Maciej KOKORNIAK*, Przemysław GARSZTKA

ZASTOSOWANIE SIECI NEURONOWYCH ORAZ ANALIZY DYSKRYMINACYJNEJ DO TWORZENIA SCORINGU BEHAWIORALNEGO RATALNYCH KREDYTÓW KONSUMPCYJNYCH

Wprowadzenie

Kredyty konsumpcyjne są specyficzną usługą, świadczoną przez banki na rzecz klientów indywidualnych (detalicznych). W literaturze przedmiotu są one często postrzegane jako środek zachęcający klientów do założenia bądź też utrzymania rachunków oszczędnościowo-rozliczeniowych (ROR) [8]. Wynika to z faktu, że klienci posiadający taki rachunek są głównymi dostarczycielami pieniądza, który jest pozyskiwany przez banki w postaci depozytów. Kredyt konsumpcyjny jest zatem postrzegany nie jako środek intensyfikacji akcji kredytowej, ale jako środek służący, w dłuższym okresie, do intensyfikacji akcji depozytowej, dzięki której możliwe jest finansowanie kredytów na cele gospodarcze oraz mieszkaniowe. Dane finansowe dotyczące polskiego sektora bankowego w latach 2000-2002 wskazują, że najlepsze wyniki osiągały banki, których udział w rynku kredytów konsumpcyjnych był najwyższy (PKO BP SA, Pekao SA). Najgorsze wyniki finansowe zanotowały natomiast banki, które zdominowały rynek kredytów gospodarczych (BRE Bank SA, Bank Handlowy w Warszawie SA). Oznacza to, że warto rozwijać narzędzia, umożliwiające lepsze zarządzanie portfelem kredytów konsumpcyjnych.

---

* Maciej Kokorniak, pracownik banku PKO BP SA.

Ratalne kredyty konsumpcyjne generalnie dzielą się na:
- gotówkowe,
- bezgotówkowe na zakup towarów lub usług,
- bezgotówkowe na zakup pojazdów lub sprzętu technicznego,
- dla studentów.

Dodatkowo do wspólnej grupy usług (produktów) bankowych wraz z kredytami konsumpcyjnymi zalicza się pożyczki lombardowe oraz hipoteczne.

Kredyty gotówkowe przyznawane są maksymalnie na cztery lata. Mogą być udzielane na warunkach ogólnych lub preferencyjnych. Ustanowienie warunków preferencyjnych jest związane z posiadaniem rachunku oszczędnościowo-rozliczeniowego w danym banku. Należy jednak spełnić dodatkowe wymagania. Maksymalna kwota kredytu gotówkowego nie może przekraczać około 100 razy najniższego wynagrodzenia za pracę, określonego w rozporządzeniu właściwego ministra. W okresach szczególnego zainteresowania klientów zakupami, banki udzielają sezonowych kredytów gotówkowych. Cechuje je uproszczona procedura przyznawania; są jednak zwykle udzielane na stosunkowo niskie kwoty.

Kredyty bezgotówkowe na zakup towarów lub usług przyznawane są maksymalnie na trzy lata. Są one udzielane na cele związane z zakupem nowych towarów oraz na cele związane z zakupem usług.

Na zakup pojazdów lub sprzętu technicznego kredyty bezgotówkowe przyznawane są maksymalnie na siedem lat. Udzielane są one na cele związane z zakupem nowych i używanych pojazdów, sprzętu technicznego oraz w celu spłaty kredytu na zakup pojazdu zaciągniętego w innym banku. Osoby posiadające ROR, w banku udzielającym kredyt, mogą uzyskać go na warunkach preferencyjnych, pod warunkiem że pokryją w części zakup z wkładu własnego (wymagana wysokość wkładu własnego wynosi w różnych bankach od 20 do 50%).

Kredyty studenckie udzielane są maksymalnie na dziesięć lat. Okres kredytowania składa się z okresu wypłaty poszczególnych transz kredytu, który kończy się wraz z ukończeniem uczelni i nie może być dłuższy niż sześć lat, oraz okresu spłaty kredytu, który rozpoczyna się nie później niż po upływie trzech miesięcy od terminowego ukończenia uczelni i nie może być dłuższy niż cztery lata. Maksymalna kwota kredytu uzależniona jest od celu, na jaki kredyt jest przeznaczony i nie może przekroczyć piętnastokrotnego przeciętnego wynagrodzenia miesięcznego w gospodarce narodowej. Wypłata kolejnej transzy kredytu może zostać wstrzymana w przypadku, gdy student korzystający z kredytu uzyskał urlop okolicznościowy, nie zaliczył odpowiedniego okresu zaliczeniowego lub nie zapłacił w terminie odsetek, w dwóch kolejnych terminach ich spłaty.

Banki dzielą kredyty konsumpcyjne na kategorie ryzyka według kryterium terminowości spłaty. W rozporządzeniu ministra finansów wyróżniono cztery kategorie ryzyka[1]:

- „normalne" – dla należności spłacanych terminowo oraz należności, w przypadku których opóźnienie w spłatach kapitału lub odsetek nie przekracza miesiąca,
- „poniżej standardu" – dla należności, w przypadku których opóźnienie w spłacie kapitału lub odsetek wynosi powyżej miesiąca i nie jest dłuższe niż trzy miesiące,
- „wątpliwe" – dla należności, w przypadku których opóźnienie w spłacie kapitału lub odsetek wynosi powyżej trzech miesięcy i nie jest dłuższe niż sześć miesięcy,
- „stracone" – dla należności, w przypadku których opóźnienie w spłacie kapitału lub odsetek jest większe niż sześć miesięcy, oraz należności, w przypadku których bank wypowiedział umowę kredytową; bank może na przykład wypowiedzieć umowę w sytuacji, gdy klient zalega dwie pełne raty kapitałowo-odsetkowe.

Taki podział wydaje się jednak niewystarczający. Po pierwsze dlatego, że dwie z czterech wymienionych kategorii ryzyka („wątpliwe" oraz „stracone") przeważnie oznaczają sytuację trwałego braku zdolności kredytowej (tzw. sytuację *default*). W normalnej obsłudze mamy do czynienia tylko z dwiema kategoriami ryzyka dla kredytów (kategorie: „normalne" oraz „poniżej standardu"). Po drugie, branie pod uwagę przy ocenie ryzyka danego kredytu wyłącznie terminowości obsługi kredytu nie pozwala na uzyskanie pełnego obrazu sytuacji. Inną bowiem wagę należy przykładać do opóźnień w spłacie kredytu w 90% spłaconego, a inną w przypadku, gdy klient dopiero zaczyna spłacać kredyt. Inaczej należy traktować niewielkie zaległości w spłacie kredytu, wynikające często z nieznajomości planu spłaty przez klientów, a inaczej zaległości będące rezultatem niepłacenia pełnych rat kredytowych. W związku z tym zasadne wydaje się dzielenie kredytów konsumpcyjnych, znajdujących się w normalnej spłacie, na dodatkowe grupy ryzyka na podstawie scoringu behawioralnego, budowanego na podstawie danych związanych z rachunkiem kredytowym. Scoring behawioralny jest techniką oceniającą, która pozwala kredytobiorcy podjąć bardziej trafną decyzję, dotyczącą stałego klienta banku poprzez przewidywanie przyszłych wyników jego działalności. Ocenę behawioralną uważa się często za bardziej wiarygodną i kompleksową ze względu na

[1] Rozporządzenie ministra finansów z dnia 10 grudnia 2001 roku w sprawie zasad tworzenia rezerw na ryzyko związane z działalnością banków.

wykorzystywanie danych historycznych, zebranych przez bank w trakcie obsługi klienta, oraz ze względu na to, że jest ona dokonywana regularnie i w związku z tym zawsze zawiera aktualne dane. Podstawową różnicą pomiędzy scoringiem behawioralnym a powszechnie stosowanym scoringiem użytkowym jest fakt, że scoring użytkowy odnosi się do nowych klientów banku. Natomiast ocena behawioralna dotyczy stałych klientów [10]. Ocena behawioralna wydaje się słabo rozwinięta i zaniedbana, a większość stosowanych w praktyce systemów jest w wysokim stopniu niedoskonałych. Do podziału kredytów na grupy ryzyka autorzy postanowili wykorzystać liniową funkcję dyskryminacyjną oraz trójwarstwową sieć neuronową z nieliniową funkcją aktywacji, a następnie porównać uzyskane wyniki. Do oszacowania funkcji dyskryminacyjnej i budowy sieci neuronowej wykorzystane zostały dane księgowe oddziałów regionu wielkopolskiego PKO BP SA z okresu od 1 listopada 2002 roku do 31 października 2003 roku.

1. Metodologia

1.1. Klasyczna analiza dyskryminacyjna

Klasyczna analiza dyskryminacyjna dotyczy klasyfikacji na podstawie wzorca. Proces klasyfikacji przebiega w dwóch etapach:

- odnajdywania charakterystyk klas na podstawie zbioru zawierającego sklasyfikowane obiekty, nazywanego dalej zbiorem uczącym;
- przydzielania nowych obiektów z tzw. zbioru testowego, dla których nie jest znane ich pochodzenie, do rozpoznanych wcześniej klas.

Do klasyfikacji użyto liniowej funkcji dyskryminacyjnej, tworzonej ze wzoru na statystykę kwalifikacyjną Walda-Andersona o postaci [12]:

$$W_{ij}=\mathbf{x}^{\mathrm{T}}\mathbf{S}^{-1}(\bar{\mathbf{x}}_i-\bar{\mathbf{x}}_j)-\frac{1}{2}(\bar{\mathbf{x}}_i+\bar{\mathbf{x}}_j)^{\mathrm{T}}\mathbf{S}^{-1}(\bar{\mathbf{x}}_i-\bar{\mathbf{x}}_j), \tag{1}$$

w której: indeksy i oraz j przebiegają numery wszystkich klas, na które dzielone są obiekty, macierz $\mathbf{S}$ jest oceną macierzy kowariancji obserwowanych wektorów zmiennych losowych. Macierz ta jest obliczana ze wzoru:

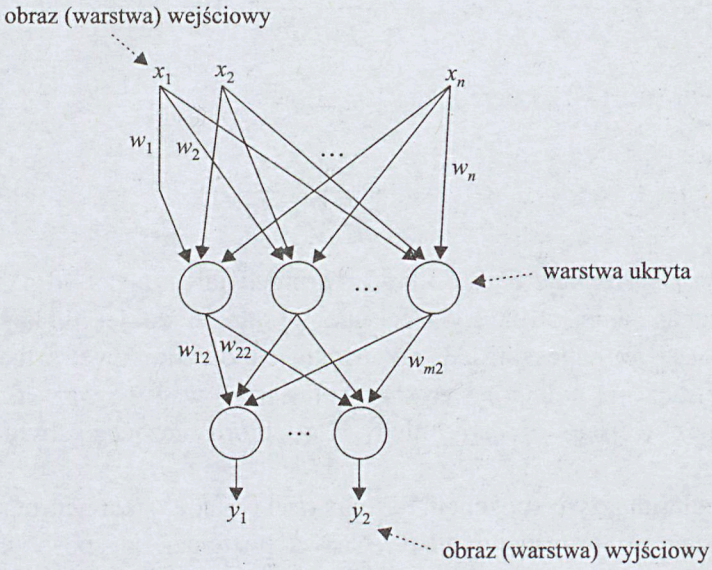
$$\mathbf{S}=\frac{1}{N-k}\sum_{j=1}^{k}\mathbf{A}_j, \tag{2}$$

w którym elementami macierzy $\mathbf{A}_j$ są sumy kwadratów oraz iloczyny wartości próbkowych cech charakteryzujących j-tą klasę, N oznacza liczbę wektorów zbioru uczącego, a k jest liczbą klas,
Wektor $\bar{\mathbf{x}}_i$ oznacza wektor średnich próbkowych i jest traktowany jak estymator wartości oczekiwanej klasy i. Zakłada się przy tym, że obserwowane wektory losowe mają wielowymiarowe rozkłady normalne.

Odpowiednie wzory można znaleźć między innymi w pracy D.F. Morrisona [12]. Zgodnie z podaną w tym opracowaniu regułą, jeżeli $\mathbf{x}$ jest nowym obiektem, którego pochodzenie nie jest znane, to zaliczamy go do klasy i, jeżeli statystyki $W_{ij} > 0$ dla wszystkich $j \neq i$.

1.2. Sztuczne sieci neuronowe

Sieci neuronowe są, oprócz systemów eksperckich i algorytmów genetycznych, narzędziami sztucznej inteligencji. Sieć neuronowa składa się z pewnej liczby elementów (neuronów) przetwarzających informację. Neurony są ze sobą powiązane za pomocą połączeń o parametrach (wagach) modyfikowanych w trakcie procesu uczenia. Zwykle sieci neuronowe mają budowę warstwową. Do rozwiązywania większości problemów wystarczają sieci trójwarstwowe [15] (rys. 1), składające się z warstwy wejściowej, która przyjmuje sygnały, warstwy



Rys. 1. Przykładowa sieć trójwarstwowa

ukrytej i warstwy wyjściowej podającej wyniki. Warstwa wyjściowa powinna liczyć tyle neuronów, ile wymaga odpowiedź na postawiony problem. Nie ma jednoznacznej odpowiedzi, ile neuronów powinna liczyć warstwa ukryta.

Oprócz warstw sieci mogą również różnić się układem połączeń między neuronami. Wyróżnić można dwie główne grupy [18]:

- sieci jednokierunkowe,
- sieci ze sprzężeniem zwrotnym,

Neurony przetwarzają sygnały wejściowe w sygnał wyjściowy zgodnie ze wskazaniami funkcji aktywacji $y=\varphi(\mathbf{e})$. Sygnał wejściowy definiuje się jako:

$$\mathbf{e}=\sum_{i=1}^{n} w_i x_i, \tag{3}$$

gdzie:

n – liczba neuronów warstwy poprzedzającej dany neuron,
w_i – waga neuronu i warstwy poprzedzającej dany neuron,
x_i – neuron i warstwy poprzedzającej dany neuron.

Jako funkcję aktywacji najczęściej stosuje się funkcje sigmoidalne, wywodzące się z funkcji logistycznej:

- bipolarnej (tzn. przyjmującej wartości z przedziału $[-1, 1]$):

$$\varphi(\mathbf{e})=\frac{2}{1+\exp(-\beta\mathbf{e})}-1, \tag{4}$$

- unipolarnej (wartości z przedziału $[0, 1]$):

$$\varphi(\mathbf{e})=\frac{1}{1+\exp(-\beta\mathbf{e})}, \tag{5}$$

Szybkość, z jaką funkcje dążą do krańców przedziału, zależy od parametru β.

Stworzenie samej struktury sieci nie wystarczy do jej funkcjonowania. Niezbędne jest jej nauczenie. W przypadku jednokierunkowej sztucznej sieci neuronowej uczenie polega na wyznaczeniu takich wag we wszystkich warstwach oprócz wejściowej, aby błędy dla zbioru uczącego były możliwe najmniejsze.

Najpopularniejszym sposobem uczenia (trenowania) sieci neuronowych jest metoda wstecznej propagacji błędu. Nazwa pochodzi od sposobu, w jakim korygowane są wagi w neuronach. W jednym kierunku przechodzi sygnał wejściowy poprzez warstwę ukrytą aż do warstwy wyjściowej. Dalej obliczany

jest błąd i w przeciwnym kierunku następuje korekta wag – najpierw w warstwie wyjściowej, potem w ukrytej.

W opracowaniu autorzy zastosowali unipolarną funkcję aktywacji oraz metodę algorytm wstecznej propagacji błędu.

Sztuczne sieci neuronowe bywają na ogół lepsze od innych metod przy spełnieniu następujących warunków [11]:

- dane, z których trzeba wyciągać wnioski, są „rozmyte" (na przykład ludzkie opinie, źle określone kategorie, obarczone dość dużymi błędami);
- wzorce ważne do podjęcia wymaganej decyzji są natury delikatnej lub są głęboko ukryte; jedną z głównych zalet sieci neuronowych jest ich zdolność do odkrywania w zbiorze wzorców, które są tak niejasne, że są niewykrywalne przez tradycyjne metody statystyczne;
- dane wykazują znaczną, nieoczekiwaną nieliniowość;
- dane są chaotyczne (w sensie matematycznym).

2. Analizy empiryczne

2.1. Opis wykorzystanych danych

W artykule wykorzystano dane księgowe Regionu Wielkopolskiego PKO BP SA, pochodzące z okresu od 1 listopada 2002 roku do 31 października 2003 roku.

Bank wyraził zgodę na udostępnienie swoich danych do badań naukowych, pod warunkiem że wszystkie dane pozwalające na określenie liczby oraz wartości spraw związanych z restrukturyzacją i windykacją należności oraz pozwalające na określenie jakości portfela jego kredytów zostaną utajnione. W związku z tym prezentacja części wyników dokonana została za pomocą indeksów jednopodstawowych.

Dokonano podziału ratalnych kredytów konsumpcyjnych w normalnej obsłudze (kategorie ryzyka „normalne" oraz „poniżej standardu") na trzy grupy ryzyka. Pierwsza grupa ryzyka oznacza kredyty znajdujące się w najlepszej sytuacji, druga grupa ryzyka oznacza kredyty nieco gorsze, trzecia natomiast oznacza kredyty dla których prawdopodobieństwo przejścia z kategorii kredytów w normalnej obsłudze do kategorii „stracone" lub znajdujących się w restrukturyzacji jest największe. Podziału dokonano dla kredytów ratalnych, znajdujących się w normalnej obsłudze według stanu na 30 czerwca 2003 roku oraz według stanu na 31 października 2003 roku. Następnie sprawdzono, co stało się po upływie czterech miesięcy (to znaczy po okresie od 1 lipca do

31 października 2003 roku dla kredytów z 30 czerwca 2003 roku) z kredytami wytypowanymi do poszczególnych grup ryzyka. Obliczenia zostały przeprowadzone dla danych z czterech miesięcy poprzedzających moment dokonania podziału na grupy ryzyka.

Jako wartości zmiennych wejściowych (zmiennych objaśniających) zbioru trenującego wykorzystano dane rejestrowane w ciągu czterech następujących po sobie miesięcy. Okres czterech miesięcy jest minimalny, aby – zgodnie z prawem bankowym – kredyty znajdujące się w normalnej obsłudze mogły zostać sklasyfikowane do kategorii „wątpliwe" lub „stracone".

Zmienne (zarówno dla funkcji dyskryminacyjnej, jak i dla sieci neuronowej) zostały zdefiniowane następująco:

- x_1 – zmienna sygnalizująca regularność dokonywania spłat. Przyjmuje wartości od -1 do 3, w zależności od tego, jak według stanu na koniec każdego z czterech poprzedzających miesięcy zmieniał się stan zadłużenia. Za każdym razem, gdy saldo w danym (2, 3 oraz 4) miesiącu uległo zmniejszeniu, w porównaniu z miesiącem poprzednim, zmienna była zwiększana o 1. Wartość -1 (niezależnie od wcześniejszej wartości zmiennej) nadawana była w przypadku, gdy zadłużenie na koniec trzeciego miesiąca było znacząco mniejsze od salda kapitału na koniec czwartego miesiąca. Jest to sytuacja nietypowa, oznaczająca często, że kredyt nie będzie dalej spłacany,
- x_2 – saldo rachunku na koniec czwartego miesiąca,
- x_3 – zmienna sygnalizująca terminowość spłat, przyjmująca wartości od 0 do 4, w zależności od tego, czy według stanu na koniec czterech badanych miesięcy istniały zaległości w spłacie kredytu (suma wartości po każdym z czterech poprzedzających miesięcy, przy punktowaniu: 0 – brak zaległości, 1 – wystąpienie zaległości),
- x_4 – saldo zaległości na koniec czwartego miesiąca,
- x_5 – liczba dni zaległości w spłacie na koniec czwartego miesiąca;
- x_6 – zmienna przyjmująca wartości od 4 do 14, w zależności od kategorii ryzyka nadawanej kredytowi według stanu na koniec każdego z czterech badanych miesięcy (suma wartości nadawanych po upływie każdego z czterech poprzedzających miesięcy przy następującym punktowaniu kategorii: 1 – „normalne", 2 – „poniżej standardu", 3 – „wątpliwe", 4 – „stracone"),
- x_7 – zmienna przyjmująca wartości 1 lub 2, w zależności od kategorii ryzyka kredytu według stanu na koniec czwartego miesiąca, gdzie 1 oznacza kredyt w kategorii normalnej, 2 oznacza kredyt w kategorii poniżej standardu,

- x_8 – liczba dni, które upłynęły od momentu przyznania danego kredytu według stanu na koniec czwartego miesiąca,
- x_9 – liczba dni, która pozostała do najbliższego terminu spłaty kapitałowej części raty kredytu według stanu na koniec czwartego miesiąca,
- x_{10} – liczba rat kapitałowo-odsetkowych, na które została podzielona spłata danego kredytu,
- x_{11} – zmienna przyjmująca wartości 0 lub 1, w zależności od tego, czy dany kredyt był na koniec czwartego miesiąca klasyfikowany automatycznie przez system informatyczny czy też „ręcznie" przez pracowników banku,
- x_{12} – zmienna przyjmująca wartości od 2 do 4, w zależności od wielkości miejscowości, w której usytuowany jest oddział banku, udzielający kredytu odnawialnego (2 – małe miejscowości, 3 – średniej wielkości miasta, 4 – dużej wielkości miasta),
- x_{13} – kwota kredytu,
- x_{14} – zmienna przyjmująca wartości 0 lub 1, w zależności od tego, czy dany kredyt był na koniec czwartego miesiąca spłacany w ratach malejących czy równych,
- x_{15} – zmienna przyjmująca wartości od -1 do 2, w zależności od tego, czy kredyt był udzielony osobie posiadającej rachunek ROR w PKO BP SA według stanu na koniec czwartego miesiąca czy też nie (-1 – rachunek umiejscowiony, 0 – brak rachunku, 1 – zwykły rachunek ROR, 2 – „złoty" lub „platynowy" ROR),
- x_{16} – zmienna przyjmująca wartości od -1 do 1, w zależności od ewentualnej kategorii ryzyka dla danego rachunku (-1 – rachunek z kategorią ryzyka „poniżej standardu", „wątpliwe" lub „stracone", 0 – brak rachunku, 1 – rachunek z kategorią ryzyka „normalne"),
- x_{17} – zmienna przyjmująca wartości 0 lub 1, w zależności od tego, czy klient, który zaciągnął kredyt, posiadał windykowane zobowiązania wobec banku na koniec czwartego miesiąca czy też nie,
- x_{18} – zmienna będąca liczbową reprezentacją typu kredytu (1 – kredyt bezgotówkowy na zakup towarów lub usług, 2 – złotowy kredyt bezgotówkowy na zakup pojazdów lub sprzętu technicznego, 3 – dewizowy kredyt bezgotówkowy na zakup pojazdów lub sprzętu technicznego, 4 – niesezonowy kredyt gotówkowy, 5 – sezonowy kredyt gotówkowy typu „Lato", 6 – sezonowy kredyt gotówkowy typu „Zima", 7 – inne kredyty).

Zmienna wyjściowa (klasa) została określona jako sytuacja danego kredytu po upływie czterech miesięcy, odpowiednio:

- dla kredytów, w przypadku których po czterech miesiącach nie wystąpiła sytuacja *default* zmienna wyjściowa przyjmowała wartość 1 (pierwsza klasa kredytów),
- dla kredytów zaliczonych do kategorii „wątpliwe" zmienna wyjściowa przyjmowała wartość 2 (słaby *default* – druga klasa kredytów),
- dla kredytów zaliczonych do kategorii „stracone" oraz kredytów restrukturyzowanych zmienna wyjściowa przyjmowała wartość 3 (silny *default* – trzecia klasa kredytów).

Wartości zmiennej wyjściowej zostały dla potrzeb sieci neuronowych znormalizowane. Fakt ten został podyktowany zastosowanym algorytmem wstecznej propagacji błędu, przy zastosowaniu unipolarnej funkcji aktywacji oraz architektury sieci z jednym neuronem wyjściowym. Wartości zmiennej wejściowej mieściły się w przedziale [0, 1].

Proporcja udziału danych opisujących poszczególne kredyty w obu zbiorach trenujących była następująca:

- 50% danych o kredytach, dla których nie wystąpiła sytuacja *defaultu*,
- 25% danych o kredytach, dla których wystąpiła sytuacja słabego *defaultu*,
- 25% danych o kredytach, dla których wystąpiła sytuacja silnego *defaultu*.

Proporcja ta wynika z pewnej generalnej zasady, mówiącej o tym, że jeżeli chcemy podzielić daną zbiorowość na elementy „dobre" i „złe", to niezależnie od przyjętej metody podziału wskazania najlepiej oprzeć na badaniach wyodrębnionej części zbiorowości, w których 50% stanowią elementy zdefiniowane jako „dobre", a drugie 50% – elementy zdefiniowane jako „złe" [13]. W analizowanym przypadku kredyty rozróżniane jako „złe" (dla których wystąpiła sytuacja *default*) zostały podzielone na dwie podgrupy.

2.2. Weryfikacja wyników uzyskanych dla zbioru uczącego

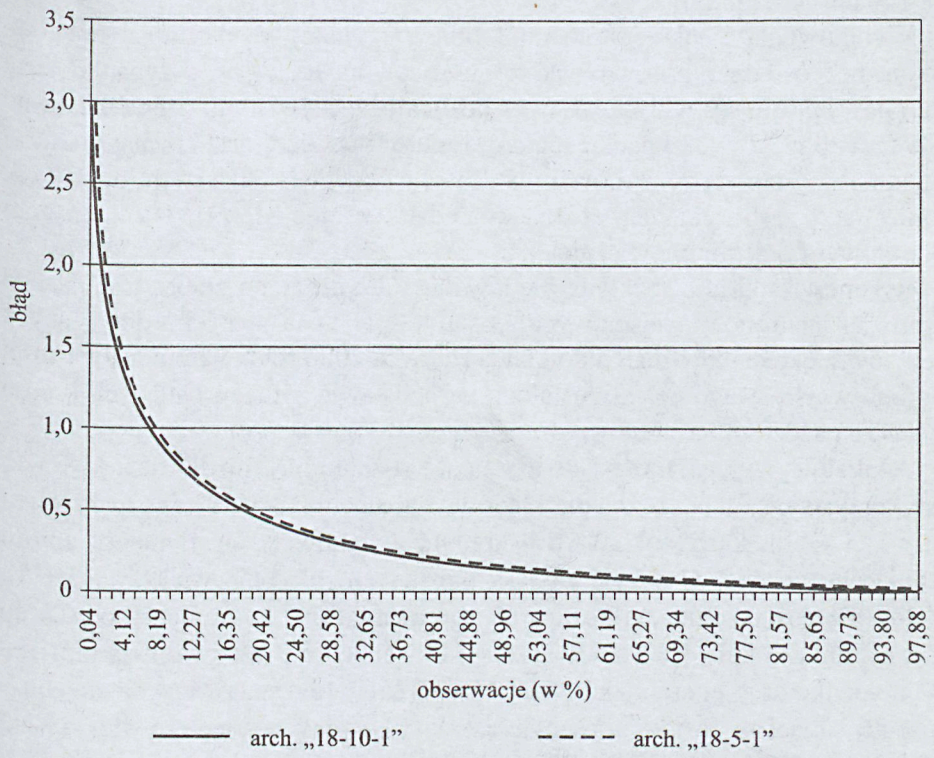
Błędy wykorzystywanych w badaniach sieci neuronowych mierzone były jako moduły różnic pomiędzy oczekiwanymi wartościami neuronu wyjściowego a wartością sygnału wyjściowego wytrenowanej sieci. Dodatkowo dla każdego zbioru trenującego wyznaczono rozkład błędów sieci, a ponadto wskazano, jaki procent jego elementów został przez sieć neuronową zaklasyfikowany właściwie, jaki procent poprawnie, a jaki procent niewłaściwie.

W przypadku liniowej funkcji dyskryminacyjnej błędy oceniane były poprzez wskazanie, jaki procent elementów zbioru trenującego został przydzielony do oczekiwanej klasy, jaki procent został przydzielony do klasy sąsiadującej oraz jaki procent został przydzielony do klasy o dwie innej od

oczekiwanej (w przypadku kredytów znajdujących się w drugiej klasie błędne zakwalifikowanie do klasy o dwie innej nie wystąpiło).

Dla określonych wcześniej warstw: wejściowej (18 neuronów) i wyjściowej (1 neuron) stworzono i trenowano sieci o dwóch strukturach różniących się od siebie liczbą neuronów warstwy ukrytej. Zastosowano architektury o 5 oraz 10 neuronach w warstwie ukrytej. Pierwsza architektura została wybrana jako osiągająca średnio najmniejszy błąd uczenia spośród dwóch innych o odpowiednio 4 i 6 neuronach w warstwie ukrytej. Te trzy architektury zostały wybrane ze względu na to, że w literaturze przedmiotu często podaje się, że wskazana liczba neuronów w warstwie ukrytej powinna równać się pierwiastkowi z iloczynu liczby neuronów warstwy wejściowej oraz wyjściowej [11]. Druga architektura została wybrana po to, aby spośród architektur spełniających regułę Bauma-Hausslera [1] znaleźć tę, dla której liczba neuronów w warstwie ukrytej będzie jak największa i przy tym nie występuje problem „wpadania" sieci podczas jej trenowania w „minima lokalne".

Rysunek 2 ukazuje rozkłady błędów sieci o 5 i 10 neuronach w warstwie ukrytej dla pierwszego zbioru trenującego. (Wartości neuronów wejściowych



Rys. 2. Rozkłady błędów sieci dla drugiego zbioru trenującego

zostały oparte na danych dotyczących kredytów z okresu od 1 listopada 2002 roku do 28 lutego 2003 roku, natomiast wartości neuronu wyjściowego zostały porównane ze stanem badanych kredytów z dnia 30 czerwca 2003 roku). Na rysunku obserwacje zostały uszeregowane od osiągających największy błąd do osiągających najmniejszych błąd.

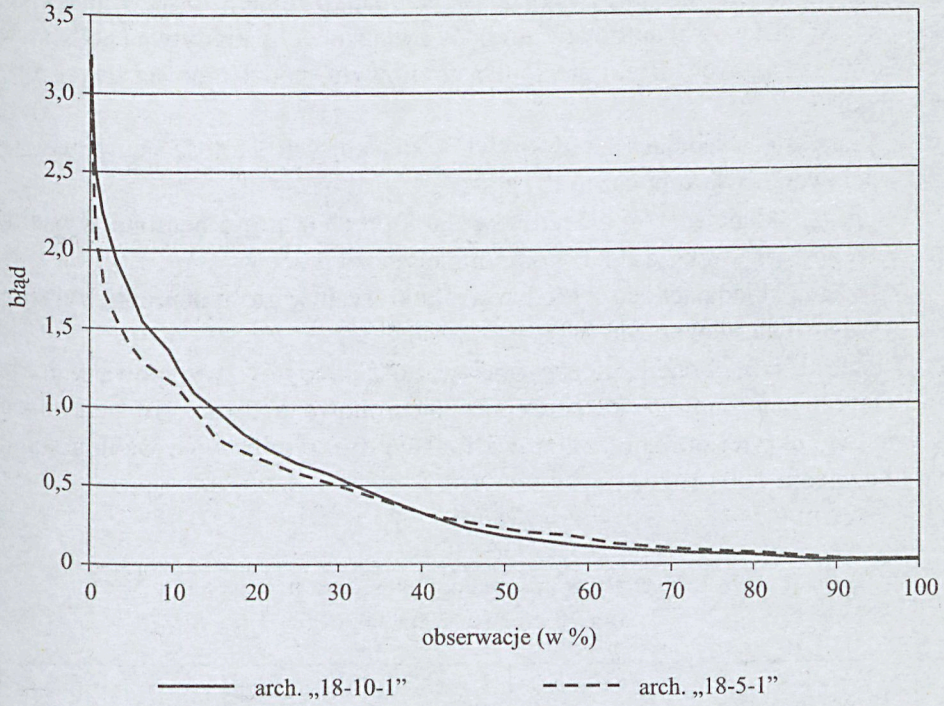
Na osi poziomej zaznaczono jedynie procent przebadanej populacji. Analizując przedstawiony wykres można stwierdzić, że rozkład błędów sieci dla architektury „18-5-1" praktycznie nie różni się od rozkładu błędów sieci dla architektury „18-10-1". W obu przypadkach około 82% kredytów stanowiących elementy zbioru trenującego zostało przez sieć neuronową właściwie zaklasyfikowanych (za takie uznane zostały obserwacje, dla których błąd był nie większy niż 0,5), około 15% zostało zaklasyfikowanych poprawnie (błąd w granicach od 0,5 do 1,5), a około 3% zostało zaklasyfikowanych źle (błąd większy niż 1,5).

W przypadku liniowej funkcji dyskryminacyjnej dla tego samego zbioru trenującego około 76% elementów zostało przydzielonych do oczekiwanej klasy, około 21% zostało przydzielony do klasy sąsiadującej, a około 3% zostało przydzielonych do klasy o dwie innej od oczekiwanej (do pierwszej zamiast trzeciej lub odwrotnie).

Wyników dla sieci neuronowej i liniowej funkcji dyskryminacyjnej nie można bezpośrednio porównywać ze względu na to, że w przypadku sieci neuronowych obrazy wyjściowe były liczbami rzeczywistymi z przedziału od 0 do 5, natomiast w przypadku funkcji dyskryminacyjnej oczekiwane wartości zmiennej wyjściowej przyjmowały wartości całkowite z przedziału od 1 do 3. Pamiętając o zastrzeżeniach, można stwierdzić, że błąd odpowiadający sieciom neuronowym był minimalnie mniejszy.

Rysunek 3 ukazuje rozkłady błędów sieci dla drugiego zbioru trenującego (Wartości neuronów wejściowych zostały oparte na danych, dotyczących kredytów z okresu od 1 marca do końca czerwca 2003 roku, natomiast wartości neuronu wyjściowego zostały ustalone na podstawie sytuacji badanych kredytów z 31 października 2003 roku).

Analizując wykres, można stwierdzić, że rozkład błędów dla sieci „18-5-1" jest korzystniejszy od rozkładu błędów dla sieci „18-10-1". W przypadku pierwszej architektury, około 70% kredytów stanowiących elementy zbioru trenującego zostało właściwie zaklasyfikowanych (błąd nie większy niż 0,5), około 26% zostało zaklasyfikowanych poprawnie (błąd w granicach od 0,5 do 1,5), natomiast około 4% zostało zaklasyfikowanych źle (błąd większy niż 1,5). W przypadku drugiej architektury około 68% kredytów stanowiących elementy zbioru trenującego zostało właściwie zaklasyfikowanych (błąd nie większy niż 0,5), około 24% zostało zaklasyfikowanych poprawnie (błąd w granicach od 0,5 do 1,5), a około 8% zostało zaklasyfikowanych źle (błąd większy niż 1).



Rys. 3. Rozkłady błędów sieci dla drugiego zbioru trenującego

W przypadku zastosowaniu funkcji dyskryminacyjnej wyznaczonej na podstawie tego samego zbioru trenującego około 71% elementów zostało przydzielonych do oczekiwanej klasy, około 24% zostało przydzielonych do klasy sąsiadującej oraz około 5% zostało przydzielonych do klasy o dwie różnej od oczekiwanej. Można zatem stwierdzić, że sieć neuronowa „18-5-1" oraz funkcja dyskryminacyjna osiągnęły na drugim zbiorze trenującym podobny poziom błędu, natomiast sieć „18-10-1" wypadła nieco gorzej.

2.3. Weryfikacja wyników dla całej populacji

Podział kredytów na grupy ryzyka

Sprawdzenie rezultatów działania sieci neuronowych wymagało dokonania podziału wszystkich uruchomionych według stanu na 30 czerwca 2003 roku kredytów, które w tym dniu zaliczane były do kategorii ryzyka „normalne" lub

„poniżej standardu" na grupy ryzyka (w przypadku funkcji dyskryminacyjnej taki podział następował automatycznie). W związku z tym kredyty na podstawie wyników uzyskanych dzięki sieciom neuronowym, podzielono na trzy grupy w ryzyka:

- pierwszą, składającą się z kredytów dla których wartość neuronu wyjściowego była mniejsza od 1,5;
- drugą, składającą się z kredytów dla których wartość neuronu wyjściowego była większa od 1,5 oraz mniejsza od 2,25;
- trzecią, składającą się z kredytów dla których wartość neuronu wyjściowego była większa od 2,25.

Tabele 1 i 2 obrazują liczbę oraz wartość kredytów wytypowanych do poszczególnych grup ryzyka przez sieci neuronowe o 5 oraz 10 neuronach w warstwie ukrytej oraz przez liniową funkcję dyskryminacyjną według stanu na 30 czerwca 2003 roku.

Tabela 1. Kredyty w „normalnej" obsłudze według stanu na 30 czerwca 2003 roku

Narzędzie klasyfikacyjne	Liczba		
	trzecia grupa ryzyka	druga grupa ryzyka	pierwsza grupa ryzyka
Sieć neuronowa o architekturze „18-5-1"	2409	8677	70 147
Sieć neuronowa o architekturze „18-10-1"	3118	7512	70 603
Funkcja dyskryminacyjna	2235	8142	70 856

Tabela 2. Kredyty w „normalnej" obsłudze według stanu na 30 czerwca 2003 roku

Narzędzie klasyfikacyjne	Wartość (w tys. zł)		
	trzecia grupa ryzyka	druga grupa ryzyka	pierwsza grupa ryzyka
Sieć neuronowa o architekturze „18-5-1"	5733	20 545	190 746
Sieć neuronowa o architekturze „18-10-1"	6935	17 279	192 811
Funkcja dyskryminacyjna	5155	12 449	199 422

Powyższe dane wskazują, że niezależnie od wykorzystanego narzędzia klasyfikacyjnego liczba i wartość kredytów zakwalifikowanych do poszczególnych grup ryzyka były podobne. Należy jednak zwrócić uwagę na to, że posługując się sieciami neuronowymi zakwalifikowano nieznacznie mniej (ilościowo i wartościowo) kredytów do pierwszej grupy ryzyka niż funkcja dyskryminacyjna.

Ocena podziału po upływie czterech miesięcy

Ocena jakości rozwiązania zadania klasyfikacyjnego – uzyskanego za pomocą zarówno sieci neuronowych, jak i funkcji dyskryminacyjnej – została dokonana na podstawie badania przejścia (migracji) badanych kredytów do innych grup ryzyka, do kategorii „wątpliwe", do kategorii „stracone" lub do grupy kredytów restrukturyzowanych po upływie czterech miesięcy.

W dalszej części przedstawiono, jak zmieniła się sytuacja kredytów zaliczonych do poszczególnych grup ryzyka według stanu na 30 czerwca 2003 roku po czterech miesiącach. Odpowiednie dane są zawarte w tabelach 3 i 4. Nagłówki tych tabel oznaczone są symbolami od M1 do M6. Symbole te oznaczają odpowiednio:

- M1 – migrację do pierwszej grupy ryzyka,
- M2 – migrację do drugiej grupy ryzyka,
- M3 – migrację do trzeciej grupy ryzyka,
- M4 – wskaźnik migracji do grupy kredytów w kategorii „wątpliwe",
- M5 – wskaźnik migracji do grupy w kredytów kategorii „stracone" lub kredytów restrukturyzowanych,
- M6 – kredyty w kategoriach ryzyka „wątpliwe" oraz „stracone" wraz z kredytami restrukturyzowanymi oraz spłaconymi; suma.

Wskaźniki migracji kredytów zbudowano zgodnie z zasadą, że grupie ryzyka, w której odsetek kredytów w kategorii „wątpliwe", „stracone" bądź w restrukturyzacji był najwyższy, nadawana była wartość 1. Natomiast wskaźniki dla pozostałych grup ryzyka zostały obliczone jako odsetek kredytów, dla których wskaźnik wynosił 1 i które znalazły się w kategorii ryzyka „wątpliwe" lub znalazły się w kategorii ryzyka „stracone" bądź w restrukturyzacji.

Tabela 3 przedstawia tablicę migracji kredytów podzielonych na grupy ryzyka na podstawie sieci neuronowej z pięcioma neuronami w warstwie ukrytej.

Najważniejsze, z punktu widzenia oceny opisywanego zadania klasyfikacyjnego, są wskaźniki zawarte w kolumnach M4 oraz M5. Na podstawie analizy wartości tych wskaźników można stwierdzić, że odsetek kredytów w „normal-

Tabela 3. Tablica czteromiesięcznej migracji kredytów podzielonych na grupy ryzyka przy zastosowaniu sieci neuronowej o architekturze „18-5-1" (w szt.)

Grupa ryzyka	Stan na 30.06.2003	Stan na 31.10.2003					
		M3	M2	M1	M4	M5	M6
Trzecia	2 409	332	309	222	**1,00**	**1,00**	1 546
Druga	8 677	947	1 793	2 477	**0,45**	**0,14**	3 460
Pierwsza	70 147	922	2 667	45 104	**0,01**	**0,01**	21 454
Suma	81 233	2 201	4 769	47 803	×	×	26 460

nej" obsłudze, które z trzeciej grupy ryzyka według stanu na 30 czerwca 2003 roku znalazły się do 31 października 2003 roku

- w kategorii ryzyka „wątpliwe" był około dwukrotnie większy niż w przypadku drugiej grupy oraz około 100 razy większy niż w przypadku grupy pierwszej,
- w kategorii ryzyka „stracone" bądź w restrukturyzacji był około siedmiokrotnie większy niż w przypadku drugiej grupy oraz około 100 razy większy niż w przypadku grupy pierwszej.

Podobne wyniki uzyskano dla drugiej sieci (tzn. „18-10-1").

Tabela 4 przedstawia migrację kredytów podzielonych na grupy ryzyka na podstawie funkcji dyskryminacyjnej.

Tabela 4. Tablica czteromiesięcznej migracji kredytów podzielonych na grupy ryzyka przy zastosowaniu liniowej funkcji dyskryminacyjnej (w szt.)

Grupa ryzyka	Stan na 30.06.2003	Stan na 31.10.2003					
		M3	M2	M1	M4	M5	M6
Trzecia	2 235	230	476	281	**1,00**	**1,00**	1 248
Druga	8 142	462	3 493	1 462	**0,25**	**0,10**	2 725
Pierwsza	70 856	1 310	6 295	40 764	**0,06**	**0,05**	22 487
Suma	81 233	2 002	10 264	42 507	×	×	26 460

Na podstawie analizy wartości wskaźników M4 oraz M5 można stwierdzić, że odsetek kredytów w „normalnej" obsłudze, które z trzeciej grupy ryzyka według stanu na 30 czerwca 2003 roku znalazły się do 31 października 2003 roku

- w kategorii ryzyka „wątpliwe" był około czterokrotnie większy niż w przypadku drugiej grupy oraz około siedemnastokrotnie większy niż w przypadku pierwszej grupy,

- w kategorii ryzyka „stracone" bądź w restrukturyzacji był około dziesięciokrotnie większy niż w przypadku drugiej grupy oraz około dwudziestokrotnie większy niż w przypadku grupy pierwszej.

Wyniki zaprezentowane w powyższych tabelach wydają się potwierdzać użyteczność sztucznych sieci neuronowych do podziału kredytów ratalnych na grupy ryzyka. Odsetek kredytów, które zostały wstępnie zakwalifikowane przez sieć neuronową jako dobre i po czterech miesiącach nie znajdowały się już w kategorii kredytów w normalnej obsłudze był znikomy. Użyteczność funkcji dyskryminacyjnej okazuje się mniejsza. Wynika to przede wszystkim z faktu, że zbyt duża liczba kredytów zaliczonych do pierwszej grupy ryzyka według stanu na 30 czerwca 2003 roku znalazła się w sytuacji *default* według stanu na 31 października 2003 roku.

Wyniki uzyskane w ujęciu wartościowym potwierdzają użyteczność sieci neuronowych do podziału kredytów na grupy ryzyka oraz dużą trafność uzyskanego podziału.

3. Wnioski

Wyniki uzyskane w artykule pokazują, że sztuczne sieci neuronowe mogą być bardzo dobrym narzędziem podziału konsumpcyjnych kredytów ratalnych na grupy ryzyka. Nieco inaczej należy ocenić jakość podziału za pomocą liniowej funkcji dyskryminacyjnej.

Liniowa funkcja dyskryminacyjna całkowicie błędnie rozpoznawała tylko 3-4% elementów zbiorów trenujących. Jednak ocena *ex post* jakości podziału całej populacji ratalnych kredytów konsumpcyjnych na grupy ryzyka jest w przypadku liniowej funkcji dyskryminacyjnej zdecydowanie niższa niż w przypadku sieci neuronowych. Powodem niskiej oceny tej funkcji jest nie dość dobre odseparowanie kredytów szczególnie ryzykownych. Jest to cecha ważna z praktycznego punktu widzenia.

Zastosowanie sztucznych sieci neuronowych było związane z błędami rzędu 3-8% dla zbioru trenującego. Jest to wynik porównywalny z wynikami uzyskanymi dla funkcji dyskryminacyjnej. Jednak ocena jakości podziału całej populacji ratalnych kredytów konsumpcyjnych na grupy ryzyka jest stanowczo lepsza w przypadku sztucznych sieci neuronowych. Sieci umożliwiały użyteczne odseparowanie z ogółu kredytów tych szczególnie ryzykownych.

Ocena kredytów po czterech miesiącach pozwoliła stwierdzić, że podział kredytów uwzględniający większy zbiór cech jest lepszy, bo pozwala wcześniej wskazać grupę kredytów szczególnie narażonych na pogorszenie sytuacji.

Biorąc pod uwagę, że liniowa funkcja dyskryminacyjna wypadła dobrze na zbiorach trenujących, przyczyn gorszej jakości można szukać w ocenie *ex post*. Jednym z powodów może być występowanie w analizowanych zależnościach powiązań o charakterze ukrytym, delikatnej natury bądź też istotnie nieliniowych. Innym z powodów może być brak spełnienia założeń, dotyczących liniowej funkcji dyskryminacyjnej, czego nie sprawdzaliśmy, zwłaszcza odnośnie do jednakowej wariancji obserwacji wchodzących w skład poszczególnych klas zbiorów trenujących.

Literatura

[1] Baum E., Haussler D., *What Size Net Gives Valid Generalization*, Neural Computation 1989, 1
[2] Bessis J., *Risk management in banking*, John Wiley & Sons, Chichester 1998
[3] Butler C., *Tajniki Value at Risk*, K.E. Liber, Warszawa 2001
[4] Dowd K., *Beyond Value at Risk*, John Wiley & Sons, Chichester 1999
[5] Gatnar E., *Nieparametryczna metoda dyskryminacji i regresji*, Wydawnictwo Naukowe PWN, Warszawa 2001
[6] Gatnar E., *Symboliczne metody klasyfikacji danych*, Wydawnictwo Naukowe PWN, Warszawa 1999
[7] Gately E.J., *Sieci neuronowe w prognozowaniu finansowym*, Wig-Press, Warszawa 1999
[8] Gigol K., *Opłacalność działalności kredytowej banku*, Biblioteka Bankowca, 2000
[9] Jagiełło R., *Zarządzanie portfelem kredytowym banku*, Fundacja Edukacji i Badań Naukowych, Warszawa 1998
[10] Janc A., Kraska M., *Credit-Scoring*, Biblioteka Menedżera i Bankowca, Warszawa 2001
[11] Masters T., *Sieci neuronowe w praktyce – programowanie w języku C++*, WNT, Warszawa 1996
[12] Morrison D.F., *Wielowymiarowa analiza statystyczna*, PWN, Warszawa 1990
[13] Refenes A., *Neural Networks in the Capital Markets*, John Wiley & Sons, New York 2001
[14] Saunders A., *Metody pomiaru ryzyka kredytowego*, Dom Wydawniczy ABC, Kraków 2001
[15] Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, Warszawa 1993
[16] Witkowska D., *Sztuczne sieci neuronowe i metody statystyczne*, C.H. Beck, Warszawa 2002

[17] Woźniak A., *Jak świat radzi sobie z ryzykiem kredytowym*, Rynek Terminowy 1999, nr 5
[18] Żurada J., Barski M., Jędruch W., *Sztuczne sieci neuronowe*, Wydawnictwo Naukowe PWN, Warszawa 1996
[19] Rozporządzenie ministra finansów z dnia 10 grudnia 2001 roku w sprawie zasad tworzenia rezerw na ryzyko związane z działalnością banków
[20] www.bzwbk.pl z dnia 30 października 2003 roku
[21] www.pekao.com.pl z dnia 30 października 2003 roku
[22] www.pkobp.pl z dnia 30 października 2003 roku

APPLICATION OF THE NEURAL NETWORKS AND DISCRIMINANT ANALYSIS IN BEHAVIORAL SCORING OF CONSUMPTION CREDITS

Summary

The aim of the paper is to prove usefulness of the artificial neural network algorithms in defining risky behavior patterns of private persons who was offered a consumption credit from a bank, basing on the real data.

Artificial neural network algorithms were elaborated to imitate the human brain competence for pattern classification, forecasting or decision-making, basing on past experience. Artificial neural networks belong to wide class of methods of behavioral scoring.

In the paper analysis applying of linear discrimination function and neural networks are employed to define risky behavior patterns of clients and to check them after four months.