

## **ProfileSEEKER — system informatyczny wczesnego ostrzeżenia małych i średnich przedsiębiorstw przed bankructwem**

**Andrzej Burda**

Wyższa Szkoła Zarządzania i Administracji w Zamościu

**Paweł Cudek, Zdzisław S. Hippe**

Wyższa Szkoła Informatyki i Zarządzania w Rzeszowie

---

### **Streszczenie**

*W artykule przedstawiono budowę systemu informatycznego ProfileSEEKER do wczesnego ostrzeżenia małych i średnich przedsiębiorstw przed bankructwem. Opracowany system stanowi zespół pięciu klasyfikatorów, wykorzystujących różnorodne topologie sztucznych sieci neuronowych oraz sieć przekonania Bayesa, wspomagany metodami nadzorowanego uczenia maszynowego. Sprawność systemu oceniono stosując nową metodę walidacji, nazwaną metodą walidacji kolejkowej.*

### **Wstęp**

Rozwój bądź upadek firmy uzależniony jest od wielu czynników, zarówno wewnętrznych, jak i pochodzących z jej otoczenia (dostawcy, klienci, usługobiorcy, i inni). Niezależnie od wielkości (mikro, małe, średnie, czy duże) oraz typu przedsiębiorstwa (państwowe, prywatne, spółdzielcze, kooperujące, podwykonawcze, itp.), jego zarząd powinien być zainteresowany metodyką, umożliwiającą szybką oraz wiarygodną ocenę zarówno aktualnego stanu firmy, jak i uzyskanie prognozy jego działania na okres co najmniej najbliższego roku.

W przypadku dużych przedsiębiorstw, dysponujących zintegrowanymi systemami informatycznymi zarządzania klasy ERP II (Lech 2003), wspomaganych modułami typu Business Intelligence (Ranjan 2009), warunek ten jest na ogół spełniony. Natomiast w sektorze małych i średnich przedsiębiorstw (zwanym dalej MSP), szczególnie gdy mają charakter biznesu rodzinnego, narzędzia tego typu wykorzystywane są jak dotąd zupełnie sporadycznie.

Przyczyn takiego stanu rzeczy należy upatrywać w dużych kosztach stosowania istniejących na rynku rozwiązań informatycznych oraz ograniczonej możliwości ich wykorzystania, z uwagi na stosunkowo kosztowny proces przygotowania koniecznych danych źródłowych i raportów. Dodatkowo należy wskazać małą skuteczność wspomnianych narzędzi informatycznych w odniesieniu do MSP, ponieważ systemy te budowane są najczęściej z przystosowaniem do baz informacyjnych, dotyczących dużych przedsiębiorstw. Nie bez znaczenia jest też fakt, że właściciele małych i mikro firm nie dysponując odpowiednią wiedzą w obszarze zarządzania, ekonometrii i informatyki (Waniak-Michalak 2007) potrzebują prostszych, bardziej przyjaznych narzędzi.

Taka sytuacja wzbudza niepokój, jeśli krytycznie spojrzymy na realia współczesnej gospodarki. MSP stanowią 99,8% firm działających na obszarze UE i są miejscem pracy dla ponad 67% z wszystkich osób zatrudnionych w sektorze prywatnym (Schmiemann 2008). Również w Polsce, udział sektora MSP jest dominujący i do roku 2008 stale się zwiększał (Żołnierski 2009). Niewielki spadek liczby omawianych przedsiębiorstw zanotowano w 2009 roku, po czym w kolejnych latach

2010–2011 odnotowano trend wzrostowy (Łapiński 2011). Jednocześnie badania prowadzone przez European Network for SME Research (Iwanienko 2009) wykazały, że na 7662 małych i średnich przedsiębiorstwach UE ok. 30% MSP upada w ciągu pierwszych 3 lat, a 50% w ciągu pierwszych 5 lat swojego istnienia.

Jeśli do tego dodać, że polscy pracodawcy szacują, że ok. 21,5% czasu poświęcają na prace, które leżą w kompetencji pracowników niższego szczebla, a wśród ośmiu najważniejszych zadań analiza sytuacji ekonomiczno-finansowej i planowanie rozwoju firmy nie są nawet wymieniane (Starczewska-Krzysztosek 2008), to nasuwa się przypuszczenie, że istotną barierą rozwoju MSP w Polsce są określone braki w dziedzinie informatyzacji. Polegają one najczęściej na dość rozpowszechnionej rezygnacji z korzystania z prostych, a jednocześnie skutecznych narzędzi informatycznych do rutynowej oceny stanu rozważanych przedsiębiorstw, z możliwością wiarygodnego prognozowania ich stanu w niezbyt odległej perspektywie czasowej.

Te spostrzeżenia zainspirowały autorów niniejszej publikacji do podjęcia badań nad opracowaniem, implementacją oraz upowszechnieniem skutecznego narzędzia informatycznego, którego zastosowanie mogłoby wypełnić zarysowaną na wstępie lukę.

## 1. Systemy wczesnego ostrzegania małych i średnich przedsiębiorstw o zagrożeniu bankructwem

Zjawisko upadłości przedsiębiorstw, w teorii ekonomii, jest zjawiskiem naturalnym, a nawet pożądanym. Jest jednym z regulatorów systemu ekonomicznego. Podmioty mniej użyteczne, ze społecznego punktu widzenia, a z ekonomicznego mało efektywne, zastępowane są przez inne, dla których pojawiają się nowe perspektywy zbytu towarów bądź usług. Jednakże każdy taki upadek w skali mikro, to niejednokrotnie nie tylko utrata źródła utrzymania dla pracodawcy i pracowników, ale również spore problemy dla otoczenia społeczno-ekonomicznego, m.in. wierzycieli, kooperantów, czy samorządów lokalnych (Korol i Prusak 2005). Dlatego wczesne ostrzeganie przed bankructwem, szczególnie w dobie coraz silniejszych powiązań organizacji z jej otoczeniem, staje się dla wszystkich uczestników rynku niezwykle istotne.

Najstarsze modele wczesnego ostrzegania przed bankructwem opierały się na poszukiwaniu zależności tej oceny od jednego deskryptora (Beaver 1966). Ze względu na to, że analiza wpływu różnych deskryptorów na ocenę tego samego przedsiębiorstwa może prowadzić do zróżnicowanych, często sprzecznych wyników, rozpowszechniły się próby wykorzystania metod wielowymiarowych. Pierwszym opisanym w literaturze modelem tego typu był model Z-score Altmana (1968) zbudowany metodą wielowymiarowej analizy dyskryminacyjnej (MDA — *Multiple Discriminant Analysis*). W kolejnych latach model ten rozwijany był przez samego Altmana (Altman 2001; Altman i inni 1994) oraz innych badaczy (Fulmer i inni 1984). Najbardziej znane polskie modele tego typu opisano w (Antonowicz 2007; Gajdka i Stos 1996; Hadasik 1998; Hamrol i Chodakowski 2008).

Badania podjęte w latach 80-tych ubiegłego wieku, z wykorzystaniem innych sposobów klasyfikacji opartych na metodach statystycznych, doprowadziły do opracowania wielu alternatywnych modeli. Wśród nich na szczególną uwagę zasługują modele logitowe (LR — *Logistic Regression*) (Ohlson 1980), dyskryminacji metodą  $k$ -tego najbliższego sąsiada (kNN, *kth-Nearest Neighbor*) (Tam i Kiang 1990), klasyfikacji przy pomocy drzew decyzji (DT- Decision Tree) (Frydman i inni 1985), sieci przekonań Bayes'a (BBN- Bayesian Belief Network) (Sarkar i Sriram 2001), wektorów nośnych (SVM) (Chaudhuri i De 2011), wnioskowania przez przypadki (CBR) (Jo i inni 1997), algorytmów genetycznych (Varetto 1998), zbiorów przybliżonych (Greco i inni 1998), czy sztucznych sieci neuronowych o architekturze MLP (Atiya 2001; Odom i Sharda 1990; Piramuthu i inni 1998), SOM (Kaski i inni 2001; SerranoCinca 1996) oraz sieci autoasocjacyjnych (Baek i Cho 2003).

Porównania jakości modeli (Altman i inni 1994; Coats i Fant 1993; McKee i Greenstein 2000; Salchenberger i inni 1992; Tam 1991; Tseng i Hu 2010; Wu i inni 2010) w zależności od horyzontu czasowego prognozy, branży bądź rodzaju firm czy rejonu ich funkcjonowania wypadają różnie. Generalnie można jednak stwierdzić, że wiele wskazuje na to, że nie da się z góry przewidzieć, która z nich w konkretnych okolicznościach (dla określonego zbioru badawczego) będzie najlepsza.


Przy ich wyborze należy kierować się tym, czy potrafią one poprawnie odpowiedzieć na wszystkie postawione problemy badawcze.

Zdecydowana większość realizowanych na ten temat badań, prowadzona jest na przykładach firm dużych, których akcje są na ogół notowane na giełdach papierów wartościowych. Uwarunkowania prawne dotyczące tej grupy podmiotów gospodarczych, ułatwiają dostęp do wszelkich danych na temat ich działalności, co niezwykle ułatwia nie tylko proces budowy modelu, ale przede wszystkim jego walidację. Nietypowe przypadki, czy dane zawierające intencjonalne lub losowe błędy, można wtedy dodatkowo weryfikować — potwierdzić, poprawić, bądź uzupełnić. Można też, w przypadku błędnych klasyfikacji poznać bliżej przyczynę tego zjawiska, stosując inne dane lub modele. W odniesieniu do MSP jest to niezwykle utrudnione; ze względu na brak jawności danych, pogłębiona analiza tych błędów wymaga użycia specjalnych metod badawczych, a często nawet w ogóle nie jest możliwa.

Dodatkowym utrudnieniem analizy danych gospodarczych MSP jest fakt, że ok. 78% tych przedsiębiorstw w Polsce, to przedsiębiorstwa rodzinne, którymi kierują dwie skrajnie różne logiki postępowania: racjonalna (ekonomiczna) i emocjonalna (rodzinna). Może to być równie często źródłem jej trwania nawet wbrew logice biznesowej, jak również, szczególnie w przypadku zaistnienia problemów rodzinnych, źródłem jej nieoczekiwanego upadku (Marjański 2011). Przypuszczalnie z powyższych powodów oraz podejrzenia, że znaczna liczba wyników finansowych firm może zawierać przypadkowe oraz intencjonalne zniekształcenia, dokładność klasyfikacji modeli dla tej grupy firm jest istotnie mniejsza niż dla dużych firm i kształtuje się w granicach od 61 do 87%, jak wynika z najnowszych doniesień naukowych (Derelioglu i Gurgun 2011; Kim i Sohn 2010; Ribeiro i inni 2012). Wydaje się jednak, że analiza nawet takich, niezwykle „trudnych” danych wybranymi metodami uczenia maszynowego, przypuszczalnie może doprowadzić do uzyskania wiarygodnych prognoz typu przetrwanie/bankructwo.

## 2. Istota opracowanej metodyki prognozowania stanu małych i średnich przedsiębiorstw

W przypadku zjawisk społeczno-gospodarczych, a do takich zaliczyć należy pojęcie stanu przedsiębiorstwa, ze względu na dużą złożoność zjawiska, i brak dostatecznie sformalizowanych teorii, parametryzacja modeli odbywa się najczęściej z wykorzystaniem danych historycznych. Schemat takiego empirycznego podejścia, pokazany jest na rysunku 1. Jeżeli modelowane zjawisko opisane jest atrybutami objaśniającymi ( $p_i$ ) oraz jedno lub wielowymiarową zmienną zależną ( $y_i$ ), to część dostępnych danych wykorzystywanych jest w procesie parametryzacji modelu, pozostałe do jego walidacji. W szczególnym przypadku, przeważnie wtedy, gdy dysponujemy ograniczoną liczbą przypadków, proces walidacji modelu może być realizowany na tym samym zbiorze danych, co proces jego parametryzacji. Ta szczególna technika sprawdzania poprawności modelu znana jest pod nazwą resubstytucji (Reich i Barai 1999).



Rys. 1. Schemat procesu modelowania

Należy jednak zaznaczyć, że zawsze kluczowym zagadnieniem modelowania, rozstrzyganym już we wstępnym etapie tego procesu, jest zdefiniowanie atrybutu, bądź atrybutów zależnych, decyzyjnych. Kolejnym ważnym etapem jest wybranie spośród wielu deskryptorów (atrybutów objaśniających) takich, które charakteryzują się możliwie największym oddziaływaniem na wartość atrybutów decyzyjnych. Następnie należy wybrać/stworzyć metodykę realizacji modelu, która uwzględniać będzie specyfikę danych. Trzeba też wspomnieć, że dla większości metod, wykorzystywanych w modelowaniu zjawisk ekonomicznych, zależność ta nie musi mieć charakteru przyczynowo-skutkowego a wystarczy, aby miała charakter symptomatyczny.

Wspomniane specyficzne uwarunkowania danych MSP powodują znaczne zróżnicowanie jakości predykcji różnych modeli uczenia maszynowego. Taka sytuacja skutkuje dużym ryzykiem błędu wnioskowania w przypadku zastosowania jednego, autonomicznego modelu do budowy systemu doradczego. Dlatego uznano za celowe zastosowanie zespołu klasyfikatorów zbudowany w oparciu o filozofię WMA (weighted majority algorithm) (Littlestone i Warmuth 1994; Sun i Li 2008; Torabi i inni 2005) oraz zastosowanie specjalnej, autorskiej metody walidacji, ze względu na swój charakter nazwaną walidacją kolejkową (Burda i Hippe 2010).

Przeprowadzone przez nas badania potwierdziły przypuszczenie, że model zespołowy, złożony z pięciu klasyfikatorów (sztucznych sieci neuronowych typu liniowego, perceptronu trójwarstwowego i czterowarstwowego, sieci neuronowej o radialnych funkcjach bazowych oraz zbioru reguł wygenerowanych z sieci przekonań Bayesa) cechował się najmniejszymi błędami prognozy dla całego zbioru badawczego obejmującego lata 1999–2007.

Należy też dodać, że szczególnie ważne dla systemu doradczego jest wykorzystanie w tej metodyce zbioru reguł decyzji postaci: **JEŻELI..., TO...**, które realizują nie tylko wspólne zadanie klasyfikacyjne, ale stanowią moduł objaśniający zaprojektowanego systemu.

### 3. Opis implementacji systemu — narzędzie informatyczne *ProfileSEEKER*

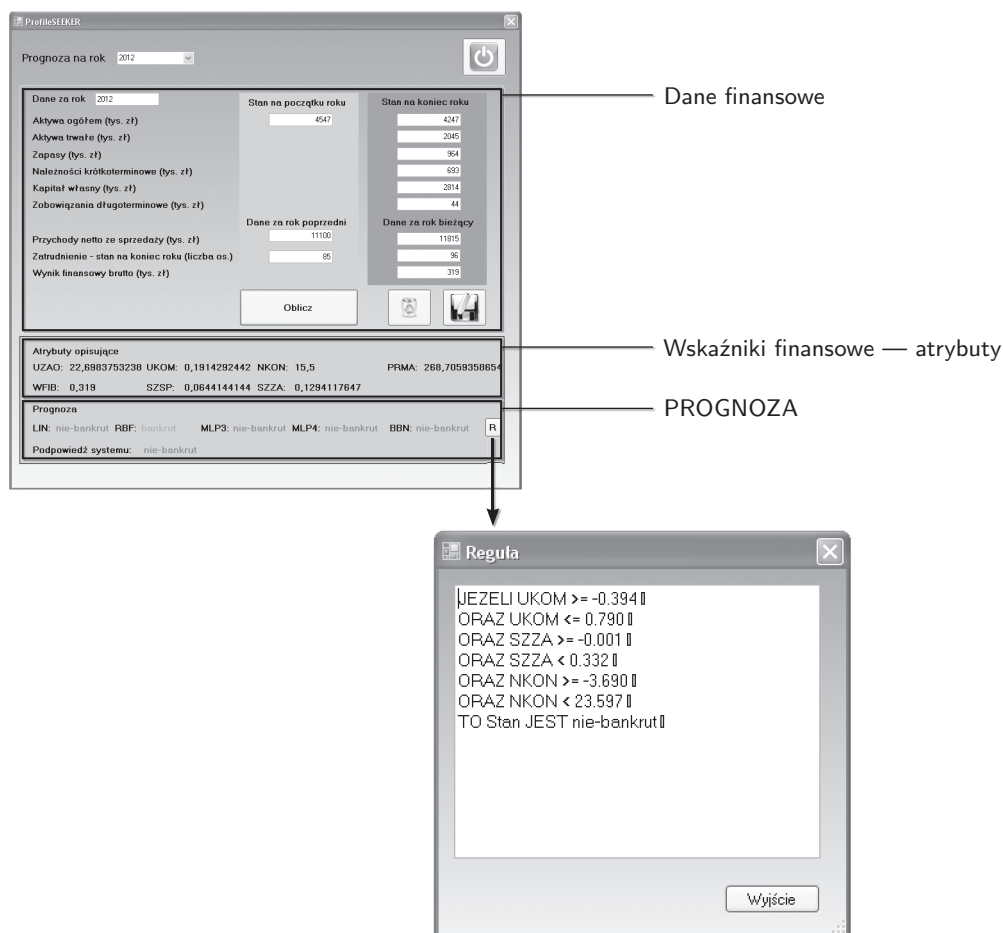
Użytkownik w oknie Dane finansowe (rys. 2) wprowadza informację o analizowanym roku działalności przedsiębiorstwa oraz dane (niezbędne) ze sprawozdania finansowego firmy. Po wypełnieniu wszystkich pól i użyciu przycisku Oblicz, system przypisuje wprowadzone dane określonym w tabeli 1 wskaźnikom ekonomiczno-finansowym firmy (atrybutom). Definicje oraz znaczenie tych wskaźników zostały przyjęte na podstawie (Nowak 2006). Dane te można zapisać (przycisk oznaczony symbolem dyskietki) w wewnętrznej, XML-owej bazie danych, lub usunąć (przycisk Kosz). Drugie okno systemu (Wskaźniki finansowe — atrybuty) ukazuje skróty nazw tych wskaźników oraz ich wartości. Tutaj, kursor myszki ujawnia pełną nazwę danego atrybutu.

Okno trzecie, Prognoza, informuje o kategorii (bankrut/nie-bankrut) przypisanej analizowanej firmie. Dla modelu BBN, po naciśnięciu przycisku R (jak Reguła), pojawia się dodatkowe okno przedstawiające regułę wnioskowania, która doprowadziła do wydania określonej konkluzji.

Należy też dodać, że wprowadzone i zapisane dane mogą być wielokrotnie odtwarzane z bazy danych systemu, i ponownie analizowane.

Tab. 1. Atrybuty opisujące stan badanych obiektów

Lp.	Nazwa atrybutu	Symbol
1	Udział zapasów w aktywach ogółem . . . . .	UZAO
2	Udział kapitału obrotowego w finansowaniu majątku ogółem	UKOM
3	Niedobór kapitału obrotowego netto . . . . .	NKON
4	Produktywność majątku. . . . .	PRMA
5	Wynik finansowy brutto. . . . .	WFIB
6	Stopa zmian sprzedaży. . . . .	SZSP
7	Stopa zmian zatrudnienia. . . . .	SZZA



Rys. 2. Graficzny interfejs użytkownika programu ProfileSEEKER

## Wnioski

Analiza dostępnych danych literaturowych oraz przeprowadzone badania własne wskazują na szczególne właściwości finansowo-ekonomiczne małych i średnich przedsiębiorstw. Właściwości te zostały uwzględnione w wewnętrznych algorytmach nowo-opracowanego systemu informatycznego ProfileSEEKER<sup>(1)</sup>, przeznaczonego do oceny stanu rozpatrywanych przedsiębiorstw oraz prognozowaniu ich dychotomicznego zachowania się (bankrut, nie-bankrut) w okresie co najmniej najbliższego roku. Badania wiarygodności prognoz, wydanych przez omawiane narzędzie informatyczne, wykazały ich zadawalającą skuteczność, zaś prosty i intuicyjny interfejs użytkownika może przyczynić się do upowszechnienia opracowanego systemu.

## Literatura

- ALTMAN E.I. (1968): *Financial Ratios, Discriminant Analysis and Prediction of Corporate Bankruptcy*. „Journal of Finance”, nr 23 (4), s. 589–609.
- ALTMAN E.I. (2001): *Predicting Financial Distress of Companies: Revisiting the Z-score and ZETA® Models* (Originally Published in, Journal of Banking & Finance, 1 1977). [dostęp: 2012.10.03], [@:] <http://people.stern.nyu.edu/ealtman/Zscores.pdf>.
- ALTMAN E.I., MARCO G., VARETTO F. (1994): *Corporate Distress Diagnosis — Comparisons Using Linear Discriminant-Analysis and Neural Networks (the Italian Experience)*. „Journal of Banking & Finance”, nr 18 (3), s. 505–529.
- ANTONOWICZ P. (2007): *Metody oceny i prognoza kondycji ekonomiczno-finansowej przedsiębiorstw*. Gdańsk, Ośrodek Doradztwa i Doskonalenia Kadr.

1. Wersję instalacyjną ProfileSEEKER można pobrać ze strony Katedry Informatyki i Inżynierii Wiedzy Wyższej Szkoły Zarządzania i Administracji w Zamościu (<http://www.wszia.edu.pl/index.php?p=katedra-informatyki-i-inzynierii-wiedzy>).

- ATIYA A.F. (2001): *Bankruptcy Prediction for Credit Risk Using Neural Networks. A Survey and New Results*. „Ieee Transactions on Neural Networks”, nr 12 (4), s. 929–935.
- BAEK J., CHO S.Z. (2003): *Bankruptcy Prediction for Credit Risk Using an Auto-Associative Neural Network in Korean Firms*. „2003 Ieee International Conference on Computational Intelligence for Financial Engineering, Proceedings”, s. 25–29.
- BEAVER W.H. (1966): *Financial Ratios as Predictors of Failure*. „Journal of Accounting Research”, nr 4, s. 71–111.
- BURDA A., HIPPE Z.S. (2010): *Uncertain Data Modeling. The Case of Small and Medium Enterprises*. 3rd International Conference on Human System Interaction, 2010.05.13–15, Rzeszów.
- CHAUDHURI A., DE K. (2011): *Fuzzy Support Vector Machine for Bankruptcy Prediction*. „Applied Soft Computing”, nr 11 (2), s. 2472–2486.
- COATS P.K., FANT L.F. (1993): *Recognizing Financial Distress Patterns Using a Neural-Network Tool*. „Financial Management”, nr 22 (3), s. 142–155.
- DERELIOGLU G., GURGEN F. (2011): *Knowledge Discovery Using Neural Approach for SME's Credit Risk Analysis Problem in Turkey*. „Expert Systems with Applications”, nr 38 (8), s. 9313–9318.
- FRYDMAN H., ALTMAN E.I., KAO D.L. (1985): *Introducing Recursive Partitioning for Financial Classification — the Case of Financial Distress*. „Journal of Finance”, nr 40 (1), s. 269–291.
- FULMER J.G.J., MOON J.E., GAVIN T.A., ERWIN M.J. (1984): *A Bankruptcy Classification Model For Small Firms*. „Journal of Commercial Bank Lending”, nr 66 (11), s. 25–37.
- GAJDKA J., STOS D. (1996): *Wykorzystanie analizy dyskryminacyjnej w ocenie kondycji finansowej przedsiębiorstw*. [w:] R. Borowiecki (red.): *Restrukturyzacja w procesie przekształceń i rozwoju przedsiębiorstw*, Kraków, Wydawnictwo Akademii Ekonomicznej w Krakowie.
- GRECO S., MATARAZZO B., SLOWINSKI R. (1998): *A New Rough Set Approach to Multicriteria and Multiattribute Classification*. „Lecture Notes in Computer Science”, nr 1424, s. 60–67.
- HADASIK D. (1998): *Upadłość przedsiębiorstw w Polsce i metody jej prognozowania*. Zeszyty Naukowe/Akademia Ekonomiczna w Poznaniu. Seria 2, Prace Habilitacyjne, t. 153, Poznań, Wydawnictwo AE.
- HAMROL M., CHODAKOWSKI J. (2008): *Prognozowanie zagrożenia finansowego przedsiębiorstwa. Wartość predykcyjna polskich modeli analizy dyskryminacyjnej*. „Badania operacyjne i decyzje”, nr 3, s. 17–32.
- IWANIENKO I. (2009): *Wpływ fazy rozwoju projektu innowacyjnego na możliwość wyboru źródła finansowania przedsiębiorstw przemysłowych*. [w:] A. Nalepka i A. Ujwary-Gil (red.): *Organizacje komercyjne i niekomercyjne wobec wzmożonej konkurencji oraz wzrastających wymagań konsumentów*, Nowy Sącz, Wyższa Szkoła Biznesu.
- JO H.K., HAN I.G., LEE H.Y. (1997): *Bankruptcy Prediction Using Case-Based Reasoning, Neural Networks, and Discriminant Analysis*. „Expert Systems with Applications”, nr 13 (2), s. 97–108.
- KASKI S., SINKKONEN J., PELTONEN J. (2001): *Bankruptcy Analysis with Self-Organizing Maps in Learning Metrics*. „Ieee Transactions on Neural Networks”, nr 12 (4), s. 936–947.
- KIM H.S., SOHN S.Y. (2010): *Support Vector Machines for Default Prediction of SMEs Based on Technology Credit*. „European Journal of Operational Research”, nr 201 (3), s. 838–846.
- KOROL T., PRUSAK B. (2005): *Upadłość przedsiębiorstw a wykorzystanie sztucznej inteligencji*. Warszawa, CeDeWu.
- LECH P. (2003): *Zintegrowane systemy zarządzania ERP/ERP II. Wykorzystanie w biznesie, wdrażanie*. Warszawa, LST — Logika Systemy Technologia: “Difin”.
- LITTLESTONE N., WARMUTH M.K. (1994): *The Weighted Majority Algorithm*. „Information and Computation”, nr 108 (2), s. 212–261.
- ŁAPIŃSKI J. (2011): *Stan sektora małych i średnich przedsiębiorstw w Polsce*. [w:] A. Brussa i A. Tarnawa (red.): *Raport o stanie sektora małych i średnich przedsiębiorstw w Polsce*, Warszawa, Polska Agencja Rozwoju Przedsiębiorczości.
- MARJAŃSKI A. (2011): *Najnowsze badania w kontekście rozwoju przedsiębiorstw rodzinnych w Polsce*. Firmy rodzinne — nowe drogi rozwoju. Zakończenie Projektu Szkoleniowo-Doradczego Firmy Rodzinne, 2011.09.07–09, Zawiercie.
- MCKEE T.E., GREENSTEIN M. (2000): *Predicting Bankruptcy Using Recursive Partitioning and a Realistically Proportioned Data Set*. „Journal of Forecasting”, nr 19 (3), s. 219–230.

- NOWAK E. (2006): *Propozycje zmiennych oceniających kondycję ekonomiczno-finansową przedsiębiorstw*. „Barometr Regionalny. Pismo społeczno-gospodarcze”, nr 6, s. 35–41.
- ODOM M.D., SHARDA R. (1990): *A Neural Network Model for Bankruptcy Prediction*. „International Joint Conference on Neural Networks, Vols 1–3”, s. B163-B168.
- OHLSON J.A. (1980): *Financial Ratios and the Probabilistic Prediction of Bankruptcy*. „Journal of Accounting Research”, nr 18 (1), s. 109–131.
- PIRAMUTHU S., RAGAVAN H., SHAW M.J. (1998): *Using Feature Construction to Improve the Performance of Neural Networks*. „Management Science”, nr 44 (3), s. 416–430.
- RANJAN J. (2009): *Business Intelligence: Concepts, Components, Techniques and Benefits*. „Journal of Theoretical and Applied Information Technology”, nr 9 (1), s. 60–70.
- REICH Y., BARAI S.V. (1999): *Evaluating Machine Learning Models for Engineering Problems*. „Artificial Intelligence in Engineering”, nr 13 (3), s. 257–272.
- RIBEIRO B., SILVA C., CHEN N., VIEIRA A., DAS NEVES J.C. (2012): *Enhanced Default Risk Models with SVM*. „Expert Systems with Applications”, nr 39 (11), s. 10140–10152.
- SALCHENBERGER L.M., CINAR E.M., LASH N.A. (1992): *Neural Networks — a New Tool for Predicting Thrift Failures*. „Decision Sciences”, nr 23 (4), s. 899–916.
- SARKAR S., SRIRAM R.S. (2001): *Bayesian Models for Early Warning of Bank Failures*. „Management Science”, nr 47 (11), s. 1457–1475.
- SCHMIEMANN M. (2008): *Enterprises by Size Class — Overview of SMEs in the EU*. „Statistics in focus”, nr 31, s. 1–8.
- SERRANO-CINCA C. (1996): *Self Organizing Neural Networks for Financial Diagnosis*. „Decision Support Systems”, nr 17 (3), s. 227–238.
- STARCZEWSKA-KRZYSZTOSZEK M. (2008): *Bariery rozwoju małych i średnich przedsiębiorstw w Polsce*. „Infos”, nr 4 (28), s. 1–4.
- SUN J., LI H. (2008): *Listed Companies' Financial Distress Prediction Based on Weighted Majority Voting Combination of Multiple Classifiers*. „Expert Systems with Applications”, nr 35 (3), s. 818–827.
- TAM K.Y. (1991): *Neural Network Models and the Prediction of Bank Bankruptcy*. „Omega”, nr 19 (5), s. 429–445.
- TAM K.Y., KIANG M.Y. (1990): *Predicting Bank Failures: A Neural Network Approach*. „Applied Artificial Intelligence”, nr 4 (4), s. 265–282.
- TORABI K., SAYAD S., BALKE S.T. (2005): *On-Line Adaptive Bayesian Classification for In-Line Particle Image Monitoring in Polymer Film Manufacturing*. „Computers & Chemical Engineering”, nr 30 (1), s. 18–27.
- TSENG F.M., HU Y.C. (2010): *Comparing Four Bankruptcy Prediction Models: Logit, Quadratic Interval Logit, Neural and Fuzzy Neural Networks*. „Expert Systems with Applications”, nr 37 (3), s. 1846–1853.
- VARETTO F. (1998): *Genetic Algorithm Applications in the Analysis of Insolvency Risk*. „Journal of Banking and Finance”, nr 22, s. 1421–14–39.
- WANIAK-MICHALAK H. (2007): *Pozabankowe źródła finansowania małych i średnich przedsiębiorstw: fundusze pożyczkowe, fundusze poręczeniowe, rynek venture capital*. Kraków–Warszawa, Wolters Kluwer Polska.
- WU Y., GAUNT C., GRAY S. (2010): *A Comparison of Alternative Bankruptcy Prediction Models*. „Journal of Contemporary Accounting & Economics”, nr 6 (1), s. 34–45.
- ŻOŁNIERSKI A. (2009): *Znaczenie sektora MŚP w Polsce*. [w:] A. Żołnierski (red.): *Raport o stanie sektora małych i średnich przedsiębiorstw w Polsce w latach 2007–2008*, Warszawa, Polska Agencja Rozwoju Przedsiębiorczości.