

PRACE NAUKOWE

Uniwersytetu Ekonomicznego we Wrocławiu

RESEARCH PAPERS

of Wrocław University of Economics

323

Inwestycje finansowe i ubezpieczenia – tendencje światowe a rynek polski



Redaktorzy naukowi

Krzysztof Jajuga

Wanda Ronka-Chmielowiec



Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu
Wrocław 2013

Redaktor Wydawnictwa: Agnieszka Flasińska

Redaktor techniczny: Barbara Łopusiewicz

Korektor: Barbara Cibis

Łamanie: Małgorzata Czupryńska

Projekt okładki: Beata Dębska

Publikacja jest dostępna w Internecie na stronach:

www.ibuk.pl, www.ebscohost.com,

w Dolnośląskiej Bibliotece Cyfrowej www.dbc.wroc.pl,

The Central and Eastern European Online Library www.ceeol.com,

a także w adnotowanej bibliografii zagadnień ekonomicznych BazEkon

http://kangur.uek.krakow.pl/bazy_ae/bazekon/nowy/index.php

Informacje o naborze artykułów i zasadach recenzowania znajdują się

na stronie internetowej Wydawnictwa

www.wydawnictwo.ue.wroc.pl

Kopiowanie i powielanie w jakiegokolwiek formie

wymaga pisemnej zgody Wydawcy

© Copyright by Uniwersytet Ekonomiczny we Wrocławiu

Wrocław 2013

ISSN 1899-3192

ISBN 978-83-7695-351-9

Wersja pierwotna: publikacja drukowana

Druk: Drukarnia TOTEM

Spis treści

Wstęp	11
Adam Adamczyk: Poziom wewnętrznych źródeł finansowania jako determinanta inwestycji w działalność B + R przedsiębiorstw	13
Roman Asyngier: Ekonomiczne i prawne aspekty nieprawidłowości funkcjonowania rynku NewConnect. Ocena i propozycje zmian.....	23
Jacek Bialek: Zastosowanie autorskiego indeksu wydajności pracy do analizy dynamiki cen jednostek rozrachunkowych OFE	34
Magdalena Chmielowiec-Lewczuk: Zrównoważona Karta Wyników w zakładzie ubezpieczeń.....	43
Dawid Dawidowicz: Ocena efektywności nowych i pozostałych funduszy inwestycyjnych akcji polskich w latach 2000–2012.....	53
Ewa Dziwok: Weryfikacja modeli krzywej dochodowości na podstawie metod dynamicznych.....	66
Krzysztof Echaust: Zwroty dzienne a zwroty nocne – porównanie wybranych własności na przykładzie kontraktów <i>futures</i> notowanych na GPW w Warszawie.....	75
Urszula Gierałtowska: Inwestowanie w metale szlachetne jako alternatywna forma lokowania kapitału	88
Paweł Kliber: Spread WIBOR-OIS jako miara ryzyka kredytowego i premii płynnościowej	101
Karol Marek Klimczak: Struktura autoregresyjna zysku rezydualnego spółek z Polski, Niemiec i Francji.....	112
Anna Korzeniowska: Wybrane problemy rynku finansowego wynikające z sytuacji na rynku oszczędności gospodarstw domowych.....	120
Mieczysław Kowerski: Cateringowa teoria dywidend.....	128
Marzena Krawczyk: Adekwatność oferty instytucji rynku finansowego do potrzeb kapitałowych MŚP.....	142
Paweł Kufel, Magdalena Mosionek-Schweda: Wpływ doświadczenia giełdowego na koszt pozyskiwania kapitału na rynku Catalyst	151
Robert Kurek: Ewolucja konwergencji regulacji i sposobów nadzorowania na rynku ubezpieczeniowym UE.....	161
Sebastian Majewski, Mariusz Doszyń: Efekty wpływu czynników behawioralnych na stopy zwrotu z akcji spółek sektora budowlanego notowanych na GPW w Warszawie.....	170

Sebastian Majewski: Behawioralny portfel według Maslowa – analiza symulacyjna.....	180
Marta Malecka: Metody oceny jakości prognoz ryzyka rynkowego – analiza porównawcza	192
Aleksander R. Mercik: Wykorzystanie rozkładu t -Studenta do szacowania wartości zagrożonej	202
Artur Mikulec: Znormalizowany względem czasu τ wskaźnik Calmara i jego zastosowanie w analizie efektywności inwestycji portfelowych.....	212
Wojciech Misterek: Bariery w zakresie pozyskania zewnętrznych źródeł finansowania na realizację projektów innowacyjnych przedsiębiorstw	223
Paweł Niszczota: Wpływ języka raportowania na płynność spółek zagranicznych notowanych na GPW	232
Dorota Pekasiewicz: Wyznaczanie współczynnika bezpieczeństwa na podstawie kwantyla rozkładu sumy roszczeń w portfelu ubezpieczeń komunikacyjnych.....	241
Agnieszka Perepeczo: Reakcja akcjonariuszy na decyzje o wypłacie dywidendy w spółkach publicznych – wyniki badań empirycznych.....	253
Tomasz Pisula: Metodyczne aspekty zastosowania modeli skoringowych do oceny zdolności kredytowej z wykorzystaniem metod ilościowych.....	265
Paweł Porcenaluk: Analiza wybranych miar ryzyka płynności dla akcji notowanych na GPW w Warszawie w latach 2001–2011	289
Marcin Salamaga: Zastosowanie metody średniej kroczącej do badania zyskowości inwestycji na polskim rynku kapitałowym	298
Rafał Siedlecki: Prognozowanie trudności finansowych przedsiębiorstw z wykorzystaniem miary rozwoju Hellwiga	308
Anna Sroczyńska-Baron: Możliwości aplikacyjne gier mniejszościowych na Gieldzie Papierów Wartościowych	319
Michał Stachura, Barbara Wodecka: Asymetria w ujęciu Boshnakova – propozycja metody szacowania miar asymetrii z próby.....	328
Piotr Staszkiwicz: Verification of the disclosure lemma applied to the model for reputation risk for subsidiaries of non-public group with reciprocal shareholding on the Polish broker-dealers market.....	337
Anna Szymańska: Bayesowskie szacowanie stawek składki w ubezpieczeniach komunikacyjnych z wybranymi funkcjami straty	347
Jacek Welc: Prognozowana dynamika zysków spółek a obciążenie błędów prognoz – doświadczenia polskie	357
Jerzy Węclawski: Pożyczki hybrydowe jako alternatywna forma finansowania przedsiębiorstw	366
Ryszard Węgrzyn: Analiza wrażliwości zmienności implikowanej względem instrumentu podstawowego opcji – podejście dynamiczne.....	375
Stanisław Wieteska: Obciążenia obiektów budowlanych śniegiem jako element ryzyka w ubezpieczeniach majątkowo-osobowych w Polskim obszarze klimatycznym	385

Zuzanna Wośko: Odporność sektora bankowego w Polsce na szoki zewnętrzne w kontekście ryzyka kredytowego. Badanie zależności między zmiennymi makroekonomicznymi	397
Anna Zamojska: Wskaźnik Sharpe'a w teorii i w praktyce.....	406
Aneta Zglińska-Pietrzak: Bootstrapowe prognozy zmienności stóp zwrotu na podstawie modelu GARCH	415
Monika Zielińska-Sitkiewicz: Ocena kondycji rynku nieruchomości mieszkaniowych na podstawie badania danych z raportów finansowych firm deweloperskich	423

Summaries

Adam Adamczyk: The level of internal sources of finance as a determinant of investment in R & D of enterprises	22
Roman Asyngier: Economic and legal aspects of irregularities in the functioning of the NewConnect market. Assessment and suggestions for changes	33
Jacek Bialek: Application of the original index of labour productivity in the analysis of open pension funds' units dynamics	42
Magdalena Chmielowiec-Lewczuk: Balanced Scorecard in insurance company.....	52
Dawid Dawidowicz: Evaluation of efficiency of new Polish equity investment funds in comparison to the other investment funds in the period 2000–2012	65
Ewa Dziwok: Yield curve verification based on the correlation surface method	74
Krzysztof Echaust: Traded period returns and non-traded period returns – comparison of selected properties on the basis of futures contracts quoted on Warsaw Stock Exchange.....	87
Urszula Gieraltowska: Investing in precious metals as an alternative form of capital investment	100
Paweł Kliber: WIBOR-OIS spread as a measure of liquidity and default risk	111
Karol Marek Klimczak: Autoregressive structure of residual income of Polish, French and German firms.....	119
Anna Korzeniowska: Selected problems of financial market resulting from the situation on household savings market	127
Mieczysław Kowerski: Catering theory of dividends	141
Marzena Krawczyk: Adequacy of the offer given by financial market institution to capital needs of SMEs	150
Paweł Kufel, Magdalena Mosionek-Schweda: The impact of the stock-market experience on the cost of capital gained on the Catalyst market.....	160

Robert Kurek: The evolution in convergence of supervision regulations and methods on the European Union insurance market	169
Sebastian Majewski, Mariusz Doszyń: The effects of impact of behavioural factors on the rate of return of construction companies stocks listed on the Warsaw Stock Exchange.....	179
Sebastian Majewski: Behavioural portfolio according to Maslov – simulation analysis	191
Marta Malecka: Methods for evaluating Value-at-Risk forecasts – comparative analysis	201
Aleksander R. Mercik: Using the Student's <i>t</i> distribution in Value-at-Risk estimation.....	211
Artur Mikulec: Tau-normalized-Calmar ratio and its application in the analysis of portfolio investment efficiency	222
Wojciech Misterek: Barriers in obtaining external funding to the realization of innovative projects in companies	231
Paweł Niszczota: The language used in filings and the trading activity of foreign companies listed on the Warsaw Stock Exchange	240
Dorota Pekasiewicz: Determination of the safety factor based on quantile of the sum of claims distribution in the portfolio of automobile insurance....	252
Agnieszka Perepeczo: Market reactions to dividend announcements in public companies – empirical evidence.....	264
Tomasz Pisula: Methodological aspects of the application of credit scoring models to assess the creditworthiness with the use of quantitative methods	288
Paweł Porcenaluk: The analysis of the selected liquidity risk measures for stocks listed on the Warsaw Stock Exchange in 2001–2011 period.....	297
Marcin Salamaga: An application of moving average rules for testing the profitability of Polish stock market.....	307
Rafał Siedlecki: Forecasting financial problems of companies based on Hellwig measurement of development	318
Anna Sroczyńska-Baron: The application of the minority games and gambling on the stock exchange.....	327
Michał Stachura, Barbara Wodecka: Boshnakov's approach to asymmetry – proposal of estimation of sample asymmetry measures	336
Piotr Staszkiwicz: Weryfikacja lematu ujawnienia dla modelu ryzyka reputacji niepublicznych grup kapitałowych z powiązaniem wzajemnymi na polskim rynku firm inwestycyjnych	346
Anna Szymańska: Bayesian estimation of premium rates in motor insurance with selected loss functions	356
Jacek Welc: Forecasted earnings growth of companies and earnings forecast bias – Polish experience.....	365
Jerzy Węclawski: Hybrid loans as an alternative form of corporate finance ..	374

Ryszard Węgrzyn: Analysis of the sensitivity of implied volatility to the underlying instrument of option – a dynamic approach.....	384
Stanisław Wieteska: Overload of roofs of buildings with snow as an element of risk in property insurance in the Polish climate area.....	396
Zuzanna Wośko: Resilience of the Polish banking sector to external shocks in the context of credit risk. Analysis of the relationship between macro-economic variables	405
Anna Zamojska: Sharpe ratio – theory and practice.....	414
Aneta Zglińska-Pietrzak: Bootstrap predictions of returns for GARCH processes	422
Monika Zielińska-Sitkiewicz: Assessment of the condition of the Polish real estate market based on the data analysis from the financial statements of developers	437

Tomasz Pisula

Politechnika Rzeszowska

METODYCZNE ASPEKTY ZASTOSOWANIA MODELI SKORINGOWYCH DO OCENY ZDOLNOŚCI KREDYTOWEJ Z WYKORZYSTANIEM METOD ILOŚCIOWYCH

Streszczenie: Artykuł przedstawia metodyczne aspekty zastosowania metod skoringowych do oceny zdolności kredytowej dla klientów indywidualnych z wykorzystaniem metod ilościowych. Na podstawie dostępnych danych kredytowych tzw. German Credit Data (GCD) przedstawiono na przykładach główne etapy budowy systemu skoringowego: fazę projektowania, fazę wdrażania wraz z etapem walidacji oraz fazę monitoringu jego stabilności. Dla potrzeb prezentowanych analiz oraz w celu zautomatyzowania obliczeń opracowano autorskie programy komputerowe (moduły napisane w języku Statistica Visual Basic), które mogą być wykorzystane w praktyce stosowania modeli skoringowych.

Słowa kluczowe: skoring kredytowy, metody ilościowe, statystyczne metody klasyfikacji.

1. Wstęp

Udzielanie kredytów jest jedną z głównych form działalności bankowej. Ten rodzaj działalności bankowej narażony jest jednak na duże ryzyko niedotrzymania zobowiązań kredytowych. Wysoki odsetek tzw. złych aktywów (niespłaconych kredytów) jest także niekiedy jedną z ważniejszych przyczyn upadłości wielu banków. Z tych też powodów wdrożenie efektywnych systemów zarządzania ryzykiem kredytowym jest niezbędne do prawidłowego funkcjonowania banku. Dzisiaj już trudno wyobrazić sobie bank, który w swojej działalności nie wdraża takich narzędzi. Komisja Nadzoru Finansowego nakłada obowiązek wdrożenia narzędzi zarządzania ryzykiem kredytowym na wszystkie funkcjonujące w Polsce banki.

Od kilkudziesięciu już lat banki z powodzeniem stosują w procesie zarządzania ryzykiem kredytowym systemy punktowej oceny zdolności kredytowej, tzw. systemy skoringowe. D. Durand w 1941 r. jako pierwszy zauważył, że metody klasyfikacji Fishera po raz pierwszy zastosowane w biologii można również wykorzystać do klasyfikacji kredytobiorców ze względu na ich wiarygodność kredytową. Ważną przesłanką wprowadzenia systemów skoringowych do praktyki bankowej było przy-

stąpienie USA do wojny i związana z tym mobilizacja *credit officers*. Akceptację i powszechność wykorzystania metod skoringowych w zastosowaniach bankowych zapoczątkowała ustawa rządu USA z 1975 r., tzw. Ustawa o równości szans w udzielaniu kredytu. Metody skoringowe sprawdziły się później w latach 80. przy wydawaniu bankowych kart kredytowych. Sukces ten przyczynił się do tego, że banki zaczęły stosować metody skoringowe także w działalności kredytowej. Rys historyczny rozwoju metod skoringowych można znaleźć m.in. w pracach: [Janc, Kraska 2001; Matuszyk 2004; Thomas 2009].

Systemy *credit scoring* w wąskim sensie definiuje się (zob. [Matuszyk 2004]) jako: metody, narzędzia i modele służące do oceny zdolności kredytowej klientów banku. Klasyfikacja klientów banku na dwie klasy (klientów dobrych i złych) odbywa się na podstawie prognozowanego prawdopodobieństwa spłaty kredytu i oszacowanej punktowej oceny (tzw. skoringu) określającej ich wiarygodność. W szerszym sensie systemy te definiuje się (zob. [Matuszyk 2004]) jako: systemy oceny i zarządzania ryzykiem kredytowym związanym z klientem indywidualnym lub całym portfelem kredytowym, które mają szczególne zastosowania przy: wspomaganii podejmowania trafnych decyzji kredytowych, tworzeniu skutecznych systemów monitorowania oraz kontroli ryzyka portfela kredytowego, izolowaniu kredytów niepewnych, czyli wymagających szczególnej uwagi, ustalaniu polityki cen kredytów uwzględniającej stopień ich ryzyka.

Systemy skoringu bankowego (zob. [Kraska 2004]) można podzielić ogólnie na dwie klasy: skoring kredytowy dla osób fizycznych (tzw. skoring konsumencki) oraz skoring kredytowy dla klientów korporacyjnych (dla dużych i małych firm). Istnieją także inne, bardziej szczegółowe kryteria podziału metod skoringowych ze względu np. na cel analizy, rodzaj kredytu, cel wykorzystania systemu, podmiot dokonujący analizy itp. Szczegółową charakterystykę różnego rodzaju systemów skoringowych można znaleźć w literaturze (zob. np. [Janc, Kraska 2001; Kraska 2004; Matuszyk 2004]).

Celem pracy jest przedstawienie metodologicznych aspektów zastosowania skoringu do oceny zdolności kredytowej dla klientów indywidualnych z wykorzystaniem metod ilościowych. Na przykładach omówiono główne aspekty budowy systemu skoringowego: fazę projektowania systemu, fazę wdrażania wraz z etapem walidacji oraz fazę monitoringu jego stabilności.

Do oceny zdolności kredytowej banki stosują w praktyce rozbudowane specjalistyczne programy komputerowe, które wspomagają wykorzystanie metod skoringowych. Przykładem takich pakietów jest m.in. „Zestaw Skoringowy” firmy StatSoft. Są to jednak bardzo drogie pakiety, dla których alternatywą mogą być autorskie zestawy procedur analityczno-obliczeniowych, które mogą być uruchamiane jako podprogramy w środowisku obliczeniowym jednego z dostępnych na rynku pakietów statystycznych (np. programy R lub Statistica). Dlatego dodatkowym celem aplikacyjnym, a także edukacyjnym pracy było opracowanie autorskich programów (napisanych w języku Statistica Visual Basic), które mogą być wykorzystane w praktyce

stosowania modeli skoringowych oraz w nauczaniu podstaw stosowania skoringu kredytowego.

Opracowane procedury SVB obejmują następujące moduły:

- moduł realizujący wstępną analizę predyktorów wykorzystywanych w ocenie zdolności kredytowej (analiza rankingu predyktorów, przekodowywanie predyktorów ilościowych, analiza ich rozkładów, poszukiwanie reguł dla profili kredytobiorców);
- moduł realizujący oszacowanie modeli skoringowych oraz konstrukcję tablicy skoringowej (wykorzystujący modele: liniowej analizy dyskryminacyjnej, regresji logistycznej oraz opcjonalnie istnieje możliwość wykorzystania modeli sieci neuronowych oraz drzew klasyfikacyjnych);
- moduł wspomagający walidację oszacowanych modeli skoringowych (daje możliwość wyznaczania statystyk walidacyjnych i kalibracyjnych dla próby zarówno uczącej, jak i testowej, graficznej prezentacji krzywych ROC i wykresów statystycznych charakteryzujących rozkłady skoringu w populacji złych i dobrych kredytów);
- moduł wspomagający wdrożenie systemu skoringowego (umożliwiający wyznaczanie optymalnego punktu odcięcia kilkoma metodami analitycznymi oraz obliczanie statystyk efektywności poprawnych klasyfikacji zarówno dla próby uczącej jak i testowej);
- moduł wspomagający fazę monitoringu systemu skoringowego (monitoring stabilności rozkładu skoringu dla populacji bazowej i testowej, monitoring stabilności predyktorów, wykresy statystyczne stabilności).

Dostęp do danych kredytowych jest chroniony prawnie, dlatego nie było możliwości skorzystania z danych kredytowych pochodzących z polskich banków. W analizach wykorzystano dane kredytowe dla niemieckich kredytobiorców indywidualnych (tzw. *German credit data*¹), które są jednym z nielicznych (dostępnych w sposób jawny) zbiorów danych kredytowych. Dane te zostały udostępnione przez H. Hofmanna z Instytutu Statystyki i Ekonometrii Uniwersytetu w Hamburgu. Nie są bliżej znane źródło danych oraz okres, z jakiego pochodzą.

2. Projektowanie systemu skoringowego

Projektowanie systemu skoringowego jest jedną z najważniejszych i bardzo często najbardziej pracochłonną fazą budowy całego systemu skoringowego. Faza projektowania obejmuje następujące czynności (zob. [Matuszyk 2004]): zdefiniowanie dobrych i złych klientów, wybór populacji bazowej (próby uczącej), analizę danych kredytowych oraz wybór właściwych predyktorów i odpowiednich ich atrybutów (przekodowanie zmiennych, grupowanie atrybutów). Obejmuje również wybór właściwej metody estymacji modelu oraz przypisanie atrybutom predyktorów odpowiednich

¹ Źródło: <http://archive.ics.uci.edu/ml/machine-learning-databases/statlog/german/>.

ocen punktowych, konstrukcję tabeli skoringowej oraz cały etap walidacji modelu (ocena jakości oszacowanego modelu, analiza właściwości prognostycznych tabeli skoringowej).

W projektowaniu efektywnych systemów skoringowych należy pamiętać, że im większa będzie liczność tzw. populacji bazowej kredytów (na podstawie której szacuje się modele skoringowe), a także im większy będzie w tej populacji odsetek złych (niespłaconych) kredytów, tym bardziej stabilne będą oszacowane modele i lepiej będą one przewidywać ryzyko niedotrzymania zobowiązań spłaty kredytowej, dla nowych nieznanymi kredytów.

Jako potencjalne predyktory do modeli skoringowych dla klientów indywidualnych (zob. [Kraska 2004]) najczęściej stosuje się czynniki jakościowe i ilościowe charakteryzujące zarówno samych kredytobiorców (np. płeć, stan cywilny), jak i ich stan posiadania, historię spłaty poprzednich zobowiązań kredytowych oraz charakterystykę aktualnie posiadanych kredytów (zob. lista predyktorów zawartych w bazie danych kredytów niemieckich, które wykorzystano w pracy – tab. 1).

Przeprowadzając wstępną analizę czynników charakteryzujących kredytobiorców, należy liczbowe charakterystyki przekodować, wyznaczając nową skalę ich wartości zgodnie z wartościami tzw. wskaźnika *WoE* (*Weight of Evidence*) obliczanego zgodnie ze wzorem (zob. [Thomas 2009]):

$$WoE_i = \ln \left(\frac{n_i^{Good} / n_{Good}}{n_i^{Bad} / n_{Bad}} \right), \quad (1)$$

gdzie: n_i^{Good} – liczba kredytów dobrych dla i -tego atrybutu (przedziału zmienności) wartości predyktora,
 n_i^{Bad} – liczba kredytów złych dla i -tego atrybutu (przedziału zmienności) wartości predyktora,
 n_{Good} – liczba kredytów dobrych,
 n_{Bad} – liczba kredytów złych.

Wartości wskaźnika *WoE* są dobrym wskaźnikiem określającym profil ryzyka kredytobiorców charakteryzowanych wartościami danego predyktora. Duże dodatnie wartości tego wskaźnika świadczą o dużym udziale kredytów dobrych w stosunku do udziału kredytów złych, a więc o dużej zdolności tej kategorii kredytobiorców do spłaty swoich zobowiązań kredytowych. Duże ujemne wartości tego wskaźnika dla danej kategorii świadczą natomiast o dużym udziale kredytów złych w stosunku do dobrych, a więc o znacznej skłonności kredytobiorców do niespłacania swoich zobowiązań kredytowych (o wysokim ryzyku niespłacenia kredytu).

Do modeli skoringowych wybiera się potencjalne predyktory o jak najlepszych właściwościach prognostycznych (mające najlepszą zdolność do poprawnej separacji kredytów dobrych i złych). Do ustalenia rankingu predyktorów, które mają najwięk-

szą siłę prognostyczną w zakresie odróżniania kredytów dobrych i złych, stosuje się w praktyce następujące współczynniki: współczynnik wartości informacyjnej (*Information Value – IV*), współczynnik Giniego oraz współczynnik *V*-Cramera. Dwa pierwsze z racji mniejszej powszechności wykorzystania wymagają bliższej charakterystyki.

Współczynnik wartości informacyjnej predyktora *IV* wyrażony jest wzorem (zob. [Thomas 2009]):

$$IV = \sum_{i=1}^k \left(\frac{n_i^{Good}}{n_{Good}} - \frac{n_i^{Bad}}{n_{Bad}} \right) \cdot WoE_i, \quad (2)$$

gdzie: *k* – liczba atrybutów (przedziałów zmienności) predyktora.

Im większe wartości przybiera współczynnik *IV*, tym większa jest moc predykcyjna badanego predyktora (lub modelu skoringowego) w zakresie rozróżniania kredytów dobrych i złych. Przyjmuje się (zob. [Cioch, Karnowska 2010]), że wartości *IV* powyżej 0,3 wskazują na silną moc predykcyjną, natomiast wartości poniżej 0,02 na całkowity brak mocy predykcyjnej.

Współczynnik Giniego, oparty na współczynniku koncentracji Lorenza (dla krzywej ROC) i wyrażający stosunek odpowiednich pól na wykresie krzywej koncentracji ROC (rys. 1) określony jest wzorem (zob. [Thomas 2009]):

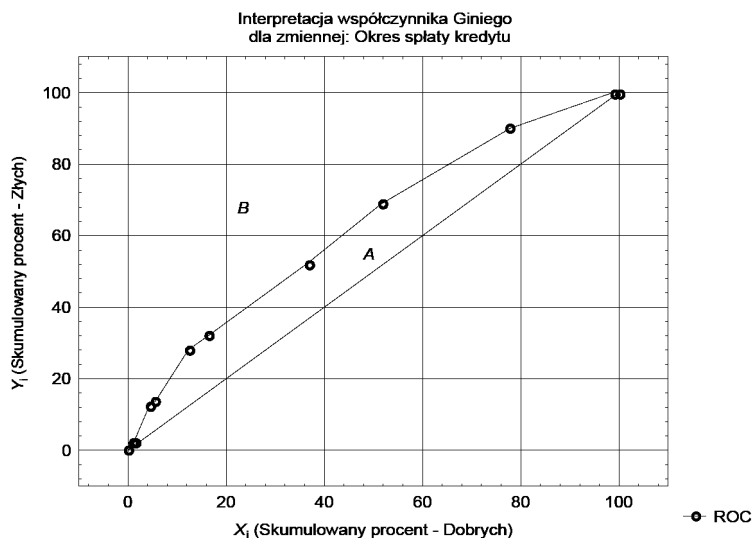
$$Gini = \frac{A}{A+B} = \frac{A}{0.5} = 2 \cdot A = 2 \cdot (0.5 - B) =$$

$$1 - 2 \cdot B = 1 - \sum_{i=1}^{k-1} (y_{i+1} - y_i) \cdot (x_{i+1} + x_i) \quad (3)$$

gdzie: $y_i = \sum_{j=1}^i \frac{n_j^{Bad}}{n_{Bad}}$ – skumulowany procent złych kredytów, dla *i*-tego atrybutu wartości zmiennej diagnostycznej lub *i*-tej kategorii zakresu jej zmienności,

$x_i = \sum_{j=1}^i \frac{n_j^{Good}}{n_{Good}}$ – skumulowany procent kredytów dobrych.

Pole obszaru *B* leżącego nad krzywą koncentracji ROC we wzorze (3) oblicza się jako sumę odpowiednich pól trapezów o wysokości $(y_{i+1} - y_i)$ i podstawach x_{i+1} oraz x_i . Podobnie jak w przypadku współczynnika *IV*, im wyższe są wartości współczynnika Giniego, tym większą zdolność poprawnego rozróżniania kredytów dobrych i złych ma analizowany predyktor (lub model skoringowy). Przyjmuje się, że wartości współczynnika Giniego poniżej 0,35 świadczą, że model zatracił zdolność klasyfikacyjną w zakresie rozróżniania kredytów dobrych i złych.



Rys. 1. Krzywa koncentracji ROC oraz interpretacja graficzna współczynnika Giniego równego 0,24 dla zmiennej: „okres spłaty kredytu”

Źródło: opracowanie własne z wykorzystaniem programu Statistica na podstawie danych kredytowych.

Tabela 1 przedstawia ranking wstępnie wytypowanych predyktorów, które zostaną wykorzystane do konstrukcji modelu skoringowego, uporządkowanych ze względu na wartości współczynnika IV . Analizując wartości wskaźników w tab. 1 można zauważyć, że predyktory od X_1 do X_{11} mają dostatecznie dobre zdolności klasyfikacyjne (co najmniej dwa wskaźniki przybierają wartości większe od 0,1 – średnia lub duża moc predykcyjna zmiennej), natomiast pozostałe predyktory mają niewielkie znaczenie dla modeli skoringowych, więc można ich w szacowanym modelu skoringowym nie brać w ogóle pod uwagę. Do dalszej analizy wybrano zatem tylko 11 predyktorów o dobrych własnościach klasyfikacyjnych.

Jako predyktory w modelach skoringowych można również stosować reguły, które określają pewne uwarunkowania, jakim podlegają kredytobiorcy, określają zatem pewien profil kredytobiorców. Jeżeli uda się wyznaczyć reguły mające dobre własności klasyfikujące kredytobiorców, to mogą one być zastosowane jako dodatkowe zmienne w modelu skoringowym. Można także próbować tworzyć modele skoringowe składające się tylko z predyktorów w postaci reguł.

Tabela 2 przedstawia 10 najlepszych reguł (o najlepszych własnościach prognostycznych) spośród 60 przebadanych, które udało się określić na podstawie wstępnie wytypowanych zmiennych opisujących profil kredytobiorców. Reguły utworzono, wykorzystując narzędzie drzew klasyfikacyjnych CHAID dostępne w pakiecie Statistica. Współczynniki jakości predykcyjnej dla wyznaczonych reguł są dość duże i przybierają wartości od 0,3 do 0,7.

Tabela 1. Ranking predyktorów pod względem mocy predykcyjnej w poprawnym rozróżnianiu dobrych i złych kredytów, uporządkowanych w zależności od wartości współczynnika wartości informacyjnej IV

Predyktor (cecha)	Wskaźnik mocy predykcyjnej			Predyktor (cecha)	Wskaźnik mocy predykcyjnej		
	IV	V -Cramera	Giniego		IV	V -Cramera	Giniego
(X_1) Stan Konta (jakościowa)	0,66	0,35	0,41	(X_{11}) Stan cywilny oraz płeć (jakościowa)	0,06	0,11	0,12
(X_2) Historia kredytowa (jakościowa)	0,33	0,26	0,26	(X_{12}) Inne kredyty (jakościowa)	0,06	0,11	0,09
(X_3) Oszczędności (jakościowa)	0,24	0,21	0,21	(X_{13}) Praca za granicą (jakościowa)	0,04	0,08	0,03
(X_4) Okres spłaty (liczbowa)	0,23	0,22	0,23	(X_{14}) Inni dłużnicy poręczyciele (jakościowa)	0,03	0,08	0,01
(X_5) Cel kredytu (jakościowa)	0,21	0,2	0,04	(X_{15}) Liczba kredytów w banku (liczbowa)	0,02	0,06	0,06
(X_6) Kwota kredytu (liczbowa)	0,14	0,18	0,11	(X_{16}) Na jakim stanowisku zatrudnienie (jakościowa)	0,02	0,06	0,04
(X_7) Wiek (liczbowa)	0,13	0,16	0,15	(X_{17}) Rata kredytu jako % dochodów (liczbowa)	0,01	0,05	0,06
(X_8) Posiadana własność (jakościowa)	0,12	0,16	0,18	(X_{18}) Posiadanie telefonu (jakościowa)	0,01	0,04	0,04
(X_9) Zatrudnienie (jakościowa)	0,11	0,15	0,15	(X_{19}) Zamieszkanie (liczbowa)	0,01	0,03	0
(X_{10}) Mieszkanie (jakościowa)	0,11	0,15	0,04	(X_{20}) Liczba osób zapewniających utrzymanie (liczbowa)	0	0	0

Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.

Tabela 2. Dziesięć reguł o najlepszych własnościach prognostycznych wyznaczone z zastosowaniem metody drzew klasyfikacyjnych CHAID

Reguła nr	Treść reguły	Współczynnik		
		IV	V-Cramera	Giniego
2	(Kwota<=7839,5) AND (Stan Konta='brak')	0,63	0,31	0,35
4	(Okres spłaty>16) AND (Stan Konta<> ,>=200' AND Stan Konta<>'brak')	0,48	0,31	0,33
6	(Oszczędności<> ,[500-1000]' AND Oszczędności <> ,>=1000' AND Oszczędności <> ,brak') AND (Stan Konta<> ,brak')	0,63	0,33	0,38
8	(Oszczędności <> ,>=1000' AND Oszczędności <> ,brak' AND Oszczędności <> ,[500-1000]') AND (Stan Konta <> ,brak' AND Stan Konta<> ,>=200')	0,68	0,35	0,4
19	(Zatrudnienie= ,powyżej 7 lat' OR Zatrudnienie= ,(4-7] lat' OR Zatrudnienie= ,(1-4] lat') AND (Stan Konta= ,brak' OR Stan Konta= ,>=200')	0,64	0,32	0,35
28	(Historia kredytowa= ,inne kredyty' OR ,Historia kredytowa= ,inne spłacane w terminie' OR Historia kredytowa= ,opóźnienia w spłacie') AND (Stan Konta= ,brak' OR Stan Konta= ,>=200')	0,64	0,33	0,38
29	(Historia kredytowa= ,inne kredyty' OR Historia kredytowa= ,inne spłacane w terminie') AND (Stan Konta= ,brak')	0,62	0,31	0,34
41	(Stan Konta= ,brak' OR Stan Konta= ,>=200) AND (Cel= ,wydatki domowe' OR ,Cel= ,podnoszenie kwalifikacji' OR Cel= ,inne' OR Cel= ,meble - sprzęt' OR Cel= ,samochód - używany' OR Cel= ,edukacja' OR Cel= ,radio - telewizja' OR Cel= ,samochód - nowy')	0,7	0,34	0,38
42	(Stan Konta= ,brak' OR Stan Konta= ,>=200')	0,62	0,33	0,37
58	(Okres spłaty<=33) AND (Stan Konta='brak')	0,58	0,3	0,33

Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.

Tabela 3 przedstawia przykładowy profil ryzyka kredytobiorców charakteryzowanych regułą nr 4. Są to kredytobiorcy, którzy pobrali kredyty z okresem spłaty powyżej 16 miesięcy oraz posiadają debet na koncie lub niewielki wkład (do 200 DM). Profil takich kredytobiorców określa kredytobiorców charakteryzujących się dużą skłonnością do niespłacania zaciągniętych zobowiązań kredytowych (duże ujemne wartości współczynnika *WoE*). W populacji kredytów złych (niespłaconych) stanowili oni ponad połowę wszystkich kredytobiorców (55%), a w populacji kredytów spłaconych jedynie 22%.

Ostatecznie jako zmienne wejściowe do budowanych modeli skoringowych wybrano 11 czynników o najlepszych własnościach klasyfikacyjnych oraz 10 najlepszych reguł (zob. tab. 1 i 2).

Tabela 3. Profil ryzyka kredytobiorców charakteryzowanych regułą 4

Reguła 4	Dobry	Zły	Ogół	% Zły/Ogół	% Zły	% Dobry	% Ogół	<i>IV</i>	<i>WoE</i>
1 – Tak	133	143	276	51,81	55	22,13	32,06	0,30	-91,04
0 – Nie	468	117	585	20,00	45	77,87	67,94	0,18	54,84
Ogół	601	260	861	30,20	100	100	100	0,48	

Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.

Do oszacowania prawdopodobieństwa zdolności spłaty kredytowej $p_{Good} = P(Y=1)$ można zastosować różnorakie metody statystyczne i podejścia niestatystyczne. Najczęściej wykorzystywanymi metodami są: wielowymiarowa analiza dyskryminacyjna, regresja logistyczna, sieci neuronowe oraz drzewa klasyfikacyjne (zob. np. [Thomas i in. 2002; Matuszyk 2004]). W pracy wykorzystano uogólniony model regresji logistycznej. Zastosowano także metodę krokową wsteczną dla poszukiwania oszacowań parametrów modelu (w celu oszacowania tylko istotnych statystycznie parametrów). Tabela 4 przedstawia uzyskane oszacowania parametrów dla przykładowego modelu skoringowego, dla którego istotnych jest tylko 7 wybranych predyktorów oraz jedna reguła (reguła nr 8).

Tabela 4. Oszacowania istotnych parametrów modelu skoringowego z 11 predyktorami i 10 regułami

Predyktor	Ocena	Błąd standardowy	Statystyka Walda	<i>p</i> -value
Wyraz wolny	0,847084	0,089579	89,42	0,000000
Posiadana własność	0,008143	0,002635	9,55	0,002001
Zatrudnienie	0,008321	0,002696	9,53	0,002026
Wiek	0,009439	0,002527	13,95	0,000187
Cel kredytu	0,010199	0,001973	26,72	0,000000
Historia kredytowa	0,007255	0,001558	21,68	0,000003
Okres spłaty	0,009177	0,001992	21,23	0,000004
Stan konta	0,003622	0,001595	5,15	0,023183
Reguła nr 8	0,006540	0,001441	20,59	0,000006

Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.

Ocenę punktową (tzw. skoring) dla poszczególnych kredytobiorców wyznacza się, stosując przeskalowanie liniowe, które wyraża liniową zależność między skoringiem a tzw. ilorazem szans *Odds*, będącym stosunkiem prawdopodobieństwa spłacenia do niespłacenia kredytu (zob. [Siddiqi 2006; Thomas i in. 2002]):

$$Score = a_0 + a_1 \cdot \ln(Odds) = a_0 + a_1 \cdot \ln\left(\frac{P_{Good}}{1 - P_{Good}}\right). \quad (4)$$

W celu ustalenia punktacji skoringowej wprowadza się również parametr *pdo*, określający, co ile punktów skoringowych następuje podwojenie szansy spłacenia kredytu. Wyraża to zależność (zob. [Siddiqi 2006]):

$$Score + pdo = a_0 + a_1 \cdot \ln(2 \cdot Odds). \quad (5)$$

Rozwiązując układ równań (4) i (5), otrzymuje się wzory na oszacowania parametrów a_0 oraz a_1 :

$$\begin{cases} a_1 = \frac{pdo}{\ln(2)} \\ a_0 = Score - a_1 \cdot \ln(Odds) \end{cases}. \quad (6)$$

Jeżeli założymy, że przy punktacji *Score* = 600 punktów istnieje szansa jak 50:1 (*Odds* = 50) na spłacenie kredytu oraz że co *pdo* = 20 punktów szansa ta ulega podwojeniu, to otrzymamy oszacowania dla parametrów: $a_0 = 487,12$ i $a_1 = 28,85$.

Dla modelu logitowego zachodzi relacja: $\ln\left(\frac{P_{Good}}{1 - P_{Good}}\right) = \beta_0 + \sum_{i=1}^n \beta_i X_i$, gdzie β_i są oszacowaniami parametrów modelu logitowego, to z zależności (4) po przekształceniach otrzymuje się wzór, wyrażający łączną ocenę punktową kredytobiorcy jako sumę ocen punktowych dla poszczególnych atrybutów każdego predyktora postaci:

$$Score = \sum_{i=1}^n \left(\frac{a_0 + a_1 \beta_0}{n} + a_1 \beta_i X_i \right) = \sum_{i=1}^n (Score_i). \quad (7)$$

Tabela 5 przedstawia przykładową tablicę skoringową dla poszczególnych wartości atrybutów predyktorów modelu skoringowego oszacowanego z wykorzystaniem modelu regresji logistycznej i autorskich procedur SVB.

Ostatnim etapem fazy projektowania modelu skoringowego jest etap walidacji oszacowanego modelu. Etap walidacji polega na zbadaniu za pomocą odpowiednich miar i statystyk zdolności oszacowanego modelu skoringowego do odróżniania kredytów dobrych i złych. Miary te wskazują, na ile odległe są od siebie rozkłady warunkowe dla wyników punktacji modelu w populacji kredytów dobrych i złych. Im bardziej te rozkłady są od siebie oddalone, tym większe wartości współczynników

walidacyjnych i tym większy potencjał prognostyczny oszacowanego modelu skoringowego (model jest lepszy do zastosowań praktycznych w zakresie klasyfikacji kredytobiorców pod względem ryzyka spłaty kredytowej).

W etapie walidacji modelu skoringowego wykorzystuje się głównie następujące statystyki opisujące jego zdolności prognostyczne: współczynnik *Information Value (IV)* i współczynnik Giniego (omówione wcześniej), a także statystykę Kołmogorowa-Smirnowa (*KS statistics*), dywergencję oraz statystykę Hosmera-Lemeshow (*HL statistics*). Graficzną metodą badania mocy predykcyjnej modelu skoringowego (zob. [Löffler, Posch 2007]) jest krzywa *ROC (Receiver Operating Characteristics)* oraz pole pod tą krzywą – *AUROC (Area Under ROC)* obliczane ze wzoru: $0,5(Gini + 1)$. Im bliższe 1 wartości dla pola pod krzywą *ROC*, tym lepsza jest zdolność prognostyczna ocenianego modelu.

Tabela 5. Przykładowa tablica skoringowa dla predyktorów modelu skoringowego oszacowanego z wykorzystaniem uogólnionej regresji logistycznej

Predyktor	Atrybuty (zakres wartości) predyktora	WoE	Parametr regresji	Punktacja skoring zaokrąglony
1	2	3	4	5
Wiek	(-inf;25]	-56,878	0,00944	48
Wiek	(25;33]	-9,65	0,00944	61
Wiek	(33;38]	56,673	0,00944	79
Wiek	(38;47]	13,065	0,00944	68
Wiek	(47;inf)	30,031	0,00944	72
Zatrudnienie	bezrobotny	-50,843	0,00832	52
Zatrudnienie	do 1 roku	-50,843	0,00832	52
Zatrudnienie	(1-4] lat	1,43	0,00832	64
Zatrudnienie	(4-7] lat	43,626	0,00832	74
Zatrudnienie	powyżej 7 lat	20,759	0,00832	69
Posiadana własność	nieruchomość	47,201	0,00814	75
Posiadana własność	mieszkanie ubezpieczenie na życie	0,704	0,00814	64
Posiadana własność	samochód inna własność	-3,596	0,00814	63
Posiadana własność	brak	-61,805	0,00814	49
Cel kredytu	meble/sprzęt	-8,65	0,0102	61
Cel kredytu	radio/telewizja	55,369	0,0102	80
Cel kredytu	wydatki domowe	-47,245	0,0102	50
Cel kredytu	remont/naprawy	-47,245	0,0102	50
Cel kredytu	edukacja	-47,245	0,0102	50

Tabela 5, cd.

1	2	3	4	5
Cel kredytu	samochód — używany	74,771	0,0102	86
Cel kredytu	podnoszenie kwalifikacji	74,771	0,0102	86
Cel kredytu	samochód — nowy	-39,736	0,0102	52
Cel kredytu	biznes	-39,736	0,0102	52
Cel kredytu	inne	-47,245	0,0102	50
Historia kredytowa	brak kredytów	-126,87	0,00726	37
Historia kredytowa	splacane w terminie	-138,796	0,00726	35
Historia kredytowa	inne splacane w terminie	-8,131	0,00726	62
Historia kredytowa	opóźnienia w spłacie	-18,399	0,00726	60
Historia kredytowa	inne kredyty	76,686	0,00726	80
Okres spłaty	(-inf;15]	45,338	0,00918	76
Okres spłaty	(15;24]	-7,22	0,00918	62
Okres spłaty	(24;30]	7,838	0,00918	66
Okres spłaty	(30;inf)	-81,088	0,00918	42
Stan konta	debet	-78,618	0,00362	56
Stan konta	brak	114,473	0,00362	76
Stan konta	[0-200)	-31,572	0,00362	61
Stan konta	[200,+inf)	-31,572	0,00362	61
Reguła nr 8	0 – Nie	84,001	0,00654	80
Reguła nr 8	1 – Tak	-85,463	0,00654	48

Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.

Statystyka Kołmogorowa-Smirnowa określa maksymalną odległość pomiędzy dystrybucjami badanych rozkładów warunkowych dla kredytów dobrych i złych i wyznaczana jest ze wzoru (zob. Thomas 2009]):

$$KS = \max_{s \in \text{Score}} |F(s | B) - F(s | G)|. \quad (8)$$

Dywergencja również wyraża miarę odległości pomiędzy tymi rozkładami warunkowymi dla wyników punktacji skoringowej i opisana jest wzorem (zob. [Thomas 2009]):

$$D = \frac{1}{2} \left(\frac{1}{\sigma_G^2} + \frac{1}{\sigma_B^2} \right) (\mu_G - \mu_B)^2 + \frac{(\sigma_G^2 - \sigma_B^2)^2}{2\sigma_G^2 \sigma_B^2}, \quad (9)$$

gdzie: $\mu_G = \sum_{s \in \text{Score}} s \cdot f(s | G)$ – średni skoring w populacji kredytów dobrych,

$$\mu_B = \sum_{s \in \text{Score}} s \cdot f(s | B) - \text{średni skoring w populacji złych kredytów,}$$

$$\sigma_G^2 = \sum_{s \in \text{Score}} (s - \mu_G)^2 \cdot f(s | G), \quad \sigma_B^2 = \sum_{s \in \text{Score}} (s - \mu_B)^2 \cdot f(s | B) - \text{wariancja}$$

skoringu odpowiednio dla kredytów dobrych i złych,

$f(s | G), f(s | B)$ – odsetek kredytów dobrych i złych w danej kategorii skoringowej.

Przyjmuje się (zob. [Cioch, Karnowska 2010]), że dywergencja powinna przybierać wartości większe od 0,5, aby badane rozkłady dla kredytów złych i dobrych leżały dostatecznie daleko od siebie i aby oszacowany model skoringowy miał akceptowalną zdolność do poprawnej separacji kredytobiorców.

Statystyka Hosmera-Lemeshow oparta jest natomiast na statystyce chi-kwadrat i obliczana jest ze wzoru (zob. [Thomas 2009]):

$$HL = \sum_{i=1}^N \frac{(n_i p_i - g_i)^2}{n_i p_i (1 - p_i)}, \quad (10)$$

gdzie: p_i – średnie prawdopodobieństwo spłaty kredytu (kredyt dobry) w danej i -tej kategorii ratingowej skoringu,
 g_i – liczba kredytów dobrych w danej kategorii ratingowej skoringu,
 N – liczba przyjętych kategorii ratingowych, na które podzielono zakres punktacji skoringowej.

Tabela 6 przedstawia statystyki walidacyjne dla 4 wariantów oszacowanych modeli skoringowych dla populacji bazowej (próby uczącej) oraz populacji testowej. W dwóch pierwszych wariantach zastosowano tylko 11 wybranych predyktorów, natomiast w kolejnych dwóch dodano dodatkowo 10 opracowanych reguł. Zastosowano również dwa warianty skali dla atrybutów wartości predyktorów. W pierwszym wariantcie tylko predyktory ilościowe przekodowano do skali *WoE*, zaś pozostałe predyktory były traktowane jako zmienne jakościowe. W drugim wariantcie przyjęto skalę *WoE* dla wszystkich predyktorów zarówno jakościowych jak i liczbowych. Można zauważyć wysokie wartości statystyk walidacyjnych dla oszacowanych modeli zarówno dla próby uczącej jak i testowej. Wartość wskaźnika wartości informacyjnej dla wszystkich 4 badanych modeli w przypadku próby uczącej przyjmuje wartości w zakresie od 0,54 do 0,73, dla próby testowej zaś w zakresie od 0,2 do 0,4. Wskazuje to na dużą moc predykcyjną modeli, nawet w przypadku zastosowania próby testowej dla nieznanymi kredytobiorców. Potwierdzają to również wysokie wartości pozostałych statystyk walidacyjnych: statystyki Kołmogorowa-Smirnowa, wskaźnika Giniego oraz dywergencji. Wartości pól pod krzywą *ROC* dla wszystkich modeli dla próby uczącej wynoszą 0,82, co świadczy również o tym, że modele mają

dobrze własności klasyfikacyjne. Dla próby testowej można zauważyć spadek jakości klasyfikacyjnej badanych modeli, ale i tak większość z nich zachowuje swoje właściwości prognostyczne na średnim poziomie.

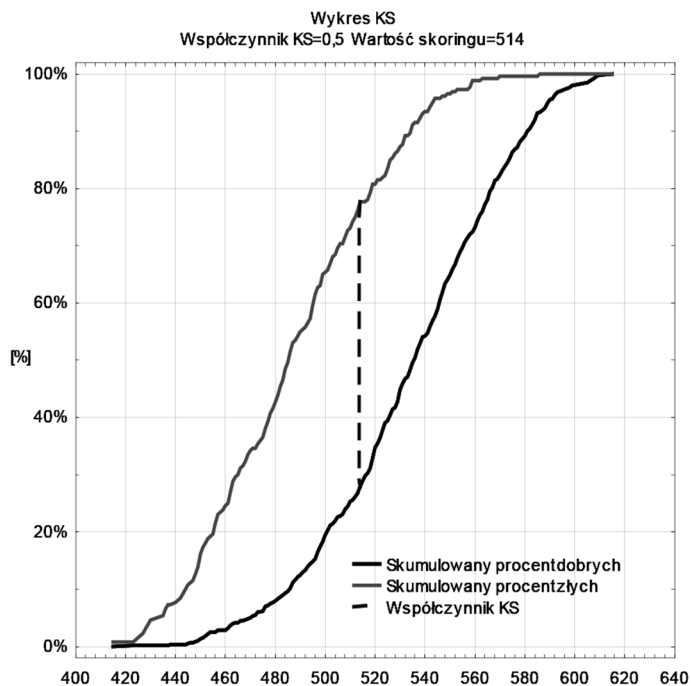
Tabela 6. Statystyki walidacyjne dla oszacowanych modeli skoringowych

Model skoringowy (liczba predyktorów, skalowanie wartości)	Statystyki walidacyjne modeli					
	<i>IV</i>	<i>KS</i>	Giniego	Dywergencja	<i>HL</i>	<i>AUROC</i>
11 wybranych predyktorów (liczbowe – skala <i>WoE</i> , jakościowe – skala jakościowa)	próba ucząca					
	0,59	0,51	0,64	1,71	5,19	0,82
	próba testowa					
	0,38	0,37	0,44	0,66	28,67	0,72
11 wybranych predyktorów (skala <i>WoE</i> dla wszystkich predyktorów)	próba ucząca					
	0,73	0,50	0,63	1,68	6,58	0,82
	próba testowa					
	0,40	0,39	0,46	0,68	20,06	0,73
11 wybranych predyktorów i 10 reguł (liczbowe – skala <i>WoE</i> , jakościowe – skala jakościowa)	próba ucząca					
	0,54	0,49	0,65	1,81	3,26	0,82
	próba testowa					
	0,27	0,28	0,31	0,32	24,79	0,66
11 wybranych predyktorów i 10 reguł (skala <i>WoE</i> dla wszystkich predyktorów)	próba ucząca					
	0,70	0,50	0,64	1,75	5,71	0,82
	próba testowa					
	0,20	0,33	0,43	0,60	6,25	0,72

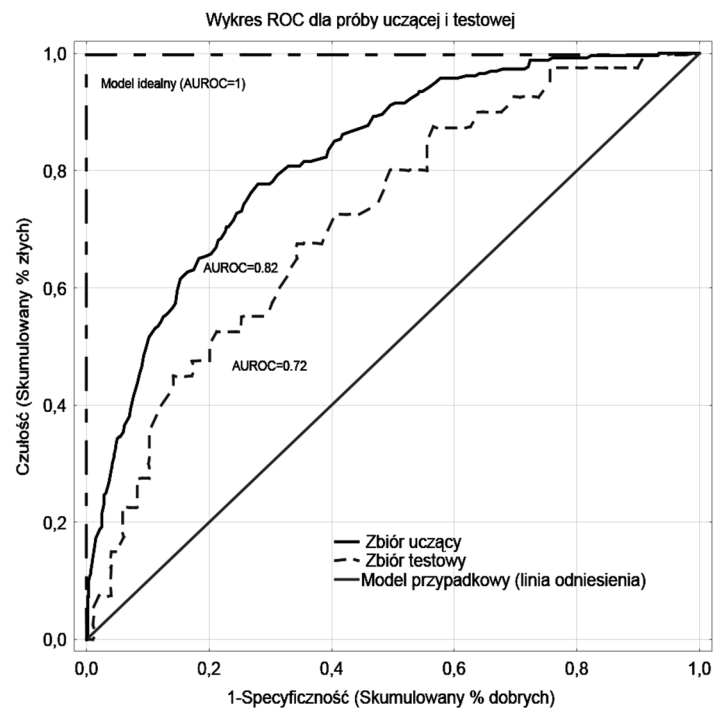
Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.

Rysunek 2a przedstawia skumulowane rozkłady warunkowe dla *skoringu* w populacji kredytów dobrych i złych dla modelu skoringowego nr 2 (zob. tab. 6) oraz próby uczącej, które ilustrują maksymalną odległość pomiędzy rozkładami równą 0,5 dla punktacji 514. Rysunek 2b natomiast przedstawia wykresy krzywych *ROC* dla tego modelu w populacji uczącej (bazowej) oraz testowej w porównaniu do modelu idealnego i przypadkowego. Na rysunku 3 zilustrowano położenie rozkładów warunkowych dla *skoringu* w populacji dobrych i złych kredytów dla tego samego modelu w przypadku próby uczącej. Wyraźnie widać dobrą zdolność separacji obu tych rozkładów przez model, a tym samym dużą zdolność klasyfikacyjną modelu wyrażoną dużą wartością dywergencji 1,68.

a

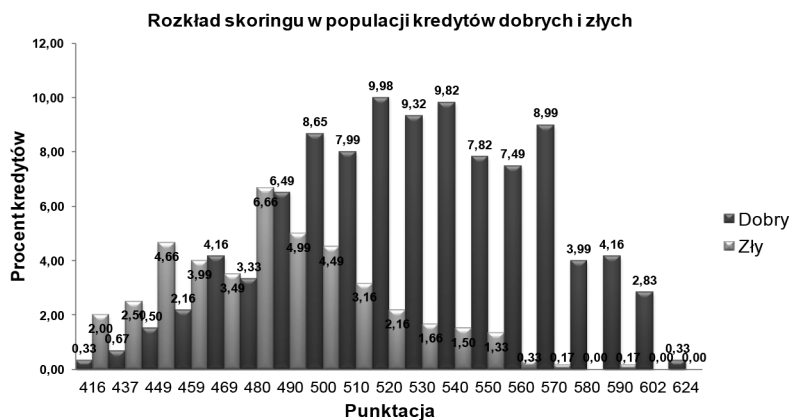


b



Rys. 2. Graficzna interpretacja statystyki $KS = 0,5$ dla modelu skoringowego nr 2 w populacji bazowej (a), wykresy krzywej ROC dla analizowanego modelu dla próby uczącej oraz testowej (b)

Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.



Rys. 3. Wykresy rozkładów warunkowych dla skoringu w populacji dobrych i złych kredytobiorców dla oszacowanego modelu skoringowego nr 2 charakteryzowanego wartością dywergencji 1,68

Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.

3. Wdrożenie systemu skoringowego

Faza wdrożeniowa oszacowanego i poddanego walidacji systemu skoringowego składa się z kilku etapów. Pierwszym etapem jest ustalenie punktu odcięcia tzw. punktu *cut-off*. Punkt ten określa wartość punktacji skoringowej, poniżej której kredytobiorcę uznaje się za niezdolnego do spłaty kredytu (kredytobiorca – zły). Czasami wyznacza się nie jeden, a dwa punkty odcięcia, dzielące kredytobiorców na 3 kategorie: złych – którym bank odmawia udzielenia kredytu, dobrych – którym przydziela się kredyt od razu, i kategorię kredytobiorców tzw. wątpliwych, dla których należy przeprowadzić dodatkowe badania ich wiarygodności przed podjęciem odpowiedniej decyzji. Kolejnym etapem jest przeprowadzenie treningu systemu skoringowego na próbie uczącej i testowej mającego na celu sprawdzenie, jak będzie poprawnie klasyfikował model kredytobiorców przy ustalonych punktach odcięcia. Jeżeli efektywność poprawnych klasyfikacji kredytobiorców jest zadowalająca, to model skoringowy można wdrożyć w praktyce.

Do badania efektywności klasyfikacji modeli skoringowych wykorzystuje się macierze poprawnych i błędnych klasyfikacji (zob. tab. 7). Liczba *TP* (*True Positive*) w tabeli oznacza liczbę poprawnie zakwalifikowanych przez model dobrych kredytobiorców. Podobnie liczba *TN* (*True Negative*) oznacza liczbę poprawnie zakwalifikowanych przez model złych kredytobiorców. Jeżeli dobrych kredytobiorców model zakwalifikuje jako złych, to taki błąd klasyfikacyjny nazywa się błędem I rodzaju, a *FP* (*False Positive*) oznacza liczbę tych błędnych klasyfikacji. Znacznie bardziej niekorzystny z punktu widzenia banku (ryzyko straty pożyczonych ak-

tywów) jest błąd klasyfikacyjny II rodzaju, który popełnia się, gdy model zakwalifikuje złych kredytobiorców jako dobrych, a *FN* oznacza liczbę takich błędnych klasyfikacji.

Tabela 7. Macierz poprawnych klasyfikacji modelu skoringowego

Rzeczywista przynależność kredytobiorcy	Prognozowana przynależność kredytobiorcy	
	Dobry	Zły
Dobry (spłaci kredyt)	<i>TP (True Positive)</i>	<i>FP (False Positive)</i> Błąd I rodzaju
Zły (nie spłaci kredytu)	<i>FN (False Negative)</i> Błąd II rodzaju	<i>TN (True Negative)</i>

Źródło: opracowanie własne.

Błąd I rodzaju, czyli odsetek błędnie zakwalifikowanych kredytów dobrych (oznaczany często również jako: 1-specyficzność), wyraża wzór:

$$Err_1 = \frac{FP}{FP + TP} = 1 - \frac{TP}{FP + TP} = 1 - Eff_1, \quad (11)$$

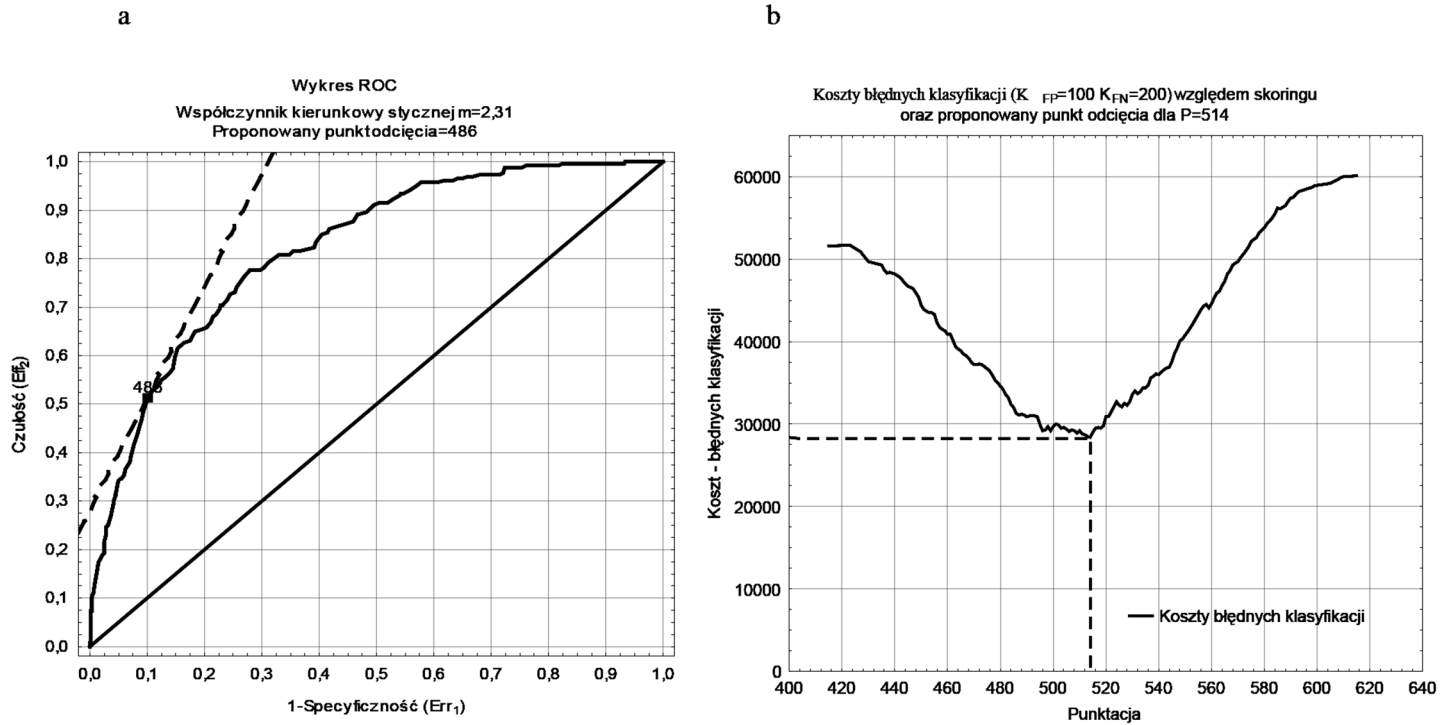
gdzie: Eff_1 (efektywność I rodzaju lub tzw. specyficzność) to odsetek poprawnie zakwalifikowanych kredytów dobrych.

Błąd II rodzaju, czyli odsetek błędnie zakwalifikowanych kredytów złych (oznaczany często również jako: 1-czułość), wyraża wzór:

$$Err_2 = \frac{FN}{FN + TN} = 1 - \frac{TN}{FN + TN} = 1 - Eff_2 \quad (12)$$

gdzie: Eff_2 (efektywność II rodzaju lub tzw. czułość) to odsetek poprawnie zakwalifikowanych kredytów złych.

Istotnym problemem jest ustalenie tzw. optymalnego punktu odcięcia, który dzieli kredytobiorców na dwie klasy: dobrych o niskim ryzyku niespłacenia kredytu oraz złych o wysokim ryzyku. Przyjęcie zbyt niskiego skoringu jako granicznego punktu odcięcia (*cut-off*) powoduje z jednej strony wysoki wskaźnik tzw. poziomu akceptacji (ogólnego odsetka kredytów przyznanych). Z drugiej jednak strony przyczynia się do tego, że możemy mieć do czynienia z bardzo niską efektywnością II rodzaju, czyli niskim poziomem poprawnego rozpoznawania złych kredytobiorców. Wysoki będzie również wtedy poziom tzw. złych przypadków, czyli udziału złych kredytów w danej klasie (co jest niekorzystne zwłaszcza dla klasy dobrych kredytobiorców). Przyjęcie asekuracyjnie dużej wartości skoringu jako punktu odcięcia powoduje, że zwiększa się efektywność II rodzaju (co jest korzystne, gdyż rośnie liczba poprawnie zakwalifikowanych złych kredytów), ale tym samym maleje efektywność I rodzaju oraz maleje poziom akceptacji (strata klientów dla banku).



Rys. 4. Optymalny punkt odcięcia $cut-off = 486$ dla zadania optymalizacyjnego postaci (13) i jednakowych kosztów błędnych klasyfikacji (a); optymalny punkt odcięcia $cut-off = 514$ dla zadania optymalizacyjnego postaci (14) i kosztów błędnych klasyfikacji dla kredytów złych $K_{FN} = 200$ oraz dobrych $K_{FP} = 100$ (b)

Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.

Istnieje kilka sposobów wyznaczania optymalnego punktu odcięcia. Pierwsza metoda polega na znalezieniu takiej wartości skoringu (*cut-off score*), dla którego spełnione jest zadanie optymalizacyjne (zob. [Zweig, Campbell 1993]):

$$Eff_2(score) - m \cdot Err_1(score) \rightarrow \max, \quad (13)$$

gdzie: $m = \frac{k_{FP}}{k_{FN}} \cdot \frac{1-p}{p}$, k_{FP} – koszty błędnych klasyfikacji kredytobiorców dobrych (popelnienia błędu I rodzaju),
 k_{FN} – koszty błędnych klasyfikacji kredytobiorców złych (popelnienia błędu II rodzaju),
 p – prawdopodobieństwo przynależności do klasy: złej.

W interpretacji geometrycznej współczynnik m jest współczynnikiem kierunkowym stycznej do krzywej *ROC* (zob. rys. 4a) w wyznaczonym optymalnym punkcie odcięcia ($Eff_2(score_{cut-off}), Err_1(score_{cut-off})$).

Rysunek 4a przedstawia wyznaczony optymalny punkt odcięcia (równy 486 punktów) dla modelu skoringowego z 11 predyktorami i 10 wybranymi regułami (skala *WoE* dla wszystkich zmiennych), przy założeniu równych kosztów błędnych klasyfikacji $koszt_{FP} = koszt_{FN}$ oraz prawdopodobieństwie niespłacenia kredytu $p = 0,302$.

Druga metoda polega na wybraniu takiego skoringu jako punktu odcięcia, który minimalizuje koszty błędnych klasyfikacji. Należy zatem rozwiązać zadanie optymalizacyjne postaci:

$$K(score) = k_{FP} \cdot FP(score) + k_{FN} \cdot FN(score) \rightarrow \min. \quad (14)$$

Rysunek 4b ilustruje dla tego samego modelu skoringowego optymalny punkt odcięcia równy 514 dla kosztów błędnych klasyfikacji $koszt_{FP} = 100$ i $koszt_{FN} = 200$.

Tabela 8 ilustruje efektywność klasyfikacyjną modelu skoringowego nr 2 dla różnych przyjętych punktów odcięcia. Wyraźnie widać, jak punkt odcięcia wpływa na poziom wniosków zaakceptowanych, poziom złych przypadków czy też na efektywność rozróżniania kredytobiorców spłacających i niespłacających kredyty. Na przykład w sytuacji zastosowania punktu odcięcia na poziomie punktacji 514 efektywność poprawnych klasyfikacji dla złych kredytów wynosi w przypadku próby testowej 60%, dla dobrych kredytów zaś nawet 69%. Poziom akceptacji (zaakceptowanych do przyznania kredytów) wynosi ponad 60%, zaś udział złych kredytów w klasie kredytów przyznanych (prognozowanych jako dobre) wynosi prawie 20%.

Tabela 8. Macierz poprawnych klasyfikacji dla próby uczącej i testowej w przypadku zastosowania modelu skoringowego nr 2 i różnych wariantów punktu odcięcia

Ocena kredytu	Kredyt		Liczba ogół	Portfel udział złych kredytów w danej klasie [%]	%		% Ogół
	Dobry	Zły			Zły	Dobry	
Populacja bazowa – próba ucząca ($N = 861$)							
Zły (-inf,486]	61	TP 134	195	68,72	51,54	10,15	22,65
Dobry (486,+inf)	540	FN 126	666	18,92	48,46	89,85	77,35
Zły (-inf,514]	168	TP 202	370	54,59	77,69	27,95	42,97
Dobry (514,+inf)	433	FN 58	491	11,81	22,31	72,05	57,03
Zły (-inf,511]	154	TP 193	347	55,62	74,23	25,62	40,3
Dobry (511,+inf)	447	FN 67	514	13,04	25,77	74,38	59,7
Próba testowa ($N = 139$)							
Zły (-inf,486]	14	18	32	56,25	45,0	14,14	23,02
Dobry (486,+inf)	85	22	107	20,56	55,0	85,86	76,98
Zły (-inf,514]	31	24	55	43,64	Eff_2 60,0	31,31	39,57
Dobry (514,+inf)	68	16	84	Poziom złych przypadków 19,05	40,0	Eff_1 68,69	Poziom akceptacji 60,43
Zły (-inf,511]	30	23	53	43,4	57,5	30,3	38,13
Dobry (511,+inf)	69	17	86	19,77	42,5	69,7	61,87

Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.

4. Monitoring modelu skoringowego

Ostatnią fazą praktycznego zastosowania modeli skoringowych w procesie zarządzania ryzykiem kredytowym w banku jest faza monitorowania wdrażanego modelu. W niektórych krajach, np. w Stanach Zjednoczonych, jest to wymóg prawny. W Polsce również KNF nakazuje bankom przeprowadzanie okresowej kontroli i monitoringu wdrażanych systemów skoringowych. Głównym zadaniem monitoringu modeli skoringowych jest sprawdzenie, czy model nie wymaga korekty. Model

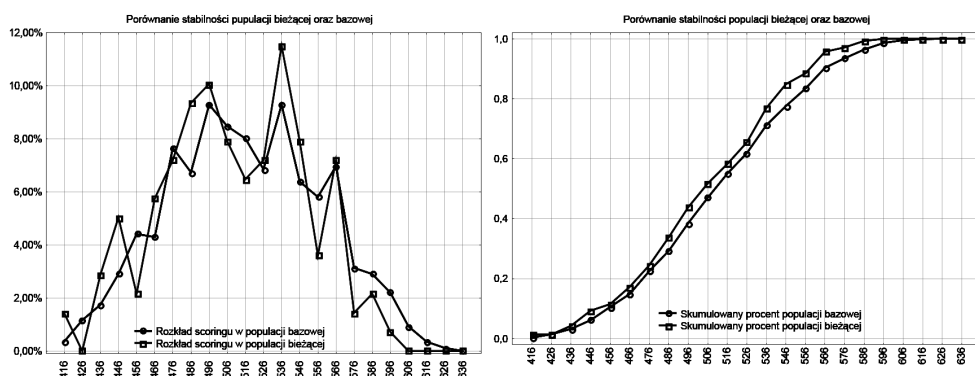
będzie wymagał korekty, gdy populacja nowych wnioskodawców zaczyna się szybko zmieniać i będzie znacznie odbiegać od populacji bazowej, na podstawie której projektowano i wdrażano model. Jednym z ważniejszych etapów w zakresie monitoringu modeli skoringowych jest badanie stabilności populacji oraz analiza zmian struktury dla cech charakteryzujących kredytobiorców, które zastosowano w modelu jako predyktory.

Do badania stabilności modelu skoringowego w populacji bazowej wykorzystuje się wskaźnik stabilności populacji określony zależnością (zob. [Cioch, Karnowska 2010]):

$$W_{SP} = \sum_{i=1}^n (\%T_i - \%U_i) \cdot \ln \left(\frac{\%T_i}{\%U_i} \right), \quad (15)$$

gdzie: n – liczba kategorii ratingowych (zakresu zmienności) punktacji,
 $\%T$ – udział procentowy punktacji w populacji bieżącej (testowej),
 $\%U$ – udział procentowy punktacji w populacji bazowej (uczącej).

Przyjmuje się (zob. [Cioch, Karnowska 2010]), że gdy $W_{SP} \leq 0,1$, to populacja testowa zachowuje się podobnie jak populacja bazowa (rozkłady skoringu w obu populacjach nie różnią się istotnie). Jeżeli $0,1 < W_{SP} < 0,25$, to populacja aktualnych kredytobiorców (testowa) różni się tylko nieznacznie od populacji bazowej, natomiast gdy $W_{SP} \geq 0,25$, to obecna populacja znacznie odbiega od populacji bazowej.



Rys. 5. Porównanie stabilności populacji bazowej (uczącej) i aktualnej (testowej) dla modelu skoringowego nr 2, dla którego współczynnik stabilności populacji wynosi $W_{SP} = 0,12$.

Źródło: opracowanie własne z wykorzystaniem autorskich procedur SVB na podstawie danych kredytowych.

Rysunek 5 przedstawia rozkład punktacji oraz jego dystrybuantę dla modelu skoringowego nr 2 dla populacji bazowej oraz testowej kredytobiorców. Widać, że wdrażany model skoringowy nie zatracił dobrych własności klasyfikacyjnych dla

populacji nowych kredytobiorców (niewielkie wartości wskaźnika stabilności populacji $W_{SP} = 0,12$).

5. Podsumowanie

Projektując i wdrażając systemy skoringowe do oceny zdolności kredytowej w działalności bankowej, należy brać pod uwagę nie tylko liczne zalety tej metody, ale także pewne jej wady. Najważniejsze zalety stosowania *skoringu* to: zwiększenie liczby zawieranych transakcji kredytowych, zwiększenie szybkości ich dokonywania, zmniejszenie kosztów badania wiarygodności kredytowej, zmniejszenie ryzyka kredytowego, wzrost wydajności operacji bankowych, kontrola bieżąca oraz możliwość przewidywania złych długów. Natomiast do głównych wad *skoringu kredytowego* należy zaliczyć: konieczność ciągłej aktualizacji wyznaczników (determinant) oceny ryzyka kredytowego i ich wag, bardzo duże uzależnienie systemu od jakości źródeł pozyskiwania danych o kredytobiorcy (często pozabankowych), możliwość szybkiej dezaktualizacji systemu skoringowego oraz niezdolność do szybkiego dostosowywania się do zmian w gospodarce i stylu życia kredytobiorcy, budowa tablicy skoringowej na podstawie populacji kredytobiorców, którym udzielono kredyt z pominięciem kredytobiorców, którym wnioski odrzucono, klasyfikowanie nowo badanych klientów często tylko do dwóch klas (dobry i zły) z pominięciem klasy klientów nieokreślonych, wymagających dalszych badań (zebrania dalszych informacji).

Analizując prezentowane w artykule oszacowane przykładowe modele skoringowe można zauważyć, że skuteczność i efektywność w dużej mierze zależy od bardzo wielu różnych czynników. Pierwszym ważnym czynnikiem determinującym ich skuteczność jest dobór właściwej próby badawczej do szacowanych modeli oraz wybór odpowiednich predyktorów mających dobre własności prognostyczne w klasyfikacji złych i dobrych kredytobiorców. Odpowiednio dobrane reguły, określające profil ryzyka kredytobiorców mogą być interesującym uzupełnieniem zbioru właściwych predyktorów. Potwierdzają to wyniki statystyk walidacyjnych modeli (zob. tab. 6), gdzie można zauważyć, że efektywność modeli z zastosowaniem reguł nie odbiega znacząco od jakości modeli bez zastosowania reguł. Wszystkie cztery rozpatrywane warianty modeli posiadały duże wartości statystyk walidacyjnych, co świadczy o ich dużej mocy predykcyjnej w poprawnej klasyfikacji kredytów dobrych i złych. Najlepsze własności klasyfikacyjne miał model 2 (z 11 wybranymi predyktorami i wspólną skalą *WoE* dla wszystkich predyktorów).

Efektywność modeli skoringowych zależy także od wyboru metody oszacowania modelu. W artykule wykorzystano model regresji logistycznej, jednak opracowane autorskie programy obliczeniowe pozwalają również zastosować inne modele: liniowej analizy dyskryminacyjnej, sieci neuronowych oraz drzew decyzyjnych. Badania autora oraz analiza wyników prac innych autorów, prowadzących podobne wyniki badań (zob. np. [Hand, Henley 1997]) pokazuje, że efektywność modeli skoringowych oszacowanych różnymi metodami może niekiedy znacznie się różnić.

Na efektywność poprawnych klasyfikacji kredytobiorców ma wpływ również wybór odpowiedniego punktu odcięcia (zob. rozważania w punkcie 3). Wybór właściwego punktu odcięcia oraz sposobu jego wyznaczania należy do menadżera zarządzającego systemem skoringowym i preferencji banku. Należy jednak zdawać sobie sprawę, że jest to jeden z kluczowych i wrażliwych elementów wdrażania systemu skoringowego.

Nie należy także zapominać, że duży wpływ na efektywność modeli skoringowych (co akcentowano już wcześniej, omawiając fazę monitoringu) ma także efekt zmiany struktury populacji bieżącej (dla której model będzie stosowany do prognoz) w stosunku do populacji bazowej (dla której model był szacowany). Dlatego, aby model skoringowy nie ztracił swoich własności prognostycznych, należy go na bieżąco monitorować i uaktualniać, dokonywać ciągłej korekty, poprzez dodawanie nowych kredytobiorców do bazy danych kredytowych. Tylko na bieżąco monitorowane systemy skoringowe będą dobrze przewidywać wiarygodność kredytową przyszłych klientów banku. Od menadżerów kredytowych wymaga się zatem, aby znając wszystkie wrażliwe aspekty tego typu systemów, minimalizowali ich wady i to zwłaszcza na etapie projektowania i wdrożenia systemu.

Literatura

- Cioch K., Karnowska K., 2010, *Ocena modeli skoringowych w SKOK Stefczyka*, StatSoft, Kraków, http://www.statsoft.pl/czytelnia/artykuly/Ocena_modeli_skoringowych_w_SK_OK_Stefczyka.pdf.
- Hand D.J., Henley W.E., 1997, *Statistical classification methods in consumer credit scoring – a review*, Journal of the Royal Statistical Society: Series A (Statistics in Society), vol. 160, no. 3, s. 523–541.
- Janc A., Kraska M., 2001, *Credit-scoring. Nowoczesna metoda oceny zdolności kredytowej*, Biblioteka Menadżera i Bankowca, Warszawa.
- Kraska M., 2004, *Credit scoring i credit rating. Zastosowanie w banku komercyjnym*, Wydawnictwo Stardruk, Warszawa.
- Löffler G., Posch P. N., 2007, *Credit risk modeling using Excel and VBA*, John Wiley & Sons, Chichester.
- Matuszyk A., 2004, *Credit scoring*, CeDeWu, Warszawa.
- Siddiqi N., 2006, *Credit Risk Scorecards. Developing and Implementing Intelligent Credit Scoring*, John Wiley & Sons, Hoboken, NJ.
- Thomas L.C., 2009, *Consumer Credit Models. Pricing Profit and Portfolios*, Oxford University Press, New York.
- Thomas L.C., Edelman D.B., Crook J.N., 2002, *Credit Scoring and Its Applications*, Society for Industrial and Applied Mathematics, Philadelphia.
- Zweig M.H., Campbell G., 1993, *Receiver-operating characteristic (ROC) plots: A fundamental evaluation tool in clinical medicine*, Clinical Chemistry, vol. 39, no. 4, s. 561–577.

METHODOLOGICAL ASPECTS OF THE APPLICATION OF CREDIT SCORING MODELS TO ASSESS THE CREDITWORTHINESS WITH THE USE OF QUANTITATIVE METHODS

Summary: The article presents the methodological aspects of the application of credit scoring methods to assess the creditworthiness for individual customers with the use of quantitative methods. Based on the available credit data, the so-called German Credit Data (GCD), there were shown the examples of the main stages of the scoring system development: the design phase and implementation phase, together with the validation phase and the phase of monitoring of its stability. For the purpose of the analyses and in order to automate calculations there were developed computer software programs (modules written in Statistica Visual Basic) which can be used in practice of the scoring models application.

Keywords: Credit scoring, quantitative methods, statistical classification methods.