

Dorota Witkowska, Władysław Kamiński***

WYKORZYSTANIE ALGORYTMU GENETYCZNEGO DO KLASYFIKACJI PRZEDSIĘBIORSTW

Streszczenie. W opracowaniu przedstawiono wyniki klasyfikacji przedsiębiorstw za pomocą jednokierunkowych sieci neuronowych trenowanych algorytmem genetycznym. Klasyfikacja obejmowała od dwóch do pięciu grup typologicznych i została przeprowadzona na podstawie danych pochodzących z wniosków kredytowych podmiotów gospodarczych ubiegających się o kredyt w jednym z banków regionalnych. W analizach porównawczych wykorzystano liniową analizę dyskryminacyjną.

Słowa kluczowe: klasyfikacja, sztuczne sieci neuronowe, algorytm genetyczny.

I. WPROWADZENIE

Ocena sytuacji ekonomiczno-finansowej przedsiębiorstw jest zadaniem analizy wielowymiarowej, dlatego stosuje się różne metody wspomagające inspektorów kredytowych. Obecnie nie ma jednej procedury oceny potencjalnych kredytobiorców, która stanowiłaby wzorzec dla wszystkich instytucji kredytowych, a wybór konkretnej metody jest ściśle związany z możliwościami jej zastosowania. W praktyce bankowej do oceny podmiotów gospodarczych najczęściej stosuje się metodę scoringową oraz liniową analizę dyskryminacyjną, a w ostatnich latach, w bankach krajów wysoko rozwiniętych, zaczęto wykorzystywać również sztuczne sieci neuronowe¹.

Sieci neuronowe mogą być wykorzystywane do rozwiązywania zadań klasyfikacji zarówno ze wzorcem, jak i bez wzorca. Coraz częściej znajdują

* Dr hab., Zakład Metod Ilościowych w Zarządzaniu, Politechnika Łódzka.

** Prof. dr hab. inż., Wydział Inżynierii Procesowej i Ochrony Środowiska, Politechnika Łódzka.

¹ Porównaj prace: J. Baetge, C. Krause (1993), M. D. Odom, R. Shrada (1993), W. Raghupathi i in. (1993), E. Rahimian i in. (1993), H. Rehkugler, A. Schmidt von Rhein (1993), R. L. Wilson, R. Shrada (1994), a także D. Witkowska (1997), (1998), (1999a).

one zastosowanie przy ocenie kondycji finansowej przedsiębiorstw. Przy czym w większości przypadków dokonuje się klasyfikacji dychotomicznej, bowiem zadanie rozpoznawania w przypadku występowania więcej niż dwóch grup typologicznych jest znacznie trudniejsze.

Celem artykułu jest przedstawienie wyników klasyfikacji podmiotów gospodarczych, ubiegających się o kredyt w jednym z banków. Wykorzystano w tym celu sieci neuronowe trenowane za pomocą algorytmu genetycznego. Dla porównania przedstawiono również wyniki klasyfikacji przeprowadzonej na podstawie algorytmu wstecznej propagacji błędów i liniowej funkcji dyskryminacji.

II. ALGORYTMY GENETYCZNE

Sztuczna sieć neuronowa składa się z pewnej liczby elementów przetwarzających informacje. Elementy te nazywane są neuronami, chociaż w stosunku do rzeczywistych komórek nerwowych ich funkcje są bardzo uproszczone. Każdy neuron przetwarza skończoną liczbę wejść zawartą w wektorze $\mathbf{x} = [x_i]$ na jedno wyjście y za pomocą tzw. wag $\mathbf{w} = [w_i]$. Można to zapisać w postaci:

$$y = \varphi(x_i, w_i), \quad i = 1, 2, \dots, n \quad (1)$$

gdzie φ jest symbolem dowolnej funkcji przekształcającej wejścia $\mathbf{x}$ na wyjście y . W najprostszym przypadku funkcja ta może być liniowa. Wówczas relację (1) można przedstawić następująco:

$$y = \sum_{i=1}^n x_i w_i = \mathbf{w}^T \mathbf{x} \quad (2)$$

gdzie $\mathbf{w}$ jest wektorem wag, $\mathbf{x}$ – wektorem sygnałów wejściowych, n – liczbą wejść neuronu.

Neurony łączą się ze sobą tworząc tzw. warstwy. Warstwa neuronów jest najprostszą siecią, w której występuje m wyjść. Każdemu wyjściu y_j odpowiada ten sam wektor sygnałów wejściowych, ale inny wektor wag $\mathbf{w}_j$ ($j = 1, 2, \dots, m$), czyli:

$$\mathbf{y} = \mathbf{W}^T \mathbf{x} \quad (3)$$

gdzie:

$\mathbf{y} = [y_j]$ – wektor m sygnałów wyjściowych,

$\mathbf{W} = [w_{ij}]$ – macierz $[n \times m]$ wag, zawierająca się m wektorów $\mathbf{W}_j [n \times 1]$.

Najbardziej popularnym typem sieci neuronowych jest sieć jednokierunkowa, w której przepływ sygnałów odbywa się tylko w jednym kierunku: od wejścia do wyjścia. Zwykle neurony ułożone są w warstwach, a powiązania międzyneuronowe dotyczą tylko neuronów w warstwach sąsiednich. Sieć ta, zwana często perceptronem wielowarstwowym, posiada warstwę wejściową, wyjściową oraz jedną lub więcej warstw ukrytych. Zadaniem elementów przetwarzających w warstwie wejściowej jest wstępne przetworzenie obrazu wejściowego, które może obejmować normalizację lub skalowanie sygnałów. Zasadnicze przetwarzanie neuronowe odbywa się w warstwach ukrytych oraz w warstwie wyjściowej. Warstwy te zbudowane są z neuronów. Połączenia pomiędzy poszczególnymi warstwami są tak zaprojektowane, że każdy element warstwy poprzedniej jest połączony z każdym elementem warstwy następnej. Połączeniom tym są przypisane odpowiednie współczynniki wagowe, które w zależności od zadania, jakie dana sieć powinna rozwiązywać, są wyznaczane dla każdego przypadku z osobna. Waga dla konkretnego połączenia może być dodatnia (połączenie pobudzające), ujemna (połączenie hamujące) lub zerowa (brak połączenia). Wagi mogą być stałe w czasie lub modyfikowane w trakcie tzw. procesu uczenia.

Ogólnie znane techniki uczenia sieci dzieli się na dwie grupy: uczenie nadzorowane (z nauczycielem) i bez nadzoru (nauczyciela). W pierwszym przypadku sieciom dostarczane są zadane wartości sygnałów wyjściowych, a więc wzorce, które sieć powinna naśladować podczas normalnego działania. W trakcie trenowania sieci pod nadzorem, odpowiedzi przez nią generowane są porównywane z wzorcami poprawnego działania i na tej podstawie sieć, korygując swoje wagi, uczy się pożądanych zachowań. Zatem trenowanie sieci przypomina estymację parametrów funkcji dyskryminacji. Z uwagi jednak na nieliniowe międzywarstwowe połączenia neuronów, proces wyznaczania wag realizowany jest przez odpowiednie procedury iteracyjne, z których najbardziej popularną jest algorytm wstecznej propagacji błędów. W tym przypadku wagi wyznaczane są w taki sposób, aby minimalizować odchylenia wygenerowanych przez sieć wyjść od wartości zadanych.

Trenując sieć bez nauczyciela, nie dostarcza się wzorców poprawnego działania, a zadaniem sieci jest wyszukanie wspólnych cech sygnałów wejściowych i pogrupowanie ich w pewne klasy. Innymi słowy, uczenie bez nadzoru polega na podawaniu na wejście sieci szeregu przykładowych zbiorów danych bez dostarczenia jakiegokolwiek informacji dotyczącej pożądanych czy oczekiwanych sygnałów wyjściowych. Sieć uczy się w ten sposób rozróżniać nadchodzące do niej bodźce i grupować je w pewne klasy, ponieważ neuron wytrenowany do rozpoznawania pewnego sygnału wejściowego będzie zdolny do rozpoznawania sygnałów, które są podobne do wzorcowego.

W procesie trenowania istotnym zagadnieniem jest sposób prezentacji ciągu treningowego. Cyklicznie powtarzane wzorce uczące mogą doprowadzić do zjawiska „zapętlenia” procesu uczenia się sieci, co powoduje, że trenowanie

sieci nie posuwa się naprzód. Natomiast prezentacja kolejnych wzorców pochodzących z tej samej klasy powoduje, że sieć, otrzymując przykłady należące do następnej klasy, zapomina poprzednio wyuczone wzorce. W związku z tym zaleca się losową prezentację ciągu uczącego i wprowadzanie jego elementów za każdym razem w innej kolejności. Zawsze jednak, poprzez odpowiedni dobór wektorów uczących, zapewnić należy pełną prezentację możliwych przykładów rozwiązywanych zadań. Drugim ważnym elementem w praktycznej realizacji procesu uczenia sieci neuronowej jest kwestia doboru początkowych wartości wag. Wartości startowe współczynników wagowych zazwyczaj dobiera się losowo.

Algorytmy genetyczne (AG) mogą być wykorzystywane do trenowania sztucznych sieci neuronowych², ponieważ należą do metod optymalizacji globalnej, wykazując uniwersalność, elastyczność i skuteczność³. Jest to niezwykle istotne, ponieważ niektóre metody uczenia sieci neuronowych (np. algorytm wstecznej propagacji błędów) zatrzymują się po znalezieniu minimum lokalnego.

Główną zasadę, na której oparte są algorytmy genetyczne, można porównać z teorią ewolucji, według której największe szanse na przeżycie i dalszą reprodukcję posiadają osobniki najsilniejsze i najlepiej przystosowane. Związane jest z tym pojęcie funkcji przystosowania lub funkcji oceny jakości, która jest definiowana w zależności od rozwiązywanego problemu.

Algorytmy genetyczne są zwykle kompromisem pomiędzy przeszukiwaniem całej dziedziny rozwiązań dopuszczalnych a optymalizacją lokalną. Jednak z bardzo wysokim prawdopodobieństwem prowadzą do poszukiwania optimum globalnego.

Podstawowy algorytm genetyczny jest przeszukiwaniem obszaru rozwiązań dopuszczalnych, opartym na mechanizmach doboru naturalnego i dziedziczności (opiera się na biologicznych modelach ewolucji), wykorzystując ewolucyjną zasadę przeżycia najlepiej przystosowanych jednostek w połączeniu ze zrandomizowaną wymianą informacji⁴. AG należą do klasy stochastycznych algorytmów optymalizacyjnych. Zwykle AG składa się z kilku etapów: selekcji, krzyżowania i mutacji, mających na celu wybór osobników, wymianę materiału genetycznego, wprowadzenie nowego czynnika genetycznego.

² Co jest przedmiotem takich opracowań, jak: J. Arabas (1994), W. Kamiński, P. Strumiłło, E. Tomczak (1996), J. Balicki, Z. Kitowski, A. Stateczny (1997), M. Nowiński (1998).

³ Do opisu algorytmów genetycznych lub ich modyfikacji stosuje się określenia zapożyczone z genetyki. Operuje się na populacjach osobników, stosując takie podstawowe pojęcia, jak: geny, chromosomy, genotyp, fenotyp. Stosuje się również metodologię odnoszącą się do podstawowych zjawisk występujących w cyklu ewolucyjnym: inicjacji, reprodukcji, mutacji, konkurencyjności i selekcji. Por. prace: D. E. Goldberg (1995), D. Rutkowska, M. Piliński, L. Rutkowski (1997).

⁴ Por. L. Davis (1991), D. B. Fogel (1994).

III. SFORMUŁOWANIE ZADANIA

Przedsiębiorstwa starające się o kredyt poddawane są ocenie przeprowadzanej przez inspektorów kredytowych, którzy określają ich sytuację ekonomiczno-finansową, zdolność kredytową i wreszcie podejmują decyzję dotyczącą przyznania (lub nie) kredytu.

Do badań udostępniono nam niektóre dane pochodzące z wniosków kredytowych złożonych przez 75 przedsiębiorstw. Spośród analizowanych wniosków inspektorzy kredytowi 55 z nich zaklasyfikowali jako stanowiące podstawę do udzielenia kredytu, a 20 przedsiębiorstwom odmówiono przyznania kredytu. Na podstawie posiadanej bazy danych każdą z analizowanych firm opisano za pomocą dziesięciu charakterystyk liczbowych, którymi są:

- a) zysk brutto za okres sprawozdawczy,
- b) zysk netto za okres sprawozdawczy,
- c) średni miesięczny zysk netto,
- d) miesięczna rata spłaty wnioskowanego kredytu,
- e) wielkość maksymalnych miesięcznych odsetek od wnioskowanego kredytu,
- f) inne obciążenia miesięczne (np. spłata innych zobowiązań),
- g) pozostały średni zysk miesięczny po odliczeniu rat i odsetek,
- h) ocena sytuacji finansowo-ekonomicznej firmy: zła – 0, słaba – 1, zadowalająca – 2, dobra – 3, bardzo dobra – 4,
- i) ocena zdolności kredytowej: brak – 0, słaba – 1, dobra – 2, bardzo dobra – 3,
- j) decyzja banku dotycząca przyznania kredytu: udzielenie kredytu – 1, odmowa przyznania kredytu – 0.

Z uwagi na fakt, że cechy (h), (i) oraz (j) wyrażają opinie inspektorów kredytowych, celem prowadzonych badań była klasyfikacja przedsiębiorstw zgodnie z tymi ocenami, wykorzystując w tym celu sztuczne sieci neuronowe, a w badaniach porównawczych również liniową analizę dyskryminacyjną.

IV. KONSTRUKCJA SZTUCZNYCH SIECI NEURONOWYCH

Spośród wymienionych cech, reprezentujących opinie inspektorów kredytowych, tylko decyzja o przyznaniu kredytu podlega dychotomicznej klasyfikacji. Ocena zdolności kredytowej wymaga klasyfikacji do czterech grup typologicznych, a ocena sytuacji ekonomiczno-finansowej – do pięciu. W związku z tym dla każdej cechy skonstruowano odpowiednią sieć

neuronową, która była trenowana, wykorzystując modyfikację algorytmu genetycznego⁵ zaproponowaną w pracy: W. Kamiński, E. Tomczak (1998).

We wszystkich skonstruowanych sieciach warstwa wejściowa⁶ zawierała neurony reprezentujące zmienne (a)–(g), a na wyjściu sieci znajdował się jeden element charakteryzujący jedną z cech (h), (i) lub (j). W przypadku klasyfikacji dychotomicznej warstwa ukryta zawierała dwa neurony (była więc postaci 7–2–1), a w pozostałych dwóch przypadkach sieci zawierały po trzy neurony ukryte (czyli były postaci: 7–3–1).

Trenując sieć pod nadzorem, zadane wartości neuronu wyjściowego są całkowite i należą do przedziałów:

- $\langle 0; 4 \rangle$ przy ocenie sytuacji ekonomiczno-finansowej (tj. dla cechy (h)),
- $\langle 0; 3 \rangle$ w przypadku oceny zdolności kredytowej (– cecha (i)),
- $\langle 0; 1 \rangle$ dla decyzji (j).

Jednakże oszacowane wartości wyjść należą do zbioru liczb rzeczywistych, trzeba zatem ustalić próg, na podstawie którego będą one utożsamiane z klasyfikacją przedsiębiorstwa do określonej grupy typologicznej. Wykorzystano w tym celu funkcję progową postaci:

$$y_i = \begin{cases} a, & \text{jeżeli } \hat{y}_i + 0,5 \geq a \\ (a - 1), & \text{jeżeli } \hat{y}_i + 0,5 \leq a \end{cases} \quad (4)$$

gdzie:

- y_i – wartość zmiennej reprezentującej grupę typologiczną,
- $\hat{y}_i$ – oszacowana wartość zmiennej wyjściowej,
- a – wartość określająca grupę typologiczną ($a = 0, 1, 2, 3, 4$ dla (h), $a = 0, 1, 2, 3$ dla (i), $a = 0, 1$ dla (j)).

Konstruując zbiory treningowy i testujący, ponumerowano wszystkie przedsiębiorstwa za pomocą generatora liczb pseudolosowych i przyjęto, że pierwszych 50 firm wykorzystanych zostanie do uczenia sieci, a ostatnie 25 do testowania.

⁵ Proponowany algorytm genetyczny składa się z czterech typowych etapów: inicjacji, reprodukcji, mutacji i selekcji.

⁶ W przypadku klasyfikacji dychotomicznej eksperymenty numeryczne prowadzono również dla zmniejszonej liczby neuronów wejściowych, o czym szczegółowo będzie mowa przy analizach wyników empirycznych.

V. MIERNIKI JAKOŚCI KLASYFIKACJI

W przypadku kiedy znane są wzorce grupowania, można wyznaczyć błędy klasyfikacji, wynikające ze złego rozpoznania obiektów badania⁷. Załóżmy zatem, że znana jest rzeczywista przynależność obiektów O_i ($i = 1, 2, \dots, N$) do określonych grup typologicznych A_p ($p = 1, 2, \dots, P$) o liczebnościach n_p , dla których zachodzi: $N = \sum_{p=1}^P n_p$.

Oznaczmy przez $\hat{A}_p$ skonstruowane, na podstawie wybranej metody klasyfikacji, grupy typologiczne o liczebnościach N_p , dla których spełnione jest: $N = \sum_{p=1}^P N_p$.

Wówczas jakość klasyfikacji można ocenić porównując ze sobą „zawartość” poszczególnych grup typologicznych $\hat{A}_p$, ze stanem rzeczywistym (czyli z „zawartością” klas A_p), który może być znany dopiero po pewnym czasie. Wtedy ogólny błąd klasyfikacji zdefiniować można w postaci:

$$E = \frac{Z}{N} = \frac{\sum_{p=1}^P Z_p}{N} \quad (5)$$

gdzie:

Z_p – liczba obiektów błędnie rozpoznanych jako pochodzące z grupy typologicznej A_p , a więc zaklasyfikowane do klasy $\hat{A}_p$, podczas gdy w rzeczywistości należą one do grupy A_q ($q = 1, 2, \dots, P$, $q \neq p$),

$Z = \sum_{p=1}^P Z_p$ – liczba wszystkich niepoprawnie rozpoznanych obiektów,

N – liczba wszystkich obiektów objętych klasyfikacją.

Można również analizować rozkład błędnie rozpoznanych obiektów w poszczególnych grupach typologicznych, określając błąd klasyfikacji do klasy A_p , dany wzorem:

$$E_p = \frac{Z_p}{n_p} \quad (6)$$

który informować będzie o udziale liczby błędnie zaklasyfikowanych do klasy $\hat{A}_p$ obiektów w rzeczywistej liczebności tej grupy typologicznej. Natomiast ogólny błąd klasyfikacji określa, jaka część rozpatrywanych w procedurze klasyfikacyjnej obiektów została niepoprawnie rozpoznana.

⁷ Innymi słowy, przyjmuje się, że *a priori* znane są klasy, do których jednostki badania mają zostać zaklasyfikowane, jednakże nie wszystkie obiekty zostały poprawnie rozpoznane. Tak jest w przypadku dokonywania klasyfikacji z nauczycielem.

Innym rodzajem błędu, który informuje o udziale błędnie rozpoznanych obiektów w analizowanej grupie typologicznej, jest błąd klasyfikacji obiektów pochodzących z grupy typologicznej A_p , a rozpoznanych jako $\hat{A}_q$, $q \neq p$.

$$E_p^* = \frac{Z_p^*}{n_p} \quad (7)$$

gdzie oznacza:

Z_p^* – liczba obiektów pochodzących z klasy A_p , a rozpoznanych jako $\hat{A}_q$, $q \neq p$.

W przypadku grupowania tylko do dwóch klas, zwłaszcza w sytuacji kiedy konsekwencje błędnej klasyfikacji do jednej z nich są bardziej znaczące niż w przypadku drugiej z wyróżnionych grup, wyznacza się tzw. błędy pierwszego i drugiego rodzaju. Innymi słowy przyjmuje się, że wyróżniono dwie grupy typologiczne A_1 i A_2 , przy czym błędna klasyfikacja do A_1 powoduje większe szkody niż w przypadku A_2 . Przykładem może być klasyfikacja wniosków kredytowych na te stanowiące podstawę do przyznania kredytu i te, na podstawie których nastąpi odmowa przyznania kredytu. Skutkiem błędu pierwszego rodzaju może być utrata kapitału przekazanego w formie kredytu (całkowita lub częściowa), natomiast błąd drugiego rodzaju spowoduje utratę dochodów przez instytucję kredytową.

Przyjmując zatem odpowiednie oznaczenia błąd pierwszego rodzaju E_1 wyznacza się ze wzoru:

$$E_1 = \frac{Z_1}{n_2} = \frac{Z_2^*}{n_2} \quad (8)$$

gdzie:

Z_1 – liczba obiektów, która została zakwalifikowana do grupy $\hat{A}_1$, a faktycznie przynależy do klasy A_2 (stąd $Z_1 = Z_2^*$),

n_2 – liczebność grupy typologicznej A_2 .

Natomiast błąd drugiego rodzaju E_2 jest postaci:

$$E_2 = \frac{Z_2}{n_1} = \frac{Z_1^*}{n_1} \quad (9)$$

gdzie:

Z_2 – liczba obiektów, która została zakwalifikowana do grupy $\hat{A}_2$, a faktycznie przynależy do klasy A_1 (stąd $Z_2 = Z_1^*$),

n_1 – liczebność grupy typologicznej A_1 .

Błąd pierwszego rodzaju informuje o udziale błędnie zaklasyfikowanych obiektów z grupy typologicznej drugiej (które w wyniku klasyfikacji znalazły się w grupie $\hat{A}_1$), a błąd drugiego rodzaju o udziale błędnie zaklasyfikowanych obiektów z grupy typologicznej pierwszej (tj. tych zaklasyfikowanych do

$\hat{A}_2$). Oba błędy (8) i (9) są *de facto* błędami klasyfikacji (7), przy założeniu, że klasyfikacja jest dychotomiczna.

VI. WYNIKI EKSPERYMENTÓW

Jakość klasyfikacji przeprowadzonej za pomocą sztucznych sieci neuronowych trenowanych algorytmem genetycznym oceniono na podstawie wyznaczonych procentowych błędów klasyfikacji (5)–(9), które zamieszczono w tablicach, podając w nawiasach numery przedsiębiorstw, które zostały błędnie rozpoznane.

Dokonując klasyfikacji dychotomicznej (tabl. 1), sieć neuronowa nauczyła się bezbłędnie rozpoznawać wszystkie analizowane przedsiębiorstwa. Natomiast w trakcie testowania błędnie rozpoznała dwie firmy, oznaczone numerami (57) i (74).

W przypadku klasyfikacji do czterech grup typologicznych (tabl. 2) obserwujemy pojawienie się błędów klasyfikacji zarówno w procedurze trenowania, jak i testowania sieci. W zbiorze treningowym błędnie zostało rozpoznanych siedem firm, a w testującym – pięć. Przy czym wszystkie przedsiębiorstwa zostały zaklasyfikowane do sąsiednich grup typologicznych. W przypadku testowania wszystkie przedsiębiorstwa (w wyniku klasyfikacji za pomocą algorytmu genetycznego) zostały rozpoznane jako firmy bardziej wiarygodne niż ocenili to eksperci bankowi.

Tablica 1

Ocena klasyfikacji wniosków kredytowych (cecha grupująca j)

Zbiór treningowy	$p = j = 0$	$p = j = 1$	E_1	E_2	E
n_p – liczba elementów w p -tej klasie	16	34			
E_p – błąd klasyfikacji do klasy p	0,00	0,00	0,00	0,00	0,00
E_p^* – błąd klasyfikacji obiektów z klasy p	0,00	0,00			
Zbiór testujący			E_1	E_2	E
n_p – liczba elementów w p -tej klasie	4	21			
E_p – błąd klasyfikacji do klasy p	0,00 (57, 74)	0,00	0,00	9,52	8,00
E_p^* – błąd klasyfikacji obiektów z klasy p	0,00	9,52 (57, 74)			

Źródło: obliczenia własne.

Tablica 2

Ocena klasyfikacji według zdolności kredytowej przedsiębiorstw
(cecha grupująca i)

Zbiór treningowy	$p = i = 0$	$p = i = 1$	$p = i = 2$	$p = i = 3$	E
n_p – liczba elementów w p -tej klasie	13	11	11	15	
E_p – błąd klasyfikacji do klasy p	7,69 (70)	9,09 (49)	27,27 (7, 34, 48)	13,33 (19, 35)	14,00
E_p^* – błąd klasyfikacji obiektów z klasy p	0	18,18 (1, 34)	27,27 (19, 35, 49)	13,33 (7, 48)	
Zbiór testujący					E
n_p – liczba elementów w p -tej klasie	4	6	9	6	
E_p – błąd klasyfikacji do klasy p	0	33,33 (53, 72)	33,33 (58, 59, 61)	0	20,00
E_p^* – błąd klasyfikacji obiektów z klasy p	0	0	22,22 (53, 72)	50,00 (58, 59, 61)	

Źródło: obliczenia własne.

Tablica 3

Ocena klasyfikacji według sytuacji ekonomiczno-financej (cecha grupująca h)

Zbiór treningowy	$p = h = 0$	$p = h = 1$	$p = h = 2$	$p = h = 3$	$p = h = 4$	E
n_p – liczba elementów w p -tej klasie	5	5	10	13	17	
E_p – błąd klasyfikacji do klasy p	40,0 (23, 30)	40,00 (37, 43)	50,00 (16, 18, 26, 28, 32)	30,77 (10, 21, 31, 42)	11,76 (8, 36)	30,00
E_p^* – błąd klasyfikacji obiektów z klasy p	0	80,00 (23, 28, 30 32)	50,00 (10, 21, 31 37, 43)	38,46 (8, 16, 18 26, 36)	5,88 (42)	
Zbiór testujący						E
n_p – liczba elementów w p -tej klasie	3	3	3	8	8	
E_p – błąd klasyfikacji do klasy p	66,67 (52, 68)	100,00 (54, 67, 74)	100,00 (53, 66, 71)	37,50 (51, 57, 70)	25,00 (56, 63)	52,00
E_p^* – błąd klasyfikacji obiektów z klasy p	0	33,33 (52)	133,33 (57, 67, 68, 74)	75,00 (53, 54, 56, 63, 66, 71)	25,00 (51, 70)	

Źródło: obliczenia własne.

Wyniki prezentowane w tab. 3 wyraźnie wskazują na to, że zwiększenie liczby grup typologicznych powoduje większe błędy klasyfikacji. Wśród przedsiębiorstw, które znalazły się w próbie uczącej błędnie rozpoznano 15 z nich, chociaż wszystkie zostały zaklasyfikowane do sąsiednich grup typologicznych. Z kolei w próbie testowej błędnie rozpoznano 13 firm, a w przypadku dwóch z nich (tj. oznaczonych numerami (54) i (68)) kondycja ekonomiczno-finansowa została oceniona przez sieci o dwie klasy wyżej niż wynikało to z opinii inspektorów kredytowych. Spośród pozostałych przedsiębiorstw, osiem zostało rozpoznanych jako firmy należące do wyższej klasy, a trzy zostały zaklasyfikowane do niższej grupy typologicznej.

VI. OCENA WYNIKÓW KLASYFIKACJI

Analizując zbór danych, na podstawie których trenowano i testowano sztuczne sieci neuronowe, można zauważyć, że oceny inspektorów kredytowych nie opierają się wyłącznie na tych informacjach. Biorąc pod uwagę pozostały zysk (cecha (g)), zauważono, że w przypadku 17 „odrzuconych” wniosków kredytowych, wartość tej zmiennej wynosiła poniżej 7 jednostek⁸, natomiast jej wartości dla firm: (10), (41) i (54) znajdowały się w przedziale (8; 9). Z kolei 53 przedsiębiorstwa, w stosunku do których podjęto decyzję o przyznaniu kredytu, osiągały wartości cechy (g) powyżej 10 jednostek, a dla firm (57) i (74) wartość tej zmiennej kształtowała się w granicach (6,4; 8,8). Co więcej, sytuację finansowo-ekonomiczną firm (10) i (57) inspektorzy kredytowi uznali za zadowalającą, chociaż oceniając zdolności kredytowe uznano je jako „słabe”, podobnie jak przedsiębiorstwa oznaczonego numerem (21), któremu odmówiono przyznania kredytu. W przypadku firm (41) i (54) opinia ekspertów dotycząca cech (h) oraz (i) została określona jako „słaba”, natomiast przedsiębiorstwo (74) według opinii inspektorów kredytowych w ogóle nie posiadało zdolności kredytowej oraz charakteryzowało się słabą kondycją finansowo-ekonomiczną, ale kredyt został mu przyznany.

Można zatem przyjąć, że popełnione błędy klasyfikacji w odniesieniu do firm oznaczonych numerami (57) i (74) nie wynikają ze złej jakości sieci, a eksperci bankowi podejmując swoje decyzje o przyznaniu kredytu kierowali się w stosunku do tych przedsiębiorstw zupełnie innymi kryteriami niż w stosunku do pozostałych firm. Podobnie jak w przypadku podmiotu gospodarczego (54) przy ocenie sytuacji ekonomiczno-finansowej. Analizując bowiem wartości cechy (c), zauważa się, że wartość tej zmiennej jest na

⁸ Dane zostały przeskalowane w stosunku do oryginalnych danych udostępnionych przez bank.

tym samym poziomie jak w firmach, których sytuacja finansowa została oceniona jako zadowalająca. Oznacza to, że w stosunku do przedsiębiorstwa (10) średni zysk uzyskany przez firmę (54) jest ponad dwukrotnie wyższy, chociaż sytuację ekonomiczną firmy (10) uznano za zadowalającą.

Warto w tym miejscu dodać, że inspektorzy kredytowi dokonują oceny na podstawie analizy sprawozdań finansowych za poprzedni rok i ostatni okres sprawozdawczy, a więc korzystają ze znacznie bogatszej bazy danych niż zawarta w zbiorze treningowym, która została skonstruowana jedynie na podstawie udostępnionych danych, zawartych we wnioskach kredytowych. Należy również wspomnieć, że granice między klasami są niezwykle płynne, a eksperci bankowi dokonując klasyfikacji biorą pod uwagę również czynniki niemierzalne, tj. specyfikę branży reprezentowanej przez klienta, okres działalności firmy (nowo powstała lub działająca na rynku), a także oceniając dotychczasową współpracę podmiotu gospodarczego z bankiem i posiadany majątek, który może stanowić zabezpieczenie kredytu.

Oceniając wyniki dychotomicznej klasyfikacji przedsiębiorstw, otrzymane przy wykorzystaniu algorytmu genetycznego (tabl. 1), porównano je z rezultatami uzyskanymi za pomocą innych metod. Wykorzystano w tym celu liniową analizę dyskryminacyjną oraz sieci neuronowe, o różnych zbiorach zmiennych wejściowych i dwóch lub czterech neuronach ukrytych, trenowane algorytmem wstecznej propagacji błędów (dane zawarte w tabl. 4).

Tablica 4

Porównanie wyników klasyfikacji wniosków kredytowych (cecha grupująca *f*)

Topologia sieci	Algorytm wstecznej propagacji błędów					Analiza dyskryminacyjna		
	7-2-1	7-4-1	4-2-1	6-2-1	6-2-1			
Zmienne diagnostyczne	a, b, c, d, e, f, g	a, b, c, d, e, f, g	d, e, f, g	b, d, e, f, g, i	c, d, e, g, h, i	d, e, f, g	b, d, e, f, g, i	c, d, e, g, h, i
Zbiór treningowy								
<i>E</i>	0,0	0,0	0,0	2,0	0,0	22,0	2,0	2,0
<i>E</i> ₁	0,0	0,0	0,0	6,2	0,0	0,0	6,2	6,2
<i>E</i> ₂	0,0	0,0	0,0	0,0	0,0	32,4	0,0	0,0
Zbiór testujący								
<i>E</i>	12,0	8,0	8,0	4,0	8,0	28,0	12,0	24,0
<i>E</i> ₁	25,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
<i>E</i> ₂	9,5	9,5	9,5	4,8	9,5	33,6	14,4	28,8

Źródło: obliczenia własne.

Jak widać (por. tabl. 1 i 4), najlepsze wyniki testowania uzyskano dla siedmiu zmiennych diagnostycznych (wejściowych) w przypadku sieci trenowanej algorytmem genetycznym oraz wstecznej propagacji błędów, ale w tym ostatnim przypadku sieć neuronowa zawierała cztery neurony ukryte. Warto w tym miejscu zauważyć, że liczba szacowanych parametrów (wag sieci) zależy od liczby neuronów ukrytych, a zdolność sieci do generalizacji wiedzy jest związana z liczbą stopni swobody. Zatem w sytuacji, gdy liczba obserwacji nie jest zbyt duża, należy wykorzystywać sieci mniej skomplikowane.

W pozostałych przypadkach dokonano selekcji zmiennych diagnostycznych na podstawie macierzy współczynników korelacji, wybierając cechy na podstawie metody Hellwiga oraz arbitralnie⁹. Wśród trzech prezentowanych zestawów zmiennych diagnostycznych tylko jeden nie zawiera ocen inspektorów kredytowych (tj. cechy (i)). Jak widać, wprowadzenie do sieci tylko czterech zmiennych diagnostycznych (są to cechy izolowane) pozwoliło uzyskać niemal identyczne wyniki klasyfikacji, jak w przypadku wykorzystania algorytmu genetycznego ($E = 8\%$), a jedyną różnicą jest tutaj błędne rozpoznanie firmy (72) zamiast (74). Podobnie jak ma to miejsce dla sieci zawierającej sześć cech wybranych arbitralnie na podstawie analizy macierzy korelacji (błędnie rozpoznane przedsiębiorstwa to (57) i (59)). Uzupełnienie zbioru cech izolowanych o cechy centralne (sześć zmiennych diagnostycznych) dało jeszcze niższe błędy klasyfikacji ($E = 4\%$), ponieważ w tym przypadku źle rozpoznane zostało jedynie przedsiębiorstwo (57). Ten zestaw zmiennych diagnostycznych generował najniższe błędy testowania również w przypadku zastosowania liniowej funkcji dyskryminacji, chociaż w tym przypadku ogólny błąd klasyfikacji wynosi $E = 12\%$ i oznacza trzy źle rozpoznane przedsiębiorstwa. Oszacowane funkcje dyskryminacji dla pozostałych dwóch zbiorów zmiennych diagnostycznych błędnie rozpoznawały po sześć ($E = 24\%$) i siedem ($E = 28\%$) firm ze zbioru testowego.

Przedstawione wyniki klasyfikacji dowodzą, że czym więcej grup typologicznych, tym klasyfikacja jest trudniejsza. W przypadku szacowania decyzji kredytowych uzyskane rezultaty są bardzo zadowalające, co wynika z faktu, że była to klasyfikacja dychotomiczna. Przy czym eksperci bankowi podejmując decyzje kierują się dodatkowo ocenami sytuacji ekonomiczno-finansowej oraz zdolności kredytowej¹⁰, a także danymi jakościowymi

⁹ Analizowano ok. 20 zestawów zmiennych diagnostycznych, z których prezentowane są tylko najciekawsze wyniki. Warto jednak wspomnieć, że we wszystkich eksperymentach sieci neuronowe lepiej rozpoznawały klasyfikowane przedsiębiorstwa niż skonstruowane funkcje dyskryminacji. Szerzej na ten temat zostało powiedziane w pracach: I. Staniec, D. Witkowska (1998), D. Witkowska (1999b).

¹⁰ Wcześniejsze badania (por. pracę: D. Witkowska (1998)) wykazały, że wprowadzenie ocen ekspertów banku na wejścia sieci nie ma istotnego wpływu na jakość klasyfikacji w procedurze przyznawania kredytów.

dotyczącymi przedsiębiorstw, które nie zostały uwzględnione w klasyfikacji przeprowadzonej za pomocą sztucznych sieci neuronowych.

Warto w tym miejscu zauważyć, że wszystkie błędy były wyznaczane w stosunku do wartości wzorcowych, tj. ocen ekspertów, ponieważ nie otrzymaliśmy danych dotyczących spłat przyznanych kredytów, które mogłyby stanowić podstawę do weryfikacji decyzji inspektorów kredytowych. Wydaje się zatem, że mimo wysokich błędów klasyfikacji dotyczącej ocen ekspertów bankowych (tj. cech (h) oraz (i)), sztuczne sieci neuronowe mogą być wykorzystywane jako narzędzie wspomagające w analizach sytuacji przedsiębiorstw. W większości przypadków błędnie rozpoznane podmioty gospodarcze zostały bowiem zaklasyfikowane do sąsiednich grup typologicznych. Jest to niezwykle istotne, ponieważ – w przypadku występowania więcej niż dwóch klas przy wielowymiarowej analizie – różnice między poszczególnymi grupami zacierają się. Powoduje to pojawienie się tzw. strefy niepewności i znaczne trudności w rozpoznawaniu obiektów.

Warto przy tym zauważyć, że wykorzystanie sztucznych sieci neuronowych (w szczególności algorytmów genetycznych) w procedurze klasyfikacji wniosków kredytowych jest znacznie szybsze i mniej pracochłonne niż metody tradycyjne. Dobre wyniki uzyskano również stosując algorytm wstecznej propagacji błędów, aczkolwiek dopiero po wstępnej analizie zmiennych diagnostycznych. Liniowa funkcja dyskryminacji błędnie rozpoznawała znacznie już więcej przedsiębiorstw.

LITERATURA

- Arabas J. (1994), *Poszukiwanie optymalnej funkcji aktywacji neuronu za pomocą algorytmu ewolucyjnego*, [w:] I Krajowa Konferencja SNIIZ, Kule, s. 122–127.
- Baetge J., Krause C. (1993), *The Classification of Companies by Means of Neural Networks*, „Journal of Information Science and Technology”, 3, 1, 96–112.
- Balicki J., Kitowski Z., Stateczny A. (1997), *Metoda nadawania rang w hybrydowym algorytmie genetycznym do wyznaczania rozwiązań Pareto optymalnych*, [w:] II Krajowa Konferencja AEiOG, Rytro, 1–8.
- Davis L. (1991), *Handbook of Genetic Algorithms*, Van Nostrand Reinhold, New York.
- Fogel D. B. (1994), *An Introduction to Simulated Evolutionary Optimization*, „IEEE Transactions on Neural Networks”, 6, 1, 3–14.
- Goldberg D. E. (1995), *Algorytmy genetyczne i ich zastosowania*, WNT, Warszawa.
- Holland J. H. (1975), *Adaptation in Natural and Artificial Systems*, Ann Arbor, University of Michigan Press.
- Holland J. H. (1987), *Genetic Algorithms and Classifier Systems, Foundation and Future Directions*, [in:] II International Conference on Genetic Algorithms, 82–89.
- Kamiński W., Strumiłło P., Tomczak E. (1996), *Genetic Algorithms and Artificial Neural Networks for Description of Thermal Deterioration Processes*, „Drying Technology”, 14(9), 2117–2133.

- Kamiński W., Tomczak E. (1998), *Zastosowanie algorytmów genetycznych w inżynierii chemicznej i procesowej*, „Inżynieria Chemiczna i Procesowa”, 19, 1, 281–295.
- Nowiński M. (1998), *Prognostowanie przy użyciu sieci neuronowych*, [w:] Trzaskalik T. (red.), *Metody i zastosowania badań operacyjnych*, cz. I, Wydawnictwo Akademii Ekonomicznej w Katowicach, Katowice, s. 91–100.
- Odom M. D., Sharda R. (1993), *A Neural Network Model for Bankruptcy Prediction*, [in:] Trippi R. R., Turban E., (Eds.), *Neural Networks in Finance and Investing*, Probus Publishing Company, Chicago–London, s. 177–185.
- Raghupathi W., Schkade L. L., Raju B. S. (1993), *A Neural Network Approach to Bankruptcy Prediction*, [in:] Trippi R. R., Turban E., (Eds.), *Neural Networks in Finance and Investing*, Probus Publishing Company, Chicago–London, s. 141–158.
- Rahimian E., Singh S., Thammachote T., Virmani R. (1993), *Bankruptcy Prediction by Neural Network*, [in:] Trippi R. R., Turban E., (Eds.), *Neural Networks in Finance and Investing*, Probus Publishing Company, Chicago–London, s. 159–176.
- Rehkugler H., Schmidt-von Rhein A. (1993), *Kreditwürdigkeitsanalyse und Prognose für Privatkundenkredite Mittels Statischer Methoden und Künstlicher Neuronaler Netze. Eine empirisch-vergleichende Studie*, Bamberger Betriebswirtschaftliche Beiträge, Otto Friedrich Universität, Bamberg, discussion paper 93/1993.
- Rutkowska D., Piliński M., Rutkowski L. (1997), *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, PWN, Warszawa–Łódź.
- Staniec I., Witkowska D. (1998), *Analiza dyskryminacyjna w klasyfikacji wniosków kredytowych*, [w:] Lewandowski J. (red.), *Zarządzanie organizacjami gospodarczymi*, Materiały Konferencyjne, cz. II, Politechnika Łódzka, Wydział Organizacji i Zarządzania, Łódź, s. 541–546.
- Wilson R. L., Sharda R. (1994), *Bankruptcy Prediction Using Neural Networks*, „Decision Support Systems”, 11, 545–557.
- Witkowska D. (1997), *Analiza wniosków kredytowych za pomocą algorytmu wstecznej propagacji błędów*, [w:] *Sztuczna inteligencja i inżynieria finansowa*, CIR-12 '97, Warszawa–Siedlce, 235–242.
- Witkowska D. (1998), *Weryfikacja decyzji kredytowych za pomocą sztucznych sieci neuronowych*, „Studia Prawno-Ekonomiczne”, LVIII, 241–256.
- Witkowska D. (1999a), *Application of Artificial Neural Networks to Bank Decision Simulations*, „International Advances in Economic Research”, 5, 3, 350–368.
- Witkowska D. (1999b), *Porównanie wyników klasyfikacji przedsiębiorstw uzyskanych za pomocą liniowej funkcji dyskryminacji i sztucznych sieci neuronowych*, [w:] *Zarządzanie Organizacjami Gospodarczymi*. Materiały konferencyjne, Wydawnictwo Politechniki Łódzkiej, Łódź, s. 775–785.

*Dorota Witkowska, Władysław Kamiński***APPLICATION OF GENETIC ALGORITHM TO FIRM CLASSIFICATION****(Summary)**

In the paper we present the results of firm classification made by artificial neural networks that were trained applying genetic algorithm. There were from two to five groups distinguished that were characterized by: decisions about allowing the credit (two classes), creditworthiness of the enterprise (four classes) and the economic and financial situation of the firm (five classes). The quality of classification was evaluated by comparing to the credit officers' opinions. The results of artificial neural network classification into two classes were compared to results obtained applying linear discrimination function.