

Andrzej Chluski

MOŻLIWOŚCI WYKORZYSTANIA SIECI NEURONOWYCH W OCENIE SCORINGOWEJ KREDYTOBIORCY

1. Wstęp

Podstawowym obszarem działalności gospodarczej banków komercyjnych i największym źródłem ich przychodów jest udzielanie kredytów. Jest to działalność obciążona sporym ryzykiem, co stawia przed bankami szczególne wymagania w zakresie procedur związanych z ich udzielaniem. Dotyczy to w szczególności kredytów konsumpcyjnych, uważanych przez banki za produkt masowy. Kredyty tego rodzaju powinny być udzielane szybko, sprawnie i w sposób możliwie automatyczny. Jednym z istotnych warunków powodzenia automatyzacji procesu udzielania kredytu jest stosowanie efektywnych i szybkich metod oceny ryzyka kredytowego związanego z konkretnym klientem. Prawidłowa ocena szeroko rozumianej zdolności kredytowej klientów banku jest bardzo ważnym elementem zarządzania ryzykiem działalności bankowej.

W artykule podjęto próbę określenia możliwości zastosowań sztucznych sieci neuronowych do oceny zdolności kredytowej klienta banku w odniesieniu do statystycznych metod klasyfikacyjnych, czyli próbę odpowiedzi na pytanie, czy metody te mogą być w tym przypadku równie efektywne i skuteczne jak metody klasyczne. Przedstawiono krótką charakterystykę powyższych metod, biorąc pod uwagę ich użyteczność w procesie oceny scoringowej klienta. W artykule wykorzystano wyniki wybranych badań, dotyczących użycia sieci neuronowych w celu klasyfikacji klientów, przeprowadzonych w ostatnich latach w polskich i zagranicznych bankach.

2. Klasyczne metody scoringowej oceny ryzyka kredytowego klienta banku

Istotnym elementem kontroli ryzyka kredytowego jest scoringowa ocena zdolności kredytowej klienta. Scoring umożliwia w miarę obiektywną i w znacznym stopniu zautomatyzowaną ocenę klienta banku, bierze pod uwagę poprzednie

doświadczenia i jest poparty odpowiednimi badaniami statystycznymi. Stosuje się go w szczególności wobec klientów detalicznych jako metodę stosunkowo skuteczną i mało czasochłonną.

Modele scoringowe należą do grupy systemów klasyfikacyjnych pozwalających na podstawie odpowiednio dobranych wskaźników dokonać podziału klientów na dwie kategorie. Pierwszą stanowią klienci rzetelni, nazywani przez banki dobrymi klientami, a drugą – klienci, którzy mogą mieć trudności ze spłatą kredytu, nazywani niesolidnymi klientami.

Stosowane w scoringu kredytowym metody klasyfikacyjne można podzielić na dwie grupy (Matuszczyk 2003, s. 55). Pierwszą z nich stanowią metody statystyczno-matematyczne, w skład których wchodzi:

- metody taksonomiczne,
- analiza dyskryminacyjna,
- regresja liniowa i logistyczna.

Do drugiej grupy należą metody niestatystyczne, oparte na sztucznych sieciach neuronowych i algorytmach genetycznych.

Metody taksonomiczne są powszechnie wykorzystywane w różnych dziedzinach nauki. Celem metod taksonomicznych jest taki podział analizowanych obiektów, który zapewni jak największą jednorodność elementów zaliczonych do tej samej klasy i jak największe różnice między elementami z różnych klas. Ze względu na cel prowadzenia badań metody taksonomiczne można podzielić na metody porządkujące, grupujące oraz metody wyboru reprezentantów odpowiednich klas obiektów. W przypadku podziału klientów banku na rzetelnych i nierzetelnych zastosowanie mają odpowiednie metody grupujące. Metody tego rodzaju można podzielić na dwie grupy (Witkowska 2002):

- metody taksonomii wzorcowej, umożliwiającej podział obiektów na klasy na podstawie znanych wcześniej wzorców tych klas,
- metody taksonomii bezwzorcowej, wykorzystywane do rozwiązywania zadań klasyfikacji w przypadkach, kiedy brak jest *a priori* informacji o wzorcach klas.

Analiza dyskryminacyjna jest klasyczną, bardzo często stosowaną metodą klasyfikacji klientów ubiegających się o kredyt. Pozwala ona na wykrycie zmiennych dyskryminujących podział klientów na tworzące się w sposób naturalny grupy – klasy klientów. Jej celem jest określenie zmiennych pozwalających najtrafniej podzielić klientów i zakwalifikować ich do odpowiedniej grupy. Dobór zmiennych ma duży wpływ na efektywność analiz dyskryminacyjnych. W ich doborze należy brać pod uwagę wiele założeń dotyczących rozkładu prawdopodobieństwa, podzielności zmiennych, odpowiednich wartości kowariancji itp. (Krzyśko 1990). W analizie dyskryminacyjnej zbiory wynikowe dla pewnego zakresu wartości zmiennej nie są rozłączne. Może to być przyczyną błędów klasyfikacji, określanych jako błędy I i II rodzaju. Z błędem I rodzaju mamy do czynienia w przypadku zaliczenia konkretnego klienta do grupy dobrych klientów, gdy w rzeczywistości

jest to klient z grupy złych klientów. W przypadku błędów II rodzaju sytuacja jest odwrotna. Banki są zainteresowane ograniczaniem występowania błędów I rodzaju, ponieważ mogą one być źródłem większych strat niż przypadki błędów II rodzaju.

Stosując metody regresyjne, do których zaliczamy m.in.: liniowy model prawdopodobieństwa, analizę logitową i probitową, otrzymujemy również wynik o wartościach typu: rzetelny albo nierzetelny. W modelu liniowego prawdopodobieństwa zmienna zależna jest związana ze zmiennymi objaśniającymi liniową zależnością w postaci funkcji regresyjnej. Metody logitowe i probitowe pozwalają na ominięcie ograniczeń związanych z założeniem liniowości poprzedniego modelu. Logit jest prawdopodobieństwem przyjęcia lub nieprzyjęcia przez zmienną klasyfikacyjną wartości logicznej typu rzetelny – nierzetelny. Analiza logitowa i probitowa dają bardzo podobne wyniki – zależność między nimi jest liniowa, różnią się o stały współczynnik (Gruszczyński 2001, s. 19).

3. Sieci neuronowe i ich zdolności klasyfikacyjne

Sztuczne sieci neuronowe są obiektem zainteresowań naukowców od połowy ubiegłego wieku. Intensywny rozwój badań nastąpił w latach osiemdziesiątych w związku z pojawieniem się sieci ze sprzężeniem zwrotnym oraz możliwościami technicznymi sprzętowej realizacji sieci – specjalizowanych układów scalonych. Sieci neuronowe są techniczną realizacją uproszczonego modelu funkcjonowania podstawowych elementów mózgu człowieka – neuronów wraz z istniejącymi między nimi połączeniami nerwowymi. Matematyczny model pojedynczego neuronu przedstawia zależność (1) (Rutkowska i in. 1997, s. 19):

$$y = f \sum_i^N w_i u_i, \quad (1)$$

gdzie: u – sygnały wejściowe,

w – tzw. wagi synaptyczne,


$f()$ nazywana jest funkcją aktywacji neuronu, która może być np. funkcją liniową, progową, sigmoidalną, tangensem hiperbolicznym.

Z praktycznego punktu widzenia funkcja aktywacji powinna być prosta. Wymagana złożoność przetwarzania sygnałów wejściowych jest realizowana przez odpowiednią topologię sieci (Tadeusiewicz 1993, s. 11).

Sieci neuronowe mają strukturę warstwową. W pierwszej warstwie znajdują się neurony przyjmujące sygnały wejściowe, w ostatniej znajdują się neurony, z których otrzymywane są sygnały wyjściowe. Między tymi warstwami mogą istnieć warstwy pośrednie nazywane warstwami ukrytymi. Poszczególne warstwy połączone są w ten sposób, że sygnały wyjściowe pierwszej warstwy stają się sygnałami wejściowymi następnej warstwy. Stosowane są również połączenia o charakterze sprzężenia zwrotnego, gdzie sygnały wyjściowe połączone są z sygnałami

wejściowymi. Topologia połączeń między neuronami poszczególnych warstw oraz ich parametry, wartości odpowiednich wag, stanowią program działania sieci, czyli jej wiedzę, natomiast sygnały wyjściowe otrzymane w wyniku aktywacji sieci sygnałami wejściowymi są rozwiązaniami zadań przez nią realizowanych (Tadeusiewicz 1993, s. 13). Przykładową topologię sieci trójwarstwowej przedstawiono na rys. 1.

Błąd!



Rys. 1. Przykładowa topologia sieci neuronowej

Źródło: (Janc, Kraska 2001, s. 90).

Ukazana na rys. 1 sieć składa się z trzech warstw – wejściowej, wyjściowej oraz trzejelementowej ukrytej warstwy środkowej.

Metody oparte na sieciach neuronowych mają swoje wady i zalety. Do wad można zaliczyć (Janc, Kraska 2001, s. 94):

- stosunkowo długi czas uczenia sieci w porównaniu z czasem działania statystycznych metod dyskryminacyjnych,
- brak teoretycznych podstaw tworzenia i parametryzowania topologii sieci oraz wyjaśniania odkrywanej przez sieć wiedzy, wartości poszczególnych wag nie dają się w prosty sposób zinterpretować,
- efekt przeuczenia sieci – przy niewłaściwej strukturze sieci traci ona właściwości generalizacji, zapamiętuje wszystkie możliwe, szczegółowe przypadki danych wejściowych,
- niebezpieczeństwo utknięcia w minimum lokalnym – sieć może nie osiągnąć globalnego ekstremum bez specjalnych zabiegów ze strony użytkownika.

Wśród zalet można wyróżnić:

- zdolności do operowania na dużych i niepewnych zbiorach danych – sieci radzą sobie z redundancją danych, nadmiarowych danych nie wykorzystują,
- odporność na dużą zmienność, dynamikę danych wejściowych,
- zdolności do generalizacji oraz znaczne możliwości adaptacyjne,
- brak restrykcyjnych wymagań co do charakteru danych wejściowych – w porównaniu z założeniami dotyczącymi metod statystycznych,

- zdolności predykcyjne – sieć może nauczyć się przewidywać sygnały wyjściowe, nawet jeżeli natura zjawiska nie jest dokładnie znana.

Poprawne działanie sieci neuronowej musi być poprzedzone odpowiednim treningiem. W zależności od typu zadania uczenie sieci może przebiegać z udziałem nauczyciela lub bez niego. Trenowanie sieci neuronowej z nauczycielem polega na dostarczeniu danych wejściowych oraz odpowiednich wzorcowych danych wyjściowych, które są porównywane z rzeczywistymi odpowiedziami sieci w procesie uczenia. Za pomocą odpowiednich algorytmów doprowadza się do minimalizacji tych różnic. Sieci trenowane bez nauczyciela są stosowane w sytuacji, gdy nasza wiedza o zadaniu, które ma ona realizować, jest ograniczona. Wykorzystuje się w tym przypadku predykcyjne zdolności sieci.

Dziedzina zastosowań klasyfikacyjnych sieci neuronowych jest ściśle związana z ich topologią, tzn. z liczbą warstw przetwarzających sygnały wejściowe. Pojedyncze neurony lub struktura jednowarstwowa są w stanie dokonać klasyfikacji dychotomicznej. Tego typu sieć dokonuje liniowego podziału przestrzeni danych na dwie półprzestrzenie (Rutkowski 2005, s. 162). W przypadku sieci dwuwarstwowej możliwości klasyfikacyjne sieci neuronowych znacznie wzrastają. Są one w stanie dokonać podziału przestrzeni decyzyjnej na obszary wypukłe. Przykładem może być podział na wewnątrz i zewnątrz elipsy w dwuwymiarowej przestrzeni decyzyjnej, czy na inny dowolny, wypukły obszar. Sieci o większej liczbie warstw mogą klasyfikować obszary o dowolnych kształtach nie spełniających warunku wypukłości. W najprostszych przypadkach podziału klientów banku na dobrych i złych można wykorzystać proste sieci jednowarstwowe. W przypadku podziału na większą liczbę klas stosuje się sieci wielowarstwowe.

4. Wybrane przykłady badań przydatności sieci neuronowych w ocenie scoringowej kredytobiorcy

Obecnie można wyróżnić około kilkudziesięciu podstawowych typów sieci neuronowych. Wykorzystując sieci neuronowe, należy dokonać odpowiedniego wyboru typu sieci w zależności od rodzaju problemu, który ma być rozwiązany, i dostosować sieć do konkretnego przypadku badawczego. Około 80% wszystkich zastosowań (Rutkowska i in. 1997, s. 17) sieci neuronowych jest realizowane za pomocą prostych sieci wielowarstwowych bez sprzężeń zwrotnych. Przepływ sygnałów jest jednokierunkowy – od pierwszej warstwy, poprzez warstwy ukryte (jeśli istnieją), do warstw wyjściowych. W przypadku zastosowań sieci neuronowych w bankowości sytuacja przedstawia się podobnie. W artykule napisanym przez A. Vellido, P.J.G. Lisboa i J. Vaughana (1999) przedstawiony jest przegląd literatury dotyczącej zastosowań sieci neuronowych w finansach. Autorzy przeanalizowali prace opisujące zastosowania sieci neuronowych m.in. w auditingu księgowym, działalności ubezpieczeniowej, bankowości, marketingu pod kątem typu sieci, rodzaju danych, sposobu badania jakości działania sieci itp. Z przeprowa-

dzonej analizy wynika, że w przypadku zastosowań dotyczących scoringu kredytowego używano najczęściej wielowarstwowych perceptronów (MLP – *multi-layer perceptron*). W większości przypadków nie stosowano żadnego wstępnego przygotowania danych wejściowych. W niewielu przypadkach stosowano sieci trenowane bez nadzoru, najczęściej sieci samoorganizujące z konkurencją. W omawianej literaturze najczęściej pojawiały się następujące wnioski (w 93 przypadkach opisywanych prac):

- sieci neuronowe dają lepsze rezultaty niż inne klasyczne metody (w 45 pracach),
- sieci neuronowe i metody klasyczne dają zbliżone rezultaty (w 14 pracach),
- sieci neuronowe dają gorsze rezultaty niż metody klasyczne (w 3 pracach),
- sieć neuronowa zastosowana w innych zintegrowanych, hybrydowych systemach znacznie poprawia ich efektywność (w 21 pracach),
- sieci neuronowe mogą mieć duże znaczenie w przyszłych praktycznych rozwiązaniach (w 29 pracach).

Do podobnych wniosków doszli R. Malhotra i D.K. Malhotra (2003), opisując badania, które wykonali w amerykańskich bankach. Badania przeprowadzono w 12 amerykańskich bankach na próbie 1078 przypadków. Porównywano metody oparte na sieciach neuronowych w postaci wielowarstwowego perceptronu (MLP) z klasycznymi metodami statystycznej analizy dyskryminacyjnej. W badaniach wykorzystano sześć zmiennych wejściowych: fakt posiadania na własność mieszkania, czas trwania stałego zameldowania, fakt posiadania karty kredytowej, stosunek wydatków do dochodów, stosunek zadłużenia do dochodów oraz czynnik klasyfikujący klienta do odpowiedniej grupy. Zastosowano klasyczną metodę wielowymiarowej analizy dyskryminacyjnej oraz model sieci neuronowej. Zbiór danych trenujących liczył 700 elementów, o takiej samej liczbie dobrych i złych klientów. Sieć neuronowa miała jedną warstwę ukrytą o strukturze podobnej do przedstawionej na rys. 1. Pierwsza warstwa miała sześć wejść odpowiadających zmiennym wejściowym. Warstwa wyjściowa miała jedno wyjście. Stan tego wyjścia klasyfikował klienta do odpowiednie grupy. W tabeli 1 przedstawiono porów-

Tabela 1. Porównanie modelu sieci neuronowych oraz analizy dyskryminacyjnej

Metoda	Zbiór testowy nr 1			Zbiór testowy nr 2			Zbiór testowy nr 3		
Klient	dobry	zły	średnia	dobry	zły	średnia	dobry	zły	średnia
Sieć neuronowa	82,0	61,7	71,9	76,9	66,6	71,8	74,6	67,6	71,1
Analiza dyskryminacyjna	79,0	60,4	69,7	77,1	61,8	69,4	73,6	65,3	69,4

Źródło: (Malhotra, Malhotra 2003, s. 93).

nanie efektywności modelu sieci neuronowej oraz wielowymiarowej analizy dyskryminacyjnej. Wartości liczbowe określają procent poprawnie zakwalifikowanych klientów do odpowiednich grup. W kolumnie „dobry” podany jest procent

dobrych klientów przydzielonych do grupy dobrych, podobnie w przypadku kolumny „zły”.

Zgodnie z badaniami opisanymi powyżej sieci neuronowe wykazywały większą efektywność niż tradycyjne metody statystycznej analizy dyskryminacyjnej. Autorzy w swoim artykule podają przykłady innych badań, w wyniku których otrzymano podobne rezultaty.

Również w polskich bankach przeprowadzano podobne badania. Wyniki badań, przeprowadzonych w wybranych polskich bankach, przedstawione przez D. Witkowską (2002) pokazują, że metody oparte na sieciach neuronowych mogą stanowić uzupełnienie metod statystycznych, zwiększając tym samym obiektywizm oceny klienta i upraszczając procedury przydzielania kredytu.

5. Zastosowanie sztucznych sieci neuronowych w komercyjnych systemach scoringowych wykorzystywanych w polskich bankach

Pod koniec XX w. niewiele polskich banków stosowało nowoczesne, zautomatyzowane systemy scoringowej oceny klienta detalicznego. Wynikało to z tego, że systemy informatyczne ówczesnych banków nie były przystosowane do wsparcia tego typu oprogramowania (rozproszone, transakcyjne systemy oddziałowe, słaba infrastruktura teleinformatyczna, brak wsparcia międzybankowych biur kredytowych itp.).

Systemy scoringowe oparte na sieciach neuronowych wykorzystuje obecnie m.in. Citibank (Boguszewski, Gelińska 2004, s. 74). W raporcie rocznym za rok 2005 Citibank Handlowy podaje, że unowocześnił system kontroli ryzyka przez zastosowanie nowych modeli scoringowych oraz zróżnicowaną, w zależności od kanału dystrybucji, politykę dotyczącą bezpieczeństwa kredytowego przez stosowanie odpowiednich kart scoringowych, wykorzystanie danych demograficznych i historii klienta uzyskanej z własnej bazy danych oraz z danych gromadzonych przez Biuro Informacji Kredytowej.

Jeden z największych polskich banków detalicznych PKO BP SA wykorzystuje system TRIAD firmy Fair Isaac Corporation (www.fairisaac.com). Jest to kompleksowy system wspomagający zarządzanie detalicznymi kredytami związanymi z kartami kredytowymi. System TRIAD jest wspomagany przez oparty na systemie transakcyjnym model zbudowany z wykorzystaniem sztucznych sieci neuronowych (sec.edgar-online.com).

W sprawozdaniu zarządu z działalności Kredyt Banku SA za rok 2005 stwierdza się, że w grupie klientów detalicznych zdolność kredytowa określana jest za pomocą systemu scoringowego, który został wdrożony w 2005 r. Znaczne zautomatyzowanie procesu udzielania kredytu w segmencie klientów detalicznych umożliwia rozwiązanie firmy Fair Isaac Corporation o nazwie StrategyWare (*Executive Strategies...* 2001). W systemie tym stosowany jest moduł wykorzystujący sztuczne sieci neuronowe.

Zastosowanie sieci neuronowych w modułach komercyjnych systemów scoringowych świadczy o ich dużej efektywności i przydatności w praktycznych rozwiązaniach.

6. Podsumowanie

Na podstawie przedstawionych wyników badań można uznać, że metody oparte na sieciach neuronowych mogą być stosowane na równi z innymi klasycznymi metodami dyskryminacyjnymi w ocenie scoringowej klienta banku. Różnice w efektywności nie są duże. Sieci neuronowe nie mają zbyt dużych wymagań dotyczących wstępnego przygotowania danych wejściowych, ani innych, mocnych założeń, które należy spełnić w przypadku metod statystycznych. Trudności w uzasadnieniu „decyzji” sieci neuronowej nie powinny mieć znaczenia w przypadku kredytów konsumpcyjnych, uważanych przez banki za produkt masowy i standardowy.

W komercyjnych systemach scoringowych modele oparte na sztucznych sieciach neuronowych są dostosowane do typowych, standardowych sytuacji związanych z konkretnym produktem bankowym i odpowiadającą mu grupą klientów. W sytuacjach nietypowych istnieje możliwość wykorzystania oprogramowania w postaci specjalizowanych pakietów statystycznych i matematycznych.

Metody oparte na sztucznych sieciach neuronowych często są łączone z metodami wykorzystującymi algorytmy genetyczne oraz teorię zbiorów rozmytych. Poszczególne metody mogą się wzajemnie uzupełniać. Część informacji, związanych z klientem banku, trudno jest w sposób jednoznaczny przedstawić w postaci numerycznej. Zastosowanie metod logiki rozmytej pozwala traktować zmienne tego typu w sposób sformalizowany, co może zwiększyć dokładność oceny klienta. W trakcie projektowania sieci neuronowych ważnym etapem jest odpowiedni dobór zmiennych wejściowych. Algorytmy genetyczne, ze względu na swoje zdolności uczenia się bez nadzoru, mogą być bardzo użyteczne podczas wstępnego przetwarzania danych wejściowych. W praktycznych zastosowaniach można zasugerować położenie większego nacisku na doskonalenie jakości danych, a także na wykorzystywanie danych pochodzących z zewnętrznych źródeł. Istotnym kierunkiem rozwoju praktycznych zastosowań scoringu może być ulepszanie metod klasyfikacyjnych, przez wykorzystanie technik hybrydowych, łączących metody oparte na sieciach neuronowych i algorytmach genetycznych z zastosowaniem logiki rozmytej.

Literatura

Boguszewski L., Gelińska B., *Podstawy statystyczne i uniwersalna funkcjonalność scoringu*, [w:] *Interdyscyplinarne wykorzystanie metod ilościowych*, red. M. Gazińska, Wydawnictwo Uniwersytetu Szczecińskiego, Szczecin 2004.

- Executive Strategies for Technology Management*, „Insurance Networking News” 01.01.2001, http://www.accessmylibrary.com/coms2/summary_02860130332_ITM.
- Gruszczyński M., *Modele i prognozy zmiennych jakościowych w finansach i bankowości*, SGH, Warszawa 2001.
- Janc A., Kraska M., *Credit-scoring nowoczesna metoda oceny zdolności kredytowej*, Biblioteka Menedżera i Bankowca, Warszawa 2001.
- Krzyśko M., *Analiza dyskryminacyjna*, WNT, Warszawa 1990.
- Malhotra R., Malhotra D.K., *Evaluating Consumer Loans Using Neural Networks*, „The International Journal of Management Science” 2003, 31, www.elsevier.com.
- Matuszczyk A., *Przeglądając się kredytobiorcom*, „Bank Miesięcznik Finansowy” 2003 luty, Warszawa 2003.
- Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN, Warszawa 1997.
- Rutkowski L., *Metody i techniki sztucznej inteligencji*, Wydawnictwo Naukowe PWN, Warszawa 2005.
- sec.edgar-online.com – <http://sec.edgar-online.com/2002/11/21/0000936392-02-001464/Section2.asp>.
- Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa 1993.
- Vellido A., Lisboa P.J.G., Vaughan J., *Neural Networks in Business: A Survey of Applications (1992-1998)*, „Expert Systems with Applications” 1999, 17.
- Witkowska D., Staniec I., *Zastosowanie wybranych metod do klasyfikacji klientów przedsiębiorstwa leasingowego*, „Bank i Kredyt” 2001, http://www.nbportal.pl/library/pub_auto_B_0002/KAT_B3256.PDF.
- Witkowska D., *Sztuczne sieci neuronowe i metody statystyczne. Wybrane zagadnienia finansowe*, Wyd. C.H. Beck, Warszawa 2002.
- www.fairisaac.com – strona firmy Fair Isaac Corporation.

THE POSSIBILITIES OF NEURAL NETWORKS USAGE IN THE SCORING ASSESSMENT OF CREDIT BENEFICIARY

Summary

The purpose of the paper is to explore in several chosen cases the ability of neural networks in building credit scoring models. The article highlights the neural networks models studies in Polish and foreign banks. As the strength of the studies there can be claimed that it is possible to use neural networks methods for bank's clients classification. The effectiveness of these methods is comparable with classic discrimination methods.