

Joanna Kisielińska¹

Katedra Ekonomiki Rolnictwa i Międzynarodowych Stosunków Gospodarczych
Szkoła Główna Gospodarstwa Wiejskiego
Warszawa

Panelowe klasyfikacyjne modele upadłości ekonomicznej gospodarstw rolniczych

Classification panel models of farm bankruptcy

Abstract. Four classification models of economic bankruptcy of farms based on panel data are presented in the article. The modelling techniques are linear discrimination function, pooled probit model, random effects probit model and artificial neural network. They give very similar quality of classification, so we can assume that the problem is linear.

Key words: classification models, qualitative panel models

Synopsis. W artykule przedstawiono cztery klasyfikacyjne modele prognozowania upadłości ekonomicznej gospodarstw rolniczych zbudowane na podstawie danych panelowych. Były to liniowa funkcja dyskryminacyjna, probitowy model dla danych połączonych, probitowy model z efektami losowymi oraz sieć neuronowa. Zbliżona ich jakość wskazuje na liniowość sformułowanego zadania.

Słowa kluczowe: modele klasyfikacyjne, jakościowe modele panelowe

Wstęp

Pierwszy klasyfikacyjny model upadłości firm opracowany został przez Altmana [1968]. Wykorzystując 5 wskaźników finansowych dla 66 amerykańskich przedsiębiorstw (z których 33 zbankrutowało, a pozostałe 33 znajdowało się w dobrej sytuacji finansowej) wyznaczył liniową funkcję dyskryminacyjną. Funkcja miała za zadanie odróżniać jednostki zagrożone bankructwem od tych, których kondycja nie budziła niepokoju. Badania w tym zakresie były następnie kontynuowane przez wielu autorów. Szeroki przegląd polskich i zagranicznych modeli upadłościowych przedstawiony został w pracy Kisielińskiej [2008].

Podstawowy problem w bezpośredniej adaptacji rozwiązań stosowanych w przypadku przedsiębiorstw w odniesieniu do gospodarstw rolniczych wynika z istotnych wyjątków w zasadach ich funkcjonowania w systemie rynkowym. Brak osobowości prawnej powoduje brak zjawiska bankructwa wśród polskich gospodarstw. Nie oznacza to jednak, że wszystkie znajdują się w dobrej sytuacji finansowej. Wiele z nich funkcjonuje na granicy lub wręcz poniżej granicy opłacalności. Można mówić wówczas o tzw. upadłości ekonomicznej, której przyczyn poszukiwał Ciechomski [2004]. Upadłość w sensie ekonomicznym oznacza prowadzenie działalności na poziomie minimalnym, nie pozwalającym na odtworzenie majątku zaangażowanego w proces produkcji. W przypadkach skrajnych sytuacja taka może wymuszać konieczność pokrywania strat z innych źródeł, a w perspektywie likwidację gospodarstwa.

¹ Dr, email: joanna_kisielinska@sggw.pl

Celem przedstawionych w artykule badań było opracowanie modeli klasyfikacyjnych pozwalających na prognozowanie upadłości ekonomicznej gospodarstw. W badaniach wykorzystane zostały dane panelowe pochodzące z gospodarstw rolniczych prowadzących rachunkowość rolną pod kierunkiem Instytutu Ekonomiki Rolnictwa i Gospodarki Żywnościowej (IERiGŻ) w latach 1992-2001. Okres taki przyjęto, ponieważ w roku 2002 zmieniono system gromadzenia danych, natomiast od roku 2004 IERiGŻ nie udostępnia danych indywidualnych.

Artykuł ma charakter przede wszystkim metodyczny. Przedstawione w nim zostaną cztery typy modeli klasyfikacyjnych dla gospodarstw rolniczych: liniowa funkcja dyskryminacyjna, probitowy model dla danych połączonych, probitowy model z efektami losowymi oraz sieć neuronowa. Metody dobrano w celu porównania liniowego z nieliniowym podejściem do postawionego zadania.

Na podkreślenie zasługuje fakt, że analizy oparto na danych panelowych. W przypadku prognozowania upadłości ekonomicznej gospodarstwa jest to możliwe, ponieważ stan upadłości ekonomicznej jest zwykle procesem rozciągniętym w czasie, a słaba kondycja gospodarstwa w danym roku może ulec poprawie w latach kolejnych. Bankructwo przedsiębiorstwa natomiast jest zdarzeniem jednorazowym, ostatecznie kończącym jego działalność. Dane o gospodarstwie mogą wobec tego pochodzić z wielu lat, natomiast o przedsiębiorstwie innego typu jedynie z jednego.

Jakościowe modele panelowe stanowią stosunkowo nowy obszar badawczy. W literaturze przedmiotu znaleźć można niewiele przykładów ich zastosowania do rozwiązywania konkretnych problemów. Z tego względu autorka ma nadzieję, że przedstawione rezultaty mogą okazać się pomocne dla badaczy zainteresowanych przedstawioną problematyką.

Kolejnym, ważnym z metodycznego punktu widzenia elementem jest problem asymetrii wyników klasyfikacji, pojawiający się, gdy klasy są różniczne. Gospodarstw w stanie upadłości ekonomicznej jest w zbiorze danych wielokrotnie mniej, niż gospodarstw nią niezagrożonych (tabela 2). Różnice w liczebności są na tyle duże, że zastosowanie tradycyjnych metod eliminacji asymetrii klasyfikacji nie daje zadowalających efektów. Przyjęto więc rozwiązanie wzorowane na stosowanym w przypadku sieci neuronowych, polegające na eksperymentalnym doborze wartości rozgraniczającej klasy, tak aby uzyskać jednakowe udziały poprawnych identyfikacji obiektów w obydwu klasach.

Obliczenia wykonano przy użyciu pakietu Statistica², Statistica Neural Networks³ oraz Stata⁴.

Metody klasyfikacji obiektów

Zakładamy, że dany jest pewien zbiór n obiektów opisanych parami $[\mathbf{x}, y]$, gdzie wektor $\mathbf{x}^T = [x_1, x_2, \dots, x_n]$ obejmuje zmienne niezależne nazywane cechami, zaś y jest zmienną zależną. Model ekonometryczny związku między zmienną y i wektorem cech \mathbf{x} można zapisać jako:

$$y = f(\mathbf{x}, \boldsymbol{\alpha}) + \varepsilon \quad (1)$$

² Numer seryjny AXXP50dC76852FA

³ Numer seryjny XXDP211B770418G60

⁴ Numer seryjny 81990517554

gdzie: $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_k]$ jest wektorem parametrów, zaś ε składnikiem losowym.

Konieczność wprowadzenia do równania (1) składnika losowego wynika z tego, że wartości jakie może przyjmować zmienna y nie są w pełni określone przez wektor cech \mathbf{x} , jak miałyby to miejsce w przypadku modelu deterministycznego. Składnik losowy reprezentuje błąd, jaki powstaje podczas szacowania wartości zmiennej y na podstawie wartości wektora \mathbf{x} .

Charakter zmiennej zależnej określa typ modelu. Jeśli y jest zmienną ilościową problem nazywamy analizą regresji, jeśli natomiast jest zmienną jakościową mówimy o zadaniu klasyfikacyjnym [Gatnar 2001].

Założmy, że w badanej zbiorowości obiektów wyróżnić można dwie⁵ klasy obiektów (nazywane czasem podpopulacjami), które oznaczymy jako 0 i 1. Poszukiwanie funkcji, której wartości pozwolą określić przynależność obiektów do klas nazywamy analizą dyskryminacyjną. Najczęściej zakładamy liniową postać tej funkcji. Problem nazywamy wówczas liniową analizą dyskryminacyjną. Liniowa funkcja dyskryminacyjna (LFD) może być zapisana jako:

$$\text{LFD}(\mathbf{x}) = \lambda_0 + \boldsymbol{\lambda}^T \cdot \mathbf{x} \quad (2)$$

gdzie $\boldsymbol{\lambda}$ jest wektorem współczynników, λ_0 wyrazem wolnym, \mathbf{x} wektorem cech.

Parametry LFD można oszacować w oparciu o Bayesowską regułę klasyfikacyjną [Krzyśko 1990] przy pewnych założeniach, które tu pominiemy, aby nie komplikować wyводу. Współczynniki $\boldsymbol{\lambda}$ i λ_0 określone są wzorami:

$$\boldsymbol{\lambda} = \mathbf{S}^{-1} \cdot (\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_0), \quad \lambda_0 = (\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_0)^T \cdot \mathbf{S}^{-1} \cdot (\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_0) \quad (3)$$

gdzie:

$$\bar{\mathbf{x}}_0 = \frac{1}{n_0} \cdot \sum_{i=1}^{n_0} \mathbf{x}_{0i} \text{ jest centroidą klasy 0, } \bar{\mathbf{x}}_1 = \frac{1}{n_1} \cdot \sum_{i=1}^{n_1} \mathbf{x}_{1i} \text{ jest centroidą klasy 1,}$$

$$\mathbf{S} = \frac{1}{n_0 + n_1 - 2} \cdot \left[\sum_{i=1}^{n_0} (\mathbf{x}_{0i} - \bar{\mathbf{x}}_0) \cdot (\mathbf{x}_{0i} - \bar{\mathbf{x}}_0)^T + \sum_{i=1}^{n_1} (\mathbf{x}_{1i} - \bar{\mathbf{x}}_1) \cdot (\mathbf{x}_{1i} - \bar{\mathbf{x}}_1)^T \right] \text{ jest macierzą}$$

wariancji-kowariancji wewnątrzgrupowej, n_0 i n_1 to liczebność klas odpowiednio 0 i 1, \mathbf{x}_{0i} to wektor cech obiektu i należącego do klasy 0, natomiast \mathbf{x}_{1i} to wektor cech obiektu i należącego do klasy 1.

Wartość LFD rozgraniczająca klasy wyznaczona na podstawie Bayesowskiej reguły klasyfikacyjnej jest równa logarytmowi naturalnemu z ilorazu liczebności klas:

$$f_g = \ln \left(\frac{n_1}{n_0} \right) \quad (4)$$

Jeżeli dla obiektu k $\text{LFD}(\mathbf{x}_k) \geq f_g$ obiekt należy do klasy oznaczonej jako 1, w przeciwnym przypadku zaś do klasy oznaczonej jako 0.

Jak wcześniej wspomniano zmienna zależna w modelu klasyfikacyjnym jest zmienną jakościową (nominalną). Przyjęcie dla klas oznaczeń 0 i 1 można rozpatrywać jako narzucenie zmiennej objaśnianej modelu (1) ograniczenia zbioru jej wartości do $\{0, 1\}$.

⁵ Rozważania ograniczono do dwóch klas ponieważ wówczas jedna funkcja pozwala zrealizować zadanie dyskryminacji. Jeśli klas jest więcej konieczne jest opracowanie większej ich liczby [Jajuga 1990].

Ograniczenie to pozwala interpretować dychotomiczną zmienną (w tym przypadku binarną) y jako prawdopodobieństwo przynależności obiektu do jednej z klas. Na tej koncepcji opiera się szereg modeli klasyfikacyjnych zwanych modelami prawdopodobieństwa. W modelach tych prawdopodobieństwo przynależności obiektu i do klasy oznaczonej jako 1 dane jest jako:

$$P_i = f(\beta^T \cdot x_i) \quad (5)$$

gdzie x_i jest wektorem cech obiektu i .

Popularnym modelem prawdopodobieństwa jest model probitowy, w którym jako funkcję f przyjmujemy dystrybuantę standaryzowanego rozkładu normalnego:

$$P_i = \int_{-\infty}^{\beta^T x_i} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{u^2}{2}\right) du \quad (6)$$

Współczynniki β dla modelu probitowego szacowane są metodą największej wiarygodności przy pomocy specjalnych procedur numerycznych.

Zarówno liniowa funkcja dyskryminacyjna jak i probitowy model prawdopodobieństwa najczęściej stosowane są dla danych przekrojowych, czyli gdy o każdym obiekcie posiadamy informacje pochodzące jedynie z jednego momentu czasu. Jeżeli natomiast dysponujemy danymi panelowymi (o obiektach mamy dane z więcej niż z jednej chwili, zaś liczba tych chwil jest znacznie mniejsza od liczby obiektów), konieczne są modyfikacje zapewniające zgodność i brak obciążenia estymatorów parametrów.

Mimo, że dane pochodzą z różnych chwil, często w modelach pomijana jest dynamika (zakładamy, że parametry modelu nie zależą od czasu i nie występują w nim zmienne opóźnione). Modele takie nazywane są modelami jednoczynnikowymi.

Wśród modeli jednoczynnikowych wyróżniamy: modele dla danych połączonych zwane też estymatorem uogólnionym (ang. „pooled estimator”), modele z efektami ustalonymi („fixed effects”) oraz modele z efektami losowymi („random effects”). W modelach dla danych połączonych zakładamy jednakowe dla wszystkich obiektów parametry. Nie ma znaczenia, z której chwili pochodzą dane, wszystkie traktowane są jednakowo. Przyjmujemy, że dane o obiekcie z chwili t_1 i z chwili t_2 są całkowicie nie związane ze sobą. Mówiąc inaczej, informacje te są traktowane jakby były informacjami o różnych obiektach. Podejście takie wprowadza pewne zafałszowanie, ponieważ istotą danych panelowych jest to, że dysponujemy danymi o obiekcie z więcej niż jednej chwili, czyli mamy o nim powtórzoną informację. Podkreślmy, powtórzoną informację o tym obiekcie, a nie powtórzenie informacji w postaci danych o innych obiektach.

W modelach z efektami ustalonymi i losowymi uwzględniona jest zmienność indywidualna obiektów, co wymusza konieczność rozróżnianie danych o wybranym obiekcie z różnych momentów czasu od danych o innych obiektach. Dane z różnych momentów czasu traktowane są jak powtórzenia i nie jest istotne ich czasowe uszeregowanie (dopiero modele dynamiczne uwzględniają kolejność w czasie). W modelach z efektami ustalonymi każdy obiekt w sposób indywidualny wpływa na zmienną zależną modelu poprzez różny dla każdego z nich wyraz wolny. W modelach z efektami losowymi, również przyjmuje się, że każdy obiekt w sposób indywidualny oddziałuje na zmienną zależną, jednak ten indywidualny sposób oddziaływania jest reprezentowany przez zmienną losową (wyraz wolny modelu jest traktowany jak zmienna losowa). Modele z

efektami ustalonymi stosujemy, jeżeli dysponujemy danymi o wszystkich badanych obiektach. Model z efektami losowymi jest właściwy, jeśli zbiór obiektów jest próbą z większej populacji (nie mamy informacji o wszystkich obiektach, dla których opracowujemy model).

Do klasyfikacji obiektów można użyć również sieci neuronowych. Udowodniono bowiem, że są one aproksymatorami uniwersalnymi⁶, pozwalającymi odwzorować dowolną zależność funkcyjną między wejściami sieci (które odpowiadają zmiennym niezależnym), a wyjściami (odpowiednikami zmiennych zależnych). Nie wymagają ponadto czynienia żadnych założeń co do postaci tej funkcji.

Sieć tworzą połączone ze sobą neurony. Działanie pojedynczego neuronu zapisać można jako realizację następującego przekształcenia sygnałów wejściowych:

$$r = \varphi(u) = \varphi\left(\sum_{i=1}^q w_i \cdot s_i + w_0\right) \quad (7)$$

gdzie: r jest sygnałem wyjściowym neuronu, $\mathbf{s}^T = [s_1, s_2, \dots, s_p]$ wektorem sygnałów wejściowych, $\mathbf{w}^T = [w_0, w_1, w_2, \dots, w_q]$ jest wektorem wag neuronu, u nazywamy łącznym sygnałem pobudzenia neuronu, zaś φ funkcją aktywacji. W zależności od rodzaju zastosowanej funkcji aktywacji wyróżniamy różne typy neuronów. Neurony liniowe mają liniową funkcję aktywacji, sigmoidalne tzw. funkcję sigmoidalną (logistyczną lub w postaci tangensa hiperbolicznego), neurony radialne zaś wykorzystują funkcję Gaussa.

Sposób łączenia oraz rodzaje użytych neuronów decydują o typie sieci. Do klasyfikacji obiektów wykorzystać można np. sieci perceptronowe oraz o radialnych funkcjach bazowych. Sieć perceptronowa (MLP) zbudowana jest z neuronów sigmoidalnych, natomiast sieć o radialnych funkcjach bazowych (RBF) wykorzystuje neurony radialne.

Aby zastosować sieć do realizacji postawionego zadania należy dobrać odpowiedni typ, architekturę (liczbę i sposób połączenia neuronów) oraz określić wagi wszystkich neuronów w niej użytych (proces doboru wag nazywany jest uczeniem lub trenowaniem sieci). W zadaniu klasyfikacyjnym trzeba dodatkowo przyjąć wartość wyjścia rozgraniczającą klasy. Nie ma w tym przypadku żadnych przesłanek teoretycznych do jej określenia. Najczęściej stosowanym rozwiązaniem jest dobór eksperymentalny.

Wyniki klasyfikacji obiektów zestawia się w tzw. macierzy klasyfikacji przedstawionej w tabeli 1. Jako n_{00} i n_{11} oznaczono liczbę prawidłowo rozpoznanych obiektów należących odpowiednio do klasy 0 i klasy 1, zaś n_{01} i n_{10} to liczba błędnie rozpoznanych obiektów z klasy 0 i z klasy 1. Popularnymi empirycznymi miarami jakości modelu klasyfikacyjnego jest łączny procent poprawnych klasyfikacji (W_t) oraz indywidualne współczynniki trafnych klasyfikacji (W_{t0} i W_{t1}). Współczynniki W_t , W_{t0} oraz W_{t1} wyznacza się ze wzorów:

$$W_t = \frac{n_{00} + n_{11}}{n_{00} + n_{11} + n_{01} + n_{10}} \quad W_{t0} = \frac{n_{00}}{n_{00} + n_{01}} \quad W_{t1} = \frac{n_{11}}{n_{11} + n_{10}} \quad (8)$$

Współczynnik W_t obrazuje udział poprawnie rozpoznanych obiektów. Jest on miarą właściwą, gdy współczynniki W_{t0} i W_{t1} mają zbliżone wartości. Duże różnice między indywidualnymi współczynnikami trafności oznaczają asymetrię klasyfikacji.

⁶ Uniwersalność sieci perceptronowych udowodnił Hornik i inni [1989], zaś sieci o radialnych funkcjach bazowych Cover [1965].

Tabela 1. Ogólny zapis macierzy klasyfikacji

Table. 1. General notation of classification matrix

Klasa	Klasa 0 określona na postawie modelu klasyfikacyjnego	Klasa 1 określona na postawie modelu klasyfikacyjnego	Procent poprawnych klasyfikacji
Klasa 0 faktyczna	n_{00}	n_{01}	Procent poprawnych klasyfikacji w klasie 0 (W_{i0})
Klasa 1 faktyczna	n_{10}	n_{11}	Procent poprawnych klasyfikacji w klasie 1 (W_{i1})
Razem	x	x	Łączny procent poprawnych klasyfikacji (W_i)

Źródło: opracowanie własne

Asymetria pojawia się najczęściej, gdy w zbiorze danych występują duże różnice w liczebnościach klas. Można wówczas bardzo prosto „sztucznie” podnieść współczynnik W_i przypisując wszystkie obiekty do klasy liczniejszej. W takim przypadku współczynniki indywidualne będą równe 100% i 0%, natomiast łączny udział poprawnych rozpoznań:

$$W_i = \frac{\max(n_0, n_1)}{n} \quad (9)$$

Współczynnik W_i będzie wówczas równy udziałowi w próbie klasy liczniejszej. Jeżeli proporcja między klasami ma się np. jak 9:1, otrzymujemy $W_i=90\%$, co zwykle uznawane jest za poziom bardzo wysoki. W takim przypadku jednak, mimo wysokich wartości W_i , klasyfikacja nie może być zaakceptowana ze względu na występującą asymetrię w rozpoznawaniu klas.

Wystąpienie asymetrii jest zjawiskiem niekorzystnym i wymaga podjęcia kroków zaradczych. Jednym z rozwiązań jest losowanie obiektów z klasy liczniejszej aby uzyskać próbę zbilansowaną. Z drugiej jednak strony losowanie zubaża próbę, poprzez eliminację części obiektów. Inna metoda polega na przyjęciu jako granicznej wartości średniej arytmetycznej zmiennej zależnej modelu dyskryminacyjnego dla centroid obydwu klas. Jeszcze innym rozwiązaniem jest dobór wartości rozgraniczającej klasy tak, aby uzyskać klasyfikację symetryczną (rozwiązanie takie stosowane jest dla sieci neuronowych).

Modele upadłości ekonomicznej gospodarstw rolniczych

Modele upadłości ekonomicznej gospodarstw rolniczych budowane były na podstawie danych z gospodarstw prowadzących rachunkowość rolną pod kierunkiem IERiGŻ w latach 1992-2001 (ich liczbę podano w tabeli 2). Ze względu na funkcję prognostyczną modeli konieczne jest, aby cechy wyprzedzały o rok kryterium klasyfikacji. Wobec tego wykorzystanie danych o wybranym gospodarstwie jest możliwe, jeśli prowadziło ono rachunkowość przynajmniej przez dwa kolejne lata. Spowodowało to konieczność rezygnacji z części danych, ponieważ w badanym okresie IERiGŻ z wieloma gospodarstwami zaprzestał współpracy, a z wieloma ją nawiązał. Jak wynika z danych przedstawionych w tabeli 2 liczba gospodarstw objętych badaniem zmienia się w kolejnych latach. Użyty panel jest więc panelem niezbilansowanym.

Opracowując modele nie wyodrębniono próby odłożonej. Zbiór danych jest bowiem dosyć liczny, wobec czego ewentualne obciążenie testów wynikające z użycia tych samych danych do budowy i testowania modeli jest niewielkie.

W modelach upadłości firm kryterium klasyfikacji może opierać się na faktycznym bankructwie jednostki ogłoszonym wyrokiem sądu, choć znaleźć można również przykłady stosowania innych rozwiązań. Może być to złożenie w sądzie wniosku o upadłość, rozpoczęcie postępowania ugodowego z wierzycielami lub opinia eksperta (patrz praca Kisieleńskiej [2008]).

Tabela 2. Liczba gospodarstw badanych

Table 2. Number of farms investigated

Liczba gospodarstw	Rok ¹⁾									
	1992	1993	1994	1995	1996	1997	1998	1999	2000	Razem
ogółem	662	702	860	771	997	998	998	912	851	7751
o ujemnym DR ⁷	32	54	34	24	105	118	234	152	150	903
o dodatnim DR	630	648	826	747	892	880	764	760	701	6848

¹⁾ W tabeli podano rok, z którego pochodziły cechy opisujące gospodarstwo.

Źródło: opracowanie własne

Jak wspomniano na wstępie w przypadku gospodarstw rolniczych nie można mówić o upadłości w sensie prawnym lecz tylko ekonomicznym. Jako podstawę stwierdzenia upadłości w sensie ekonomicznym gospodarstwa można przyjąć uzyskiwanie ujemnego dochodu rolniczego netto (DR). Ujemny dochód rolniczy netto nie oznacza zwykle konieczności finansowania gospodarstwa z innych źródeł. Jeśli zostanie on powiększony o amortyzację (mowa wówczas o dochodzie rolniczym brutto) okazuje się, że tylko nieliczne gospodarstwa mają wynik ujemny. Pozostałe natomiast prowadzą działalność na poziomie minimalnym, nie dającym środków na odtworzenie majątku. W perspektywie wieloletniej stan taki z pewnością zakończy się likwidacją czy upadkiem gospodarstwa, jeśli nie zostaną podjęte kroki zaradcze.

Badaną zbiorowość podzielono na dwie klasy. Klasa 0 obejmuje gospodarstwa o ujemnym dochodzie rolniczym netto. Klasę 1 zaś tworzą gospodarstwa osiągające dochód dodatni, czyli te, które mają perspektywy działania i rozwoju. Liczby gospodarstw o ujemnym i dodatnim DR przedstawiono w tabeli 2. W zbiorze występuje silna asymetria w liczebności klas. Gospodarstw z klasy 0 jest ponad 7 razy mniej niż z klasy 1.

Funkcje zmiennych objaśniających w modelu pełnią wskaźniki finansowe, uzupełnione o dodatkowe informacje o gospodarstwie i osobie je prowadzącej. Wyboru wskaźników dokonano w oparciu o pracę Wyszowskiej [1996] oraz Ziętary i innych [1994]. Uwzględniono wszystkie podstawowe ich grupy, czyli wskaźniki płynności, rentowności, obrotowości, sprawności gospodarowania, wspomagania finansowego oraz wskaźniki stanowiące charakterystykę majątku trwałego. Dodatkowo wykorzystano charakterystyki oznaczające powierzchnię użytków rolnych, poziom intensywności produkcji, poziom intensywności organizacji produkcji (wyznaczany według Kopcina), wiek oraz poziom wykształcenia rolnika.

⁷ Dochód rolniczy

Zestaw cech obejmował początkowo 33 zmienne, z których wyeliminowano 14 na podstawie występującej między nimi silnej korelacji korelacji. Dalsza redukcja liczby cech prowadzona była odrębnie dla każdego opracowywanego modelu (będzie o tym mowa dalej).

Po wstępnej eliminacji opartej na współczynnikach korelacji pozostało 19 cech. Były to: powierzchnia użytków rolnych w hektarach przeliczeniowych (URP), wskaźnik obciążenia aktywów bieżących zobowiązaniami bieżącymi (WOABZB), wskaźnik rentowności sprzedaży (obrotu) (WRS), wskaźnik rentowności kapitału własnego (WRKW), wskaźnik cash flow (WCF), wskaźnik obrotowości zapasów (WOZ), należności i przedpłaty przypadające na produkcję końcową brutto (NPNPKB), wskaźnik produktywności ziemi (WPZ), wskaźnik wydajności pracy (WWP), wskaźnik zaangażowania majątku obrotowego (WZMO), wskaźnik zaangażowania kapitału pracującego (WZKP), obciążenie przedsiębiorstwa zobowiązaniami długoterminowymi (OPZD), wskaźnik ogólnego zadłużenia (WZ), poziom intensywności organizacji produkcji (PIOP), wiek kierownika gospodarstwa (WIEK) oraz zmienne reprezentujące poziom wykształcenia rolniczego kierownika. Były to 4 zmienne binarne o następujących znaczeniach: rolnik bez wykształcenia (BW), rolnik z wykształceniem rolniczym zawodowym (RZ), średnim (RS) i wyższym (RW). Wszystkie wymienione cechy opisane są w pracy Kisielińskiej [2008].

Dla panelowego zbioru danych opracowano modele dla danych połączonych oraz model z efektami losowymi. Nie jest celowe stosowanie modeli z efektami ustalonymi, ponieważ badany zbiór nie obejmuje wszystkich gospodarstw, jest jedynie pewną ich próbą. Zbudowano model liniowy w postaci liniowej funkcji dyskryminacyjnej, model probitowy oraz najbardziej ogólny model nieliniowy w postaci sieci neuronowej. Modele liniowy i sieciowy były modelami dla danych połączonych. Natomiast modele probitowe opracowano w dwóch wariantach, jako estymator uogólniony oraz model z efektami losowymi. Oznaczenia upadłościowych modeli klasyfikacyjnych dla gospodarstw są następujące:

- liniowa funkcja dyskryminacyjna (LFD),
- probitowy model dla danych połączonych (PP),
- probitowy model z efektami losowymi (PR),
- sztuczna sieć neuronowa (SN).

W każdym modelu prowadzona była dalsza redukcja cech. Liniową analizę dyskryminacyjną zastosowano w wersji krokowej, w modelach probitowych eliminowano cechy nieistotne statystycznie, zaś sieci budowano w wielu wariantach wykorzystujących różne zestawy cech, spośród których ostatecznie wybierano sieć najlepiej realizująca postawione zadanie. Z uwagi na różne licznosci klas modele funkcyjne cechowała bardzo silna asymetria w ich rozpoznawaniu. Asymetrię usuwano manipulując wartością rozgraniczającą klasy, dobierając ją tak, aby uzyskać klasyfikację w pełni symetryczną. W tabeli 3 umieszczono macierze klasyfikacji dla wszystkich modeli, a w tabeli 4 uwzględnione w nich cechy.

Z przedstawionych w tabeli 3 macierzy klasyfikacji wynika bardzo zbliżona jakość wszystkich modeli. Różnica między modelem najlepszym i najgorszym jest rzędu jednego procentu. Najlepsza okazała się sieć neuronowa, następnie modele probitowe, najgorsza zaś liniowa funkcja dyskryminacyjna. Kolejności takiej należało się spodziewać. Sieci zwykle pozwalają uzyskać najlepsze modele klasyfikacyjne, ponieważ umożliwiają odwzorowanie

dowolnej zależności nieliniowej bez konieczności zakładania jej postaci. Modele probitowe są modelami nieliniowymi, jednak poprzez założoną postać wprowadzają pewne ograniczenia. Największe restrykcje nakłada funkcja dyskryminacyjna, poprzez wymaganie związków liniowych. Ponieważ różnice między modelem liniowym i najbardziej ogólnym nieliniowym (SN) są bardzo małe, można przyjąć, że klasyfikacyjny model upadłości ekonomicznej gospodarstw jest liniowy.

Tabela 3. Wskaźniki trafności macierzy klasyfikacji

Table 3. Accuracy indices for classification matrices

Model	Procent poprawnie rozpoznanych gospodarstw		
	Klasa 0	Klasa 1	Razem
Liniowa funkcja dyskryminacyjna (LFD)	77,74%	77,73%	77,73%
Probitowy model dla danych połączonych (PP)	78,07%	78,07%	78,07%
Probitowy model z efektami losowymi (PR)	78,18%	78,08%	78,09%
Sieć neuronowa (SN)	78,85%	78,86%	78,85%

Uwaga: ¹⁾ W tabeli podano rok z którego pochodziły cechy opisujące gospodarstwo.

Źródło: opracowanie własne

Tabela 4. Cechy uwzględnione w klasyfikacyjnych modelach upadłości gospodarstw.

Table 4. Variables selected in classification models

Cecha	Rodzaj modelu			
	LFD	PP	PR	SN ¹⁾
WRS	5,231	3,162	3,049	X
WRKW	0	2,178	2,371	
WCF	-3,072	-1,378	-1,514	X
WOZ	-0,041	-0,012	-0,020	
WPZ	-0,00015	-0,00014	-0,00018	
WZMO	0,172	0	0,115	X
WZKP	0,00096	0	0	
OPZD	-1,737	0	0	
PIOP	0,00106	0,00089	0,00112	
BW	-0,095	0	0	
RS	0,102	0	0	
RW	-0,185	0	0	

Uwaga: ¹⁾ Dla sieci neuronowej przez X oznaczono uwzględnione w niej cechy.

Źródło: opracowanie własne

Udział poprawnych identyfikacji gospodarstw jest zbliżony do 80%. Można zadać pytanie, czy to dużo, czy mało? Jeżeli rezultaty te porównamy z klasyfikacyjnymi modelami upadłości przedsiębiorstw (patrz praca Kisielińskiej [2008]), stwierdzamy w

wielu przypadkach porównywalną lub nawet wyższą jakością modelu upadłości gospodarstw mimo bardzo licznego zbioru danych (modele upadłości przedsiębiorstw rzadko budowane są na podstawie zbioru liczącego więcej niż 100 obiektów). Z drugiej strony niektórzy autorzy (np. Zaleska [2002]) uważają, że maksymalny poziom błędnych przewidywań dla prognoz ostrzegawczych to 10%. Z pewnością więc warto podejmować działania w celu poprawy jakości modeli poprzez dodawanie nowych cech lub budowę modeli dedykowanych dla wyodrębnionych w zbiorowości podgrup. W przypadku gospodarstw można je wylaniać np. na podstawie wielkości ekonomicznej czy typów produkcyjnych.

W tabeli 4 zawarto informacje o ostatecznie uwzględnionych w poszczególnych modelach cechach. Okazało się, że żaden z nich nie wykorzystał URP, WOABZB, NPNPKB, WWP, WZ, WIEK i RZ. Zaskakuje zwłaszcza pominięcie powierzchni użytków rolnych, która w modelach służących prognozowaniu sytuacji finansowej gospodarstw pełniła rolę kluczową (patrz praca Kisielewskiej [2008]). Oznacza to, że ryzyko upadłości ekonomicznej gospodarstw nie zależy od powierzchni gospodarstwa.

Podsumowanie

W artykule przedstawiono cztery modele budowane na podstawie danych panelowych, których zadaniem było prognozowanie upadku ekonomicznego gospodarstwa rolniczego. Pierwszy oparto na liniowej funkcji dyskryminacyjnej, dwa kolejne były modelami probitowymi (dla danych połączonych i z efektami losowymi), ostatnim zaś był modelem w postaci sztucznej sieci neuronowej. Wyniki klasyfikacji dokonanej przy ich pomocy były bardzo zbliżone. Najwięcej poprawnych rozpoznań uzyskano stosując sieć neuronową. Najgorsze wyniki dała liniowa funkcja dyskryminacyjna, choć procent poprawnych identyfikacji uzyskany przy jej użyciu był zaledwie o 1% gorszy od klasyfikacji modelem najlepszym. Bardzo zbliżona jakość użytych modeli oznacza, że zależności między zmienną reprezentującą klasę a cechami opisującymi obiekty są najprawdopodobniej liniowe.

Łączny i indywidualne współczynniki trafności klasyfikacji były zbliżone do 80%, co uznać można za wynik dosyć dobry, chociaż warto podejmować działania aby go poprawić. Potwierdza on poprawność metodyczną przeprowadzonych badań i zachęca do ich kontynuowania.

Literatura

- Altman E. I. [1968]: Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *Journal of Finance* nr 23 September.
- Ciechomski W. [2004]: Analiza czynników determinujących „upadłość ekonomiczną” indywidualnych gospodarstw rolnych i przedsiębiorstw przetwórstwa rolno-spożywczego w Polsce w minionym dziesięcioleciu. [W:] Upadłość przedsiębiorstw w Polsce w latach 1990-2003: teoria i praktyka. *Zeszyty Naukowe Akademii Ekonomicznej w Poznaniu* nr 49.
- Cover T. M. [1965]: Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. *IEEE Transactions on Electronic Computers* nr 14.
- Cramer J. S. [1999]: Predictive performance of the binary logit model in unbalanced samples. *The Statistician* t. 48, nr 1.
- Gatnar E. [2001]: Nieparametryczna metoda dyskryminacji i regresji. Wydawnictwo Naukowe PWN. Warszawa.

- Gruszczyński M. [2002]: Modele i prognozy zmiennych jakościowych w finansach i bankowości. Szkoła Główna Handlowa, Warszawa.
- Hornik K., Stinchcombe M., White H. [1989]: Multilayer feedforward networks are universal approximators. *Neural Networks* t. 2, nr 5.
- Jajuga K. [1990]: Statystyczna teoria rozpoznawania obrazów. Państwowe Wydawnictwo Naukowe, Warszawa.
- Kisielińska J. [2008]: Modele klasyfikacyjne prognozowania sytuacji finansowej gospodarstw rolniczych. Wydawnictwo SGGW, Warszawa.
- Krzyśko M. [1990]: Analiza dyskryminacyjna. Wydawnictwo Naukowo-Techniczne, Warszawa.
- Maddala G. S. [1983]: Limited-dependent and qualitative variables in econometrics. Cambridge University Press, Cambridge.
- Wyszkowska Z. [1996]: Wybrane elementy wskaźnikowej analizy finansowej na przykładzie przedsiębiorstw rolniczych. Wyd. ART, Bydgoszcz.
- Zaleska M. [2002]: Ocena ekonomiczno-finansowa przedsiębiorstwa przez analityka bankowego. Szkoła Główna Handlowa, Warszawa.
- Ziętara W., Kosiorek M., Tchorzewska E., Kondraszuk T. [1994]: Rachunek ekonomiczny i analiza finansowa w przedsiębiorstwie rolniczym. Centrum Doradztwa i Edukacji, Brwinów.