



Milan Popović

Uniwersytet Łódzki
Wydział Ekonomiczno-Socjologiczny
Katedra Informatyki Ekonomicznej
milanp@uni.lodz.pl

**ZARZĄDZANIE RYZYKIEM OPERACYJNYM
W PROCESIE KLASYFIKACJI TRANSAKCJI
FAKTORINGOWYCH Z UŻYCIEM
DRZEW KLASYFIKACYJNYCH**

Streszczenie: Faktoring obok leasingu i kredytu stanowi jedno ze źródeł finansowania bieżącej działalności przedsiębiorstwa. Jednak transakcja faktoringowa okazuje się bardziej obciążona ryzykiem niż inne formy finansowania. Niniejszy artykuł ma na celu wskazanie problemu ryzyka operacyjnego, które towarzyszy transakcjom faktoringowym. W pierwszej części została przedstawiona istota faktoringu, strony umowy i przebieg procesów z wykorzystaniem transakcji faktoringowej. Następnie poruszono kwestie związane z ryzykiem operacyjnym, które towarzyszy faktoringowi. Ostatnia, trzecia część artykułu stanowi badanie empiryczne mające na celu zaproponowanie procesu ograniczenia ryzyka operacyjnego poprzez segmentację transakcji faktoringowych z wykorzystaniem wybranych parametrów. Po zastosowaniu metody drzew klasyfikacyjnych, która posiada zdolność uczenia i uogólniania, zaproponowany model wskaże odpowiednio sklasyfikowane transakcje, na podstawie których można wnioskować o jakości transakcji faktoringowych.

Słowa kluczowe: faktoring, ryzyko operacyjne, eksploracja danych, drzewa klasyfikacyjne.

JEL Classification: G23, G32.

Wprowadzenie

Ostatnimi laty mamy do czynienia z różnego rodzaju światowymi kryzysami gospodarczymi. W takiej sytuacji przedsiębiorcy, aby ustabilizować swoją sytuację finansową bądź aby przetrwać na rynku, są zmuszeni korzystać z usług

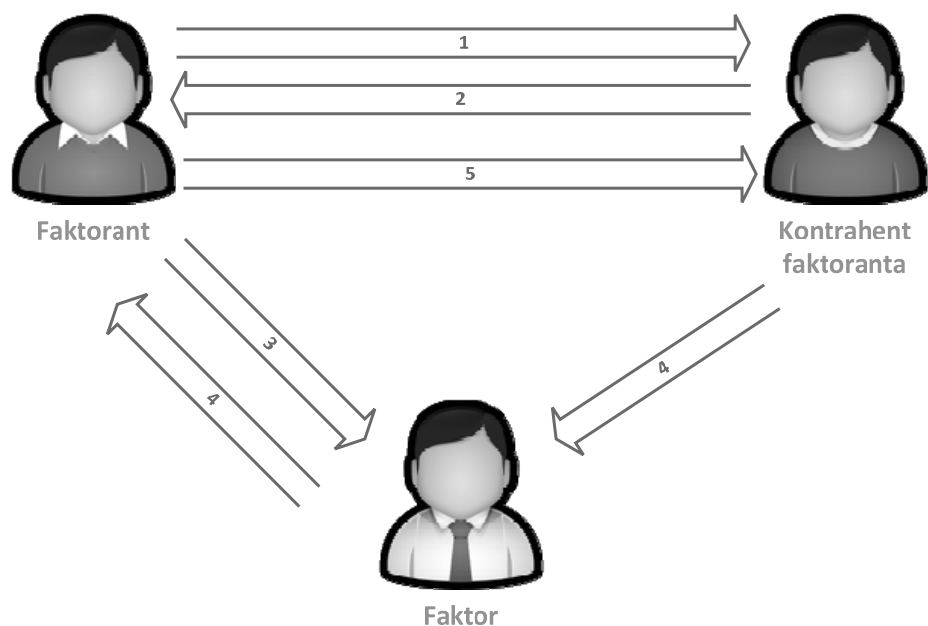
instytucji finansowych w celu pozyskania kapitału. Jeżeli przedsiębiorstwo posiada stałych kontrahentów, wówczas usługa faktoringu stanowi jedną z możliwości zwiększenia płynności finansowej.

Według danych Głównego Urzędu Statystycznego za 2015 r. z usługi faktoringu korzystało 12 650 przedsiębiorstw [www 3], których łączny udział obrotów objętych faktoringiem sięgał 171 640 mln zł. Warty podkreślenia jest fakt, że tylko 0,5% przedsiębiorstw w Polsce, korzystających z usług faktoringowych, generowało obroty na poziomie aż 9,6% Produktu Krajowego Brutto za 2015 r. [www 4].

1. Faktoring

Przedsiębiorstwa nieustannie szukają nowych sposobów na pozyskiwanie kapitału. W zależności od tego, w jakim celu kapitał ma być pozyskiwany, bardzo często przedsiębiorstwa korzystają z usług bankowych, takich jak kredyt w przypadku pozyskania gotówki na konkretny cel lub np. leasing w przypadku najmu pojazdów. Wówczas podpisywana jest umowa z bankiem bądź wyspecjalizowaną spółką leasingową, najczęściej będącą częścią bankowej lub ubezpieczeniowej grupy kapitałowej. Umowa faktoringu stanowi natomiast umowę trójstronną pomiędzy instytucją finansową, przedsiębiorcą oraz kontrahentem przedsiębiorcy [por. Kreczmańska, 1997; Tokarski, 2005; Kreczmańska-Gigol, 2006; Korenik, 2007]. Stronami umowy są *faktor* – instytucja finansowa udzielająca finansowania, *faktorant* – producent towarów bądź usługodawca, który zwraca się do faktora, oraz *kontrahent* – klient faktoranta, nabywca jego towarów bądź usług.

Faktoring, najkrócej ujmując, przedstawia sposób na kredytowanie należności przedsiębiorstw faktorantowi przez faktora. Sam proces faktoringowy, który został przedstawiony na rys. 1, wygląda następująco. Po podpisaniu trójstronnej umowy w pierwszym kroku (1) przedsiębiorca (faktorant) sprzedaje swoje towary bądź usługi swojemu kontrahentowi, który staje się dłużnikiem względem faktoranta, więc powstaje zobowiązanie zapłaty (2), za które kontrahent musi zapłacić w wyznaczonym terminie. Faktor przejmuje wierzytelność od faktoranta (3), wypłacając mu kwotę wierzytelności (4) pomniejszoną o swój zarobek. O zmianie wierzyciela faktor musi poinformować kontrahenta (5), który musi spłacić faktorowi kwotę należności (6) w umówionym wcześniej terminie.



Rys. 1. Przebieg transakcji handlowej z użyciem faktoringu

Źródło: Opracowanie własne na podstawie: Kreczmańska-Gigol [2006, s. 12].

2. Ryzyko operacyjne w faktoringu

Wybierając finansowanie za pomocą usługi faktoringu, przedsiębiorca musi przyjąć założenie, że koszty, które poniesie z tytułu umowy faktoringowej, będą niższe niż korzyści, które otrzyma z tytułu wcześniejszego finansowania. Jeżeli jednak wystąpią niesprzyjające okoliczności, wówczas faktorant zamiast otrzymać „zastrzyk finansowy”, może wpaść w jeszcze większe zadłużenie niż dotychczas. Jeśli umowa faktoringu nie została dobrze oszacowana przez przedsiębiorcę, transakcje faktoringowe mogą się okazać dla niego nieopłacalne z powodu zbyt dużych kosztów usługi. Może wystąpić utrata kontrahentów wskutek zawarcia umowy faktoringowej i przeniesienia wierzytelności na instytucję faktoringową [Kreczmańska-Gigol, 2013, s. 63]. W skrajnym przypadku umowa faktoringu może również doprowadzić do upadłości faktoranta.

Idąc tym tropem, transakcja faktoringowa jest obciążona wysokim ryzykiem, gdyż występuje dużo czynników, które mogą wpłynąć na to, że relacja między faktorantem a instytucją faktoringową będzie musiała być rozwiązana ze względu na potencjalne bądź rzeczywiste zagrożenie nieodzyskania środków

finansowych przez faktora. Ryzyko operacyjne towarzyszące działalności faktoringowej może przyjąć dwie postacie: ryzyka rzeczowo-techniczne oraz personalnego [Kreczmańska-Gigoł, 2011, s. 442]. Ryzyko rzeczowo-techniczne jest uzależnione od rodzaju działalności faktoranta i związane z pozyskiwaniem środków wytwórczych i wszelkim ich zastosowaniem. Ryzyko personalne jest dużo bardziej złożone, gdyż może się ono wiązać zarówno ze świadomym lub nieświadomym działaniem pracowników faktora, którzy działają na jego szkodę, jak i z oszustwem ze strony faktoranta bądź jego kontrahentów. Z tym ostatnim może być najwięcej trudności, gdyż faktor może mieć dużo problemów w procesie kontroli faktoranta, a w szczególności jego kontrahentów.

W procesie przeciwdziałania ryzyku operacyjnemu w faktoringu bardzo istotną rolę mogą odgrywać procedury, które mają na celu kontrolę zarówno poprawności danych, jak i ich spójności. Wykorzystując wiedzę branżową oraz informatyczną, istnieje możliwość budowy informatycznego systemu prewencyjnego [Opolski, 2010, s. 16-17], który na podstawie wprowadzonych danych byłby w stanie, poprzez wykorzystanie odpowiednich modeli i algorytmów [Kisielnicki, 2005, s. 18], zaprezentować informacje, na podstawie których można podjąć decyzję o kontynuowaniu bądź zaprzestaniu dalszej współpracy z obecnym partnerem lub kontrahentem.

3. Klasyfikacja transakcji faktoringowych

Przedstawiona w dalszej części artykułu analiza ma na celu zaproponowanie procesu ograniczenia ryzyka operacyjnego poprzez segmentację transakcji faktoringowych z wykorzystaniem wybranych parametrów. W przedstawionej analizie zbiory danych faktorantów zostały przygotowane na podstawie informacji dotyczących transakcji faktoringowych uzyskanych od jednego z polskich banków. Transakcje dotyczyły faktoringu klasycznego pełnego, bez regresu. Opierając się na opiniach ekspertów branżowych, ustalono, czy ich zdaniem dla każdego zbioru danych danemu faktorantowi należy dalej udzielać usługi faktoringu, czy dalsze udzielanie faktoringu będzie wymagało dodatkowej weryfikacji lub czy zaprezentowane dane wskazują, iż faktorantowi nie powinno się udzielać faktoringu w przyszłości. Zgodnie z powyższym wykonując badanie, przyjęto założenie, iż po zastosowaniu metody drzew klasyfikacyjnych model wskaże trzy segmenty transakcji: transakcje dobre, transakcje złe oraz transakcje do dodatkowej weryfikacji.

Mianem transakcji dobrych będą określane takie zbiory transakcji, które wskazują na wzorową relację faktoranta ze swoimi klientami. Na potrzeby niniejszego badania zostaną one oznaczone jako *Grupa A*. Transakcje złe to zaś takie, które wskazują, iż relacji między faktorem a jego klientami należy zaprzestać bądź zrezygnować z usługi faktoringu dla danego faktoranta. Będą one oznaczone jako *Grupa C*. Natomiast trzeci segment – transakcje do dodatkowej weryfikacji – przedstawia zbiory transakcji, dla których nie można jednoznacznie stwierdzić, iż odzwierciedlają wzorowe relacje między faktorem a jego klientami, ale z drugiej strony nie dają podstaw, by radykalnie zaprzestawać współpracy ani z klientami faktoranta, z którymi relacje są nawiązywane, ani faktora z faktorem. Takie zbiory transakcji powinny być dodatkowo weryfikowane, gdyż mogą występować pozorne problemy, które de facto problemami nie są, i mogą zostać uzasadnione zarówno przez faktoranta, jak i klientów pozostających z nim w relacjach. Na potrzeby niniejszego badania tego typu transakcje zostaną oznaczone jako *Grupa B*.

Metoda drzew klasyfikacyjnych przedstawia metodę klasyfikacji z zastosowaniem eksploracji danych [Larose, 2005; 2013], w której budowa węzłów decyzyjnych zaczyna się od korzeni, które dzielą się na gałęzie, te zaś kończą się liśćmi decyzyjnymi. Od korzenia, poprzez gałęzie, aż do liści parametry są weryfikowane w węzłach decyzyjnych. Każdorazowe przejście do kolejnego poziomu jest oznaczone jako gałąź, która z kolei może prowadzić do następnej gałęzi lub być zakończona liściem, a ten ostatecznie kończy proces decyzyjny.

Należy podkreślić, iż analizowany zbiór danych powinien przedstawiać grupę reprezentatywną, czyli zawierać zarówno przypadki skrajne, jak i takie, które mogą być na pograniczu poszczególnych grup klasyfikacyjnych. W tym celu autor wykorzystał badanie [Popović, 2017] polegające na wskazaniu przez ekspertów, na podstawie przedstawionych im danych, czy wybrany zbiór transakcji (stanowiący relację między faktorem a jego dłużnikami) przedstawia zbiór transakcji dobrych, transakcji złych, czy nie da się tego jednocześnie wskazać bez dodatkowej weryfikacji.

W opisanych niżej drzewach klasyfikacyjnych zmienna zależna powinna odzwierciedlać wybór ekspertów. Na te potrzeby predyktorami będą zmienne oznaczone jako L_{FX} oraz Q_{FX} , które przedstawiają odpowiednio udział liczby (L) i wartości (Q) faktur korygowanych „w dół” (FK), faktur korygowanych do wartości zerowej (FA), jak również spłat z nieznanymi faktorowi rachunków bankowych (SN) w ogólnej liczbie i kwocie wszystkich faktur w badanym okresie (odpowiednio L_{FS} oraz Q_{FS}), co zostało przedstawione poniższymi wzorami:

$$L_{FX} = \left(\frac{L_{FA} + L_{FK} + L_{SN}}{L_{FS}} \right) \quad (1)$$

oraz:

$$Q_{FX} = \left(\frac{Q_{FA} + Q_{FK} + Q_{SN}}{Q_{FS}} \right). \quad (2)$$

W przeprowadzonym badaniu drzewa klasyfikacyjne będą tworzyć podziały, opierając się na zmiennych predykcyjnych, które decydują o przynależności poszczególnych przypadków do jednej z trzech wyznaczonych klas zbiorów transakcji. W związku z powyższym każdy podział jest wybierany pojedynczo, zaczynając od podziału przy węźle źródłowym, poprzez kolejne podziały węzłów, aż do przerwania, w wyniku którego ostatnie węzły nie zostają podzielone i stają się węzłami końcowymi [www 2].

Badanie zostało wykonane za pomocą pakietu matematyczno-statystycznego *Statistica 10*, zatem poniższa analiza wykorzystuje trzy metody wyboru podziałów w celu zbudowania drzewa klasyfikacyjnego, które są dostępne w tymże pakiecie:


1. Dyskryminacyjne podziały jednowymiarowe.
2. Dyskryminacyjne podziały z wykorzystaniem kombinacji liniowych.
3. Metoda CART wyczerpującego poszukiwania podziałów.

Dodatkowo przy budowie drzew klasyfikacyjnych zostało przyjęte założenie, że koszty błędów klasyfikacji do zbioru transakcji przeznaczonych do dodatkowej weryfikacji (zbiór B) będą wyższe niż koszty pozostałych klasyfikacji. Zwieńczeniem niniejszej analizy dla każdej metody jest obliczenie współczynnika błędu klasyfikacji całego drzewa (ang. *classification error rate*). Jest on średnią ważoną współczynników błędów liści, uwzględniając proporcjonalnie odsetek przypadków zaklasyfikowanych do poszczególnych liści [Larose, 2013]. W analizach uwzględniono pięćdziesiąt zbiorów transakcji faktoringowych, z czego czterdzieści losowo wybranych zostało wykorzystanych jako zbiór uczący. Następnie wykorzystano pozostałych dziesięć jako zbiór testowy, który pozwala ocenić, w jakim stopniu wykryte na podstawie próby uczącej prawidłowości pozwalają prawidłowo klasyfikować obserwacje niebędące częścią próby uczącej.

3.1. Dyskryminacyjne podziały jednowymiarowe

Pierwszą metodą budowy drzew klasyfikacyjnych jest dyskryminacyjny podział jednowymiarowy, którego predyktory otrzymują wartości dyskretne. Polega on na wyznaczeniu takiego węzła końcowego, który podzieli bieżące

drzewo, opierając się na zmiennej predykcyjnej dla tego podziału. W następnych krokach należy dla każdego kolejnego węzła końcowego obliczyć tzw. p-value, czyli poziom krytyczny testu niezależności chi-kwadrat, który sprawdza hipotezę, iż przyporządkowanie zbioru transakcji do którejś z grup (A, B lub C) nie jest uzależnione od rzeczywistej przynależności do tychże grup. Innymi słowy, niska wartość poziomu krytycznego umożliwiłaby odrzucenie powyższej hipotezy na rzecz hipotezy alternatywnej o występowaniu takiej zależności, która byłaby statystycznie istotna [www 2]. Następnie zostaną wyznaczone podziały z wykorzystaniem predyktorów. Drzewo decyzyjne dobiera taką postać modelu, aby błąd klasyfikacji był możliwie najmniejszy. Zatem można uzyskać dużo gałęzi, uzyskując poprawną klasyfikację dla wszystkich elementów zbioru uczącego przy stosunkowo dużym błędzie predykcji lub uzyskać postać bardziej ogólną przy możliwie najmniejszym błędzie



Rys. 2. Drzewo klasyfikacyjne zbudowane na podstawie dyskryminacyjnych podziałów jednowymiarowych


Źródło: Opracowanie własne na podstawie pakietu statystycznego Statistica, wersja 10.

Spśród 40 transakcji zbioru uczącego jeden zbiór transakcji z grupy B został błędnie przypisany do grupy A, dwa zbiory z grupy C zostały sklasyfikowane do grupy B oraz trzy zbiory grupy B zostały przypisane do grupy C. Drzewo

decyzyjne przedstawione na rys. 2 przedstawia 6 błędnych transakcji uzyskanych w porównaniu do wzorca, co stanowi 15% zbioru uczącego (przy ważonym współczynniku błędu klasyfikacji 0,15). Po dokonaniu weryfikacji z użyciem zbioru testowego nie zaobserwowano błędnych klasyfikacji.

3.2. Dyskryminacyjne podziały z wykorzystaniem kombinacji liniowych

Dyskryminacyjny podział z wykorzystaniem kombinacji liniowych realizuje się podobnie do dyskryminacyjnych podziałów jednowymiarowych, z tą różnicą, że zmienne porządkowe traktuje się jako predyktory ciągłe [www 2]. Podobnie jak w przypadku dyskryminacyjnych podziałów jednowymiarowych, drzewo decyzyjne dobiera taką postać modelu, aby błąd klasyfikacji był możliwie najmniejszy, a jednocześnie posiadał duży stopień uogólniania.



Rys. 3. Drzewo klasyfikacyjne zbudowane na podstawie dyskryminacyjnych podziałów z wykorzystaniem kombinacji liniowych

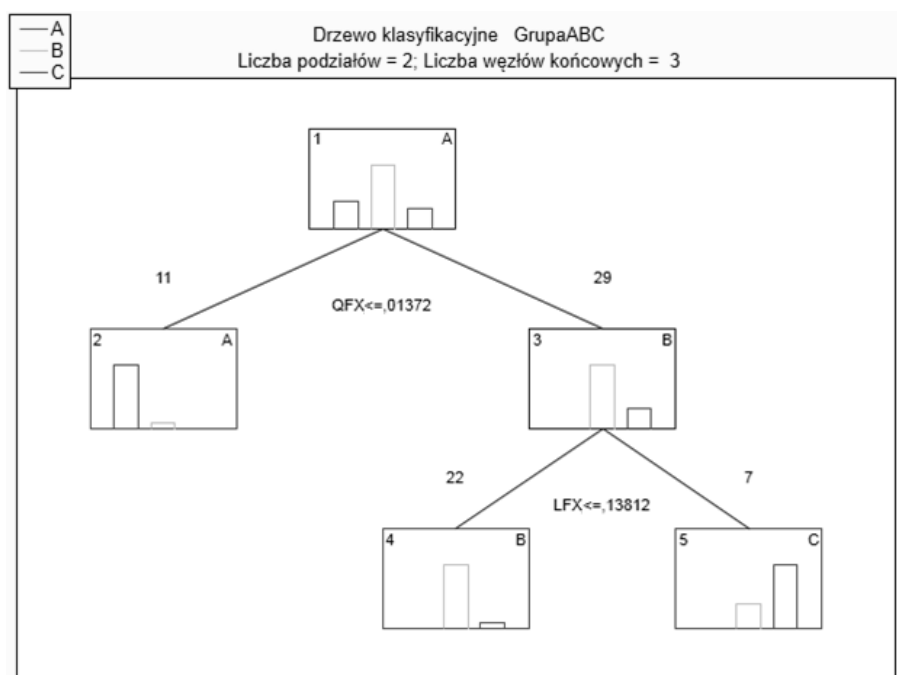
Źródło: Opracowanie własne na podstawie pakietu statystycznego Statistica, wersja 10.

Spośród 40 transakcji zbioru uczącego jeden zbiór transakcji z grupy B został błędnie przypisany do grupy A, dwa zbiory z grupy C zostały sklasyfikowane do grupy B oraz dwa zbiory grupy B zostały przypisane do grupy C. Drzewo decyzyjne przedstawione na rys. 3 zostało podzielone na podstawie wartości funkcji dyskryminacyjnej z wykorzystaniem kombinacji liniowych $F(0)$. Przedstawia 5 błędnych transakcji uzyskanych w porównaniu do wzorca, co stanowi 12,5% zbioru uczącego (ważony współczynnik błędu klasyfikacji: 0,125). Po dokonaniu weryfikacji z użyciem zbioru testowego nie zaobserwowano błędnych klasyfikacji.

3.3. Metoda CART wyczerpującego poszukiwania podziałów jednowymiarowych

W przypadku wykorzystywania drzew klasyfikacyjnych i regresyjnych metoda CART (ang. *Classification and Regression Trees*) jest jedną z najpopularniejszych metod [por. Briemann i in., 1984; Cherkassky i in., 1998; Michie i in., 1994], która tworzy drzewa binarne zarówno z użyciem cech ciągłych, jak i dyskretnych. W wyniku zastosowania tejże metody podziały są dokonywane na podstawie liniowej kombinacji zmiennych predykcyjnych [www 2].

Za pomocą metody CART otrzymano wyniki bardzo podobne do wyników metody dyskryminacyjnych podziałów z wykorzystaniem kombinacji liniowych. Mianowicie spośród 40 transakcji zbioru uczącego jeden zbiór transakcji z grupy B został błędnie przypisany do grupy A, dwa zbiory z grupy C zostały sklasyfikowane do grupy B oraz dwa zbiory grupy B zostały przypisane do grupy C. Drzewo decyzyjne przedstawione na rys. 4 przedstawia 5 błędnych transakcji uzyskanych w porównaniu do wzorca, co stanowi 12,5% zbioru uczącego (przy ważonym współczynniku błędu klasyfikacji 0,125). Podobnie do poprzednich metod, po dokonaniu weryfikacji z użyciem zbioru testowego nie zaobserwowano błędnych klasyfikacji.



Rys. 4. Drzewo klasyfikacyjne zbudowane z wykorzystaniem metody wyczerpującego poszukiwania podziałów jednowymiarowych (CART)

Źródło: Opracowanie własne na podstawie pakietu statystycznego Statistica, wersja 10.

Podsumowanie

W przypadku algorytmów drzew klasyfikacyjnych największą zaletą jest zdolność uogólniania, natomiast problemem może być dobranie takiej postaci modelu, aby błąd klasyfikacji był możliwie najmniejszy. W związku z powyższym, w celu optymalizacji klasyfikacji drzew można uzyskać dużo gałęzi przy stosunkowo dużym błędzie predykcji, albo, co ważniejsze, uzyskać postać bardziej ogólną przy możliwie najmniejszym błędzie. W konsekwencji aby uprościć stopień złożoności algorytmu, można zastosować tzw. przycinanie gałęzi (ang. *pruning*), uzyskując tym samym większą umiejętność uogólniania [Gatnar, 2013]. Z drugiej strony bardziej złożona postać algorytmu będzie umożliwiała kolejne podziały, w których liczba analizowanych danych jest coraz mniejsza, a tym samym każda z kolejnych prób staje się coraz mniej reprezentatywna [Larose, 2013] w odniesieniu do całego zbioru danych.

Konkludując, różnorodność i większa liczebność zbioru danych uczących zwiększy prawdopodobieństwo tego, iż utworzone drzewo klasyfikacyjne będzie poprawnie klasyfikować przypadki. Przedstawione badanie w zbiorze danych uczących zawierało zarówno przypadki skrajne, jednoznacznie wskazujące na grupę, do której przypadek powinien zostać sklasyfikowany, jak i takie przypadki, które były na pograniczu klasyfikacji dwóch grup, co przyczyniło się do tego, że mogły one zostać błędnie sklasyfikowane. Wówczas należałoby dokonać „ręcznej” weryfikacji przypadków z wartościami „granicznymi”. Dotyczy to w szczególności przypadków, w których transakcje z grupy, która powinna podlegać dodatkowej weryfikacji (grupa B), zostały błędnie przydzielone do skrajnych grup (grupa A – transakcje dobre oraz grupa C – transakcje złe).

Literatura

- Briemann L., Friedman J.H., Stone C.J., Olshen R.A. (1984), *Classification and Regression Trees*, Wadsworth, Belmont.
- Cherkassky V., Muiler F. (1998), *Learning from Data*, John Wiley & Sons, River Street.
- Gatnar E. (2013), *Analiza dyskryminacyjna – stan aktualny i kierunki rozwoju*, „Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach”, nr 152, Katowice.
- Kisielnicki J., Sroka H. (2005), *Systemy informacyjne biznesu. Informatyka dla zarządzania*, Placet, Warszawa.
- Korenik D. (2007), *Factoring w bankowości. Strategia przyszłości*, CeDeWu, Warszawa.
- Kreczmańska K. (1997), *Factoring w przedsiębiorstwie*, Bart, Warszawa.
- Kreczmańska-Gigol K. (2006), *Factoring w świetle prawa cywilnego, podatkowego i bilansowego*, Centrum Doradztwa i Informacji Difin, Warszawa.
- Kreczmańska-Gigol K. (2011), *Windykacja należności. Ujęcie interdyscyplinarne*, Difin, Warszawa.
- Kreczmańska-Gigol K. (2013), *Factoring jako jeden z instrumentów zarządzania należnościami i zobowiązaniami handlowymi a struktura kapitału*, Difin, Warszawa.
- Larose D.T. (2005), *Discovering Knowledge in Data. An Introduction to Data Mining*, John Wiley & Sons, Hoboken, New Jersey.
- Larose D.T. (2013), *Odkrywanie wiedzy z danych. Wprowadzenie do eksploracji danych*, Wydawnictwo Naukowe PWN, Warszawa.
- Michie D., Spiegelhalter D.J., Taylor C.C. (1994), *Machine Learning, Neural and Statistical Classification*, Elis Horwood, London.

- Opolski K. (2010), *Narzędzia informatyczne do zarządzania ryzykiem operacyjnym w instytucjach finansowych*, materiały konferencyjne „XXII Forum bankowości elektronicznej: Narzędzia informatyczne do zarządzania ryzykiem operacyjnym i compliance w instytucjach finansowych”, Wyd. Centrum Promocji Informatyki, Warszawa.
- Popović M. (2017), *Ograniczanie ryzyka operacyjnego w transakcjach faktoringowych przy użyciu technologii informatycznych*, rozprawa doktorska napisana pod kierunkiem prof. dr. hab. Mariana Niedźwiedzińskiego, Uniwersytet Łódzki, Łódź.
- Tokarski M. (2005), *Factoring w małych i średnich przedsiębiorstwach, forma krótkoterminowego finansowania działalności*, Oficyna Ekonomiczna, Kraków.
- [www 1] Centralny Ośrodek Informacji Gospodarczej, *Spis polskich firm*, http://www.coig.com.pl/spis-polskich-firm_katalog_polskich_firm.php (dostęp: 30.07.2016).
- [www 2] *Drzewa klasyfikacyjne. Internetowy Podręcznik Statystyki*, <http://www.statsoft.pl/textbook/stclatre.html> (dostęp: 30.07.2016).
- [www 3] *Działalność faktoringowa przedsiębiorstw finansowych w 2015 roku*, <http://stat.gov.pl/obszary-tematyczne/podmioty-gospodarcze-wyniki-finansowe/przedsiębiorstwa-finansowe/dzialalnosc-factoringowa-przedsiębiorstw-finansowych-w-2015-roku,2,11.html> (dostęp: 30.07.2016).
- [www 4] *Produkt krajowy brutto w 2015 r. – Szacunek wstępny*, <http://stat.gov.pl/obszary-tematyczne/rachunki-narodowe/roczne-rachunki-narodowe/produkt-krajowy-brutto-w-2015-r-szacunek-wstepny,2,5.html> (dostęp: 30.07.2016).

OPERATIONAL RISK MANAGEMENT IN THE FACTORING TRANSACTIONS' CLASSIFICATION PROCESS WITH CLASSIFICATION TREES USE

Summary: Among loans and leasing, factoring is being one of source for financing the companies' business. However, the factoring transaction appears to be more fraught with risk than other forms of financing. This paper aims to identify the problem of operational risk in factoring transactions. In the first part was presented the essence of factoring, the parties and processes in the use of factoring transactions. Next part discusses the issues related to operational risk in factoring. The last, third part of the study is an empirical study aimed at proposing processes of, reducing operational risk by segmenting factoring transactions based on selected parameters. Use of the classification trees method, which has the ability to learn and generalize, the model indicates adequately classified transactions. On that basis the quality of factoring transactions can be indicated.

Keywords: factoring, operational risk, data mining, classification trees.