

JERZY MARZEC

BAYESOWSKA ANALIZA MODELI DISKRETNEGO WYBORU (DWUMIANOWYCH)¹

1. WSTĘP

W latach siedemdziesiątych ubiegłego stulecia nastąpił gwałtowny rozwój ekonometrycznych modeli dla zmiennych dyskretnych (jakościowych), które w skrócie nazywa się modelami dyskretnego wyboru (ang. *quantal response or discrete choice models*). Podstawową cechą tych modeli jest to, że zmienna endogeniczna przyjmuje tylko skończoną liczbę wartości. W chwili obecnej ekonometryczne modelowanie zmiennych jakościowych w ujęciu klasycznym stanowi standardową treść średnio zaawansowanych anglojęzycznych podręczników ekonometrii, np. Greene [7].

W polskiej literaturze jednym z pierwszych monograficznych ujęć metod ekonometrycznej analizy zjawisk jakościowych była praca Wiśniewskiego [19], natomiast monografia Gruszczyńskiego [8] stanowi prezentację aktualnego dorobku mikroekonometrii stosowanej w finansach i bankowości, interesującą z punktu widzenia badań prowadzonych przez autora niniejszego opracowania. Z drugiej strony, w ciągu ostatnich dwudziestu lat na gruncie ekonometrii bayesowskiej pojawiło się wiele metodologicznych propozycji dotyczących bayesowskiej specyfikacji, estymacji i uogólnień klasycznych modeli dyskretnego wyboru. Jednymi z pierwszych autorów byli Zellner [21] oraz Zellner i Rossi [22].

Głównym celem niniejszego opracowania jest prezentacja nowych (bayesowskich) podejść do modelowania zmiennych jakościowych i ich zastosowanie w analizie rzeczywistych danych finansowych. W szczególności, w niniejszej pracy przedstawimy specyfikację bayesowskich modeli dwumianowych, tzn. dla zmiennych binarnych (dychotomicznych), zaproponowaną przez Alberta i Chiba [1]. Zaprezentujemy przypadek modelu opartego na rozkładzie t-Studenta z nieznaną (podlegającą estymacji) liczbą stopni swobody, który stanowi uogólnienie najczęściej stosowanego w praktyce modelu probitowego. Następnie zastosujemy to podejście do badania ryzyka kredytowego pojedynczej umowy kredytowej dla klientów detalicznych pewnego polskiego banku komercyjnego. W celu uzyskania momentów i gęstości brzegowych rozkładów a posteriori

¹ Autor pragnie wyrazić podziękowania Profesorowi Jackowi Osiewalskiemu za cenne uwagi merytoryczne w trakcie powstawania niniejszego opracowania. Praca wykonana w ramach badań statutowych finansowanych przez Akademię Ekonomiczną w Krakowie w roku 2003 r.

parametrów modeli wykorzystamy losowanie Gibbsa. Wyniki a posteriori pokazują, że zaproponowane uogólnienie (związane z rozkładem t-Studenta) lepiej opisuje dane empiryczne, więc jego wykorzystanie w badaniach jest w pełni uzasadnione.

2. MODEL DYSKRETNEGO WYBORU

Niech y_1, \dots, y_T będzie ciągiem niezależnych zmiennych losowych o rozkładzie zero-jedynkowym z prawdopodobieństwem sukcesu $\Pr(y_t=1)$ równym p_t . W literaturze zależność między p_t a wektorem zmiennych egzogenicznych x_t (lub znanych ich funkcji, jak w części 5) opisuje się za pomocą modelu dyskretnego wyboru (ang. *binary choice models*). Model ten, nazywany także modelem dwumianowym lub dychotomicznym, ma postać

$$p_t \equiv \Pr(y_t = 1) = F(x_t \cdot \beta) \text{ dla } t=1, \dots, T, \quad (1)$$

gdzie β to wektor $k \times 1$ nieznanych parametrów, zaś $x_t = (x_{t1} \dots x_{tk})$ oznacza wektor ustalonych wartości k zmiennych egzogenicznych, $F(\cdot)$ jest znaną funkcją wiążącą prawdopodobieństwo p_t z x_t i β , określającą klasę modelu. Jeżeli $F(\cdot)$ jest dystrybuantą zmiennej losowej o standaryzowanym rozkładzie normalnym, to mamy do czynienia z modelem probitowym². Teoretyczne podstawy innych definicji modeli dyskretnego wyboru przedstawia m.in. Amemiya w pracy [2].

Równoważną specyfikację modelu dwumianowego otrzymamy wprowadzając T niezależnych zmiennych ukrytych (nieobserwowalnych) z_1, \dots, z_T . Jeżeli założymy, że obserwujemy $y_t=1$, gdy $z_t \geq 0$ i $y_t=0$ w przeciwnym przypadku, to model dyskretnego wyboru zapiszemy za pomocą dwóch równań

$$\begin{aligned} z_t &= x_t \cdot \beta + \varepsilon_t \\ y_t &= I_{(0, \infty)}(z_t), \end{aligned} \quad (2)$$

gdzie $I_{\Omega}(w)=1$, gdy $w \in \Omega$ i $I_{\Omega}(w)=0$, jeżeli $w \notin \Omega$; zob. np. [1] lub [17]. Powyższa konstrukcja modelu ma szersze znaczenie, ponieważ wykorzystuje się ją także do konstrukcji modelu dla danych wielomianowych; zob. [3], [9] i [13].

Najczęściej stosowany model probitowy otrzymamy przyjmując dla składników losowych ε_t standaryzowane (niezależne) rozkłady normalne, $\varepsilon_t \sim N(0, 1)$. Wówczas zmienne ukryte z_t posiadają rozkład normalny o wartości oczekiwanej $x_t \beta$ i jednostkowej wariancji, $z_t \sim N(x_t \beta, 1)$. Zauważmy, że znamy jedynie znak nieobserwowalnych zmiennych z_t , zatem wariancja składnika losowego jest nieidentyfikowalnym parametrem, stąd przyjmuje się, że wynosi ona jeden. Korzystając z definicji dystrybuanty możemy łatwo sprawdzić równoważność specyfikacji (1) i (2):

² Drugim najczęściej stosowanym modelem w przypadku analizy danych jakościowych jest model logitowy, który uzyskujemy przyjmując za $F(\cdot)$ dystrybuantę rozkładu logistycznego.

$$p_t = 1 - \Pr(y_t = 0) = 1 - \int_{-\infty}^0 f_N(w|x_t\beta, 1)dw = 1 - \int_{-\infty}^{-x_t\beta} f_N(w'|0, 1)dw' = 1 - F(-x_t\beta) = F(x_t\beta), \quad (3)$$

gdzie $f_N(\cdot|a,b)$ jest funkcją gęstości rozkładu normalnego o wartości oczekiwanej a i wariancji b . Powyższa zależność jest prawdziwa nie tylko w przypadku rozkładu normalnego, ale dla zmiennej z_t o dowolnym ciągłym rozkładzie prawdopodobieństwa z symetryczną funkcją gęstości.

W niniejszej pracy w celu estymacji modelu (2) wykorzystamy podejście bayesowskie, które w przypadku analizy danych jakościowych stosują m.in. autorzy prac: [1], [12], [13], [21] i [22].

3. BAYESOWKI MODEL PROBITOWY.

Na gruncie bayesowskim każdą nieznaną wielkość traktujemy jako zmienną losową, a zatem funkcja (gęstości) prawdopodobieństwa jej rozkładu odzwierciedla pełną wiedzę o tej wielkości. Różne elementy modelu statystycznego (obserwacje - y i parametry - θ) traktowane są symetrycznie, więc wstępną wiedzę o wszystkich nieznanach wielkościach (obserwowalnych i nieobserwowalnych) posiadaną przed zaobserwowaniem zjawiska empirycznego odzwierciedla łączny rozkład prawdopodobieństwa o funkcji gęstości $p(y, \theta)$ (lub uogólnionej gęstości w przypadku rozkładu mieszanego, dyskretno-ciągłego). W bayesowskim modelu statystycznym ogólne zasady estymacji parametrów sprowadzają się do wyznaczenia z rozkładu łącznego $p(y, \theta)$ warunkowej gęstości dla wektora parametrów θ , przy zaobserwowanym wektorze y , czyli funkcji gęstości tzw. rozkładu a posteriori, danej wzorem Bayesa:

$$p(\theta|y) = \frac{p(y, \theta)}{p(y)} = \frac{p(y|\theta) \cdot p(\theta)}{\int_{\Theta} p(y|\theta) \cdot p(\theta) d\theta} \propto l(\theta|y) \cdot p(\theta), \quad (4)$$

gdzie $l(\theta|y)$ jest funkcją wiarygodności, wyznaczoną z rozkładu próbkowego ($l(\theta|y) = p(y|\theta)$), a \propto jest znakiem proporcjonalności, zob. Osiewalski [14].

Model (2) jest przykładem modelu hierarchicznego, więc łączna funkcja uogólnionej gęstości dla parametrów β i wielkości nieobserwowalnych $z = (z_1, \dots, z_T)'$ oraz wektora obserwacji $y = (y_1, \dots, y_T)'$, charakteryzująca jednoznacznie bayesowski model statystyczny, ma postać³

$$p(y, z, \beta) = p(y|z, \beta) \cdot p(z, \beta) = p(y|z, \beta) \cdot p(z|\beta) \cdot p(\beta), \quad (5)$$

gdzie $p(\beta)$ to rozkład a priori, a $p(z|\beta)$ to gęstość warunkowego rozkładu wektora zmiennych ukrytych z , której postać zależy od postaci przyjętego rozkładu dla ε_t w równaniu (2). Korzystając ze wzoru (4), gdzie $\theta = (\beta' z)'$ otrzymujemy postać łącznej funkcji gęstości rozkładu a posteriori dla β i z przy danym y :

³ W zapisie pominięto, że wszystkie funkcje gęstości prawdopodobieństwa są warunkowe względem egzogenicznej macierzy danych $X = (x_1', \dots, x_T)'$.

$$p(z, \beta | y) = \frac{p(y, z, \beta)}{p(y)} \propto p(y|z, \beta) \cdot p(z|\beta) \cdot p(\beta), \text{ gdzie} \quad (6)$$

zdegenerowany (jednopunktowy) rozkład próbkowy dla zaobserwowanego wektora y (warunkowy względem z i β) ma postać

$$p(y|z, \beta) = \prod_{t=1}^T (y_t \cdot I_{[0, \infty)}(z_t) + (1 - y_t) \cdot I_{(-\infty, 0)}(z_t)). \quad (7)$$

W celu uzyskania z formuły (6) brzegowych rozkładów a posteriori powinniśmy dokonać wielokrotnego całkowania, przy czym uzyskanie np. brzegowej gęstości a posteriori $p(\beta/y)$ wymaga T -krotnego całkowania (względem T zmiennych ukrytych), gdzie T to liczba obserwacji. Za sprawą niestandardowej postaci rozkładu próbkowego (6) całkowanie analityczne jest wykluczone. W tego typu zagadnieniach wykorzystuje się metody numerycznej aproksymacji brzegowych rozkładów a posteriori stosując losowanie Gibbsa. (ang. *Gibbs Sampling*). W metodzie tej posługujemy się jedynie rozkładami warunkowymi, z których uzyskujemy poprzez wielokrotne generowanie liczb pseudolosowych próbę z rozkładu a posteriori (choć tylko w sensie asymptotycznym), zob. np. [4], [15] i [18].

W przypadku modelu probitowego, gdy wektor składników losowych $\varepsilon = (\varepsilon_1, \dots, \varepsilon_T)'$ ma wielowymiarowy rozkład normalny o jednostkowej macierzy kowariancji (I_T) scentrowany wokół zera, $\varepsilon \sim N^{(T)}(0, I_T)$, łączna funkcja gęstości dla β i z przy danym y ma postać

$$p(z, \beta | y) \propto p(\beta) \cdot \prod_{t=1}^T (y_t \cdot I_{[0, \infty)}(z_t) + (1 - y_t) \cdot I_{(-\infty, 0)}(z_t)) \cdot f_N(z_t | x_t \beta, 1). \quad (8)$$

W celu zastosowania algorytmu Gibbsa wyznaczamy z gęstości (8) warunkowy względem z rozkład a posteriori dla β , co zapiszemy jako $p(\beta|z, y)$, oraz rozkład a posteriori dla z warunkowy względem β . Zauważmy, że ze wzoru (8) otrzymujemy

$$p(\beta|z, y) \propto p(\beta) \cdot \prod_{t=1}^T f_N(z_t | x_t \beta, 1), \quad (9)$$

co odpowiada przypadkowi normalnej regresji liniowej postaci $z = X\beta + \varepsilon$, gdzie $\varepsilon \sim N^{(T)}(0, I_T)$; nie pojawiają się tu zmienne dyskretne y_t .

W zastosowaniach wnioskowania bayesowskiego istotny jest dobór rozkładu a priori. Przy jego doborze próbujemy pogodzić zasadę wiernego odzwierciedlenia wstępnej wiedzy o parametrze (w naszym przypadku jej braku) i unikanie komplikacji obliczeń na etapie wyznaczania rozkładu a posteriori. W omawianym przypadku wybór rozkładu a priori dla β nie stanowi problemu. Jeżeli przyjmiemy jako $p(\beta)$ niewłaściwy rozkład jednostajny na całej przestrzeni R^k , to warunkowy względem z rozkład a posteriori dla β to k -wymiarowy rozkład normalny o wektorze wartości oczekiwanych β_z i macierzy kowariancji $(X'X)^{-1}$, co zapisujemy

$$\beta|z, y \sim N^{(k)}(\hat{\beta}_z, (X'X)^{-1}), \text{ gdzie } \hat{\beta}_z = (X'X)^{-1} X'z. \quad (10)$$

Jeżeli natomiast dla β przyjmiemy informacyjny rozkład a priori, tj. normalny o wartości oczekiwanej β^* i macierzy kowariancji H^* , który należy do tzw. sprzężonej rodziny rozkładów, to poszukiwany rozkład a posteriori dla wektora parametrów β (warunkowy względem z i y) jest także rozkładem normalnym

$$\beta|z, y \sim N^{(k)}(\tilde{\beta}, \tilde{H}), \quad (11)$$

o następujących parametrach

$$\begin{aligned} \tilde{\beta} &= \tilde{H}(H^{*-1}\beta^* + X'z) \\ \tilde{H} &= (H^{*-1} + X'X)^{-1}. \end{aligned}$$

W tym przypadku istotne znaczenie ma dobór stałych β^* i H^* , aby przyjęty rozkład a priori dobrze reprezentował wstępną wiedzę badacza.

Pełny warunkowy rozkład a posteriori dla wektora z wyznaczamy w oparciu o wzór (8). Założyliśmy wcześniej, że zmienne $z=(z_1, \dots, z_T)'$ są niezależne (przy ustalonym β), więc

$$z_i|\beta, z \text{ ma rozkład } N(x_i\beta, 1) \text{ ucięty na lewo (na prawo) od zera, gdy } y_i=1 \text{ (} y_i=0\text{)}. \quad (12)$$

Aby uzyskać próbę z rozkładu a posteriori (8) stosując schemat Gibbsa, w pojedynczym cyklu losujemy najpierw z gęstości rozkładu normalnego (12), a następnie (w zależności od przyjętego rozkładu a priori dla β) losujemy z gęstości (10) albo (11). Za wartości inicjujące łańcuch Markowa przyjmujemy dla β oceny uzyskane metodą największej wiarygodności (MNV) lub oceny estymatora metody najmniejszych kwadratów dla liniowego modelu prawdopodobieństwa, czyli korzystając z formuły $(X'X)^{-1}X'y$.

4. BAYESOWSKI MODEL t-STUDENTA.

Specyfikacja modelu dwumianowego poprzez wprowadzenie w (2) zmiennych ukrytych z_t pozwala na uogólnienie modelu probitowego. Rozszerzenie klasy modelu można uzyskać poprzez wprowadzenie dla ε_t rozkładu z rodziny t-Studenta jak proponują Albert i Chib [1]. Jeżeli przyjmiemy, że parametrem podlegającym estymacji jest również liczba stopni swobody $\nu > 0$, to wówczas pozwolimy danym empirycznym wyznaczyć najbardziej prawdopodobną a posteriori wartość tego parametru, a wartości zakładane a priori w innych modelach mogą podlegać testowaniu. Stosowanie tej rodziny rozkładów jest tym bardziej uzasadnione, że (jak zauważyli autorzy pracy [1]) często stosowany model logistyczny w przybliżeniu odpowiada przyjęciu założenia o około 8 stopniach swobody dla rozkładu t-Studenta.⁴ Zatem w ramach modelu z

⁴ Albert i Chib [1] uzyskali m.in. wyniki a posteriori dla modelu t-Studenta z 8 stopniami swobody zbliżone do wyników dla modelu logitowego. Ponadto G. Mudholkar i E. George ("A Remark on the Shape of the Logistic

rozkładem t-Studenta można dokonać statystycznej weryfikacji obu najbardziej znanych modeli dla danych dychotomicznych: logistycznego $\nu=8$ i probitowego $\nu=+\infty$. W szczególności, gdyby uzyskane wyniki wskazywały na dużą liczbę stopni swobody, to wówczas model probitowy byłby wystarczająco adekwatny.

Zatem przyjmijmy, że zmienne z_t w równaniu (2) mają niezależne rozkłady t-Studenta z ν stopniami swobody, parametrem położenia (niecentralności) $x_t\beta$ i jednostkowym parametrem skali. Równoważną specyfikację tego modelu uzyskujemy budując model hierarchiczny, który uwzględnia dodatkowe zmienne $\lambda_1, \dots, \lambda_T$ o rozkładzie gamma z parametrami $\nu/2$ i $\nu/2$ i przyjmując dla z_t warunkowy (względem λ_t) rozkład normalny o parametrach $x_t\beta$ i λ_t^{-1} :

$$\begin{aligned} z_t | \beta, \lambda &\sim N(x_t\beta, \lambda_t^{-1}) \\ \lambda_t | \nu &\sim \text{Gamma}(\nu/2, \nu/2) \end{aligned} \quad (13)$$

Powyższa dekompozycja wynika z tożsamości

$$p(z_t | \beta, \nu) = \int_0^{\infty} p(z_t, \lambda_t | \beta, \nu) d\lambda_t = \int_0^{\infty} f_N(z_t | x_t\beta, \lambda_t^{-1}) f_G(\lambda_t | \nu/2, \nu/2) d\lambda_t = f_{St}(z_t | \nu, x_t\beta, 1),$$

gdzie $f_G(\cdot | a, b)$ jest funkcją gęstości rozkładu gamma o wartości oczekiwanej a/b i wariancji a/b^2 , natomiast $f_{St}(\cdot)$ jest funkcją gęstości rozkładu t-Studenta (zob. [14]).

Przyjmując za autorami [1] niewłaściwy rozkład a priori dla β , otrzymamy łączną gęstość rozkładu a posteriori dla z, β, λ i ν (przy zaobserwowanym y) postaci

$$\begin{aligned} p(z, \beta, \lambda, \nu | y) &\propto \\ p(\nu) \cdot \prod_{t=1}^T (y_t \cdot I_{(0, \infty)}(z_t) + (1 - y_t) \cdot I_{(-\infty, 0)}(z_t)) \cdot f_N(z_t | x_t\beta, \lambda_t^{-1}) \cdot f_G(\lambda_t | \frac{\nu}{2}, \frac{\nu}{2}), \end{aligned} \quad (14)$$

gdzie $p(\nu)$ to rozkład a priori dla stopni swobody. Warunkowe rozkłady a posteriori dla z, β i λ , będące podstawą do wykorzystania algorytmu Gibbsa, wyprowadzamy z łącznej gęstości (14) uzyskując

$$z_t | \beta, \lambda, \nu, y \sim N(x_t\beta, \lambda_t^{-1}) \text{ ucięty na lewo (na prawo) od zera, gdy } y_t = 1 \text{ (} y_t = 0 \text{)}. \quad (15)$$

$$\beta | z, \lambda, \nu, y \sim N^{(k)}(\beta_{z, \lambda}, (X'WX)^{-1}), \text{ gdzie } \beta_{z, \lambda} = (X'WX)^{-1} X'Wz, \quad (16)$$

$$\lambda_t | z, \beta, \nu, y \sim \text{Gamma}\left(\frac{\nu+1}{2}, \frac{1}{2}(\nu + (z_t - x_t\beta)^2)\right), \quad (17)$$

gdzie W jest diagonalną macierzą o wymiarach T na T zawierającą na przekątnej elementy λ_t , czyli $W = \text{Diag}(\lambda_1, \dots, \lambda_T)$. Natomiast warunkowy rozkład a posteriori dla ν nie jest gęstością żadnego ze znanych rozkładów prawdopodobieństwa, przy czym jądro tego rozkładu ma postać

Distribution”, Biometrika, 1978) pokazali, że rozkład logistyczny ma identyczną kurtozę, jak rozkład t-Studenta z 9 stopniami swobody.

$$p(v|z, \beta, \lambda, y) \propto p(v) \cdot \prod_{t=1}^T \Gamma\left(\frac{v}{2}\right)^{-1} \cdot \left(\frac{v}{2}\right)^{v/2} \cdot \lambda_t^{v/2-1} \exp\left(-\frac{v}{2} \lambda_t\right). \quad (18)$$

Jako rozkład a priori dla parametru swobody przyjmujemy, jak w pracy [6], rozkład wykładniczy z parametrem γ o funkcji gęstości $p(v) = \gamma \exp(-\gamma v)$. Wartość parametru γ równa np. 10^{-1} implikuje rozkład a priori o wartości oczekiwanej 10 i wariancji 100, który możemy uznać za prawie nieinformacyjny rozkład a priori. Uwzględniając wykładniczy rozkład a priori, postać warunkowego rozkładu a posteriori dla v ma postać

$$p(v|z, \beta, \lambda, y) = c_0 \cdot c_1 \cdot \Gamma\left(\frac{v}{2}\right)^{-T} \cdot \left(\frac{v}{2}\right)^{Tv/2} \cdot \exp(-v \cdot c_2), \quad \text{gdzie} \quad (19)$$

c_0 – stała normująca, $c_1 = \gamma \cdot \prod_{t=1}^T \lambda_t$ oraz $c_2 = \gamma + \frac{1}{2} \left(\sum_{t=1}^T \lambda_t - \sum_{t=1}^T \ln \lambda_t \right)$, przy czym wielkości c_0 i c_1 nie mają znaczenia w dalszej, gdyż nie zależą od v .

Zatem w przypadku parametru v musimy zastosować inną technikę uzyskiwania realizacji z rozkładu a posteriori, mianowicie wykorzystujemy losowanie z odrzucaniem (ang. *acceptance – rejection sampling*) opisane w omawianym przypadku m.in. w pracy [6] lub [16]. Schemat losowania z odrzucaniem polega na tym, że chcąc uzyskać realizację z ciągłego rozkładu (19), który oznaczmy $p(v; T, c_2)$, w pierwszym kroku losujemy realizację innej zmiennej losowej - v^* - z rozkładu pomocniczego $g(v^*; \alpha)$, gdzie α jest parametrem tego rozkładu. Zakładamy, że istnieje kres górny ilorazu obu gęstości: $\sup_v [p(v; T, c_2)/g(v; \alpha)] = c(\alpha) < \infty$. Następnie jeżeli zachodzi nierówność $[c(\alpha)]^{-1} \cdot p(v^*; T, c_2)/g(v^*; \alpha) > u$ przyjmujemy, że $v = v^*$, gdzie u jest realizacją z rozkładu jednostajnego na przedziale (0;1). Oznacza to, że losując z gęstości pomocniczej $g(v^*; \alpha)$, z prawdopodobieństwem akceptacji równym $[c(\alpha)]^{-1} \cdot p(v^*; T, c_2)/g(v^*; \alpha)$, uzyskaliśmy realizację zmiennej v z rozkładu $p(v; T, c_2)$. W przeciwnym razie powtarzamy losowanie z $g(v^*; \alpha)$, aż do spełnienia powyższej nierówności. Bezwarunkowe prawdopodobieństwo spełnienia powyższej nierówności jest równe stałej $[c(\alpha)]^{-1}$, więc tak dobieramy parametr funkcji pomocniczej α , aby to prawdopodobieństwo było maksymalne.

W omawianym przypadku niech $g(v^*; \alpha)$ będzie gęstością rozkładu wykładniczego z parametrem α . Następnie konstruujemy funkcje pomocniczą:

$$Q(v, \alpha; T, c_2) = \ln \frac{p(v; T, c_0, c_1, c_2)}{g(v; \alpha)} = \ln(c_0 c_1) - T \ln \Gamma\left(\frac{v}{2}\right) + T v / 2 \cdot \ln\left(\frac{v}{2}\right) + v(\alpha - c_2) - \ln \alpha, \quad (20)$$

aby znaleźć optymalne α i stałą $c(\alpha)$ rozwiązując następujący problem

$$\inf_{\alpha} \left(\sup_v (Q(v, \alpha; T, c_2)) \right).$$

Zauważmy, że $\partial Q/\partial \alpha = \nu - 1/\alpha$, więc optymalna wartość parametru α gęstości pomocniczej wynosi $1/\nu$. Zatem warunek konieczny (i wystarczający) na istnienie ekstremum funkcji, przy czym $\alpha = 1/\nu$, ma postać:

$$\frac{\partial Q}{\partial \nu} = \frac{T}{2} \left(\ln \frac{\nu}{2} + 1 - \frac{\partial \ln \Gamma(\frac{\nu}{2})}{\partial \frac{\nu}{2}} \right) - c_2 + \alpha = 0. \quad (21)$$

Następnie numerycznie rozwiązujemy równanie (21), uzyskując rozwiązanie optymalne ν_{opt} . Podsumowując, losowanie z odrzucaniem w omawianym przypadku składa się z następujących kroków:

1. losujemy ν^* z rozkładu wykładniczego z parametrem $1/\nu_{opt}$, czyli o wartości oczekiwanej ν_{opt} i wariancji $(\nu_{opt})^2$,
2. losujemy u z rozkładu jednostajnego (0;1),
3. jeżeli zachodzi poniższa nierówność

$$\Gamma\left(\frac{\nu^*}{2}\right)^{-T} \Gamma\left(\frac{\nu_{opt}}{2}\right)^T \left(\frac{\nu^*}{2}\right)^{0.5T \cdot \nu^*} \left(\frac{\nu_{opt}}{2}\right)^{-0.5T \cdot \nu^*} e^{(\nu_{opt} - \nu^*)(c_2 - 1/\nu_{opt})} \leq u,$$

to powtarzamy losowanie z punktu 1,

4. w przeciwnym przypadku przyjmujemy, że ν^* pochodzi z rozkładu o gęstości (19).

Przedstawione powyżej losowanie z odrzucaniem (dla uzyskania realizacji z warunkowego rozkładu a posteriori parametru ν) będziemy stosować w ramach losowania Gibbsa. Mając dane $z^{(q)}$, $\beta^{(q)}$, $\lambda^{(q)}$, $\nu^{(q)}$ jako rezultat q -tego losowania, w kolejnym cyklu dokonujemy następujących kroków:

- $z^{(q+1)}$ jest losowane z rozkładu o gęstości (15) dla $\beta = \beta^{(q)}$, $\lambda = \lambda^{(q)}$,
- $\beta^{(q+1)}$ jest losowane z rozkładu o gęstości (16) dla $z = z^{(q+1)}$, $\lambda = \lambda^{(q)}$,
- $\lambda_t^{(q+1)}$ ($t=1, \dots, T$) jest losowane z rozkładu o gęstości (17) dla $z = z^{(q+1)}$, $\beta = \beta^{(q+1)}$, $\nu = \nu^{(q)}$,
- $\nu^{(q+1)}$ jest losowane z rozkładu o gęstości (19) dla $\lambda = \lambda^{(q+1)}$ w sposób opisany wcześniej,

przy czym przyjmujemy takie same wartości początkowe dla $\beta^{(0)}$ jak w przypadku bayesowskiego modelu probitowego, natomiast $\lambda_t^{(0)} = 1$ dla $t=1, \dots, T$ oraz $\nu^{(0)} = 10$.

Zasadniczą kwestią w sytuacji, gdy stosujemy schemat Gibbsa jako numeryczną metodę aproksymacji brzegowych rozkładów a posteriori, jest zbadanie zbieżności tego algorytmu, którą w praktyce uzyskuje się po wykonaniu odpowiednio dużej liczby cykli – losowań Gibbsa. Możemy spodziewać się, że stabilizacja w kolejnych cyklach wartości oczekiwanych i odchyłeń standardowych a posteriori po odrzuceniu odpowiedniej liczby początkowych losowań, tzw. cykli spalonych, oznacza osiągnięcie zbieżności tej metody. Jedną z graficznych metod badania zbieżności algorytmu jest metoda CumSum, zaproponowana przez Yu i Mykland i opisana m.in. w pracy [5].

Chcąc zastosować w praktyce wnioskowanie bayesowskie dla rozważanego modelu dychotomicznego, musimy w pierwszej kolejności ustalić parametry rozkładów a priori dla wektora β i parametru ν . W przypadku rozkładu a priori dla β przyjęliśmy, że β^* jest wektorem zerowym, a macierz kowariancji $H^* = \sigma_\varepsilon^2 \cdot I$ - macierzą diagonalną. Wartości stałej σ_ε^2 ustaliliśmy w trzech wariantach na poziomie odpowiednio 49, 100 i 256. Ponadto przyjęliśmy, że wartość oczekiwana i wariancja wykładniczego rozkładu a priori dla stopni swobody ν wynosi odpowiednio 10 i 100, a zatem $\gamma = 10^{-1}$. Uzyskane wyniki empiryczne (w postaci rozkładów a posteriori oraz odpowiednich charakterystyk tych rozkładów dla parametrów β i wielkości prawdopodobieństwa p_i) nie były wrażliwe przyjęte na wartości parametrów rozkładów a priori.

5. WYNIKI EMPIRYCZNE

W celu empirycznej prezentacji bayesowskich modeli dychotomicznych: probitowego i t-Studenta wykorzystamy dane o kredytach detalicznych, tj. kredytach konsumpcyjnych i hipotecznych, które zostały udzielone klientom indywidualnym przez jeden z dużych, polskich banków komercyjnych w okresie 01.01.2000 - 30.09.2001 r. Wcześniej wykorzystano te dane w pracy [10] i [11] do estymacji m.in. modelu logitowego i probitowego metodą największej wiarygodności.

Niech objaśniana zmienna dychotomiczna y_t przyjmuje następujące wartości:

- $y_t = 1$ w przypadku, gdy kredytobiorca na dzień 30.09.2001 ma zaległości w spłacie rat kapitałowo-odsetkowych, tzn. opóźnienie w spłacie ostatniej raty wynosi więcej niż jeden miesiąc. W tym przypadku bank ma obowiązek odprowadzić rezerwy celowe w wysokości 20%, albo 50%, albo 100% wartości zadłużenia w zależności od okresu niespłacania rat przez klienta⁵.
- $y_t = 0$ w przypadku, gdy kredytobiorca na dzień 30.09.2001 w terminie spłaca raty kapitałowo-odsetkowe od zaciągniętego kredytu.

Dla uproszczenia możemy zatem przyjąć, że z punktu widzenia banku jeżeli $y_t = 1$, to kredytobiorca jest „złym” klientem, a w przeciwnym przypadku „dobrym”.

W niniejszej analizie wykorzystaliśmy prawie 40 tysięcy rachunków kredytowych, a jako potencjalne zmienne egzogeniczne wyjaśniające ryzyko pojedynczej umowy kredytowej przyjęliśmy (jak w pracy [10] i [11]):⁶

- płeć (zmienna przyjmuje wartość 1, jeżeli klientem jest mężczyzna, 0 w przypadku kobiety),

⁵ Uchwała nr 8/1999 Komisji Nadzoru Bankowego z 22 grudnia 1999 r. stanowi zasady tworzenia przez banki rezerw celowych od należności zagrożonych.

⁶ Podstawowe charakterystyki tego zbioru danych zostały przedstawione w pracy [10].

- wiek klienta (w setkach lat, aby odpowiednio wyskalować dane),
- wpływy, tzn. wielkość miesięcznych wpływów w latach 2000-2001 (w setkach tys. zł) na rachunki *a vista* kredytobiorcy w badanym banku (przede wszystkim rachunki oszczędnościowo-rozliczeniowe ROR); jeżeli nie posiada rachunku ROR w tym banku przyjęto, że wpływy wynoszą zero,
- posiadanie przez kredytobiorcę rachunku ROR w analizowanym banku (1 - posiada, 0 – nie posiada),
- informację o tym, czy kredytobiorca posiada karty płatnicze lub kredytowe wydane przez rozważany bank (1 - posiada choć jedną kartę, 0 - nie posiada),
- sposób udzielenia klientowi kredytu (1 – udzielono go poprzez pośrednika kredytowego, 0 – bezpośrednio przez bank),
- typ kredytu (1 - kredyt konsumpcyjny, 0 – kredyt hipoteczny),
- podstawowe źródło dochodu uzyskiwanego przez kredytobiorcę (zmienna *zrdoch*), tj. umowa o pracę, albo renta lub emerytura, albo własna działalność, umowa o dzieło lub umowa zlecenie, albo inne źródło (np. stypendium).

Zmienna *zrdoch* przyjmuje cztery różne wartości. Chcąc ją uwzględnić w równaniu regresji z wyrazem wolnym, za referencyjną wartość tej zmiennej przyjęliśmy „umowę o pracę” (dla 75% kredytobiorców stanowi podstawowe źródło dochodu). Typ źródła dochodu określony jest przez trzy następujące zmienne zerojedynkowe *zrdoch1*, *zrdoch2*, *zrdoch3*, przy czym źródłem dochodu kredytobiorcy jest umowa o pracę, jeżeli wszystkie te zmienne przyjmują wartość jeden. W pozostałych przypadkach, gdy

- źródłem dochodu kredytobiorcy jest renta lub emerytura, to $zrdoch1 = 0$ i $zrdoch2 = zrdoch3 = 1$,
- źródłem dochodu kredytobiorcy jest własna działalność, umowa o dzieło lub umowa zlecenie, to $zrdoch2 = 0$ i $zrdoch1 = zrdoch3 = 1$,
- źródło dochodu jest inne niż wcześniej wymienione, np. stypendium, to $zrdoch3 = 0$ i $zrdoch1 = zrdoch2 = 1$.

Podstawowe charakterystyki wykorzystywanego zbioru danych przedstawiamy w pracy [10]. W niniejszej pracy - w odróżnieniu do prac [10] i [11] - założyliśmy, że w modelu (1) prawdopodobieństwo niedotrzymania umowy przez kredytobiorcę (p_t) może zależeć liniowo (poprzez funkcję F) nie tylko od zmiennych egzogenicznych w_{ij} , a także od iloczynów tych zmiennych oraz kwadratów zmiennych ciągłych (wiek, wpływy), co prowadzi do następującego, bardziej ogólnego niż w [10] i [11], modelu:

$$z_t = \beta_1 + \sum_j w_{ij} \beta_j + \sum_j \sum_{i \geq j} w_{ij} w_{ii} \beta_{ij} + \varepsilon_t \quad (22)$$

$$y_t = I_{(0, \infty)}(z_t)$$

W efekcie wymiar wektora parametrów β zwiększył się z 11 do 54 (po uwzględnieniu faktu, że zmienna *pośrednik* determinuje *typ kredytu*). Z punktu widzenia omówionych wcześniej metod wnioskowania, sposób wprowadzenia zmiennych egzogenicznych w formule (22) nie wnosi żadnych komplikacji, gdyż z_t jest nadal liniowo zależne od parametrów β . Powyższa modyfikacja pozwoli na lepsze oszacowanie p_t i umożliwi poszukiwanie optymalnych wartości zmiennych ciągłych (ze względu na minimalizację wielkości p_t). Zauważmy, że jeżeli w modelu (22) założymy $\beta_{ij}=0$, wówczas iloraz pochodnych cząstkowych prawdopodobieństwa p_t względem zmiennych w_{ti} i w_{tj} , tzw. efektów krańcowych, jest równy ilorazowi parametrów, tj. β_i/β_j , a zatem nie zależy od wartości tych zmiennych. Zatem uwzględnienie w (22) iloczynów i kwadratów zmiennych egzogenicznych w_{ij} powoduje, że iloraz efektów krańcowych zależy od wszystkich zmiennych egzogenicznych, czyli dla każdej obserwacji może być inny. Powyższe rozszerzenie liczby czynników wyjaśniających p_t może być przedmiotem statystycznej weryfikacji, co pokazujemy w dalszej części.

Wyniki przeprowadzonych badań wskazują (zgodnie z intuicją), że w przypadku bardzo dużej liczby obserwacji, wyniki dla modelu probitowego uzyskane metodą największej wiarygodności są identyczne z rezultatami dla bayesowskiego modelu o normalnym rozkładzie zmiennej ukrytej z_t (por. [11]). Zatem w dalszej części przedstawiamy przede wszystkim wyniki estymacji bayesowskiego modelu t-Studenta o nieznannej liczbie stopni swobody na tle klasycznego modelu probitowego, który jest najczęściej wykorzystywany w praktyce. Tabela 1 zawiera wartości oczekiwane i odchylenia standardowe a posteriori dla parametrów modelu t-Studenta, czyli dla wektora β oraz stopni swobody ν .

Tabela 1

Wartość oczekiwana a posteriori dla stopni swobody wynosi około 1,3 przy niewielkim odchyleniu standardowym, a zatem założenie normalności składnika losowego w równaniu (2) jest bezzasadne⁷. Rozkład próbkowy dla zmiennych z_t charakteryzuje się rozkładem o tak bardzo grubych ogonach, że nie posiada wariacji. Innymi słowy, dystrybuanta F w (1) jest znacznie spłaszczona w stosunku do modelu probitowego. W świetle wyników dla ν ogólniejszy model t-Studenta jest zdecydowanie bardziej preferowany przez dane niż model ze składnikiem losowym o rozkładzie normalnym.

Ogólna postać (22) wprowadzająca iloczyny i kwadraty zmiennych w_{ij} , może być przedmiotem testowania. Przy weryfikacji tej specyfikacji wykorzystaliśmy bayesowski odpowiednik klasycznego testu F na redukcję modelu, posługując się formą kwadratową:

⁷ W przypadku bayesowskiego modelu t-Studenta z 11 parametrami wartość oczekiwana dla parametru stopni swobody wynosi około 2, por. Marzec [2003b].

$$u(\beta_{(2)}) = (\beta_{(2)} - b_{(2)})^T H_{22}^{-1} (\beta_{(2)} - b_{(2)}) / k_2, \text{ gdzie } \beta_{(2)} = [\beta_{12} \dots \beta_{54}]'. \quad (23)$$

Jeżeli brzegowy rozkład a posteriori wektora $\beta_{(2)}$ jest k_2 -wymiarowym rozkładem t-Studenta o $T-k$ stopniach swobody ($1 \leq k_2 \leq k$), wektorze niecentralności $b_{(2)}$ i macierzy precyzji H_{22}^{-1} , to rozkład a posteriori $u(\beta_{(2)})$ jest rozkładem F-Snedecora o $(k_2, T-k)$ stopniach swobody; por. Zellner [20]. Dla restrykcji $\beta_{(2)} = [\beta_{12} \dots \beta_{54}]' = [0 \dots 0]'$, która odpowiada redukcji modelu (22) do modelu liniowego względem w_{ij} , wartość $u([0 \dots 0]')$ wynosi około 279. Jest to wartość z ogona rozkładu $F(k_2, T-k)$, który jest dobrą aproksymacją rozkładu a posteriori tej formy kwadratowej. Wobec tego wybrany element podprzestrzeni parametrów $\beta_{(2)} = [0 \dots 0]'$ znajduje się w podzbiorze wartości parametrów mało prawdopodobnych a posteriori. W takim wypadku nie jesteśmy skłonni przyjąć, że $\beta_{(2)} = [0 \dots 0]'$ i nie dokonujemy redukcji modelu. Testy wyraźnie wskazują na przewagę modelu z 54 parametrami (ogólniejszego) nad modelem z 11 parametrami (zagnieżdżonym)⁸. Posługując się najprostszymi skalarnymi miernikami dopasowania modelu do danych empirycznych nie uzyskujemy tak jednoznacznych wyników (faworyzujących model lepiej sparametryzowany). Współczynnik determinacji Efrona - $R^2 = 1 - \sum (y_t - \hat{p}_t)^2 / \sum (y_t - \bar{y})^2$ (zob. np. [1]) - dla obu tych modeli przyjmuje zbliżone wartości rzędu 0.28 – 0.27, przy czym tak niskie wartości są typowe z uwagi na dychotomiczny charakter zmiennej y_t . Oba modele - ogólniejszy i zagnieżdżony – równie dobrze prognozują $\Pr(y_t=1)$, tzn. udział złych prognoz zmiennej y_t w obu przypadkach wynosi około 19%, przy czym w modelu (22) jest on nieznacznie niższy. Przez złą prognozę rozumiemy sytuację, gdy obserwujemy $y_t = 1$, a oszacowane prawdopodobieństwo jest mniejsze od 0.5 oraz gdy $y_t = 0$, a \hat{p}_t jest co najmniej 0.5 (zob. np. [2], [7]).

Pojedyncze parametry β_j badanego modelu (22) nie mają bezpośredniej interpretacji. W celu porównania wyników obu modeli – z 11 i 54 parametrami, obliczyliśmy średnie arytmetyczne po wszystkich obserwacjach dla efektów krańcowych względem zmiennych egzogenicznych, tj. dla $\partial \Pr(y_t=1) / \partial w_{ij}$. Wyniki te przedstawia Tabela 2.

Tabela 2

Należy zwrócić uwagę na zgodność znaków badanych charakterystyk w przedstawionych powyżej modelach, z wyłączeniem znaku przy zmiennej ROR . Z uwagi na to, że spośród przedstawionych modeli dane zdecydowanie preferują ogólniejszy model t-Studenta z 54 parametrami, zatem interpretację wyników przedstawimy przede wszystkim dla tego modelu. Dodatni znak efektu krańcowego informuje nas, że wzrost w_{ij} powoduje wzrost szans, że $y_t = 1$. Zatem, jeżeli hipotetycznym klientem okazuje się być mężczyzna, to ryzyko niedotrzymania przez niego umowy jest wyższe niż w przypadku kobiety. Analogicznie posiadanie przez kredytobiorcę rachunku

oszczędnościowo-rozliczeniowego, w przeciwieństwie do posiadania choć jednej karty płatniczej lub kredytowej, wiąże się z wyższym prawdopodobieństwem niespłacenia przez niego kredytu. Udzielenie kredytu poprzez pośrednika, podobnie jak udzielenie kredytu konsumpcyjnego zamiast hipotecznego, zwiększa ryzyko kredytowe. W przypadku zmiennych określających źródło dochodu wszystkie trzy modele zgodnie informują, że studenci korzystający z kredytu studenckiego (*zrdoch3*) oraz emeryci i renciści (*zrdoch1*) są mniej ryzykownymi kredytobiorcami niż klienci zatrudnieni na umowę o pracę. Największe ryzyko kredytowe wiąże się z udzieleniem kredytu detalicznego klientom prowadzącym własną działalność gospodarczą (*zrdoch2*). Podsumowując, spośród zmiennych zero-jedynkowych w_{ij} największy wpływ na ryzyko kredytowe ma typ udzielonego kredytu oraz fakt, czy klient posiada kartę płatniczą lub kredytową czy nie. Ponadto wraz z wiekiem kredytobiorcy i wielkością jego wpływów na rachunek ROR maleje prawdopodobieństwo niedotrzymania umowy kredytowej.

Iloraz efektów krańcowych względem pary zmiennych np. w_{ii} i w_{ij} informuje, ile razy większa jest reakcja $\Pr(y_i=1)$ na jednostkowy przyrost w_{ii} , w porównaniu z reakcją $\Pr(y_i=1)$ na jednostkowy przyrost w_{ij} . Przykładowo, w bayesowskim modelu t-Studenta z 54 parametrami, reakcja prawdopodobieństwa niedotrzymania umowy przez kredytobiorcę ze względu na sposób udzielenia kredytu jest około 28,5 razy większa niż reakcja $\Pr(y_i=1)$ na to, czy kredytobiorcą jest kobieta, czy mężczyzną. Natomiast w klasycznym modelu probitowym oraz w drugim modelu t-Studenta ($k=11$) parametrami iloraz ten wynosi odpowiednio około 31 i 90. Przedstawione modele różnią się znacząco ze względu na wartość i ranking efektów krańcowych oraz ilorazy tych wielkości.

Ponadto zbadaliśmy, czy istnieją optymalne ze względu na p_i wartości zmiennych ciągłych, tj. wieku i wpływów. Dla czterech hipotetycznych kredytobiorców (por. Tabela 3) obliczyliśmy optymalne wartości obu zmiennych, które minimalizują p_i , jednakże wykraczają one poza zakres obserwowanych wartości tych zmiennych. Ponadto ze statystycznego punktu widzenia duże odchylenie standardowe a posteriori dla parametru β_{21} (przy kwadracie zmiennej *wiek*) w stosunku do wartości oczekiwanej wskazuje, że zerowa wartość tego parametru jest wysoce prawdopodobna a posteriori. Zatem rozproszenie rozkładu a posteriori dla optymalnego wieku kredytobiorcy byłoby relatywnie duże, a wnioskowanie o tej wielkości byłoby słabe.

Oszacowane modele możemy wykorzystać do celów prognostycznych, czyli prognozowania prawdopodobieństwa „złego kredytu” w przypadku potencjalnego kredytobiorcy. Dla uproszczenia rozważmy cztery hipotetyczne sylwetki potencjalnych klientów starających się o kredyt, które przedstawia Tabela 3 (zob. także [10] i [11]). Wszystkie modele zgodnie prognozują, że największe ryzyko kredytowe związane jest z klientem będącym młodym mężczyzną, który utrzymuje się z

⁸ Podobne wyniki otrzymaliśmy także w przypadku klasycznego modelu probitowego, w którym wartość ilorazu wiarygodności modelu ogólniejszego i zagnieżdżonego wynosi około 377.

prowadzenia własnej działalności i nie korzysta z jakichkolwiek innych usług badanego banku oprócz kredytu, który został mu udzielony poprzez pośrednika. Preferowany przez dane model t-Studenta z 54 parametrami wskazuje, że prawdopodobieństwo niedotrzymania umowy kredytowej (p_t) przez tego „młodego biznesmena” jest bardzo wysokie i wynosi $0,55 (\pm 0,05)$. Jednocześnie we wszystkich modelach precyzja wnioskowania o p_t dla „młodego biznesmena” jest najmniejsza w porównaniu do pozostałych klientów. Najmniejsze ryzyko kredytowe, spośród czterech rozważanych kredytobiorców, związane jest ze starszą panią utrzymującą się z emerytury, której udzielono kredyt hipoteczny. Model t-Studenta ($k=54$) wskazuje, że praktycznie brak jest jakiegokolwiek ryzyka w przypadku tego klienta. Największe różnice w oszacowaniu p_t dotyczą „najczęstszego klienta”, tzn. o cechach najczęstszych w próbie (dotyczy zmiennych jakościowych) i przeciętnych (dla zmiennych ciągłych) w badanej zbiorowości, który uzyskał kredyt poprzez pośrednika. W przypadku tego klienta, w modelu t-Studenta ($k=54$) prawdopodobieństwo „złego kredytu” wynosi $0,044$, to jest istotnie mniej niż w przypadku modelu probitowego, który szacuje tę wielkość na poziomie $0,3-0,19$. W przypadku „najczęstszego klienta”, który uzyskał kredyt konsumpcyjny bezpośrednio z banku, model t-Studenta ($k=54$) szacuje p_t na poziomie $0,015$, co z praktycznego punktu widzenia oznacza brak ryzyka. Także pozostałe modele prognozują to prawdopodobieństwo na podobnym poziomie. Podsumowując, widoczne są istotne różnice w wielkości oszacowanego prawdopodobieństwa „złego kredytu” między preferowanym przez dane modelem t-Studenta ($k=54$), a często stosowanym modelem probitowym, a także modelem logistycznym; por. [9]. Natomiast różnice między dwoma bayesowskimi modelami t-Studenta z 54 i 11 parametrami nie są już tak wyraźne.

Tabela 3

6. PODSUMOWANIE

W niniejszym opracowaniu przedstawiliśmy, odwołując się do literatury przedmiotu, specyfikację bayesowskich modeli dla danych dwumianowych, zarówno z normalnym składnikiem losowym, jak i z rozkładem t-Studenta o nieznannej liczbie stopni swobody. Dla tej klasy modeli omówiliśmy szczegółowo wykorzystanie losowania Gibbsa jako metody numerycznej aproksymacji brzegowych rozkładów a posteriori. Przeprowadzone badania empiryczne wskazują, że podejście bayesowskie pozwoliło na uzyskanie nowych wyników. Warto pamiętać, że na gruncie klasycznym metoda największej wiarygodności, wystarczająca w przypadku tak dużej liczbie obserwacji, nie ma zbadanych własności w przypadku modelu t-Studenta, stąd potrzeba zastosowania podejścia bayesowskiego. Ponadto w przypadku małej próby podejście bayesowskie jest polecane z uwagi na

nieasymptotyczne (małopróbkowe) własności, o czym w przypadku analizy modeli dychotomicznych pisze np. Zellner [21]. Wyniki empiryczne wyraźnie preferują model t-Studenta z około jednym stopniem swobody, tj. model z rozkładem Cauchy'ego. Zatem zastosowanie w tym przypadku modelu probitowego czy logitowego jest nieuzasadnione ze statystycznego punktu widzenia, zwłaszcza, że uzyskane prognozy prawdopodobieństwa niespłacenia kredytu czy efekty krańcowe są bardzo rozbieżne w modelach: probitowym i t-Studenta.

Akademia Ekonomiczna w Krakowie

LITERATURA

- [1] Albert J. Chib S., 1993, *Bayesian Analysis of Binary and Polychotomous Response Data*, Journal of the American Statistical Association, 88, s. 669-679.
- [2] Amemiya T., 1981, *Qualitative Response Models: A Survey*, Journal of Economic Literature, 19.
- [3] Amemiya T., 1985, *Advanced Econometrics*, Harvard University Press, Cambridge Massachusetts.
- [4] Casella G., E. George, 1992, *Explaining the Gibbs Sampler*, The American Statistician, 46.
- [5] Cowles M.K., B.P. Carlin, 1996, *Markov Chain Monte Carlo Covergence Diagnostic: A Comparative Review*, Journal of the American Statistical Association, 91, s. 883-904.
- [6] Geweke J., 1996, *Monte Carlo Simulation and Numerical Integration* in H. Amman, D. Kendrick and J. Rust (eds.), *Handbook of Computational Economics*, Amsterdam: North-Holland.
- [7] Greene W.H., 1993, *Econometric Analysis*, Macmillan Publishing Company, New York.
- [8] Gruszczyński M., 2001, *Modele i prognozy zmiennych jakościowych w finansach i bankowości*, Monografie i Opracowania SGH, Warszawa, nr 6.
- [9] Maddala G.S., 1983, *Limited dependent and qualitative variables in econometrics*, Cambridge University Press, Cambridge.
- [10] Marzec J., 2003a, *Badanie niewypłacalności kredytobiorcy na podstawie modeli logitowych i probitowych*, Zeszyty Naukowe Akademii Ekonomicznej w Krakowie nr 628 (w druku).
- [11] Marzec J., 2003b, *Badanie niespłacalności kredytów za pomocą bayesowskich modeli dychotomicznych - założenia i wyniki*, Metody ilościowe w naukach ekonomicznych (red. A. Welfe), Wydawnictwo SGH w Warszawie (w druku).
- [12] McCulloch R.E., N.G. Polson, P. E. Rossi, 2000, *A Bayesian Analysis of the Multinomial Probit Model with Fully Identified Parameters*, Journal of Econometrics, 99, s. 173-193.
- [13] McCulloch R.E., P. E. Rossi, 1993, *An exact Likelihood Analysis of the Multinomial Probit Model*, Journal of Econometrics, 64, s. 207-240.
- [14] Osiewalski J., 1991, *Bayesowska estymacja i predykcja dla jednorównaniowych modeli ekonometrycznych*, Akademia Ekonomiczna w Krakowie, Zeszyty Naukowe, Seria specjalna: Monografie, nr 100, Kraków.
- [15] Osiewalski J., 2001, *Ekonometria bayesowska w zastosowaniach*, Wydawnictwo Akademii Ekonomicznej w Krakowie, Kraków.
- [16] Pajor A., 2002, *Bayesowska estymacja i prognozowanie w modelu stochastycznej zmienności z błędem t-Studenta*, Dynamiczne Modele Ekonometryczne (VII Ogólnopolskie Seminarium Naukowe 4-6 września 2001), Wydawnictwo Uniwersytetu M. Kopernika, Toruń, s. 256-274.
- [17] Poirier D.J., P.A. Ruud, 1988, *Probit with dependent observations*, Review of Economics Studies, 55, s. 593-614.

- [18] Tierney L., 1994, *Markov chains for exploring posterior distributions (with discussion)*, Annals of Statistics, 22, s. 1701-1762.
- [19] Wiśniewski J., 1986, *Ekonometryczne badanie zjawisk jakościowych (studium metodologiczne)*, Uniwersytet M. Kopernika, Toruń
- [20] Zellner A., 1971, *An Introduction to Bayesian Inference in Econometrics*, J. Wiley, New York 1971.
- [21] Zellner A., 1983, *Bayesian Analysis of Simple Multinomial Logit Model*, Economics Letters, 11, s. 133-136.
- [22] Zellner A., P. Rossi, 1984, *Bayesian Analysis of Dichotomous Quantal Response Models*, Journal of Econometrics, 25, s. 365-393.

Tabela 1.

Wartości oczekiwane i odchylenia standardowe a posteriori parametrów bayesowskiego modelu t-Studenta o nieznannej liczbie stopni swobody ν .

Zmienna	parametr	E(y)	D(y)	Zmienna	Parametr	E(y)	D(y)
Stała	β_1	-73.376	13.139	$w_2 \cdot w_{10}$	β_{29}	-1.276	1.367
Płeć (w_1)	β_2	2.445	1.990	$(w_3)^2$	β_{30}	0.221	0.008
Wiek (w_2)	β_3	-3.293	7.399	$w_3 \cdot w_4$	β_{31}	5.592	27.477
Wpływy (w_3)	β_4	-425.893	35.095	$w_3 \cdot w_5$	β_{32}	-4.468	2.652
ROR (w_4)	β_5	52.060	9.691	$w_3 \cdot w_6$	β_{33}	54.125	3.917
Karty (w_5)	β_6	-62.388	31.318	$w_3 \cdot w_7$	β_{34}	-47.521	4.392
Pośrednik (w_6)	β_7	9.807	3.949	$w_3 \cdot w_8$	β_{35}	69.560	17.420
Typ kredytu (w_7)	β_8	64.462	12.374	$w_3 \cdot w_9$	β_{36}	-55.882	3.825
Zrdoch1 (w_8)	β_9	12.283	10.314	$w_3 \cdot w_{10}$	β_{37}	341.724	14.861
Zrdoch2 (w_9)	β_{10}	-3.798	1.678	$w_4 \cdot w_5$	β_{38}	45.302	30.235
Zrdoch3 (w_{10})	β_{11}	10.570	14.561	$w_4 \cdot w_6$	β_{39}	-1.627	0.259
$w_1 \cdot w_2$	β_{12}	-0.562	0.257	$w_4 \cdot w_7$	β_{40}	-45.269	9.006
$w_1 \cdot w_3$	β_{13}	-0.294	2.148	$w_4 \cdot w_8$	β_{41}	-0.204	0.490
$w_1 \cdot w_4$	β_{14}	0.395	0.240	$w_4 \cdot w_9$	β_{42}	1.536	0.327
$w_1 \cdot w_5$	β_{15}	0.256	0.305	$w_4 \cdot w_{10}$	β_{43}	-6.385	3.812
$w_1 \cdot w_6$	β_{16}	-0.338	0.203	$w_5 \cdot w_6$	β_{44}	0.856	0.300
$w_1 \cdot w_7$	β_{17}	-2.444	1.963	$w_5 \cdot w_7$	β_{45}	0.081	1.449
$w_1 \cdot w_8$	β_{18}	-0.030	0.083	$w_5 \cdot w_8$	β_{46}	-0.742	0.667
$w_1 \cdot w_9$	β_{19}	0.323	0.166	$w_5 \cdot w_9$	β_{47}	-0.863	0.371
$w_1 \cdot w_{10}$	β_{20}	0.262	0.313	$w_5 \cdot w_{10}$	β_{48}	17.953	6.037
$(w_2)^2$	β_{21}	0.064	1.006	$w_6 \cdot w_8$	β_{49}	-0.808	0.451
$w_2 \cdot w_3$	β_{22}	11.445	15.377	$w_6 \cdot w_9$	β_{50}	1.599	0.263
$w_2 \cdot w_4$	β_{23}	0.469	1.110	$w_6 \cdot w_{10}$	β_{51}	-8.167	3.818
$w_2 \cdot w_5$	β_{24}	-0.715	1.388	$w_7 \cdot w_8$	β_{52}	-11.904	10.285
$w_2 \cdot w_6$	β_{25}	0.568	0.964	$w_7 \cdot w_9$	β_{53}	1.528	1.632
$w_2 \cdot w_7$	β_{26}	0.473	7.149	$w_7 \cdot w_{10}$	β_{54}	-1.947	14.147
$w_2 \cdot w_8$	β_{27}	0.975	0.483	-	ν	1.302	0.067
$w_2 \cdot w_9$	β_{28}	1.715	0.810				

Źródło: obliczenia własne.

Tabela 2.

Oceny MNW oraz wartości oczekiwane i odchylenia standardowe a posteriori dla uśrednionych efektów krańcowych.

Zmienna	Model probitowy - MMW (11 parametrów)			Bayesowski model t—Studenta (11 parametrów)		Bayesowski model t—Studenta (54 parametrów)	
	Oceny	Błędy szacunku	Stat. t	E(y)	D(y)	E(y)	D(y)
pleć	0,008	0,003	2,4	0,004	0,005	0,019	0,006
wiek	-0,170	0,017	-10,0	-0,221	0,023	-0,266	0,031
wpływy	-0,333	0,044	-7,6	-8,297	0,227	-15,733	5,204
ROR	-0,056	0,008	-7,5	0,128	0,017	0,662	0,329
karty	-0,034	0,007	-5,2	-0,053	0,019	-7,907	5,274
pośrednik	0,251	0,006	43,3	0,358	0,011	0,542	0,036
typ kredytu	0,036	0,013	2,8	0,237	0,069	9,412	1,511
Zrdoch1	0,018	0,006	3,1	0,021	0,007	0,076	0,031
Zrdoch2	-0,062	0,008	-7,6	-0,018	0,014	-0,030	0,019
Zrdoch3	0,045	0,015	3,1	0,101	0,027	0,592	0,085

Źródło: obliczenia własne.

Tabela 3.

Wartości oczekiwane i odchylenia standardowe a posteriori prawdopodobieństwa niespłacenia kredytu - $\Pr(y_i=1)=F(x_i\beta)$.

Zmienna	Najczęstszy Klient		„Młody Biznesmen”	„Starsza Pani”
	Pośrednik=1	Pośrednik=0		
Stała	1	1	1	1
Płeć	1	1	1	0
Wiek (w latach)	40,2	40,2	21	60
Wpływy (w tys. zł)	10,2	10,2	0	1
ROR	1	1	0	1
Karty płatnicze	0	0	0	1
Pośrednik	1	0	1	0
Typ kredytu: konsumpcyjny	1	1	1	0
Zrdoch1	1	1	1	0
Zrdoch2	1	1	0	1
Zrdoch3	1	1	1	1
Model probitowy (MNW, 11 parametrów)				
Ocena p_t	0,306	0,038	0,664	0,011
Błąd szacunku	(0,014)	(0,002)	(0,016)	(0,002)
Model probitowy (MNW, 54 parametrów)				
Ocena p_t	0,193	0,028	0,551	$4,16 \cdot 10^{-6}$
Błąd szacunku	(0,047)	(0,003)	(0,042)	$(4,84 \cdot 10^{-4})$
Bayesowski model t-Studenta (ν estymowane, 11 parametrów)				
$E(p_t y)$	0,034	0,016	0,584	0,039
$D(p_t y)$	(0,002)	(0,001)	(0,025)	(0,007)
Bayesowski model t-Studenta (ν estymowane, 54 parametrów)				
$E(p_t y)$	0,044	0,015	0,553	0,009
$D(p_t y)$	(0,006)	(0,002)	(0,053)	(0,009)

Źródło: obliczenia własne.