



POLSKA AKADEMIA NAUK
Instytut Badań Systemowych

**BADANIA OPERACYJNE I SYSTEMOWE:
ŚRODOWISKO NATURALNE,
PRZESTRZEŃ, OPTYMALIZACJA**

**Olgierd Hryniewicz,
Andrzej Straszak,
Jan Studziński
red.**



**BADANIA OPERACYJNE
I SYSTEMOWE:
ŚRODOWISKO NATURALNE, PRZE-
STRZEŃ, OPTIMALIZACJA**

INSTYTUT BADAŃ SYSTEMOWYCH • POLSKA AKADEMIA NAUK

Seria: BADANIA SYSTEMOWE
tom 63

Redaktor naukowy:

Prof. dr hab. inż. Jakub Gutenbaum

Warszawa 2008

Olgierd Hryniewicz, Andrzej Straszak, Jan Studziński

**BADANIA OPERACYJNE I SYSTEMOWE:
ŚRODOWISKO NATURALNE, PRZESTRZEŃ,
OPTIMALIZACJA**

Publikacja była opiniowana do druku przez zespół recenzentów, którego skład podano w treści tomu

Opinie, wyrażone przez autorów w pracach, zawartych w niniejszym tomie, nie są oficjalnymi opiniami Instytutu Badań Systemowych PAN, ani Polskiego Towarzystwa Badań Operacyjnych i Systemowych.

Copyright © by Instytut Badań Systemowych PAN & Polskie Towarzystwo Badań Operacyjnych i Systemowych
Warszawa 2008

ISBN 83-894-7519-7
EAN 9788389475190

Redakcja i opracowanie techniczne: Jan W. Owskiński, Aneta M. Pielak, Anna Gostyńska

**Lista recenzentów
artykułów, wchodzących w skład tomów serii „Badania Systemowe”
związanych z konferencją BOS 2008**

Dr Paweł Bartoszczuk
Dr inż. Lucyna Bogdan
Dr hab. inż. Zbigniew Buchalski
Mgr inż. Hanna Bury
Prof. dr hab. Marian Chudy
Dr Jan Gadomski
Mgr Grażyna Grabowska
Mgr inż. Andrzej Jakubowski
Dr hab. inż. Ignacy Kaliszewski
Dr Andrzej Kałuszko
Dr hab. Leszek Klukowski
Dr hab. inż. Wiesław Krajewski
Dr inż. Lech Kruś
Dr hab. inż. Marek Libura
Dr Barbara Mażbic-Kulma
Dr inż. Edward Michalewski
Dr inż. Jan W. Owiński
Dr inż. Grażyna Petriczek
Dr inż. Henryk Potrzebowski
Dr Maciej Romaniuk
Prof. dr hab. Piotr Sienkiewicz
Dr hab. Henryk Spustek
Prof. dr hab. Andrzej Straszak
Dr hab. inż. Jan Studziński
Prof. dr hab. Tomasz Szapiro
Mgr Anna Szediw
Dr inż. Grażyna Szkatuła
Dr hab. inż. Tadeusz Witkowski
Dr Irena Woroniecka-Leciejewicz
Dr hab. Sławomir Zadrozny
Dr inż. Andrzej Ziółkowski

**Komitety Konferencji
Badania Operacyjne i Systemowe 2008
Rembertów, Akademia Obrony Narodowej**

Patronat honorowy

Bogdan Klich, Minister Obrony Narodowej
Maciej Nowicki, Minister Środowiska i Zasobów Naturalnych

Komitet Sterujący

Janusz Kacprzyk, Prezes Polskiego Towarzystwa Badań Operacyjnych i Systemowych
Olgierd Hryniewicz, Dyrektor Instytutu Badań Systemowych
Janusz Kręcikij, Komendant Akademii Obrony Narodowej

Komitet Programowy

Piotr Sienkiewicz, *Przewodniczący*
Jacek Mercik, *Wiceprzewodniczący*

<i>Tomasz Ambroziak</i>	<i>Ryszard Budziński</i>	<i>Wojciech Cellary</i>
<i>Marian Chudy</i>	<i>Ludostaw Drelichowski</i>	<i>Jerzy Hołubiec</i>
<i>Olgierd Hryniewicz</i>	<i>Adam A. Janiak</i>	<i>Jerzy Józefczyk</i>
<i>Ignacy Kaliszewski</i>	<i>Józef Korbicz</i>	<i>Maciej Krawczak</i>
<i>Piotr Kulczycki</i>	<i>Małgorzata Łatuszyńska</i>	<i>Marek J. Malarski</i>
<i>Barbara Mażbic-Kulma</i>	<i>Zbigniew Nahorski</i>	<i>Andrzej Najgebauer</i>
<i>Włodzimierz Ogryczak</i>	<i>Wojciech Olejniczak</i>	<i>Jan W. Owsiański</i>
<i>Andrzej Piegat</i>	<i>Krzysztof Santarek</i>	<i>Roman Słowiński</i>
<i>Honorata Sosnowska</i>	<i>Henryk Spustek</i>	<i>Jan Stachowicz</i>
<i>Andrzej Straszak</i>	<i>Tomasz Szapiro</i>	<i>Andrzej Szymonik</i>
<i>Ryszard Tadeusiewicz</i>	<i>Eugeniusz Toczyłowski</i>	<i>Tadeusz Trzaskalik</i>
<i>Jan Węglarz</i>	<i>Tadeusz Witkowski</i>	<i>Stanisław Zajas</i>
	<i>Bogdan Zdrowski</i>	

Komitet Organizacyjny

Jan W. Owsiański, Andrzej Kałużko, Mieczysław Pelc, Zbigniew Piątek

Sekretariat

Krystyna Warzywoda, Monika Majkut, Aneta M. Pielak, Krzysztof Sep,
Anna Stachowiak, Halina Świeboda, Tadeusz Winiarski

Redakcja wydawnictw

Janusz Kacprzyk, Piotr Sienkiewicz, Andrzej Najgebauer,
Olgierd Hryniewicz, Andrzej Straszak, Jan Studziński,
Jan W. Owsiański, Zbigniew Nahorski, Tomasz Szapiro

Metody:
Optymalizacja, dane, analiza

OCENA ZDOLNOŚCI ALGORYTMÓW KLASYFIKACJI DO GENERALIZACJI WIEDZY

Dorota Dżęga, Wojciech Olejniczak
Wydział Informatyki Politechniki Szczecińskiej
ul. Żołnierska 49, 71 – 210 Szczecin

Wynik działania algorytmów klasyfikacji stanowi informacja określająca oczekiwane sposoby zachowania się systemu w postaci odpowiedzi dla danego zbioru wektorów wejściowych. Zadanie „uczenia” polega na nauce właściwych odpowiedzi poprzez obserwację sekwencji wektorów wejściowych. Wiedza pozyskana w ten sposób wykorzystywana jest do generowania nowej lub udoskonalenia istniejącej w systemie. W artykule przedstawiono wyniki badań dotyczące zdolności wybranych algorytmów klasyfikacji do generalizacji wiedzy na przykładzie oceny ryzyka projektów informatycznych.

1. Wprowadzenie

Zadania klasyfikacji i aproksymacji to najbardziej typowe sposoby wykorzystania wiedzy lub umiejętności. Zadania klasyfikacji polegają na uczeniu się pojęć, czyli na ustaleniu przynależności obiektów lub wzorców do danej kategorii. Natomiast zadania aproksymacji obejmują odwzorowanie obiektów lub wzorców na zbiór liczb rzeczywistych. Tradycyjny podział źródła oraz postaci dostępnej informacji, zwanej informacją trenującą to uczenie się z nadzorem (klasyfikacja) oraz uczenie się bez nadzoru (aproksymacja) (szerzej w Hand i in., 2005; Larose, 2005).

Dobór metod klasyfikacji stanów obiektów umożliwia znalezienie odwzorowania nowych danych na zdefiniowane uprzednio klasy. Odwzorowanie pozwala na pozyskanie wiedzy o systemie na podstawie informacji historycznej i znajduje zastosowanie w różnych dziedzinach działalności człowieka, przykładowo w klasyfikacji klientów oraz w diagnostyce medycznej. Podstawowe etapy działania systemów uczących się, przedstawiane w literaturze przedmiotu, między innymi w Cichosz (2007), Mulawka (1999), Patterson-Hine i in. (2005), obejmują selekcję, transformację, filtrację oraz przygotowanie danych, następnie dobór technik przetwarzania danych w zależności od charakteru danych oraz testowanie i walidację modeli uzyskanych w wyniku przetwarzania danych.

2. Wskaźniki oceny modeli predykcyjnych

Wybór modelu predykcyjnego najlepiej opisującego obiekty badawcze poprzedzony jest analizą rozkładu pomyłek. Analiza rozkładu pomyłek możliwa jest do przeprowadzenia poprzez dostępność macierzy pomyłek (ang. *confusion matrix*), pozwalającej na porównanie decyzji klasyfikatora z poprawnym zaklasyfikowaniem (przypisaniem) obiektów do klas. Macierz pomyłek umożliwia w prosty sposób ujawnienie nadmiernego dopasowania danych w sytuacji, gdy dany klasyfikator

przejawia nadmierną skłonność do generalizowania wiedzy uzyskanej na podstawie zbioru trenującego (szerzej w pracy Hand i in., 2005).

Najczęściej spotykaną przesłanką o podjęciu decyzji wykorzystania danego modelu do klasyfikacji przyszłych danych i przewidywania wartości nowych przykładów dla których wartość atrybutu decyzyjnego nie jest znana, prezentowaną w pracy Witten i Frank (2005), jest akceptacja danego poziomu dokładności modelu. Natomiast w pracach Hand i in. (2005) oraz Cichosz (2007) podkreślane jest znaczenie następujących wskaźników oceny zdolności modeli predykcyjnych do generalizacji wiedzy:

- **dokładność** (ang. *Correctly Classified Instances*) - procent przykładów poprawnie zaklasyfikowanych, wyrażona wzorem (1):

$$\frac{e(0,0) + e(1,1)}{e(0,0) + e(0,1) + e(1,0) + e(1,1)}, \quad (1)$$

- **skuteczność** (ang. *Recall*) - procent pozytywnych przykładów, które zostały wykryte, wyrażona wzorem (2):

$$\frac{e(1,1)}{e(0,1) + e(1,1)}, \quad (2)$$

- **precyzja** (ang. *Precision*) - procent wykrytych przykładów, które są pozytywne, wyrażona wzorem (3):

$$\frac{e(1,1)}{e(1,0) + e(1,1)}, \quad (3)$$

gdzie:

- $e(0,0)$ – liczba prawdziwych negatywnych (ang. *True Negatives*) – decyzja prawdziwa negatywna,
- $e(0,1)$ – liczba fałszywych negatywnych (ang. *False Negatives*) – decyzja fałszywa negatywna,
- $e(1,0)$ – liczba fałszywych pozytywnych (ang. *False Positives*) – decyzja fałszywa pozytywna,
- $e(1,1)$ – liczba prawdziwych pozytywnych (ang. *True Positives*) – decyzja prawdziwa pozytywna.

Powyższe postacie wskaźników znajdują zastosowanie dla klasyfikacji klasycznej dwustanowej. Natomiast w przypadku klasyfikacji wielostanowej przyjmują one następującą postać:

- **dokładność** (ang. *Correctly Classified Instances*) - procent przykładów poprawnie zaklasyfikowanych, wyrażona wzorem (4):

$$\frac{e(i,i)}{\sum_{j=0}^4 \sum_{i=0}^4 e(i,j)}, \quad (4)$$

- **skuteczność** (ang. *Recall*) - stosunek wyszukanych obiektów istotnych do całkowitej liczby obiektów istotnych w zbiorze danych, wyrażona wzorem (5):

$$\frac{e(i,i)}{\sum_{j=0}^4 e(j,i)}, \quad (5)$$

- **precyzja** (ang. *Precision*) - frakcja wyszukanych istotnych obiektów, wyrażona wzorem (6):

$$\frac{e(i,i)}{\sum_{j=0}^4 e(i,j)}. \quad (6)$$

gdzie:

- $e(j,j)$ - liczba prawdziwych negatywnych, decyzja prawdziwa negatywna,
- $e(j,i)$ - liczba fałszywych negatywnych, decyzja fałszywa negatywna,
- $e(i,j)$ - liczba fałszywych pozytywnych, decyzja fałszywa pozytywna,
- $e(i,i)$ - liczba prawdziwych pozytywnych, decyzja prawdziwa pozytywna.

Znajomość wskaźników oceny działania poszczególnych klasyfikatorów umożliwia wyselekcjonowanie zbioru atrybutów opisującego obiekty badawcze. Główne korzyści płynące ze zmniejszenia liczby atrybutów informacyjnych to między innymi usprawnienie procesu podejmowania decyzji poprzez wykorzystanie właściwych informacji oraz skrócenie czasu klasyfikacji nowych przypadków.

3. Wyniki przeprowadzonych badań

Przeprowadzone badania dotyczyły zastosowanie wielostanowej klasyfikacji jako metody prognostycznej do opracowania zobiektywizowanego rozwiązania pozwalającego na usprawnienie procesu decyzyjnego podczas planowania oraz realizacji projektów informatycznych. Wybór metod klasyfikacji został podyktowany specyficznym charakterem projektów informatycznych, gdzie podstawowe problemy wpływające na możliwość szacowania wielkości to przede wszystkim: duża nieokreśloność projektów softwarowych, „pływający zakres” (ang. *floating scope*), czy też wysoka unikalność przedsięwzięć.

Eksperymenty badawcze przeprowadzono na bazie projektów software'owych udostępnianych na licencji FLOSS (ang. *Free/Libre/Open Source Softwa-*

re). Projekty informatyczne opisano za pomocą trzech obiektów badawczych: projektu, zadania projektowego oraz wykonawcy projektu. Atrybuty decyzyjne wyłonię w obrębie wymienionych powyżej obiektów badawczych obejmowały:

- zakres projektu $Z(t)$ – liczba miesięcy trwania danej kategorii projektu od momentu podjęcia decyzji o rozpoczęciu projektu (rejestracji projektu) do ostatniej publikacji jego efektów,
- czas trwania projektu $C(t)$ – liczba roboczogodzin przeznaczona na realizację danego zadania,
- koszt prac projektowych $K(t)$ – przeciętna liczba roboczogodzin przypadających na realizację zadania przez danego wykonawcę,
- efekty projektu $E(t)$ – liczba zamkniętych zadań (stan na dzień przeprowadzenia diagnozy).

Zakres projektu oraz efekty projektu wraz ze zbiorami atrybutów informacyjnych dotyczyły obiektu badawczego: projekt. Czas trwania projektu wraz ze zbiorem atrybutów informacyjnych posłużył do reprezentacji obiektu badawczego: zadanie projektowe. Natomiast, atrybut decyzyjny koszt prac projektowych wraz ze zbiorem atrybutów informacyjnych reprezentował wykonawcę projektu. Źródło danych pierwotnych o obiektach badawczych stanowiło repozytorium projektów zarejestrowanych na platformie SourceForge.net.

Wyjściowe zbiory atrybutów informacyjnych umożliwiających dokonanie predykcji przynależności do danej klasy decyzyjnej dla odpowiednich atrybutów decyzyjnych przedstawiała się następująco:

- zakresu projektu – 39 atrybutów opisujących dziedzinę projektu, zasoby projektu oraz komunikację zachodzącą w projekcie,
- czas trwania prac projektowych – 12 atrybutów opisujących ogólne warunki realizacji zadania oraz zasoby wykonawców zadania,
- koszt prac projektowych – 18 atrybutów opisujących kompetencje danego wykonawcy oraz jego aktywność w realizowanych przedsięwzięciach,
- efekty projektu – 21 atrybutów opisujących przebieg prac projektowych oraz aktywność komunikacji w danym przedsięwzięciu.

Wyłonię obiekty badawcze wraz z atrybutami decyzyjnymi oraz informacyjnymi stanowiły podstawowe składowe wielowymiarowej oceny ryzyka projektów informatycznych (szerzej w Dżega i Olejniczak, 2008).

W przeprowadzonych badaniach zastosowano następujące algorytmy klasyfikacji: drzewo decyzyjne C4.5, drzewo losowe (ang. *Random Tree*, *RT*), sieć bayesowską (ang. *Bayesian Belief Network*, *BBN*) oraz perceptron wielowarstwowy (ang. *Multilayer Perceptron*, *MLP*). Testowanie modeli predykcyjnych przeprowadzono z zastosowaniem 5-krotnej walidacji krzyżowej (ang. *Cross-Validation*, *CV-5*).

W celu zachowania równej liczebności klas zastosowano, w przypadku zbiorów danych reprezentujących atrybuty decyzyjne $C(t)$, $K(t)$ oraz $E(t)$ zastosowano procedurę *resamplingu*, polegającą na redukcji próbek z wyrównaniem do klasy o najmniejszej liczebności. W przypadku atrybutu decyzyjnego $Z(t)$ zaobserwowano równomierny rozkład próbek badawczych we wszystkich klasach, zbiór ten nie wymagał redukcji przykładów. Przyjęto podział atrybutów decyzyjnych na pięć klas, działanie to miało na celu umożliwienie dokonywania oszacowań jak najbardziej zbliżonych do warunków, w których realizowane są projekty informatyczne oraz stanowiło kompromis między rozpiętością prognozy a jej dokładnością. Szczegółowy przebieg eksperymentów badawczych oraz otrzymanych rezultatów zawiera praca Dżega (2008).

Jakość klasyfikacji powinna uwzględniać specyfikę zbioru danych, w zależności od łatwości separacji klas, jak i prawdopodobieństwo „ślepego trafu”. W przeprowadzonych badaniach prawdopodobieństwo „ślepego trafu” dla równego rozkładu klas, przy podziale atrybutów decyzyjnych w prezentowanych badaniach na pięć klas, wyniosło 20%. Do oceny zdolności predykcyjnych modeli klasyfikacyjnych uzyskanych w badaniach wykorzystano wskaźniki dokładności, skuteczności oraz precyzji.

W Tabeli 1 przedstawiono najlepsze modele predykcyjne uzyskane w wyniku przeprowadzonych eksperymentów. Oznaczenie „A” w Tabeli 1 informuje o liczbie atrybutów informacyjnych wymaganych w danym modelu.

Tabela 1. Modele predykcyjne o najwyższym współczynniku dokładności

Klasyfikator	Zakres projektu, $Z(t)$		Czas trwania projektu, $C(t)$		Koszt prac projektowych, $K(t)$		Efekty projektu, $E(t)$	
	Dokładność	A	Dokładność	A	Dokładność	A	Dokładność	A
BBN	93.61%	9	60.24%	9	69.80%	6	46.18%	12
C4.5	97.36%	9	67.65%	9	78.27%	6	55.31%	12
MLP	44.44%	9	34.57%	7	38.61%	6	38.51%	3
RT	99.28%	9	71.87%	4	91.98%	6	76.83%	12

Źródło: opracowanie własne


Ocena dokładności modeli predykcyjnych dla wyselekcjonowanych zbiorów atrybutów informacyjnych w przypadku atrybutu decyzyjnego $Z(t)$ ukazała zbliżone wartości uzyskane dla trzech klasyfikatorów: drzewo losowe, drzewo decyzyjne C4.5 oraz sieć bayesowska. Najdokładniej działający klasyfikator drzewo losowe osiągnął wynik 99.28% poprawnie zaklasyfikowanych przypadków.

Podobna sytuacja miała miejsce w przypadku atrybutu decyzyjnego $C(t)$. Najwyższą dokładność modelu uzyskano dla klasyfikator drzewo losowe 71.87% poprawnie zaklasyfikowanych przypadków. W przypadku atrybutu decyzyjnego $K(t)$ zbliżone wartości uzyskano dla dwóch klasyfikatorów: drzewo decyzyjne C4.5 oraz sieć bayesowska. Najdokładniej działający klasyfikator losowe osiągnął wynik 91.98% poprawnie zaklasyfikowanych przypadków. Ocena dokładności modeli

predykcyjnych dla atrybutu decyzyjnego $E(t)$ ukazała znaczne rozbieżności pomiędzy wynikami uzyskanymi dla poszczególnych klasyfikatorów. Najdokładniej działający klasyfikator drzewo losowe osiągnął wynik 76.83% poprawnie zaklasyfikowanych przypadków.

Na Rys. 1–4 przedstawiono rozkład wskaźników skuteczności oraz precyzji dla modeli predykcyjnych o najwyższym współczynniku dokładności. Oznaczenia I, II, III, IV, V informują o etykietach klas atrybutów decyzyjnych.


Rys. 1. Rozkład wskaźników skuteczności i precyzji w poszczególnych klasach atrybut decyzyjnego zakres projektu



Źródło: opracowanie własne

W przypadku atrybutu decyzyjnego zakres projektu najwyższą precyzję odnotowano dla drzewa losowego, kształtującą się na średnim poziomie 99.28%, odchylenie standardowe rozkładu próbek od wartości średniej wahało się w granicach $\pm 0.26\%$. Najniższą precyzję modelu uzyskano dla perceptronu wielowarstwowego o przeciętnej wartości 45.50%, odchylenie standardowe rozkładu próbek od wartości średniej wahało się w granicach $\pm 8.46\%$. Najwyższą skuteczność klasyfikacji odnotowano dla drzewa losowego, kształtującą się na przeciętnym poziomie 99.30%, odchylenie standardowe rozkładu próbek od wartości średniej wahało się w granicach $\pm 00.58\%$ (Rys. 1).


Rys. 2. Rozkład wskaźników skuteczności i precyzji w poszczególnych klasach atrybut decyzyjnego *czas trwania projektu*



Źródło: opracowanie własne

Dla atrybutu decyzyjnego *czas trwania projektu* najwyższą precyzję odnotowano dla drzewa losowego, kształtującą się na średnim poziomie 72.30%. Najniższą wartość odchylenia standardowego zaobserwowano dla drzewa decyzyjnego C4.5 kształtującą się na poziomie $\pm 3.84\%$. Najniższą przeciętną precyzję modelu uzyskano dla perceptronu wielowarstwowego, 34.92%. Najwyższą przeciętną skuteczność odnotowano dla drzewa losowego, 71.90%, odchylenie standardowe rozkładu próbek wahało się w granicach $\pm 4.68\%$ (Rys. 2).

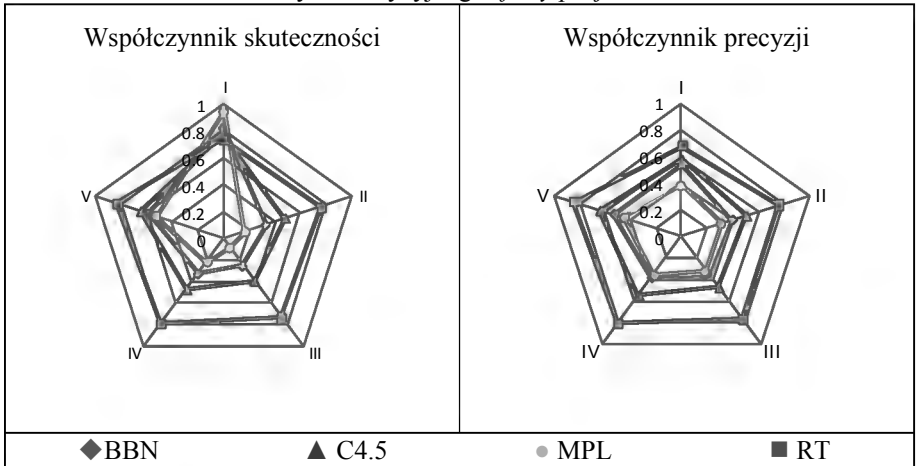
Rys. 3. Rozkład wskaźników skuteczności i precyzji w poszczególnych klasach atrybut decyzyjnego *koszt prac projektowych*



Źródło: opracowanie własne

W przypadku atrybutu decyzyjnego koszt prac projektowych najwyższą precyzję odnotowano w przypadku klasyfikatora drzewo losowe, kształtującą się na średnim poziomie 92.08%, odchylenie standardowe rozkładu próbek od wartości średniej wahało się w granicach $\pm 2.50\%$. Najniższą precyzję modelu uzyskano dla klasyfikatora perceptron wielowarstwowy przyjmująca przeciętną wartość 38.60%, odchylenie standardowe wahało się w granicach $\pm 17.68\%$. Najwyższą skuteczność klasyfikacji odnotowano dla klasyfikatora drzewo losowe, kształtującą się na przeciętnym poziomie 91.96%, odchylenie standardowe wahało się w granicach $\pm 1.38\%$ (Rys. 3).

Rys. 4. Rozkład wskaźników skuteczności i precyzji w poszczególnych klasach atrybut decyzyjnego efekty projektu



Źródło: opracowanie własne

W przypadku atrybutu decyzyjnego efekty projektu najwyższą precyzję odnotowano w przypadku klasyfikatora drzewo losowe. Przeciętny poziom wskaźnika precyzji kształtował się na średnim poziomie 77.02%, odchylenie standardowe wahało się w granicach $\pm 6.25\%$. Najniższą precyzję modelu uzyskano dla klasyfikatora perceptron wielowarstwowy przyjmująca przeciętną wartość 36.32%. Najwyższą wartość odchylenia standardowego kształtującą się na poziomie $\pm 8.60\%$ zaobserwowano dla klasyfikatora sieć bayesowska. Najwyższą skuteczność klasyfikacji odnotowano dla klasyfikatora drzewo losowe, kształtującą się na przeciętnym poziomie 76.84%, odchylenie standardowe wahało się w granicach $\pm 4.41\%$ (Rys. 4).

W wyniku przeprowadzonych badań najlepsze rezultaty otrzymano dla drzew losowych (RT), dobre wyniki dały również takie klasyfikatory jak: drzewo C4.5 oraz sieci bayesowskie (BBN). Natomiast, zaobserwowany niski poziom klasyfikacji dla perceptronu wielowarstwowego (MLP) mógł wynikać ze znacznego udziału w próbie badawczej zmiennych kategoriowych, nie będących zmiennymi porządkowymi. Analiza rozkładu odchylenia standardowego dla zaprezentowanych wartości wskaźników precyzji oraz skuteczności w poszczególnych klasach wskazała na stabilne zachowanie klasyfikatorów drzewiastych. Ponadto, najlepsze rezultaty

otrzymano dla zbioru danych reprezentującego zakres projektu, który charakteryzował się równomiernym rozkładem próbek w poszczególnych klasach decyzyjnych i nie wymagał redukcji przykładów.

4. Podsumowanie

Zaprezentowane badania ukazały wartość informacji płynącą z analizy wskaźników skuteczności oraz precyzji. Ukazano, że posługiwanie się wyłącznie wskaźnikami dokładności lub błędu prognozy w zadaniach dotyczących zachowania danych obiektów w przyszłości, może okazać się niewystarczające. Zaakcentowano, także znaczenie wartości odchylenia standardowego wskaźników skuteczności oraz precyzji, przedstawiającego rzeczywisty rozkład próbek badawczych w odniesieniu do poszczególnych klas decyzyjnych. Wybór klasyfikatora powinien zostać poprzedzony przetestowaniem zachowania danego zbioru danych przy zastosowaniu różnych algorytmów klasyfikacji oraz obserwacją rozkładu wskaźników skuteczności i precyzji w odniesieniu do poszczególnych klasach.

Praca naukowa finansowana ze środków na naukę w latach 2007-2008 jako projekt badawczy N115 080 32/4229.

Literatura

- Cichosz P. (2007) *Systemy uczące się.*, Wydawnictwa Naukowo-Techniczne, Warszawa.
- Dżęga D. (2008) *Metoda oceny ryzyka projektów informatycznych.* Rozprawa doktorska, Wydział Informatyki Politechniki Szczecińskiej.
- Dżęga D. i Olejniczak W. (2008) Wielowymiarowa ocena ryzyka projektów informatycznych. *Materiały konferencyjne X Krajowej Konferencji Inżynierii Oprogramowania KKIO'2008, Szklarska Poręba 2008.*
- Hand D. i in. (2005) *Eksploracja danych.* Wydawnictwa Naukowo-Techniczne, Warszawa.
- Larose D. (2005) *Discovering knowledge in data. An Introduction to Data Mining.* Wiley&Sons. New Jersey, 2005
- Mulawka J. (1999) *Systemy ekspertowe.* Wydawnictwa Naukowo-Techniczne, Warszawa.
- Patterson-Hine A. i in. (2005) *A Review of Diagnostic Techniques for ISHM Applications.* NASA.
- Witten I. i Frank E. (2005) *Data Mining. Practical Machine Learning Tools and Techniques.* Second Edition, Morgan Kaufmann Publishers.

IBS PAN *Konf.*

46003

Bibl. podręczna

**Olgierd Hryniewicz, Andrzej Straszak, Jan Studziński
red.**

**BADANIA OPERACYJNE I SYSTEMOWE:
ŚRODOWISKO NATURALNE, PRZESTRZEŃ,
OPTYMALIZACJA**

Książka składa się z artykułów przedstawiających wyniki prac z dziedziny badań operacyjnych i systemowych, poświęconych środowisku naturalnemu i zarządzaniu nim, zwłaszcza w zakresie ochrony atmosfery, globalnego ocieplenia i walki z nim, jakości i zaopatrzenia w wodę. Tematyka ta jest rozszerzona o aspekty przestrzenne, regionalne i samorządowe, a także planowanie i funkcjonowanie infrastruktury. Tom zamykają prace metodyczne, dostarczające technik, będących podstawą prezentowanych zastosowań.

ISBN 83-894-7519-7

EAN 9788389475190

Instytut Badań Systemowych PAN
tel. (4822) 3810241 / 3810273 e-mail: biblioteka@ibspan.waw.pl