

ZASTOSOWANIE ROZMYTEJ MAPY KOGNITYWNEJ W PROGNOZOWANIU EFEKTYWNOŚCI PRACY WYPOŻYCZALNI ROWEROWYCH

Aleksander Jastriebow, Łukasz Kubuś, Katarzyna Poczęta

¹Politechnika Świętokrzyska, Katedra Systemów Informatycznych

Streszczenie. W pracy zaproponowano zastosowanie rozmytej mapy kognitywnej wraz z ewolucyjnymi algorytmami uczenia do modelowania systemu prognozowania efektywności pracy wypożyczalni rowerowych. Na podstawie danych historycznych zbudowano rozmytą mapę kognitywną, którą następnie zastosowano do prognozowania liczby rowerzystów i klientów wypożyczalni w trzech kolejnych dniach. Proces uczenia zrealizowano z zastosowaniem indywidualnego kierunkowego algorytmu ewolucyjnego IDEA oraz algorytmu genetycznego z kodowaniem zmiennoprzecinkowym RCGA. Analizę symulacyjną systemu prognozowania efektywności pracy wypożyczalni rowerowych przeprowadzono przy pomocy oprogramowania opracowanego w technologii JAVA.

Słowa kluczowe: rozmyta mapa kognitywna, model prognozowania, obliczenia ewolucyjne, uczenie maszynowe

APPLICATION OF FUZZY COGNITIVE MAP TO PREDICT OF EFFECTIVENESS OF BIKE SHARING SYSTEMS

Abstract. This paper proposes application of fuzzy cognitive map with evolutionary learning algorithms to model a system for prediction of effectiveness of bike sharing systems. Fuzzy cognitive map was constructed based on historical data and next used to forecast the number of cyclists and customers of bike sharing systems on three consecutive days. The learning process was realized with the use of Individually Directional Evolutionary Algorithm IDEA and Real-Coded Genetic Algorithm RCGA. Simulation analysis of the system for prediction of effectiveness of bike sharing systems was carried out with the use of software developed in JAVA.

Keywords: fuzzy cognitive map, predictive model, evolutionary computation, machine learning

Wstęp

Rozmyta mapa kognitywna (ang. *fuzzy cognitive map* FCM) to inteligentny model umożliwiający zobrazowanie działania złożonych systemów dynamicznych. Budowa FCM polega na wyborze zbioru czynników istotnych dla analizowanego problemu i określeniu powiązań pomiędzy nimi [11]. Rozmyte mapy kognitywne znajdują zastosowanie w modelowaniu systemów wspomagania decyzyjnego, m.in. w predykcji szeregów czasowych [8, 17].

Zaletą zastosowania rozmytych map kognitywnych jest możliwość ich budowy na podstawie dostępnych historycznych danych. W ostatnich latach wzrosło zainteresowanie tą tematyką wśród naukowców [14]. W pracach [6, 18] zaprezentowano efektywność ewolucyjnych algorytmów uczenia FCM. Wielokrokowy algorytm nadzorowany bazujący na metodzie gradientowej przedstawiono w [15]. Praca [21] dotyczy uczenia rozmytych map kognitywnych bazującego na algorytmie „big bang big crunch”. Imperialistyczny konkurencyjny algorytm uczenia FCM zaproponowano w [2]. W [1] zastosowano memetyczny algorytm do inicjalizacji struktury mapy. Pewne rozszerzenia klasycznych genetycznych algorytmów uczenia rozmytych map kognitywnych pozwalające na wybór tylko najistotniejszych powiązań między czynnikami przedstawiono w [16, 19].

Niniejsza praca poświęcona jest zastosowaniu rozmytej mapy kognitywnej wraz z indywidualnym kierunkowym algorytmem ewolucyjnym (ang. *Individually Directional Evolutionary Algorithm* IDEA) [9, 12] oraz algorytmem genetycznym z kodowaniem zmiennoprzecinkowym (ang. *Real-Coded Genetic Algorithm* RCGA) [18] w prognozowaniu efektywności pracy wypożyczalni rowerowych. Uczenie i testowanie FCM przeprowadzono na podstawie historycznych danych pobranych z Repozytorium Uczenia Maszynowego UCI [5]. Eksperymenty przeprowadzono przy pomocy oprogramowania opracowanego w technologii JAVA.

Rozdział 1 krótko charakteryzuje rozmyte mapy kognitywne. W rozdziale 2 przedstawiono zastosowane w uczeniu FCM algorytmy ewolucyjne. Wybrane wyniki analizy symulacyjnej proponowanego systemu prognozowania efektywności pracy wypożyczalni rowerowych zaprezentowano w rozdziale 3. Ostatni rozdział stanowi podsumowanie pracy.

1. Rozmyta mapa kognitywna

Rozmyta mapa kognitywna to graf skierowany, którego zbiór wierzchołków X odpowiada czynnikom istotnym dla analizowanego zagadnienia. Czynniki te wpływają na siebie z siłą opisaną przez macierz powiązań między nimi R . FCM można opisać jako parę uporządkowaną:

$$\langle X, R \rangle \quad (1)$$

gdzie: $X = [X_1, \dots, X_n]^T$ – wektor wartości czynników mapy, X_i – wartość i -tego czynnika mapy, liczba z przedziału $[0, 1]$, $R = \{r_{j,i}\}$ – macierz powiązań pomiędzy czynnikami, $r_{j,i}$ – waga powiązania pomiędzy j -tym i i -tym czynnikiem, liczba z przedziału $[-1, 1]$, $i, j = 1, \dots, n$, n – liczba czynników.

Wartości czynników FCM w kolejnych iteracjach wyznaczone są na podstawie wybranego modelu dynamiki. W pracy zastosowano często stosowany model opisany zależnością [2, 18, 19]:

$$X_i(t+1) = f \left(X_i(t) + \sum_{\substack{j=1 \\ j \neq i}}^n X_j(t) \cdot r_{j,i} \right) \quad (2)$$

gdzie: t – dyskretny czas (numer kolejnej iteracji), $t = 0, 1, \dots, T$, T – czas symulacji, f – sigmoidalna funkcja stabilizująca:

$$f(x) = \frac{1}{1 + e^{-cx}} \quad (3)$$

gdzie: c – parametr, $c > 0$.

Podstawowym elementem związanym z modelowaniem systemów predykcji szeregów czasowych z zastosowaniem rozmytej mapy kognitywnej jest proces uczenia macierzy powiązań R na podstawie dostępnych historycznych danych. Poniżej przedstawiono ewolucyjne algorytmy uczenia FCM.

2. Ewolucyjne algorytmy uczenia

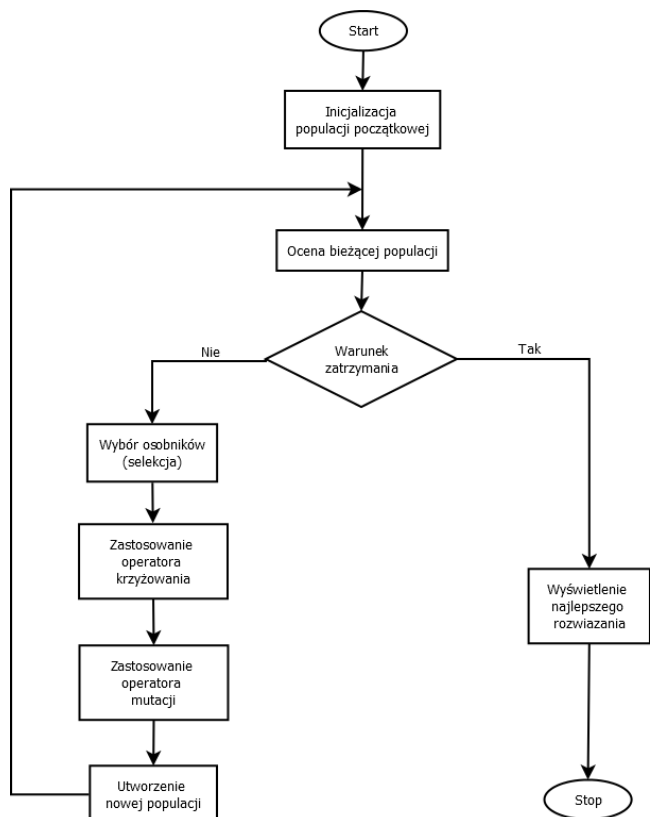
Ewolucyjne algorytmy uczenia pozwalają na utworzenie rozmytej mapy kognitywnej przy wykorzystaniu dostępnych danych historycznych [18, 19]. W pracy analizowano jeden z najpopularniejszych algorytmów uczenia FCM – algorytm genetyczny z kodowaniem zmiennoprzecinkowym RCGA oraz opracowany indywidualny kierunkowy algorytm ewolucyjny IDEA.

2.1. Algorytm genetyczny z kodowaniem zmiennoprzecinkowym

Algorytm genetyczny z kodowaniem zmiennoprzecinkowym wykorzystuje do reprezentacji rozwiązania wektor liczb rzeczywistych [3, 7]. Działanie tego algorytmu zilustrowano na rysunku 1. Schemat działania algorytmu RCGA jest zgodny z klasycznym algorytmem genetycznym zaproponowanym przez Hollanda [7]. Algorytm rozpoczyna się inicjalizacją i oceną populacji początkowej. Następnym etapem jest pętla ewolucyjna, w której następuje zastosowanie operatorów genetycznych takich jak krzyżowanie i mutacja. Utworzona populacja jest oceniana, a następnie sprawdzany jest warunek zatrzymania algorytmu. Kryterium zatrzymania algorytmu może być osiągnięcie zakładanej liczby iteracji (generacji) lub otrzymanie satysfakcjonującego wyniku reprezentowanego przez jednego z osobników populacji [3].

Stosowanie reprezentacji zmiennoprzecinkowej w procesie uczenia rozmytej mapy kognitywnej jest wygodne i powszechnie stosowane [9, 16, 18, 19]. Proces uczenia zakłada bowiem znalezienie macierzy wag, która jest kluczowa do prognozowania wybranych wartości przy pomocy danych historycznych. Macierz ta zawiera liczby zmiennoprzecinkowe. Stosowanie tej reprezentacji jest prostsze i wydajniejsze niż zastosowanie reprezentacji jako łańcucha binarnego. Kodowanie binarne powodowałoby nieefektywność algorytmu genetycznego spowodowane przez duży rozmiar genotypu [7].

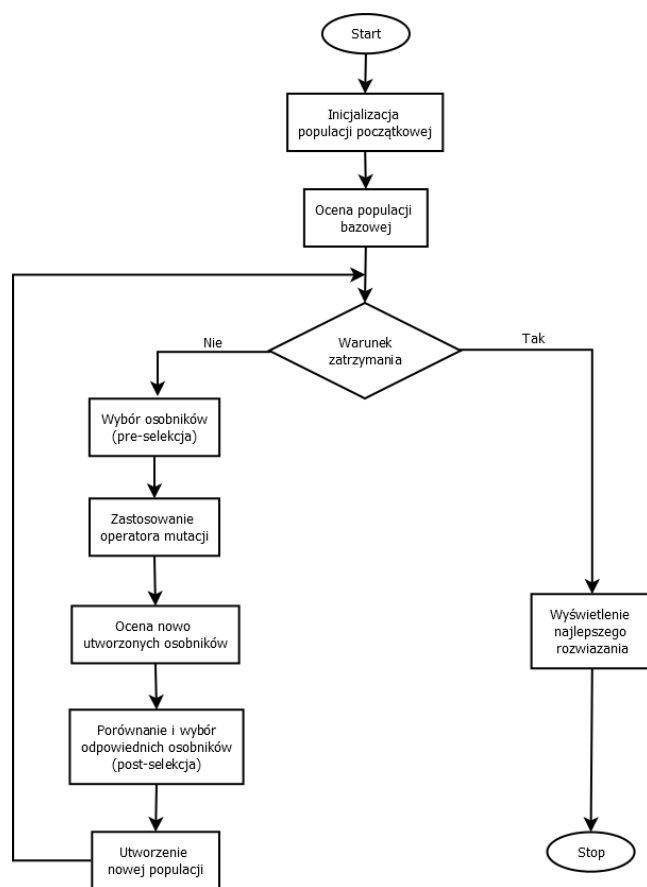
Reprezentacja zmiennoprzecinkowa pozwala również na wykorzystanie złożonych operatorów genetycznych. Można do nich zaliczyć: krzyżowanie uśredniające [3] oraz operatory mutacji takie jak mutacja losowa wykorzystująca rozkład normalny lub rozkład Cauchy'ego [3], a także mutację niejednorodną [13]. Charakterystyczną grupę operatorów mutacji dla reprezentacji zmiennoprzecinkowej stanowią kierunkowe operatory mutacji [4, 10, 20]. Działanie tych operatorów nie jest wyłącznie losowe. Wykorzystują one dodatkowe informacje o populacji oraz poprzednich generacjach.



Rys. 1. Schemat algorytmu RCGA

2.2. Indywidualny kierunkowy algorytm ewolucyjny

Indywidualny kierunkowy algorytm ewolucyjny [9, 12] wykorzystuje charakterystyczne elementy algorytmu ewolucyjnego: preselekcja proporcjonalna (ruletkowa) z dynamicznym liniowym skalowaniem funkcji przystosowania [7], kierunkowa mutacja niejednorodna. Schemat działania IDEA przedstawia rysunek 2. Inicjacja pętli ewolucyjnej wygląda tak samo jak w każdym algorytmie ewolucyjnym. Na pętli ewolucyjnej składają się cztery etapy. W etapie pierwszym z obecnej populacji bazowej P^t wybierane są osobniki, które zostaną poddane mutacji. Osobniki te tworzą populację tymczasową T^t . W kolejnym etapie utworzona zostaje druga populacja tymczasowa T^t , zawierająca nowe osobniki utworzone w wyniku działania operacji genetycznych (operatora mutacji) na populacji T^t . W etapie trzecim następuje ocena nowoutworzonych osobników z populacji tymczasowej T^t . Ostatni etap to utworzenie nowej populacji bazowej P^{t+1} poprzez wybór osobników z obu populacji tymczasowych.



Rys. 2. Schemat algorytmu IDEA

Operator kierunkowej mutacji niejednorodnej [12] to zmodyfikowany operator mutacji niejednorodnej [4]. Wprowadzona zmiana działania operatora polega na modyfikacji genu osobnika zgodnie z wartością odpowiadającego mu elementu wektora kierunku d_i :

$$y_i = \begin{cases} x_i - \Delta(t, x_i - l_i) & \text{dla } d_i = -1 \\ x_i + \Delta(t, u_i - x_i) & \text{dla } d_i = 1 \end{cases} \quad (4)$$

gdzie: d_i – kierunek modyfikacji i -tego genu, x_i – aktualna wartość i -tego genu, y_i – nowa wartość i -tego genu, t – numer generacji, $x_i \in [l_i, u_i]$, $y_i \in [l_i, u_i]$, $i = 1, 2, 3, \dots, n$.

Efektym działania operatora jest modyfikacja losowo wybranego jednego i tylko jednego elementu wektora osobnika reprezentującego rozwiązanie. Pozwala to na korygowanie kierunku mutacji w procesie post-selekcji [12].

3. Wybrane wyniki analizy symulacyjnej

Celem analizy symulacyjnej jest modelowanie systemu prognozowania efektywności pracy wypożyczalni rowerowych na podstawie historycznych danych pobranych z Repozytorium Uczenia Maszynowego UCI. Zbiór zawiera dzienne pomiary dane uzyskane z systemów wypożyczalni rowerowych [5]:

X_1 – wakacje (tak, nie),

X_2 – weekend (tak, nie),

X_3 – dzień pracujący (wakacje lub weekend, dzień pracujący),

X_4 – warunki pogodowe (pogodnie, pochmurnie, śnieg, duży deszcz),

X_5 – temperatura,

X_6 – temperatura odczuwalna,

X_7 – wilgotność,

X_8 – prędkość wiatru,

X_9 – liczba zwykłych rowerzystów – czynnik wyjściowy,

X_{10} – liczba klientów wypożyczalni rowerowych – czynnik wyjściowy.

Systemy wypożyczalni rowerów to nowa generacja tradycyjnych wypożyczalni pozwalające na automatyzację procesu wynajmu rowerów w jednym punkcie i zwrotu w innym miejscu. Odrzuwają ważną rolę w kwestii ruchu drogowego, ochrony środowiska i zdrowia. Monitorowanie danych uzyskiwanych z czujników oraz prognozowanie liczby rowerzystów stanowi istotny element ułatwiający ocenę efektywności pracy wypożyczalni i wspomagający procesy decyzyjne [5].

Celem przeprowadzonej analizy symulacyjnej jest predykcja liczby rowerzystów X_9 oraz klientów wypożyczalni X_{10} w trzech kolejnych dniach (wartości czynników wyjściowych w trzech kolejnych iteracjach) na podstawie aktualnych pomiarów. Do budowy modeli FCM użyto danych uczących pochodzących z poszczególnych miesięcy pierwszego roku obserwacji. Celem procesu uczenia z zastosowaniem algorytmów RCGA i IDEA jest minimalizacja błędów uczenia opisanego zależnością (5). Do testowania uzyskanych modeli zastosowano dane z odpowiednich miesięcy kolejnego roku obserwacji. Wynikowe mapy oceniano na podstawie błędów prognozowania dla danych uczących J_u (5) oraz dla danych testowych J_t (6).


$$J_u = \frac{1}{3(T_u - 3)2} \sum_{t=1}^{T_u} \sum_{i=1}^2 \sum_{k=0}^2 |Z_i^w(t+k) - X_i^w(t+k)| \quad (5)$$

gdzie: T_u – liczba rekordów uczących, $X_i^w(t+k)$ – prognozowana wartość i -tego czynnika wyjściowego w kolejnych iteracjach $t+k$, $Z_i^w(t+k)$ – zadana wartość i -tego czynnika wyjściowego w kolejnych iteracjach $t+k$ dla rekordów uczących.

$$J_t = \frac{1}{3(T_t - 3)2} \sum_{t=1}^{T_t} \sum_{i=1}^2 \sum_{k=0}^2 |Z_i^w(t+k) - X_i^w(t+k)| \quad (6)$$

gdzie: T_t – liczba rekordów testowych, $X_i^w(t+k)$ – prognozowana wartość i -tego czynnika wyjściowego w kolejnych iteracjach $t+k$, $Z_i^w(t+k)$ – zadana wartość i -tego czynnika wyjściowego w kolejnych iteracjach $t+k$ dla rekordów testowych.

Symulacje przeprowadzono za pomocą opracowanej biblioteki Java umożliwiającej analizę zastosowania algorytmów ewolucyjnych w uczeniu rozmytych map kognitywnych. Oprogramowanie umożliwia inicjalizację rozmytej mapy kognitywnej oraz przeprowadzenie procesu uczenia z zastosowaniem algorytmu genetycznego z kodowaniem zmiennoprzecinkowym oraz indywidualnego kierunkowego algorytmu ewolucyjnego. Rysunek 3 prezentuje przykładową strukturę systemu prognozowania efektywności pracy wypożyczalni rowerowych bazującego na FCM. W tabeli 1. zaprezentowano uzyskane wartości błędów prognozowania dla danych uczących J_u i danych testowych J_t w poszczególnych miesiącach.




Rys. 3. Przykładowa struktura rozmytej mapy kognitywnej

Tabela 1. Wybrane wyniki analizy symulacyjnej

Algorytm	Miesiąc	J_u	J_t
RCGA	I	0,04044568	0,156065426
	II	0,049760327	0,178264647
	III	0,066438442	0,308095219
	IV	0,099893948	0,292347874
	V	0,092090885	0,245443656
	VI	0,07929454	0,25317886
	VII	0,103243502	0,21660568
	VIII	0,077438485	0,242513526
	IX	0,099974465	0,286390754
	X	0,09588997	0,275569588
	XI	0,083182564	0,205199513
	XII	0,086976271	0,17703638
Średnia		0,081219	0,236393
IDEA	I	0,024026	0,150057894
	II	0,036409	0,163694966
	III	0,052072	0,300632201
	IV	0,070353	0,269461892
	V	0,072866	0,222614149
	VI	0,05774	0,22386808
	VII	0,08468	0,221658811
	VIII	0,062865	0,23718716
	IX	0,084218	0,331720679
	X	0,088271	0,3129148
	XI	0,05745	0,209604568
	XII	0,054883	0,159559496
Średnia		0,062153	0,233581

Modele FCM uzyskane dla algorytmu RCGA uzyskały średni błąd prognozowania liczby rowerzystów w trzech kolejnych dniach dla danych uczących $J_u = 0,081219$ oraz dla danych testowych które różniły się znacząco od uczących $J_t = 0,236393$. Zastosowanie opracowanego algorytmu IDEA pozwoliło na zwiększenie dokładności predykcji i otrzymanie odpowiednio $J_u = 0,062153$ oraz $J_t = 0,233581$. Uzyskane modele systemu prognozowania efektywności wypożyczalni rowerowych mogą stanowić wsparcie dla procesów decyzyjnych w wypożyczalniach.

Rysunek 4 prezentuje prognozowaną liczbę klientów wypożyczalni rowerowych w następnym dniu w odniesieniu do wartości wzorcowych $Z_{10}(t)$ dla miesiąca styczeń dla pierwszego roku obserwacji.



Rys. 4. Przykładowe wyniki testowania nauczonej mapy dla danych uczących z miesiąca styczeń

Na podstawie otrzymanych wyników można stwierdzić że rozmyta mapa kognitywna wraz z ewolucyjnymi algorytmami uczenia stanowi efektywne narzędzie modelowania systemu prognozowania efektywności pracy wypożyczalni rowerowych.

4. Wnioski

Praca dotyczy analizy symulacyjnej zastosowania rozmytej mapy kognitywnej wraz z ewolucyjnymi algorytmami uczenia w prognozowaniu efektywności pracy wypożyczalni rowerowych poprzez predykcję liczby zwykłych rowerzystów oraz klientów wypożyczalni w trzech kolejnych dniach na podstawie aktualnych wartości analizowanych czynników. Krótko scharakteryzowano podstawowe własności rozmytych map kognitywnych oraz zastosowane metody uczenia: algorytm genetyczny z kodowaniem zmiennoprzecinkowym oraz indywidualny kierunkowy algorytm ewolucyjny. Zaprezentowano wybrane wyniki analizy symulacyjnej przeprowadzonej na podstawie historycznych danych. Uzyskane wyniki potwierdzają dostateczną efektywność zastosowania rozmytej mapy kognitywnej i ewolucyjnych algorytmów uczenia w prognozowaniu efektywności pracy wypożyczalni rowerowych.

Literatura

- [1] Acampora G., Pedrycz W., Vitiello A.: A Competent Memetic Algorithm for Learning Fuzzy Cognitive Maps. *IEEE Transactions on Fuzzy Systems* 23(6)/2015, 2397–2411.
- [2] Ahmadi S., Alizadeh S., Forouzideh N., Yeh C., Martin R. L., Papageorgiou E.: ICLA: Imperialist Competitive Learning Algorithm for Fuzzy Cognitive Map. *Proceedings of the 2014 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, Beijing, China, 2014.
- [3] Arabas J.: Wykłady z algorytmów ewolucyjnych, WNT, Warszawa 2001.
- [4] Berry A., Vamplew P.: PoD Can Mutate: A Simple Dynamic Directed Mutation Approach for Genetic Algorithms. *Proceedings of AISAT 2004: The 2nd International Conference on Artificial Intelligence in Science and Technology*, 2004, 200–205.
- [5] Fanaee-T H., Gama J.: Event labeling combining ensemble detectors and background knowledge. *Progress in Artificial Intelligence*, Springer Berlin Heidelberg, 2013, 1–15.
- [6] Froelich W., Papageorgiou E.: Extended Evolutionary Learning of Fuzzy Cognitive Maps for the Prediction of Multivariate Time-Series. *Papageorgiou E.I.: Fuzzy Cognitive maps for Applied Sciences and Engineering From fundamentals to extensions and learning algorithms. Intelligent Systems Reference Library* 54/2014, 121–131.
- [7] Goldberg D. E.: *Algorytmy genetyczne i ich zastosowania*. WNT, Warszawa 1995.

- [8] Homenda W., Jastrzebska A., Pedrycz W.: Modeling Time Series with Fuzzy Cognitive Maps. *2014 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, Beijing, China, 2014, 2055–2062.
- [9] Jastrzebow A., Kubus L., Poczęta K.: Learning fuzzy cognitive maps using Individually Directional Evolutionary Algorithm. In: *Jastrzebow A., Worwa K.: Applications of information technologies - theory and practice. Institute for Sustainable Technologies – National Research Institute, Radom 2015*, 37–48.
- [10] Korejo I., Yang S., Li C.: A Directed Mutation Operator for Real Coded Genetic Algorithms. *Applications of Evolutionary Computation* 6024/2010, 491–500.
- [11] Kosko B.: Fuzzy cognitive maps. *International Journal of Man-Machine Studies* 24(1)/1986, 65–75.
- [12] Kubus L.: Individually Directional Evolutionary Algorithm for Solving Global Optimization Problems - Comparative Study, *International Journal of Intelligent Systems and Applications (IJISA)* 7(9)/2015, 12–19.
- [13] Michalewicz Z.: *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. WNT, Warszawa 1999.
- [14] Papageorgiou E. I.: Learning Algorithms for Fuzzy Cognitive Maps - A Review Study. *IEEE Transactions on Systems, Man, and Cybernetics – Part C: Applications and Reviews* 42(2)/2012, 150–163.
- [15] Poczęta K., Yastrebov A.: Analysis of Fuzzy Cognitive Maps with Multi-Step Learning Algorithms in Valuation of Owner-Occupied Homes. *2014 IEEE International Conference on Fuzzy Systems (FUZZIEEE)*, Beijing, China 2014, 1029–1035.
- [16] Poczęta K., A. Yastrebov, Papageorgiou E. I.: Learning Fuzzy Cognitive Maps using Structure Optimization Genetic Algorithm. *2015 Federated Conference on Computer Science and Information Systems (FedCSIS)*, Lodz, Poland, 2015, 547–554.
- [17] Song H., Miao C., Roel W., Shen Z.: Implementation of fuzzy cognitive maps based on fuzzy neural network and application in prediction of time series. *IEEE Transactions on Fuzzy Systems* 18(2)/2010, 233–250.
- [18] Stach W., Kurgan L., Pedrycz W., Reformat M.: Genetic learning of fuzzy cognitive maps. *Fuzzy Sets and Systems* 153(3)/2005, 371–401.
- [19] Stach W., Pedrycz W., Kurgan L. A.: Learning of fuzzy cognitive maps using density estimate. *IEEE Trans. on Systems, Man, and Cybernetics, Part B*, vol. 42(3)/2012, 900–912.
- [20] Tang P., Tseng M.: Adaptive directed mutation for real-coded genetic algorithms. *Applied Soft Computing* 13(1)/2013, 600–614.
- [21] Yesil E., Urbas L.: Big bang: big crunch learning method for fuzzy cognitive maps. *World Acad. Sci. Eng. Technol.* 7/2010, 815–8124.

Prof. dr hab. Aleksander Jastrzebow
e-mail: a.jastrzebow@tu.kielce.pl

Prof. dr hab. Aleksander Jastrzebow jest profesorem zwyczajnym w Katedrze Systemów Informatycznych Politechniki Świętokrzyskiej w Kielcach. Jest autorem oraz współautorem ponad 250 publikacji naukowych. Jego zainteresowania naukowe obejmują diagnostykę, sztuczną inteligencję, automatykę, zastosowania informatyki.



Mgr inż. Łukasz Kubus
e-mail: l.kubus@tu.kielce.pl

Mgr inż. Łukasz Kubus jest doktorantem na Politechnice Świętokrzyskiej w Kielcach. Jest autorem oraz współautorem 4 publikacji naukowych. Jego zainteresowania naukowe obejmują diagnostykę, sztuczną inteligencję, algorytmy ewolucyjne, rozmyte mapy kognitywne oraz uczenie maszynowe.



Dr inż. Katarzyna Poczęta
e-mail: k.piotrowska@tu.kielce.pl

Dr inż. Katarzyna Poczęta jest adiunktem w Katedrze Systemów Informatycznych Politechniki Świętokrzyskiej w Kielcach. Jest autorem oraz współautorem 32 publikacji naukowych. Jej zainteresowania naukowe obejmują systemy wspomagania decyzyjnego, rozmyte mapy kognitywne, uczenie maszynowe oraz predykcję szeregów czasowych.



otrzymano/received: 15.06.2016

przyjęto do druku/accepted: 22.11.2017