującej mogą celowo doprowadzić firmę do bankructwa, wyprowadzając nieco wcześniej jej aktywa np. do „rajów podatkowych”. Żaden model predykcji bankructwa nie uwzględnia celowego działania zarządców firm w kierunku celowego doprowadzenia do bankructwa.

Kolejnym źródłem błędów jest niestabilny charakter badanych populacji. Populacje bankrutów i przedsiębiorstw dobrze funkcjonujących w sytuacji koniunktury gospodarczej nie są identyczne z tymi populacjami w okresie kryzysu gospodarczego. Błąd prognozy może więc zależeć od tego, że model zbudowany został dla danych z okresu koniunktury, a prognoza budowana jest dla firmy w okresie recesji. Należy więc zapytać, czy uwzględnienie w modelach prognostycznych czynników koniunkturalnych może podnieść ich zdolność prognostyczną.

5. Koniunktura gospodarcza jako determinanta bankructwa firmy

W polskiej statystyce publicznej znajdujemy wiele informacji dotyczących koniunktury gospodarczej. Główny Urząd Statystyczny swoje badania koniunktury gospodarczej rozpoczął w 1992 r., badaniem koniunktury gospodarczej w przemyśle. W 1993 r. podjęto badania koniunktury w budownictwie i handlu, a w 2003 r. w usługach. Badania prowadzone są z częstotliwością miesięczną, metodą ankietową [2]. Ankieta dzieli się na część diagnostyczną i prognostyczną. Część diagnostyczna obejmuje m.in. pytania dotyczące oceny: ogólnej sytuacji gospodarczej przedsiębiorstwa, portfela zamówień, w tym zagranicznych, produkcji bieżącej i w ostatnich trzech miesiącach, stanu zapasów wyrobów gotowych. Część prognostyczna obejmuje pytania dotyczące przewidywań kształtowania się tych cech, które były oceniane wcześniej. Wielkości próby to około: dla przemysłu 3500 przedsiębiorstw, dla budownictwa 5000, dla handlu 5000, dla usług 5550 przedsiębiorstw. Wyniki badań publikowane są comiesięcznie w serii *Informacje bieżące – wyniki wstępne* oraz „Biuletynie Statystycznym”.

Na podstawie tak zebranych informacji liczone są następujące grupy wskaźników koniunktury: wskaźniki sektorowe (według PKD 2007) dla przemysłu, budownictwa, handlu, usług; wskaźniki koniunktury według wielkości przedsiębiorstwa:

firmy małe, średnie, duże; wskaźniki proste: lustro koniunktury, wskaźniki intensywności odczuwanych barier; wskaźniki złożone: wskaźnik ogólnego klimatu koniunktury, wskaźnik odczuć ekonomicznych (*Economic Sentiment Indicator* – ESI), syntetyczny wskaźnik koniunktury gospodarczej (*Synthetic Indicator* – SI).

Koniunktura gospodarcza podlega istotnym wahaniom sezonowym. Z tego względu należy dokonywać wyrównywania wahań sezonowych wskaźników koniunktury, pozwalających na wyeliminowanie wpływu zjawisk przyrodniczych na koniunkturę gospodarczą. Do eliminacji wahań sezonowych z szeregów czasowych koniunktury gospodarczej, zgodnie z zaleceniem Eurostatu, jest wykorzystywana metoda TRAMO-SEATS. Odpowiednie szeregi czasowe, po eliminacji wahań sezonowych, prezentowane są comiesięcznie w „Biuletynie Statystycznym” GUS.

Wyrównane szeregi czasowe wskaźników koniunktury pozwalają na budowanie prognoz dotyczących ich przebiegu w przyszłości. Prognozowanie koniunktury gospodarczej jest z jednej strony bardzo potrzebne i może być fascynujące, a z drugiej strony jest to zajęcie trudne i ryzykowne. Ich celem jest określanie długości cykli koniunkturalnych, długości faz wzrostu i spadku koniunktury oraz wyznaczanie punktów zwrotnych. Prostsza sprawą jest budowanie krótkookresowych prognoz sytuacji gospodarczej. Tutaj GUS stosuje tak zwane wskaźniki wyprzedzające (*Composite Leading Indicator* – CLI), zgodnie z metodologią Eurostatu. Szczegóły badania koniunktury gospodarczej są przedstawione w pracy [2].

Głównym wnioskiem wynikającym z prezentowanych dotychczas rozważań jest postulat głoszący konieczność uwzględniania w modelach prognozowania bankructwa oprócz finansowych czynników wewnętrznych także czynników zewnętrznych o charakterze koniunkturalnym, oddziałujących na kondycję finansową przedsiębiorstwa.

6. Możliwości uwzględnienia czynników koniunkturalnych w prognozowaniu bankructwa

Jeśli stwierdzenie, że w procesie prognozowania bankructwa należy uwzględnić zmiany otoczenia gospodarczego firm, których syntetycznym miernikiem jest stan koniunktury gospodarczej, jest wnioskiem oczywistym, to jednak powstaje tutaj wiele problemów metodologicznych. Modele predykcji bankructwa, jako modele klasyfikujące badany obiekt (przedsiębiorstwo) do grupy bankrutów lub do grupy przedsiębiorstw „zdrowych” mają ze swojej natury charakter statyczny. Takimi modelami są przede wszystkim liniowe funkcje dyskryminacyjne. Modele koniunktury gospodarczej mają zaś ze swej natury charakter dynamiczny. Pozostaje więc problem teoretyczny i metodologiczny powiązania modeli klasyfikacji danych z modelami szeregów czasowych.

W sposób bezpośredni można zdynamizować sieć neuronową. Sztuczna sieć neuronowa jest techniką informatyczną wzorowaną na strukturze i sposobie działania układów nerwowych organizmów żywych. Sztuczny neuron jest to model swo-

jego rzeczywistego odpowiednika. Jego zasadniczym celem jest przetworzenie informacji wejściowej, dostarczanej w postaci wektora skończonej liczby sygnałów wejściowych x_1, \dots, x_n w wartość wyjściową y . Sygnały wejściowe mogą mieć charakter dynamiczny, a więc i sygnał wyjściowy może mieć taki charakter. Przyjmuje się, że zarówno wartości wejściowe neuronu, jak i wartość wyjściowa mają postać liczb rzeczywistych. Z każdym wejściem neuronu związany jest współczynnik nazywany wagą. Współczynniki wagowe neuronu są podstawowymi parametrami wpływającymi na sposób funkcjonowania sztucznej komórki nerwowej. Tak jak naturalne komórki nerwowe reagują na bodźce w sposób dynamiczny, tak i sztuczna sieć neuronowa może reagować w ten sposób.

Sieci neuronowe, podobnie jak inne statystyczne metody badania procesów ekonomicznych, opierają się na pewnych założeniach, od których nie można abstrahować, mają swoje zalety i wady, które należy znać i uwzględniać w badaniach empirycznych [21, s. 157]. Niemniej jednak mają one wiele zalet, które czynią je nowoczesnym i atrakcyjnym narzędziem badań ekonomicznych. Do nich należą:

1. Nieliniowość i nieparametryczność. W rzeczywistości społeczno-gospodarczej istnieje ogromna liczba zagadnień, w których wiedza na temat badanego zjawiska jest niewystarczająca, nie jest znana analityczna postać modelu ani nie są znane rozkłady badanych zmiennych losowych. Przewaga sieci neuronowych nad klasycznymi metodami statystycznymi polega na tym, iż są one nieliniowymi metodami nieparametrycznymi, czyli nie jest konieczne określanie *a priori* postaci funkcji tworzącej model ani też czynienia założeń co do wartości parametrów czy też postaci analitycznych rozkładów danych. W wyniku procesu uczenia się sieć nabywa zdolności do przewidywania wyjściowych sygnałów wyłącznie na podstawie obserwacji, bez konieczności stawiania w sposób jawny hipotez o naturze i postaci analitycznej związku pomiędzy danymi wejściowymi i wyjściowymi.

2. Adaptacyjność. Sieć reaguje na zmieniające się charakterystyki zewnętrzne. Jest to szczególnie istotne w prognozowaniu bankructwa firm. Zmieniające się realia ekonomiczne powodują, że budowane modele parametryczne dość szybko tracą swoje właściwości predykcyjne.

3. Równoległość. Sztuczne sieci neuronowe są układem przetwarzającym informacje w sposób równoległy, co pozwala na jednoczesne analizowanie kilku wielkości, z uwzględnieniem nie tylko każdej z osobna, ale również ich współzależności.

4. Miara wiarygodności. Sieci neuronowe nie tylko dokonują klasyfikacji, lecz także dostarczają informację o stopniu wiarygodności przynależności do danej grupy. Pozwala to na eliminowanie danych, które charakteryzują się niejednoznacznością.

5. Uniwersalność. Sieci neuronowe są segmentami wielu identycznych elementów przetwarzających dane. Z tego powodu zasady budowy sieci są bardzo uniwersalne.

Biorąc pod uwagę zalety sieci neuronowych, jako narzędzia prognostycznego, należy wykorzystywać je jako jedną z dynamicznych metod prognozowania bankructwa.

Kolejną drogą dynamizacji modeli prognozowania bankructwa jest dynamizacja modeli logitowych. W modelu logitowym przyjmuje się, że rosnąca funkcja kombinacji liniowej zmiennych X_1, \dots, X_n oraz składnika losowego jest dystrybuantą rozkładu logistycznego. Logit jest logarytmem ilorazu szans przyjęcia oraz nieprzyjęcia wartości 1 przez zmienną losową Y . Wprowadzenie logitu przedstawia zależność prawdopodobieństwa wystąpienia interesującego nas wariantu sytuacji od zmiennych objaśniających sprowadzonych do postaci liniowej [27, s. 310-314]. Macierz danych wejściowych \mathbf{X} może więc mieć postać przekrojowo-czasową. Do estymacji modelu logitowego z reguły stosujemy uogólnioną metodę najmniejszych kwadratów.

Inną obiecującą drogą może być prowadzenie badań eksploracyjnych nad zależnością między intensywnością upadłości przedsiębiorstw a koniunkturą gospodarczą z wykorzystaniem modeli SEM (*Structural Equation Modelling*) [11]. Koniunktura gospodarcza i kondycja przedsiębiorstw w tych badaniach są reprezentowane przez zmienne obserwowalne, stanowiące odzwierciedlenie oddziaływania zjawisk nieobserwowalnych (ukrytych). Podstawowym problemem metodologicznym jest pomiar zmiennej ukrytej. Można to zrobić, budując model relacji między zmienną ukrytą lub zmiennymi ukrytymi a zmiennymi obserwowalnymi, jako model SEM. Za pomocą modelowania strukturalnego można analizować zależności między intensywnością upadłości przedsiębiorstw a koniunkturą gospodarczą.

Podsumowując, należy stwierdzić, że dotychczasowe modele predykcji bankructwa nie są spójnym segmentem systemów wczesnego ostrzegania. Jak to podkreśla U. Siedlecka, „prognozy ostrzegawcze powinny być konstruowane na podstawie wewnętrznej analizy sytuacji gospodarczej kraju, oceny przebiegu trendów wielkości gospodarczych w długich okresach, zmian zachodzących w strukturze obserwowanych wielkości oraz zmian zachodzących w otoczeniu kraju. Z tych właśnie względów w prognozowaniu ostrzegawczym powinny znajdować zastosowanie różnorodne niekonwencjonalne metody prognostyczne, takie jak np. metody heurystyczne, w których podstawowe znaczenie mają sposoby przetwarzania informacji, oparte na indywidualnych i zespołowych ekspertyzach. Informacje uzyskane w taki sposób mają przy tym charakter częściowo jakościowy niż ilościowy” [24, s. 10]. Sygnałem wyjściowym sieci neuronowej oraz modelu logitowego jest określenie prawdopodobieństwa wystąpienia cechy jakościowej, jaką jest fakt bankructwa. Modele równań strukturalnych również w znacznym stopniu uwzględniają nieobserwowalne cechy jakościowe. Przedstawione powyżej trzy możliwości „dynamizacji” modeli prognozowania bankructwa czynią więc zadość wymaganiom stawianym przez systemy wczesnego ostrzegania przedsiębiorstw.

Literatura

- [1] Altman E.I., *Financial ratios, discriminant analysis and prediction of corporate bankruptcy*, „The Journal of Finance” 1968, vol. 23, September.
- [2] *Badanie koniunktury gospodarczej*, Główny Urząd Statystyczny, Warszawa, listopad 2009.

- [3] Bell T.B., Ribar G.S., Verchio J., *Neural nets versus logistic regression: A comparison of each model's ability to predict commercial bank failures*, [w:] R.P. Srivastava (red.), *Proceedings of the 1990 Deloitte and Touché/University of Kansas Symposium of Auditing Problems*, 1990.
- [4] Gajdka J., Stos D., *Wykorzystanie analizy dyskryminacyjnej w ocenie kondycji finansowej przedsiębiorstw*, [w:] R. Borowiecki (red.), *Restrukturyzacja w procesie przekształceń i rozwoju przedsiębiorstw*, Wydawnictwo Akademii Ekonomicznej, Kraków 1996.
- [5] Gruszczyński M., *Modele i prognozy zmiennych jakościowych w finansach i bankowości*, „Monografie i Opracowania” nr 490, SGH, Warszawa 2001.
- [6] Gruszczyński M., *Modele mikroekonometrii w analizie i prognozowaniu zagrożenia finansowego przedsiębiorstw*, „Working papers” no. 34, Instytut Nauk Ekonomicznych PAN, Warszawa 2003.
- [7] Hadasiak D., *Upadłość przedsiębiorstw w Polsce i metody jej prognozowania*, „Zeszyty Naukowe AE w Poznaniu”, seria II, z. 153, Poznań 1998.
- [8] Hellwig Z., Polak H., *Zarys koncepcji statystycznej procedury wczesnego ostrzegania (na przykładzie gospodarki żywnościowej)*, Z prac Zakładu Badań Statystyczno-Ekonomicznych, z. 158, Zakład Badań Statystyczno-Ekonomicznych GUS i PAN, Warszawa 1986.
- [9] Hołda A., *Prognozowanie bankructwa jednostki w warunkach gospodarki polskiej z wykorzystaniem funkcji dyskryminacyjnej Z_{IP}* , „Rachunkowość” 2001, nr 5.
- [10] Hołda A., *Zasada kontynuacji działalności i prognozowanie upadłości w polskich realiach gospodarczych*, Wydawnictwo Akademii Ekonomicznej, seria specjalna nr 174, Kraków 2006.
- [11] Konarski R., *Modelowanie równań strukturalnych*, Wydawnictwo Naukowe PWN, Warszawa 2009.
- [12] Korol T., Prusak B., *Upadłość przedsiębiorstw a wykorzystanie sztucznej inteligencji*, CeDeWu, Warszawa 2005.
- [13] Mączyńska E., *Ocena kondycji przedsiębiorstwa (uproszczone metody)*, „Życie Gospodarcze” 1994, nr 38.
- [14] McKee T.E., *Developing a bankruptcy prediction model via rough sets theory*, „International Journal of Intelligent Systems in Accounting, Finance and Management” 2000, no. 9.
- [15] Michaluk K., *Efektywność modeli prognozujących upadłość przedsiębiorstw*, praca doktorska, Uniwersytet Szczeciński, Szczecin 2000.
- [16] Odom M.D., Sharda R., *A neural network model for bankruptcy prediction*, [w:] *Proceedings of IEEE International Conference on Neural Networks*, vol. 2, San Diego 1990.
- [17] Ohlson J., *Financial ratios and the probabilistic prediction of bankruptcy*, „Journal of Accounting Research” 1980, no. 1.
- [18] Pocięcha J., *Dyskryminacyjne metody klasyfikacji danych w prognozowaniu bankructwa firmy*, [w:] K. Jajuga, M. Walesiak (red.), *Klasyfikacja i analiza danych – teoria i zastosowania*, Prace Naukowe Akademii Ekonomicznej nr 1126, „Taksonomia” 13: Wydawnictwo Akademii Ekonomicznej, Wrocław 2006.
- [19] Pocięcha J., *Problemy prognozowania bankructwa firmy metodą analizy dyskryminacyjnej*, „Acta Universitatis Lodzensis, Folia Oeconomica” nr 205, Łódź 2007.
- [20] Pocięcha J., *Metodologiczne problemy prognozowania bankructwa*, [w:] K. Jajuga, M. Walesiak (red.), *Klasyfikacja i analiza danych – teoria i zastosowania*, Prace Naukowe Uniwersytetu Ekonomicznego nr 107, „Taksonomia 17”, Wydawnictwo Uniwersytetu Ekonomicznego, Wrocław 2010.
- [21] Pocięcha J., *Zastosowania sztucznych sieci neuronowych w prognozowaniu bankructwa firm*, [w:] *Nauki ekonomiczne wobec wyzwań współczesnej gospodarki światowej*, Wydawnictwo Uniwersytetu Ekonomicznego, Kraków 2010.
- [22] Prusak B., *Nowoczesne metody prognozowania zagrożenia finansowego przedsiębiorstw*, Difin, Warszawa 2005.
- [23] Sharda R., Wilson L., *Bankruptcy prediction using neural networks*, „Decision Support System” 1994, nr 11.

- [24] Siedlecka U., *Prognozowanie ostrzegawcze w gospodarce*, PWE, Warszawa 1996.
- [25] Strąk T., Stepień P., *Binomial Logit Models Predicted Corporate Bankruptcy*, Uniwersytet Szczeciński, Szczecin 1999.
- [26] Wędzki D., *Zastosowanie logitowego modelu upadłości przedsiębiorstw*, „*Ekonomista*” 2005, nr 5.
- [27] Zeliaś A., Pawełek B., Wanat S., *Prognozowanie ekonomiczne. Teoria, przykłady, zadania*, Wydawnictwo Naukowe PWN, Warszawa 2004.

BANKRUPTCY PREDICTION MODELS IN THE CORPORATE EARLY WARNING SYSTEM

Summary: Warning predictions and early warning systems are, by their very nature, dynamic. Bankruptcy prediction models, on the other hand, are usually classification models and as such are static. For this reason, they do not constitute cohesive components of early warning systems. The paper is a review of major bankruptcy prediction models and it presents the measures of prediction efficiency based on classification models as well as the possible sources of errors in predicting corporate bankruptcy. The author stresses the necessity of considering business cycles as the major determinants of bankruptcy risk. The final part of the paper discusses the possibility of a dynamic approach to bankruptcy prediction models in artificial neural network, logit and SEM models.