

# Współczesna Gospodarka



Contemporary Economy  
Electronic Scientific Journal  
www.wspolczesnagospodarka.pl

Vol. 7 Issue 2 (2016) 21-36  
ISSN 2082-677X

## METODY NEURONOWE DO PROGNOZOWANIA FINANSOWEGO

**Jerzy Balicki, Piotr Dryja, Waldemar Korlub, Piotr Przybyłek, Maciej Tyszka,  
Marcin Zadroga, Marcin Zakidalski**

### Streszczenie

Sztuczne sieci neuronowe mogą być stosowane do prognozowania kursów akcji na giełdzie, oceny wiarygodności kredytobiorców czy prognozowania kryzysów bankowych. W referacie omówiono zasady współpracy sieci neuronowych z algorytmami ewolucyjnymi oraz metodą wektorów wspierających. Ponadto, odniesiono się do pozostałych metod sztucznej inteligencji, które stosowane są w finansach.

**Słowa kluczowe:** sztuczne sieci neuronowe, inwestowanie na giełdzie papierów wartościowych, metody ewolucyjno-neuronowe

### Wstęp

Sztuczne sieci neuronowe (ANN, od ang. *Artificial Neural Networks*) stosowane są coraz częściej do wspomagania inwestycji giełdowych. Aplikacje tej klasy używane są jako jedna z wielu platform doradczych, co szeroko opisał w swojej pracy Gately. ANN wykorzystują dane historyczne, które dostępne są w ramach analizy technicznej.


Sztuczne sieci neuronowe stosuje się także do predykcji kryzysów w sektorze bankowym, co jest istotne do „wczesnego ostrzegania” przed zachwianiem stabilności sektora finansowego. Bankowość to system naczyń połączonych, w którym upadłość jednego z banków mogą wywołać efekt domina. Kryzysy finansowe występują względnie często, a kryzysy w zakresie bankowości obserwuje się rzadziej. W ciągu ostatnich czterdziestu lat zaobserwowano około 100 kryzysów bankowych w różnych częściach świata.

Warto także zauważyć, że kryzys bankowy w Polsce w 2009 roku zachwiał dosyć mocno gospodarką krajową, gdyż PKB spadło o 13,5%, z 364 mld euro do 315 mld euro. Załamanie nie było długotrwałe, gdyż już w 2010 roku gospodarka została odbudowana do poziomu PKB 360 mld euro, a w 2014 roku PKB osiągnęło 408 mld euro wg danych Eurostatu.

W pierwszej części pracy omówiono prognostyczne sieci neuronowe do gry na giełdzie papierów wartościowych. Następnie scharakteryzowano metody ewolucyjno-neuronowe w kontekście badań nad wiarygodnością kredytobiorców. Za zakończenie odniesiono się do neuronowych metod stosowanych do szacowania ryzyka sektora bankowego w celu wczesnego ostrzegania przed nieprawidłowościami w bankowości.

## 1. Sztuczne sieci neuronowe do wspomaganie inwestycji giełdowych

Neuronowa sieć jednokierunkowa złożona jest zazwyczaj z kilku warstw neuronów: wejściowej, jednej lub więcej warstw ukrytych, a także warstwy wyjściowej (rys. 1). Predykcja może dotyczyć zarówno cech o wartościach liczbowych, jak i symbolicznych. W przypadku przewidywania wartości liczbowych mówimy o regresji, natomiast w przypadku wartości symbolicznych - o klasyfikacji. W kontekście predykcji giełdowej mamy do czynienia ze specyficznym problemem przewidywania wartości szeregów czasowych.



**Rysunek. 1.** Diagram wielowarstwowej sieci neuronowej do wspomaganie inwestycji giełdowych

Możliwe jest uczenie z nauczycielem, kiedy na wejścia sieci podawane są dane testowe z giełdy, a następnie sieć oblicza wynik. Rezultat ten jest porównywany z wzorcowym wynikiem, co umożliwia skorygowanie wag<sup>1</sup>. Predykcja giełdowa w oparciu o dane z historycznych notowań jest trudnym zadaniem<sup>2</sup>. Przyczyną problemów jest charakterystyka danych, które w dużej mierze podlegają wpływowi czynników losowych. Zazwyczaj występują duże rozmiary zbiorów uczących. Wielkości zbiorów uczących zależą od częstotliwości pobierania danych z giełdy, która może odbywać się nawet co sekundę. Niektórzy autorzy proponowali znaczące zmniejszenie intensywności pobierania danych z giełdy<sup>3</sup>. Z drugiej strony obecnie, w czasach zmniejszających się kosztów przestrzeni dyskowej i mocy obliczeniowej, idea przetwarzania wielkich zbiorów danych, wydaje się cieszyć coraz większą popularnością. Związane jest to oczywiście z będącymi obecnie w centrum zainteresowania technologiami *Big Data*<sup>4 5</sup>.

Bardziej realna wydaje się analiza notowań o interwale o długości jednego dnia, gdyż ceny akcji oraz instrumentów finansowych na otwarciu i zamknięciu sesji giełdowej stabilizują się. Wynika to z charakterystyki faz sesji giełdowej. W fazie przed otwarciem i przed zamknięciem można składać i anulować zlecenia kupna i sprzedaży. Transakcje realizowane są natomiast

<sup>1</sup> Davis E. P., Karim D.: *Comparing early warning systems for banking crises*. Journal of Financial Stability, vol. 4, no. 2, 2008, p. 89.

<sup>2</sup> Srivastava R. P.: *Automating judgmental decisions using neural networks: a model for processing business loan applications*, Proceedings of the 1992 ACM Annual Conf. on Communications, p. 355.

<sup>3</sup> Demirguc-Kunt A., Detragiache E.: *Monitoring banking sector fragility: a multivariate logit approach*. World Bank Economic Review, vol. 14, no. 2, 2000, p. 287.

<sup>4</sup> <http://iknowfirst.com/the-big-data-solution-for-wall-street>

<sup>5</sup> <http://hortonworks.com/blog/building-stock-trading-strategies-20-faster-with-hadoop/>

dopiero w kolejnych fazach - otwarcia i zamknięcia. Dzięki temu kurs akcji na zamknięciu i otwarciu jest mniej wrażliwy na wahania spowodowane emocjami inwestorów.

Ponadto, od każdej transakcji kupna i sprzedaży makler pobiera prowizję w wysokości około 0,3%. W konsekwencji w celu uzyskania zysku trzeba sprzedać akcje po cenie przynajmniej 0,6% większej od ceny, po której zostały zakupione. Stosunkowo wysokie prowizje maklerów wykluczają zyskowość bardzo częstych transakcji rynkowych dla instrumentów finansowych o stabilnym kursie. Z tego względu problem rozwiązują kontrakty terminowe.

Prognozę utrudnia też niewielka ilość informacji w notowaniach. Notowania dostarczone przez Giełdę Papierów Wartościowych składają się z pięciu kolumn: cena otwarcia, najwyższa cena danego dnia, najniższa cena danego dnia, cena zamknięcia oraz wolumen obrotu. Sieć neuronowa musi opierać się na zaledwie pięciu cechach bazowych, które w dodatku w dużym stopniu zależą od czynników losowych. Zagadnienie jest o tyle trudne, że mimo potencjalnie niskiego stopnia złożoności, wynikającego z niewielkiej liczby cech, ludzki umysł nie jest w stanie go rozwiązać z wysoką skutecznością.

Co do możliwości uczenia sieci neuronowych w sposób nienadzorowany, w kontekście inwestycji giełdowych, jest to wykorzystywane m.in. w celu wykrywania anomalii. Anomaliami tymi może być zarówno niespotykana sytuacja na rynku, jak też sprawdzaniu podlegać mogą pojedyncze transakcje na rynku (w celu wykrycia nadużyć)<sup>6</sup>.

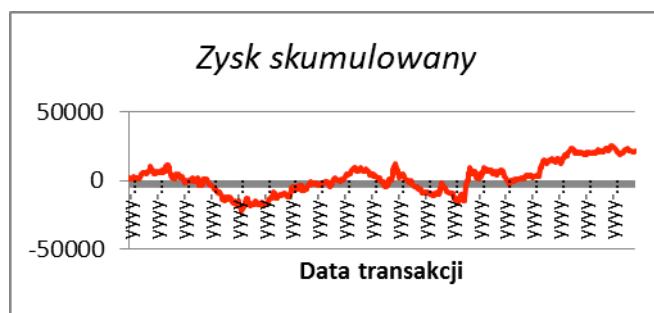
W ramach próby wydobycia z danych większej ilości informacji, przed wykorzystaniem ich w uczeniu sieci, należy poddać je procesowi wstępnego przetwarzania. Pierwszym krokiem jest sprowadzenie problemu do analizy szeregów czasowych. W pojedynczym przykładzie uczącym znalazły się procentowe zmiany wartości bazowych dla wybranej liczby kolejnych sesji giełdowych. Następnie, przykłady uczące powinny być rozbudowane o wartości wskaźników giełdowych. Wskaźniki można podzielić na dwie grupy: wskaźniki zależne lub niezależne od opóźnienia.

Wskaźniki zależne od opóźnienia to takie, których parametrem jest liczba kolejnych wartości, a przykładem takiego wskaźnika jest średnia krocząca. W jej przypadku wartość opóźnienia określa, z jakiej liczby historycznych wartości obliczana jest wartość średniej. Takie wskaźniki pozwalają wyznaczyć kierunek trendu, a także pomagają przewidywać jego zmianę oraz agregować informacje z dłuższego okresu. W proponowanym modelu wskaźniki oblicza się dla każdej z wartości bazowych oraz dla opóźnień wynoszących 3, 7, 14 i 30 dni. Wyznacza się także inne wskaźniki: regresja liniowa, kierunek regresji liniowej, tempo zmian, indeks względnej stabilności, a także wykładnicza średnia krocząca. Ponadto oblicza się wskaźniki niezależne od opóźnienia: miara zbieżności i rozbieżności średnich ruchomych, indeks równowagi ceny do liczby akcji, czy oscylator *Chaikina*<sup>7</sup>.

Na rysunku 2 zobrazowano symulowaną zależność osiągniętego zysku przez neuronowy predyktor od daty przeprowadzenia transakcji. Eksperyment przeprowadzono w odniesieniu do akcji WIG20.

<sup>6</sup> Ferdousi Z., Maeda A.: *Anomaly Detection Using Unsupervised Profiling Method in Time Series Data*, Proc. Of 10th Conference on Advances in Databases and Information Systems, Tesaloniki 2006.

<sup>7</sup> Pietrzak E., Markiewicz M. (red.): *Finanse, bankowość i rynki finansowe*, Wyd. Uniwersytetu Gdańskiego, Gdańsk 2006, s. 27.



**Rysunek 2.** Przykładowa symulacja osiągnięcia skumulowanego zysku od daty przeprowadzenia transakcji

Źródło: Gis A.: *Wielowątkowa aplikacja wykorzystująca sztuczne sieci neuronowe i algorytm roju do predykcji na giełdzie*. Praca magisterska, Politechnika Gdańska, Gdańsk 2015, s. 97.

Okres symulacji obejmuje przedział czasu od 03.01.1997 do 23.12.2014. Uczenie zachodzi na zbiorze 50 sesji giełdowych. Warto podkreślić, że nie udało się opracować strategii, która zawsze będzie wygrywała, a możemy raczej mówić o sieciach wygrywających w pewnym (raczej dłuższym) okresie czasu.

Sieci neuronowe wykorzystywane są także do optymalizacji portfela akcji, gdyż sprawdziły się do optymalizacji kombinatorycznych problemów NP-trudnych.<sup>8</sup> Wśród zadań związanych z działalnością finansową, dla których udało się zastosować wspomaganie oparte o sztuczne sieci neuronowe, można wymienić analizę zdolności kredytowej klientów banków<sup>9</sup>, analizę ryzyka związanego z udzieleniem kredytu hipotecznego<sup>10</sup>, budowanie strategii ofertowych, prognozowanie wartości indeksów<sup>11</sup> i kierunków trendów na giełdzie, określenie klas ryzyka giełdowych instrumentów finansowych, wykrywanie regularności w zmianach cen instrumentów finansowych oraz prognozowanie bankructw i upadłości firm<sup>12</sup>.

Z reguły efektywnego rozwiązania finansowego nie można przewidzieć za pomocą modelu matematycznego. Wpływ czynnika losowego – brany pod uwagę w wielu modelach – jest zazwyczaj zbyt silny. Sieci neuronowe nie zawierają żadnego założenia *a priori* dotyczącego opisywanego zjawiska. Z tego powodu mogą identyfikować lokalne zaburzenia rynku czy też zależności występujące przez krótki czas na rynkach finansowych<sup>13</sup>.

Alternatywnym sposobem stosowania systemów wspomagających inwestycje giełdowe jest implementacja wirtualnych maklerów do automatycznego wykonywania transakcji na rynku. Automatycznych systemów transakcyjnych używa się podczas bardzo intensywnej wymiany walorów (ang. *High Frequency Trading* HFT), obejmującej tysiące transakcji podczas jednej sesji. Zazwyczaj w takich systemach stosuje się właśnie algorytmy oparte o sztuczne sieci neuronowe. Do 1998 roku inwestor mógł posiadać akcje przez kilkanaście sekund, po

<sup>8</sup> Staniec I., *Zastosowanie sztucznych sieci neuronowych i wybranych metod statystycznych do wspomagania decyzji kredytowych*, Zastosowania metod statystycznych w badaniach naukowych II, StatSoft Polska, Kraków 2003, s. 20.

<sup>9</sup> Yobas M.B., Crook J.N., Ross P.: *Credit scoring using neural and evolutionary techniques*. IMA Journal of Mathematics Applied in Business and Industry, Vol. 11, 2000, p. 112.

<sup>10</sup> Zan H. et al.: *Credit rating analysis with support vector machines and neural networks: a market comparative study*. Decision Support Systems, vol. 37, 2004, ss. 543–558.

<sup>11</sup> *Benchmark z danymi kredytowymi*, <http://archive.ics.uci.edu/ml/datasets/Statlog+%28German+Credit+Data%29>, dostęp: 2.09.2015.

<sup>12</sup> Brown C.: *Technical Analysis for the Trading Professional*, Second Edition: Strategies and Techniques for Today's Turbulent Global Financial Markets, The McGrawHill Companies, New York 2011, s. 226.

<sup>13</sup> Oet M., Eiben R., Bianco T., Gramlich D., Ong S., Wang J.: *SAFE: an early warning system for systemic banking risk*. Proc. of the 24th Australasian Finance and Banking Conference, SSRN, 2011, p. 243.

czym je sprzedawał. Obecnie na ważniejszych giełdach można być właścicielem akcji przez mili-, a nawet mikrosekundy.

Jednakże ryzyko związane z bardzo intensywnym prowadzeniem działalności inwestycyjnej jest dużo większe. Przekonała się o tym firma *Knight Capital Group*, broker na amerykańskim rynku akcji, która ze względu na błąd w ich automatycznym systemie transakcyjnym *HFC* podczas sesji na nowojorskiej giełdzie 1 sierpnia 2012 straciła 440 milionów dolarów w 30 minut<sup>14</sup>.

Ważnym zagadnieniem jest też krótki czas przydatności nauczonej sieci neuronowej, musi ona być cały czas douczana. W związku z tym, w realnych zastosowaniach w systemach HFT, sieci neuronowe są wykorzystywane w specyficznym cyklu: *uczenie->testowanie->predykcja->uczenie-> ...*.

W celu prognozy kursów akcji zdobywane są informacje o firmach w różny sposób. Nowoczesne metody wykorzystują wiadomości o firmach w elektronicznym formacie tekstowym, które są dostępne z wielu źródeł, w tym od komercyjnych dostawców, takich jak *Bloomberg*, publicznych serwisów informacyjnych, czy serwisów społecznościowych, takich jak *Twitter*. Aplikacje mogą identyfikować nazwy firm, słowa kluczowe, a także semantykę wiadomości, dzięki czemu możliwe jest badanie tzw. sentymentu wiadomości (informacja pozytywna, negatywna, neutralna).

## 2. Hybrydowe metody neuronowe do oceny wiarygodności kredytowej

W tym opracowaniu pojęcie wiarygodności kredytowej będzie rozumiane jako zdolność osoby fizycznej lub podmiotu prawnego do terminowego spłacania zaciągniętego zobowiązania. Tak przyjęta definicja jest w znacznym stopniu uproszczona. Nie uwzględnia ona m. in. następujących aspektów będących w obrębie zainteresowania nowoczesnych metod oceny wiarygodności kredytowej<sup>15</sup>:

- prognozowanie prawdopodobieństwa obniżenia oceny wiarygodności kredytowej analizowanego podmiotu;
- dopasowania oferty kredytowej do kredytobiorcy na podstawie jego aktywności w obrębie danej instytucji finansowej.

Z oczywistych względów takich, jak chociażby czynniki losowe (klęski żywiołowe, fazy cyklu koniunkturalnego) nie jest możliwa dokładna ocena wiarygodności kredytowej. Z tego powodu próbuje się dokonywać jej oceny na podstawie występowania pewnych cech wśród podmiotów spłacających swoje zobowiązania. Istniejące systemy oceny wiarygodności kredytowej korzystające ze sztucznych sieci neuronowych eksploatowane są w liczących się bankach w Europie, Stanach Zjednoczonych i Japonii<sup>16</sup>.

Spśród tradycyjnych metod analizy wiarygodności kredytowej warto wymienić metodę oceny statusu kredytobiorcy przez pracownika banku. Metoda ta jest najstarszym podejściem do tego zagadnienia, a opiera się wyłącznie na podstawie szczegółowego wywiadu przeprowadzonego z klientem. Wyniki zależą w dużej mierze od wiedzy merytorycznej, doświadczenia oraz uczciwości eksperta przeprowadzającego wywiad. To podejście spotykało się z falą krytyki ze względu na podatność na uprzedzenia rasowe, płciowe i etniczne pracowników banku dokonujących analizy. Mimo tego metoda ta jest powszechnie stosowana według ścisłych wytycznych na różnych etapach weryfikacyjnych procesu przydzielania kredytów.

<sup>14</sup> <http://www.bloomberg.com/bw/articles/2012-08-02/knight-shows-how-to-lose-440-million-in-30-minutes>

<sup>15</sup> Matuszczyk A., *Credit Scoring*, Wydawnictwo CeDeWu, Warszawa 2012, s. 32 – 40.

<sup>16</sup> Staniec I., *Zastosowanie sztucznych sieci neuronowych i wybranych metod statystycznych do wspomaganie decyzji kredytowych*, Zastosowania metod statystycznych w badaniach naukowych II, StatSoft Polska, Kraków 2003, s. 20.



Natomiast w statystycznych modelach dyskryminacyjnych wyznacza się liniową kombinację wybranych cech badanych obiektów, która umożliwia podzielenie obiektów na klasy odpowiadające prawdopodobieństwu spłacenia w przyszłości kredytu<sup>17</sup>. Z kolei w modelach logitowych przekształceniu podlegają wartości prawdopodobieństw zdarzeń do wartości rzeczywistych i zastosowaniu metody regresji liniowej<sup>18</sup>.

W metodzie sztucznej inteligencji o nazwie *k*-najbliższych sąsiadów, potencjalny kredytobiorca jest kwalifikowany jako wiarygodny/niewiarygodny w zależności od klasy, która przeważa wśród *k* ocen znajdujących się w jego najbliższym sąsiedztwie<sup>19</sup>. Wykorzystuje się także algorytmy genetyczne oraz drzewa decyzyjne<sup>20</sup>. Alternatywne systemy eksperckie zawierają reprezentację wiedzy dziedzinowej pracowników oceniających wnioski kredytowe. Często są one zdolne do samodzielnego pozyskiwania nowej wiedzy na podstawie decyzji kredytowych podjętych za pomocą innych metod.

Ocena wiarygodności kredytowej ma za zadanie wyłonić tych, którzy najlepiej rokują w zakresie spłacania kredytów. Sieci neuronowe wykorzystuje się również do wyselekcjonowania tych kredytobiorców, którzy w najbliższej przyszłości mogą przestać spłacać już zaciągnięte zobowiązania<sup>21</sup>.

Do oceny wiarygodności kredytowej w coraz większym stopniu są wykorzystywane również media społecznościowe. Serwis Facebook opatentował w Stanach Zjednoczonych metodę badania zdolności kredytowej opartą na charakterystyce znajomych potencjalnego kredytobiorcy w sieci społecznościowej. Sama idea patentu jest bardzo prosta. Dla wszystkich znajomych aplikanta kredytowego jest obliczana ich wiarygodność kredytowa. Jeżeli średnia wartość tejże wiarygodności kredytowej znajduje się poniżej pewnej obliczonej wartości progowej, to wniosek potencjalnego kredytobiorcy zostaje odrzucony<sup>22</sup>. Ze względów prawnych ten patent pozostaje w chwili pisania tych słów niewykorzystany.

Regulacje Nowej Umowy Kapitałowej (potoczna nazwa: Bazylea II) nakładają na instytucje finansowe konieczność posiadania rezerw finansowych dla poszczególnych typów depozytów na poziomie całego banku. Do ich obliczenia stosuje się następujące parametry<sup>23</sup>:

- *PD* (ang. *probability of default*) – prawdopodobieństwo niewypłacalności dłużnika w okresie jednego roku;
- *LGD* (ang. *Loss Given Default*) – strata zaistniała w wyniku niewypłacalności. Jest ona wyrażona jako procent całkowitej kwoty zobowiązania, który nie zostanie spłacony. Wartość *LGD* może przekraczać 100%, gdyż wlicza się do niej wszystkie koszty ekonomiczne związane z długiem (jak chociażby koszty egzekucji);
- *EAD* (ang. *Exposure At Default*) – rozmiar ekspozycji kredytowej w przypadku niewypłacalności. Jest on wyrażony kwotą pozostałą do spłaty w momencie zaistnienia zdarzenia niewypłacalności. Jest ona wyrażona w jednostkach pieniężnych.

<sup>17</sup> Mylonakis J., Diacogiannis G., *Evaluating the Likelihood of Using Linear Discriminant Analysis as a Commercial Bank Card Owners Credit Scoring Model*, Int. Business Research, Vol. 3, No. 2, 2010, s. 43.

<sup>18</sup> Majer I., *Application scoring: logit model approach and the divergence method compared*, Department of Applied Econometrics Working Papers, Working Paper No. 10-06, 2006, s. 27.

<sup>19</sup> Henley W.E., Hand D.J., *A k-nearest-neighbour Classifier for assessing consumer credit risk*, The Statistician, Volume 45, Issue 1 (1996), pp. 75 – 95, s. 77.

<sup>20</sup> Yobas M.B., Crook J.N., Ross P., *Credit scoring using neural and evolutionary techniques*, IMA Journal of Mathematics Applied in Business and Industry, (2000) 11, pp. 111-125, s. 121.

<sup>21</sup> Srivastava R. P., *Automating judgmental decisions using neural networks: a model for processing business loan applications*, Proceedings of the 1992 ACM annual conference on Communications, pp. 351-357, s. 355

<sup>22</sup> „Facebook patent: Your friends could help you get a loan - or not”, <http://money.cnn.com/2015/08/04/technology/facebook-loan-patent/>, dostęp 6 marca 2016r.

<sup>23</sup> Iwanicz-Drozdowska M., *Edukacja finansowa i świadomość*, Oficyna Wydawnicza Szkoły Głównej Handlowej w Warszawie, Warszawa 2011r, rozdział: „Metody pomiaru *LGD* dla kredytów detalicznych”.



W chwili tworzenia tego opracowania główny nurt badań dotyczących zastosowań sztucznej inteligencji w analizie wiarygodności kredytowej skupia się na szacowaniu wspomnianych wyżej parametrów.

Prace nad efektywnymi metodami oceny wiarygodności kredytowej są utrudnione, gdyż informacje o wiarygodności kredytowej są objęte tajemnicą finansową. W literaturze przedmiotu można wyróżnić dwa podejścia do rozwiązania tego problemu:

- korzystanie w powszechnie dostępnych benchmarków z danymi opisującymi wiarygodność kredytową, np. z zestawu danych *Statlog (German Credit Data)*<sup>24</sup>;
- pozyskanie z instytucji finansowej próbki danych zebranych na potrzeby oceny wiarygodności kredytowej; takie dane muszą być anonimowe i należeć do pewnego podzbioru klientów instytucji finansowej<sup>25</sup>. Wykorzystuje się nie tylko dane osób fizycznych, ale również firm. Wielkość danych w niektórych przypadkach jest ograniczona. Przykładowo *Nazari* wykorzystał próbę składającą się z zaledwie 90 przypadków<sup>26</sup>.

Częściowym rozwiązaniem tego problemu jest to, że niektóre instytucje finansowe (jak chociażby amerykański *LendingClub.com*) zdecydowały się na publiczne udostępnienie danych dotyczących przyznanych oraz odmówionych wniosków kredytowych. *Lending Club* nie dostarczył informacji dotyczących kompletności tychże danych. Uwarunkowania rynku amerykańskiego pozwalają jednak domniemywać, iż wspomniany zbiór danych zawiera tylko i wyłącznie dane osób, które wyraziły na to zgodę.

Dla kredytów udzielanych osobom fizycznym zazwyczaj danymi wejściowymi systemu oceny wiarygodności są: wiek, stan cywilny, posiadanie mieszkania czy też innej nieruchomości, miesięczny dochód, fakt prowadzenia działalności gospodarczej, informacje o posiadanych zobowiązaniach, liczba dzieci oraz okres zatrudnienia u obecnego pracodawcy. Przy badaniu zdolności kredytowej firm wykorzystuje się wskaźniki finansowe obliczone na podstawie ostatniego bilansu firmy. Wachlarz powyższych cech można wzbogacić – w przypadku, gdy firma jest już klientem instytucji finansowej, w której pragnie zaciągnąć zobowiązanie – o analizę przeszłych wzorców zachowań finansowych.

Do prognozy zastosowano: perceptron wielowarstwowy z radialną funkcją aktywacji, sieć jednokierunkową z liniową funkcją aktywacji czy też sekwencyjne połączenie dwóch sieci neuronowych, z których pierwsza oblicza wstępny współczynnik wiarygodności kredytowej.

Sztuczne sieci neuronowe są narzędziem oceny kredytowej o skuteczności porównywalnej ze standardowymi metodami ekonometrycznymi. Uzyskane wyniki ze względu na ograniczony czasowo dobór próby powinno się je traktować raczej jako dowód na duży potencjał prognostyczny sieci neuronowych w analizie wiarygodności kredytowej.

*Staniec*<sup>27</sup> zauważa, że stan przechowywanej informacji ulega systematycznym zmianom, przy czym mamy do czynienia z niekompletną informacją. Jednakże z tymi trudnościami sieci neuronowe bardzo dobrze sobie radzą. Ponadto biorąc pod uwagę moc obliczeniową superkomputerów wirtualnych, nawet konieczność cyklicznego uczenia sieci neuronowej nie stanowi przeszkody. Sieć neuronowa nie musi być jedynym narzędziem służącym do oceny wiarygodności kredytowej. Nadaje się ona do wykonania wstępnej oceny, a co jest także ważne, coraz więcej banków udziela kredytów, korzystając z sieci.

<sup>24</sup> <http://archive.ics.uci.edu/ml/datasets/Statlog+%28German+Credit+Data%29>, dostęp: 2 września 2014 r.

<sup>25</sup> Bechler A., *Porównanie efektywności sieci neuronowych i modeli ekonometrycznych we wspomaganie decyzji kredytowych*, Zastosowania metod statystycznych w badaniach naukowych II, StatSoft Polska, Kraków 2003, s. 24.

<sup>26</sup> Nazari M., Alidadi M., *Measuring Credit Risk of Bank Customers Using Artificial Neural Network*, Journal of Management Research, Vol. 5, No. 2, 2013, s. 44.

<sup>27</sup> Staniec I., *op. cit.*, s. 23

*Baesens et al.* zaprezentowali interesujące podejście polegające na wydobyciu reguł z wytrenowanej sieci neuronowej<sup>28</sup>. Takie odwrócenie kolejności działań pozwala na podstawie zasad działania wytrenowanej sieci neuronowej skonstruować nowe narzędzia do oceny wiarygodności kredytowej przy uwzględnieniu wiedzy eksperta.

Zastosowanie metod ewolucyjno-neuronowych do oceny wiarygodności kredytowej ma wiele zalet, jak chociażby znaczne przyspieszenie procesu kredytowego. Inteligentne metody oceny wiarygodności kredytowej bardzo szybko są w stanie odrzucić wnioski, które nie spełniają podstawowych kryteriów kredytowych. Minimalizowana jest również rola czynnika ludzkiego.

Ponadto istnieje możliwość adaptacji do zmieniających się warunków zewnętrznych. Istotna jest szybka możliwość weryfikacji sposobu działania modelu na podstawie danych historycznych. Ze względu na zautomatyzowanie całego procesu przetestowanie nowego modelu, jak również modelu ze zmodyfikowanymi parametrami sterującymi nie jest złożone. Istnieje możliwość połączenia kilku metod w jednej system weryfikacji wiarygodności kredytowej. Sieć neuronowa klasyfikująca klientów może być trenowana za pomocą algorytmu genetycznego, a system ekspercki może bazować na regułach wydobytych z sieci neuronowej.

### 3. Modele prognozowania kryzysów bankowych

Spóźnione działania prewencyjne w wypadku wystąpienia kryzysu bankowego polegają na udzieleniu bezpośredniej pomocy finansowej, co może się odbić na osłabieniu gospodarki, gdyż plany ratunkowe są zazwyczaj na poziomie kilkunastu procent PKB dla państw rozwijających się oraz dwudziestu kilku procent dla gospodarek rozwiniętych. Znacznie mniejszego budżetu wymagają działania prewencji antykryzysowej, które opierają się na badaniu wypłacalności banków, prognozowaniu kryzysów lub też na wprowadzeniu innowacji technologicznych obniżających koszty operacyjne<sup>29</sup>.

W wypadku przewidywania kryzysu bankowego, wysokość adekwatności kapitałowej  $W$  na poziomie 8% może być zwiększona. Współczynnik wypłacalności banku oblicza się za pomocą poniższej zależności:

$$W = \frac{(F_{wz} + K_k) * 100}{W_k * 12,5} \quad (1)$$

gdzie:

$F_{wz}$ - fundusze własne;

$K_k$ - kapitał krótkoterminowy;

$W_k$ - całkowity wymóg kapitałowy.

W sytuacjach kryzysowych zwiększone mogą być również wartości wag aktywów. Bank posiadający bardziej ryzykowne aktywa powinien posiadać większy kapitał niż bank o bezpieczniejszych aktywach. Wagi przypisane aktywom przyjmują wartości w zależności od poziomu ryzyka operacji i kraju działalności banku. Waga niskiego ryzyka wynosi 0% w odniesieniu do gotówki, należności od rządów państw, banku centralnego UE i banków centralnych krajów należących do OECD. Waga umiarkowanego ryzyka w wysokości 20% dotyczy należności od banków krajowych i banków należących do OECD. Waga 50% odnosi się do aktywów średniego ryzyka, w tym kredytów hipotecznych. Waga wysokiego ryzyka 100% dyskryminuje pozostałe kredyty, większość operacji pozabilansowych, czy też inwestycje banku na rynku kapitałowym.

<sup>28</sup> Baesens B., Setiono R., Mues C., Vanthien J., *Using Neural Network Rule Extraction and Decision Tables for Credit-Risk Evaluation*, Management Science, Vol. 49, No. 3, March 2003 pp. 312–320, s. 317.

<sup>29</sup> Balicka H. et al.: *Metody sztucznej inteligencji do wspomaganie bankowych systemów informatycznych*. [w:] K. Kreft, D. Wach, J. Winiarski (red.): *Systemy informatyczne w gospodarce*. Wyd. Uniwersytetu Gdańskiego, Gdańsk 2013, s. 127.





W modelu predykcji *Frankela-Rose'a* wykorzystano wskaźniki odnoszące się do wschodzących rynków walutowych<sup>30</sup>. Zmienne do prognozy podzielono na cztery kategorie. Do pierwszej zaliczono wskaźniki rynków zagranicznych, takie jak wskaźniki stóp procentowych i dynamiki produkcji. Do drugiej grupy zaproponowano wskaźniki makroekonomiczne, takie jako zmiany tempa produkcji, czy kryteria drastycznych zmian monetarnych i fiskalnych. Natomiast zmienne zewnętrzne, takie jak wskaźniki przeszacowania cen, stan na rachunku obrotów bieżących i poziom zadłużenia, zaliczono do trzeciej kategorii. Czwartą klasę zmiennych opisują determinanty struktury zadłużenia.

Model *Kaminsky'ego-Reinharta* opiera się na założeniu, że przyczyny kryzysu sektora bankowego rzutują na przyczyny kryzysu bilansu płatniczego<sup>31</sup>. Ponieważ liberalizacja finansowa zazwyczaj poprzedza kryzysy bankowe, to można przewidywać kryzysy bankowe za pomocą metod statystycznych. Na podstawie wcześniejszych sygnałów o problemach w sektorze bankowym, można zatem przewidywać kryzys bilansu płatniczego.

*Demirguc-Kunt* i *Detragiache* (model DKD) zastosowali model logiki wielowartościowej do przewidywania kryzysów bankowych.<sup>32</sup> Proponowana ocena prawdopodobieństwa kryzysu bankowego ma przerystą interpretację w oparciu o przykładowe statystyki. Model cechuje się wyższą jakością niż inne dostępne wówczas modele alternatywne. System monitorowania stanu bankowości może być dopasowany do preferencji decydentów. Model DKD może być zatem użyteczny do wstępnej prognozy, aby zredukować koszty monitorowania.

Model *Hanschela-Monniniego* cechuje się innym podejściem do wczesnego ostrzegania o kryzysach bankowych i finansowych, które to podejście opiera się na modelu regresji.<sup>33</sup> Wskaźnik zagrożenia kryzysem (ang. *the stress index*) wyznaczono dla sektora bankowego w *Szwajcarii* oraz omówiono jego rolę w kontekście zaburzeń równowagi makroekonomicznej. Wskaźnik zagrożenia kryzysem może służyć jako sygnał wczesnego ostrzegania przed kryzysem bankowym w krajach rozwiniętych. Zauważono, że kryzysy finansowe są skorelowane ze zmianami stóp procentowych.

*Davis* i *Karim* porównali systemy wczesnego ostrzegania o kryzysach bankowych<sup>34</sup>. Mimo obszernej literatury na temat przewidywania kryzysów bankowych przez systemy wczesnego ostrzegania EWS, ich praktyczne wykorzystanie przez decydentów jest niewielkie, nawet w międzynarodowych instytucjach finansowych. Paradoks polega na tym, że ze względu na zmieniający się charakter ryzyka w bankowości, liberalizację gospodarki, a także rozwój systemów finansowych oraz liczne innowacje, korzystanie z EWS jest obecnie bardziej konieczne niż kiedykolwiek.

Koszty ratowania (ang. *bailout costs*) sektora bankowego w sytuacjach kryzysowych są niebagatelne. Podczas kryzysu bankowości w Meksyku (ang. *the Mexican Tequila Crisis*) w 1994 roku koszty te były na poziomie 20% PKB tego kraju, a podczas kryzysu na Jamajce w 1996 roku - aż 37% PKB<sup>35</sup>. Zazwyczaj kryzys bankowy poprzedzany jest dwuletnim kryzysem finansowym. Również po kryzysie bankowym występuje dwuletni kryzys finansowy. Średnie skumulowane straty dla tych trzech okresów kryzysowych (ang. *banking and twin crises*)

<sup>30</sup> J. A. Frankel, A. K. Rose, "Currency crashes in emerging markets: an empirical treatment" *Journal of International Economics*, vol. 41, no. 3-4, pp. 351-366, 1996, p. 353.

<sup>31</sup> G. L. Kaminsky, C. M. Reinhart: *The twin crises: the causes of banking and balance-of-payments problems*. *American Economic Review*, vol. 89, no. 3, pp. 473-500, 1999, p. 492.

<sup>32</sup> A. Demirguc-Kunt, E. Detragiache: *Monitoring banking sector fragility: a multivariate logit approach*. *World Bank Economic Review*, vol. 14, no. 2, pp. 287-307, 2000, p. 293.

<sup>33</sup> E. Hanschel, P. Monnin: *Measuring and forecasting stress in the banking sector: evidence from Switzerland*. *Investigating the Relationship between the Financial and Real Economy*, BIS Papers no. 22, pp. 431-449, 2005, p. 433.

<sup>34</sup> E. P. Davis, D. Karim: *Comparing early warning systems for banking crises*. *Journal of Financial Stability*, vol. 4, no. 2, pp. 89-120, 2008, p. 97.

<sup>35</sup> *Ibid.*, p. 90.

szacowane są na poziomie 24% PKB w odniesieniu do krajów należących do OECD oraz 14% dla rozwijających się gospodarek.

Istotnym objawem kryzysu bankowego jest wzrost ryzyka kredytowego lub wzrost prawdopodobieństwa, że pożyczkobiorca nie wywiąże się z regularnej spłaty kredytów. Natomiast sygnałem wczesnego ostrzegania przed kryzysem jest szybki wzrost udzielonych kredytów i przekroczenie maksymalnego progu ostrzegawczego dotyczącego udziału kredytów udzielonych dla sektora prywatnego w odniesieniu do PKB. Istotne są oczywiście podstawowe wskaźniki makroekonomiczne: zmiany PKB, PKB *per capita*, stosunek nadwyżki budżetowej do PKB, poziom inflacji, amortyzacja nominalna, wolumen wymiany handlowej, rezerwy walutowe, dynamika kredytów dla gospodarstw domowych czy wielkość ubezpieczonych depozytów.

Prawdopodobieństwo wystąpienia kryzysu bankowego można oszacować następująco:

$$\ln P = \sum_{i=1}^n \sum_{t=1}^T [(Y_{it} \ln F(\beta' X_{it})) + (1 - Y_{it}) \ln(1 - F(\beta' X_{it}))], \quad (2)$$

gdzie:

$Y_{it}$  – stan bankowości państwa nr  $i$  w czasie  $t$ ;

$\beta$  – wektor współczynników;

$X_{it}$  – wartość zmiennych decyzyjnych państwa nr  $i$  w czasie  $t$ ;

$F(\beta X_{it})$  – skumulowany rozkład logistyczny,  $F(\beta X_{it}) = P(Y_{it} = 1) = \frac{e^{\beta' X_{it}}}{1 + e^{\beta' X_{it}}}$ .

Warto wspomnieć także o systemie wczesnego ostrzegania SAFE opracowanym w 2011 roku<sup>36</sup>. Ponadto, metody stosowane do prognozowania kryzysów bankowych mogą być stosowane do wyceny i szacowania ryzyka papierów dłużnych. Natomiast, najpoważniejszym ograniczeniem metod statystycznych jest wrażliwość na zmienne zależne od siebie oraz założenie o normalności wielowymiarowego rozkładu prawdopodobieństwa dla wielu zmiennych wejściowych<sup>37</sup>.


#### 4. Sieć neuronowa do wyznaczania współczynników funkcji jądrowych w metodzie wektorów wspierających do prognozowania kryzysów bankowych

Do nowszych metod prognozowania kryzysu bankowego można zaliczyć metody uczenia maszynowego, a w szczególności jednokierunkową sieć neuronową z propagacją wsteczną i sieć neuronową z radialną funkcją aktywacji. Sieć neuronowa umożliwia także wyznaczanie parametrów w metodzie wektorów nośnych (ang. *Support Vector Machine* – SVM)<sup>38</sup>. W metodzie SVM problem prognozy polega na wyznaczeniu takich wartości wektora współczynników  $w$ , aby wyznaczona hiperpłaszczyzna o współczynnikach z wektora  $w$  dzieliła dwie klasy z maksymalnym marginesem.

<sup>36</sup> M. Oet, R. Eiben, T. Bianco, D. Gramlich, S. Ong, J. Wang: *SAFE: an early warning system for systemic banking risk*. Proceedings of the 24th Australasian Finance and Banking Conference, SSRN, 2011.

<sup>37</sup> Zan H. et al.: *Credit rating analysis with support vector machines and neural networks: a market comparative study*. Decision Support Systems, Vol. 37, 2004, s. 555.

<sup>38</sup> Larousse D. T.: *Metody i modele eksploracji danych*. Wydawnictwo Naukowe PWN, Warszawa 2008, s. 223.



**Rysunek 3.** Hiperpłaszczyzna separująca

Wyszukanie zbioru wag  $w$  sprowadza się do zagadnienia optymalizacji, w którym minimalizowana jest norma wektora  $w$ . Tak sformułowane zagadnienie optymalizacyjne można rozwiązać za pomocą przekształcenia problemu podstawowego w problem dualny (gdzie problem optymalizacyjny jest przedstawiony jako liniowa kombinacja wektorów ze zbioru uczącego) i użycia metody mnożników *Lagrange'a*<sup>39</sup>. Zależności między wektorem  $w$ , a wektorem  $\alpha$  przedstawione są poniżej:

$$w^* = \sum_{i=1}^l y_i a_i^* x_i,$$

$$\langle w^*, w^* \rangle = \sum_{i=1}^l a_i^*.$$

W praktyce większość współczynników *Lagrange'a*  $\alpha_i$  wynosi 0. Wektory wejściowe ze zbioru uczącego, którym została przyporządkowana wartość  $\alpha_i > 0$  są właśnie *wektorami nośnymi*<sup>40</sup>.

Metoda wektorów nośnych stosowana jest w różnorodnych obszarach bankowości.<sup>41</sup> *Shouwei, Mingliang* oraz *Jianmin* zastosowali metodę wektorów nośnych wraz z sieciami neuronowymi do oszacowania systemowego ryzyka sektora bankowego w Chinach<sup>42</sup>. Szacując prawdopodobieństwo załamania finansowego pojedynczego banku, wzięto pod uwagę nie tylko jego własne wskaźniki ekonomiczne jak: *ROE* (ang. *return on equity*), *ROA* (ang. *return on assets*) i wskaźniki płynności, ale również wskaźniki makroekonomiczne (np. wzrost PKB) oraz wskaźniki związane z zależnościami od innych banków.

Uwzględniono 17 wskaźników określających kondycję 36 banków. Banki podzielono na zbiór uczący (19 przypadków) i zbiór testujący (17 przypadków). Użyto rozszerzonej metody SVM wykorzystującej tzw. funkcję bazową  $K$  (ang. *kernel function*), która pozwala na projekcję układu  $n$ -wymiarowego na układ  $m$ -wymiarowy, gdzie  $m \gg n$ . Dzięki temu zabiegowi możliwa jest separacja klas nieseparowanych liniowo w układach o mniejszej liczbie wymiarów. Funkcja  $f$ , którą wyznaczono za pomocą metody wektorów nośnych, przydziela zadany wektor wejściowy  $x_i$  do jednej z dwóch klas (1 albo -1):

$$f(x) = \text{sign}(\sum_{i=1}^M \alpha_i y_i K(x, x_i) + b), \quad (3)$$

gdzie:

$M$  – liczba elementów zbioru uczącego, w tym wypadku 19,

$y_i$  – etykieta (wartość 1 lub -1) przypisana  $i$ -temu elementowi zbioru uczącego,

<sup>39</sup> Chaveesuk R., Srivaree-Ratana C., Smith A.E.: Alternative neural network approaches to corporate bond rating. *Journal of Engineering Valuation and Cost Analysis*, 2, 1999, s. 127.

<sup>40</sup> Zan H. et al., *op. cit.*, s. 554.

<sup>41</sup> Shouwei L., Mingliang W., Jianmin H.: *Prediction of Banking Systemic Risk Based on Support Vector Machine*. *Mathematical Problems in Engineering*, Vol. 2013, April 2013, s. 5.

<sup>42</sup> *Ibid.*, s. 1.



$b$  – wartość przesunięcia iloczynu wektorowego  $w$  oraz  $x$

$\alpha_i$  – współczynnik przypisany  $i$ -temu elementowi zbioru uczącego

Parametry metody SVM (parametry funkcji bazowej, waga przypisana błędom oszacowań ze zbioru uczącego) można m. in. wyznaczyć za pomocą sztucznych sieci neuronowych. Dokładność predykcji za pomocą metody wektorów nośnych porównano z wynikami uzyskanymi sztuczną sieć neuronową z propagacją wsteczną. Za pomocą testu statystycznego *McNemara* dla małej liczebności próby wykazano, że metoda SVM z siecią neuronową cechuje się precyzyjniejszą predykcją od pojedynczej sieci neuronowej z istotnością 0,1<sup>43</sup>.

## 5. Wybrane metody sztucznej inteligencji w prognozowaniu finansowym

Efektywnym modelem wykorzystującym sztuczną inteligencję do przewidywania kursu na giełdzie był model hybrydowy składający się z modułowej morfologicznej sieci neuronów (ang. *Morphological Neural Network* - MMNN) połączony z algorytmem optymalizacji roju cząstek (ang. *Particle Swarm Optimizer* - PSO).

Rout *et. al.* zaproponowali nowy model hybrydowy, w którym wykorzystano sieć *Adaline* (ang. *Adaptive Linear Neurons*) oraz stosunkowo nowy algorytm zwany ewolucją różnicową (ang. *differential evolution* - DE), który był odpowiedzialny za uczenie modelu<sup>44</sup>. Do przeprowadzenia badań wykorzystano 3 228 danych zgromadzonych w latach od 1994 do 2006. Z danych tych utworzono 3 168 wzorców z czego 2 510 użyto do treningu modelu, a 658 do jego testowania. Prognozuje się wartości dwóch indeksów giełdowych DJIA oraz S&P 500 dla jednego, trzech i siedmiu dni. W badaniu wykorzystano średni bezwzględny odsetek błędów (ang. *mean absolute percentage of error* – *MAPE*), który wyznacza się w oparciu o  $y(m)$  - rzeczywistą cenę akcji,  $\hat{y}(m)$  przewidywaną cenę akcji oraz  $M$  liczbę próbek. Tabela 1 reprezentuje wyniki, które wskazują na mniejszą liczbę popełnionych błędów przez algorytm ewolucji różnicowej w stosunku do *PSO*. Metoda DE okazała się również szybszy od *PSO* podczas procesu uczenia.

**Tabela 1.** Porównanie uśrednionej bezwzględnej stopy błędów prognozy za pomocą sztucznej sieci neuronowej trenowanej za pomocą DE oraz PSO

Liczba dni	DE		PSO	
	DJIA	S&P500	DJIA	S&P500
1	0,6494	0,7765	0,8070	0,8634
3	0,9420	0,9897	1,0770	0,9846
7	1,3984	1,3953	1,4024	1,4136

Źródło: Rout M., *et al.*, op cit. s. 183.

Również metody programowania genetycznego wykorzystywane są do inwestowania na giełdzie. Popularnym podejściem jest wykorzystanie programowania genetycznego w połączeniu z analizą techniczną. Pozwala ono na automatyczne i dynamiczne przewidywanie kursów oraz generowanie wskazówek kupna i sprzedaży w krótkim odcinku czasu - tzw. strategia *market timing*. W odróżnieniu od rozpowszechnionej strategii inwestycyjnej *buy and hold*, zakładającej długotrwałe posiadanie aktywów, pozwala na wykorzystanie

<sup>43</sup> Shouwei L., Mingliang W., Jianmin H., *op. cit.*, s. 4.

<sup>44</sup> Rout M., Majhi B., Majhi R., Panda G.: *Novel Stock Market Prediction Using a Hybrid Model of Adaptive Linear Combiner and Differential Evolution*, Communications in Computer and Information Science, Vol. 142, p. 187.

krótkoterminowych fluktuacji rynku. Rozwiązanie takie okazało się korzystne w przypadku, gdy rynek jest stabilny lub gdy odnotowywane są spadki<sup>45</sup>.

Interesującym obszarem, w którym zastosowanie programowania genetycznego przynosi znaczące korzyści jest predykcja rozwoju firm. Bankructwo firmy może być istotnym wydarzeniem mającym wpływ na inwestorów. *Etemadi, Rostamy i Dehkordi* przeprowadzili analizę firm notowanych na giełdzie w *Teheranie*<sup>46</sup>. Porównali w ten sposób dwa modele, z których model oparty o programowanie genetyczne pozwolił na uzyskanie znacząco lepszych rezultatów.

## Zakończenie

W pracy scharakteryzowano stan zaawansowania sztucznych sieci neuronowych do prognozowania finansowego ze szczególnym uwzględnieniem gry na giełdzie. Ponadto omówiono wykorzystanie metody ewolucyjno-neuronowe do oceny wiarygodności kredytobiorców. Doprecyzowano zasady funkcjonowania hybrydowej metody wektorów wspierających z sieciami neuronowymi do prognozowania kryzysów bankowych. Omówiono wykorzystanie ewolucji różnicowej oraz programowania genetycznego do prognozowania finansowego.

Interesującym kierunkiem dalszych badań jest opracowanie neuronowych sieci impulsowych do prognozowania finansowego. Sieci tej klasy zaimplementowane na superkomputerach wirtualnych niewątpliwie poprawią jakość opracowywanych prognoz.

*Niniejsza praca została w całości zrealizowana i opublikowana w ramach środków: Działalność Statutowa (DS), Katedra Architektury Systemów Komputerowych, Wydział Elektroniki, Telekomunikacji i Informatyki, Politechnika Gdańska.*

## Literatura

1. Baesens B., Setiono R., Mues C., Vanthien J.: *Using neural network rule extraction and decision tables for credit-risk evaluation*. Management Science, Vol. 49, No. 3, March 2003, pp. 312–320
2. Balicka H. et al.: *Superkomputery do wspomaganie procesów gospodarczych ze szczególnym uwzględnieniem sektora bankowego*. „Współczesna Gospodarka”, Nr 4, 2014, ss. 1-12
3. Bechler A.: *Porównanie efektywności sieci neuronowych i modeli ekonometrycznych we wspomaganie decyzji kredytowych*, Zastosowania metod statystycznych w badaniach naukowych, StatSoft Polska, Kraków 2003
4. Brown C.: *Technical Analysis for the Trading Professional, Second Edition: Strategies and Techniques for Today's Turbulent Global Financial Markets*. The McGrawHill Companies, New York 2011
5. Chaveesuk R., Srivaree-Ratana C., Smith A.E.: *Alternative neural network approaches to corporate bond rating*. Journal of Engineering Valuation and Cost Analysis, vol. 2, 1999, ss. 117-131
6. Davis E. P., Karim D.: *Comparing early warning systems for banking crises*. Journal of Financial Stability, vol. 4, no. 2, 2008, pp. 89–120

<sup>45</sup> Potvin J.-Y., Soriano P., Vallée M.: *Generating trading rules on the stock markets with genetic programming*, Computers & Operations Search, Vol. 31, No. 7, June 2004, p. 1033.

<sup>46</sup> Etemadi H., Rostamy A., Dehkordi H., *A genetic programming model for bankruptcy prediction: Empirical evidence from Iran*, Expert Systems with Applications, Vol. 36, No. 2, March 2009, pp. 3199.

7. Demircuc-Kunt A., Detragiache E.: *Monitoring banking sector fragility: a multivariate logit approach*. World Bank Economic Review, vol. 14, no. 2, 2000, pp. 287–307
8. Eurostat. <http://ec.europa.eu/eurostat/>, dostęp: 17.02.2016
9. Etemadi H., Rostamy A., Dehkordi H., *A genetic programming model for bankruptcy prediction: Empirical evidence from Iran*, Expert Systems with Applications, Vol. 36, No. 2, March 2009, pp. 3199-3207
10. Frankel J. A., Rose A. K.: *Currency crashes in emerging markets: an empirical treatment*. Journal of International Economics, vol. 41, no. 3-4, 1996, pp. 351–366
11. Gately E. *Sieci Neuronowe. Prognozowanie finansowe i projektowanie systemów transakcyjnych*. Warszawa: WIG-Press, 1999
12. Golobic, S. L., et al.: *The impact of e-commerce on supply chain relationships*. Int. Journal of Physical Distribution, vol. 32, 2002, pp. 851–871
13. Hanschel E., Monnin P.: *Measuring and forecasting stress in the banking sector: evidence from Switzerland*. Investigating the Relationship between the Financial and Real Economy, BIS Papers, no. 22, 2005, pp. 431-449
14. Henley W.E., Hand D.J.: *A k-nearest-neighbour classifier for assessing consumer credit risk*, The Statistician, Vol. 45, Issue 1, 1996, pp. 75 – 95
15. <http://archive.ics.uci.edu/ml/datasets/Statlog+%28German+Credit+Data%29>, dostęp: 2 września 2014 r.
16. Kaminsky G. L., Reinhart C. M.: *The twin crises: the causes of banking and balance-of-payments problems*. American Economic Review, vol. 89, no. 3, pp. 473–500, 1999
17. Leyton-Brown K., Shoham Y.: *Multiagent Systems: Algorithmic, Game- Theoretic, and Logical Foundations*. Cambridge University Press, 2008
18. Majer I.: *Application scoring: logit model approach and the divergence method compared*, Department of Applied Econometrics, Working Paper, No. 10-06, 2006
19. Mylonakis J., Diacogiannis G.: *Evaluating the likelihood of using linear discriminant analysis as a commercial bank card owners credit scoring model*. International Business Research, Vol. 3, No. 2, 2010
20. Nazari M., Alidadi M.: *Measuring credit risk of bank customers using artificial neural network*. Journal of Management Research, Vol. 5, No. 2, 2013
21. Oet M., Eiben R., Bianco T., Gramlich D., Ong S., Wang J.: *SAFE: an early warning system for systemic banking risk*. Proc. of the 24th Australasian Finance and Banking Conference, SSRN, 2011
22. Pandey V., Wee-Keong Ng, Ee-Peng Lim: *Financial advisor agent in a multi-agent financial trading system*. Proc. 11th Int. Workshop on Database and Expert Systems Applications, 2000, pp. 482-486
23. Pietrzak E., Markiewicz M. (red.): *Finanse, bankowość i rynki finansowe*, Wyd. Uniwersytetu Gdańskiego, Gdańsk 2007
24. Pietrzak J.: *Czynniki przewagi konkurencyjnej na rynku bankowych usług detalicznych*, Wyd. Uniwersytetu Gdańskiego, Gdańsk 2002
25. Potvin J.-Y., Soriano P., Vallée M.: *Generating trading rules on the stock markets with genetic programming*, Computers & Operations Search, Vol. 31, No. 7, June 2004, pp. 1033-1047
26. Rout M., Majhi B., Majhi R., Panda G.: *Novel Stock Market Prediction Using a Hybrid Model of Adaptive Linear Combiner and Differential Evolution*. Communications in Computer and Information Science, Vol. 142, pp 187-191
27. Schwaerzel R.: *Financial Time Series Prediction and Evaluation by Genetic Programming with Trigonometric Functions and High-Order Statistics*. Ph.D. Dissertation. The University of Texas at San Antonio. Advisor(s) Tom Bylander, 2006

28. Shouwei L., Mingliang W., Jianmin H.: *Prediction of Banking Systemic Risk Based on Support Vector Machine*. Mathematical Problems in Engineering, Vol. 2013, April 2013, pp. 1-15
29. Srivastava R. P.: *Automating judgmental decisions using neural networks: a model for processing business loan applications*, Proc. of the 1992 ACM Annual Conference on Communications, pp. 351-357
30. Staniec I.: *Zastosowanie sztucznych sieci neuronowych i wybranych metod statystycznych do wspomagania decyzji kredytowych*, Zastosowania metod statystycznych w badaniach naukowych II, StatSoft Polska, Kraków 2003, s. 20
31. Svangard N.; Nordin P.; Lloyd S.; Wihlborg C.: *Evolving short-term trading strategies using genetic programming*. Proc. of the Congress on Evolutionary Computation, vol. 2, 2002, pp. 2006-2010.
32. Yobas M.B., Crook J.N., Ross P.: *Credit scoring using neural and evolutionary techniques*. IMA Journal of Mathematics Applied in Business and Industry, Vol. 11, 2000, pp. 111-125
33. Zan H. et al.: *Credit rating analysis with support vector machines and neural networks: a market comparative study*. Decision Support Systems, vol. 37, 2004, ss. 543–558
34. Zarys strategii gospodarczej USA, <http://www.whitehouse.gov/economy>, dostęp: 29.11.2015

## NEURAL METHODS FOR THE FINANCIAL PREDICTION

### Summary

Artificial neural networks can be used to predict share investment on the stock market, assess the reliability of credit client or predicting banking crises. Moreover, this paper discusses the principles of cooperation neural network algorithms with evolutionary method, and support vector machines. In addition, a reference is made to other methods of artificial intelligence, which are used in finance prediction.

**Keywords:** artificial neural networks, share investment on the stock market, evolutionary-neural method

Prof. UW, dr hab. Jerzy Balicki  
Politechnika Warszawska, Wydział Matematyki i Nauk Informatycznych  
Zakład Strukturalnych Metod Przetwarzania Wiedzy  
ul. Koszykowa 75  
00-662 Warszawa  
e-mail: J.Balicki@mini.pw.edu.pl

Piotr Dryja  
Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki  
Katedra Architektury Systemów Komputerowych  
ul. G. Narutowicza 11/12

80-233 Gdańsk

e-mail: dragon-83@o2.pl

Waldemar Korłub

Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki

Katedra Architektury Systemów Komputerowych

ul. G. Narutowicza 11/12

80-233 Gdańsk

e-mail: waldemar.korlub@pg.gda.pl

Piotr Przybyłek

Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki

Katedra Architektury Systemów Komputerowych

ul. G. Narutowicza 11/12

80-233 Gdańsk

e-mail: piotr.przybylek@gmail.com

Maciej Tyszka

Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki

Katedra Architektury Systemów Komputerowych

ul. G. Narutowicza 11/12

80-233 Gdańsk

e-mail: tyszka.maciej@gmail.com

Marcin Zadroga

Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki

Katedra Architektury Systemów Komputerowych

ul. G. Narutowicza 11/12

80-233 Gdańsk

e-mail: marcin.zadroga@pg.gda.pl

Marcin Zakidalski

Politechnika Gdańska, Wydział Elektroniki, Telekomunikacji i Informatyki

Katedra Architektury Systemów Komputerowych

ul. G. Narutowicza 11/12

80-233 Gdańsk

e-mail: mzakidalski@gmail.com

