

PIOTR A. KOWALSKI \*

## ZASTOSOWANIE WYBRANYCH ALGORYTMÓW OBLICZEŃ NATURALNYCH W PROCESIE UCZENIA SIECI NEURONOWYCH TYPU FUZZY FLIP FLOP

### APPLICATION OF SELECTED NATURAL COMPUTING ALGORITHMS FOR LEARNING PROCESS OF FUZZY FLIP FLOP NEURAL NETWORKS

#### Streszczenie

W pracy rozważane jest zastosowanie wybranych algorytmów obliczeń naturalnych do zagadnienia ustalenia topologii oraz parametrów w sieciach neuronowych typu Fuzzy Flip-Flop. Z powodu specyficznej funkcji aktywacji oraz jej numerycznej pochodnej, algorytm uczenia propagacji wstecznej błędu nie jest stosowany w powyższych sieciach, ponieważ cechuje go bardzo słaba zbieżność. Z tego powodu do procesu adaptacji wag, użyte zostały algorytmy inspirowane biologicznie tj. strategie ewolucyjne oraz metaheurystyki rojowe.

*Słowa kluczowe: sztuczne sieci neuronowe, algorytmy obliczeń naturalnych, metaheurystyki, algorytmy rojowe, algorytmy uczenia, sieci Fuzzy Flip-Flop, analiza i eksploracja danych.*

#### Abstract

The paper introduces a usage of selected natural computing algorithms to establish the architecture and the connection weights for Fuzzy Flip-Flop Neural Networks. Due to the specific transfer function and its numerical derivatives, Back Propagation Algorithm has weak convergence rates and is not applicable in this case. Therefore biological inspired procedures i.e. Evolutionary Strategy and Swarm Algorithms will be applied.

*Keywords: Neural Networks, Natural Computing Algorithms, Metaheuristics, Swarm Algorithms, Learning Process, Fuzzy Flip-Flop Neural Networks, Exploratory Data Analysis.*

---

\* dr inż. Piotr A. Kowalski, Katedra Automatyki i Technik Informatycznych, Wydział Inżynierii Elektrycznej i Komputerowej, Politechnika Krakowska oraz Instytut Badań Systemowych, Polska Akademia Nauk.

## ZARYS IDEII SIECI NEURONOWYCH TYPU FUZZY FLIP-FLOP

Poniższa praca stanowi początek badań naukowych autora związanych z zastosowaniem algorytmów genetycznych [6, 17], ewolucyjnych [1] oraz innych algorytmów inspirowanych biologicznie [2, 7, 14, 16, 18] do optymalizacji parametrów sieci neuronowej typu *Fuzzy Flip-Flop* ( $F^3$ ). Sieć ta została wprowadzona przez profesora Hirota wraz ze swoimi uczniami w roku 1980 [5, 12]. Niestety przez blisko dwadzieścia lat była ona tematem prac niemal wyłącznie teoretycznych. Główną tego przyczyną był brak dostępu do szybkich maszyn obliczeniowych i w rezultacie niemożność zastosowania uniwersalnych algorytmów uczenia nadzorowanego. W szczególności trudno było rozważać możliwość użycia wyspecjalizowanego algorytmu adaptacji parametrów bazującego na choćby najprostszych metaheurystykach.

Niniejsza sieć stanowi bardzo szczególny przypadek sieci rekurencyjnej [15], a jej budowa oparta jest na połączeniu idei klasycznych sieci opartych o neurony z funkcją aktywacji bazującą na zasadzie działania przerzutnika typu J-K lub D [10], w których zastąpiono klasyczną dwuwartościową logikę operatorami rozmytymi [4]. Dzięki tym modyfikacjom sieci neuronowe ( $F^3$ ) mają znacznie lepsze własności związane z rozpoznawaniem wzorców i odkrywaniem wiedzy, stanowiąc wierniejsze przybliżenie procesów zachodzących w mózgu człowieka tj. percepcja i zapamiętywanie.

Nietypowość oraz zróżnicowanie funkcji aktywacji uwarunkowało brak możliwości efektywnego zastosowania znanych - klasycznych - metod uczenia takich jak choćby jedna z najbardziej rozpowszechnionych propagacji wstecznej błędu [15]. Główną przeszkodą w zastosowaniu powszechnie znanych procedur nadzorowanego uczenia sieci neuronowych jest brak możliwości analitycznego wyznaczenia operatora pochodnej, bazującego na informacji o bieżącej wartości funkcji aktywacji. Jedynym znanym w literaturze efektywnym algorytmem uczenia sieci neuronowych opisanych powyżej jest procedura *Bacterial Memetic Algorithm* [3, 13] wprowadzona przez grupę profesora Laszlo T. Koczy [8, 10].

Dodatkowym zagadnieniem podczas modelowania tak stworzoną siecią jest ustalenie rozmytego stanu początkowego neuronów związanego z zastosowaniem idei przerzutników jako funkcji aktywacji [11], co również będzie należało do zadań realizowanych przez zastosowany w niniejszych badaniach algorytm.

## NUMERYCZNA ANALIZA WERYFIKACYJNA ZAGADNIENIA

W pracy zastosowane zostały algorytmy ewolucyjne a w szczególności strategię (1+1), ( $\mu+\lambda$ ) oraz ( $\mu, \lambda$ ) do procedury adaptacji wag oraz parametrów funkcji aktywacji sieci neuronowej ( $F^3$ ). Inną grupą algorytmów heurystycznych wykorzystanych do uczenia powyższych sieci były metody rojowe głównie algorytm *Artificial Bee Colony* [7].

I Międzynarodowa Konferencja Automatyka i Technologie Informatyczne  
The First International Conference on Automatic Control and Information Technology

Wstępna weryfikacja numeryczna wykazała pozytywne własności sieci neuronowych typu *Fuzzy Flip-Flop* wraz z zastosowanymi heurystycznymi algorytmami uczenia nadzorowanego.

Jako podstawowy – w czasie weryfikacji – przyjęty został test aproksymacji kilku funkcji (w tym również wielowymiarowych) oraz prostej klasyfikacji opartej na danych pozyskanych z generatora liczb losowych o rozkładzie Gaussa.

Rozważany heurystyczny algorytm nadzorowanego uczenia wraz z siecią neuronową typu *Fuzzy Flip-Flop* będzie można zastosować jako kompletne narzędzie do modelowania systemów dynamicznych, rozpoznawania wzorców oraz innych algorytmów technik informacyjnych [9], a w szczególności procedur analizy i eksploracji danych.

Jako przykładowe aplikacje powyższej metodyki w przyszłości zostaną szczegółowo przeanalizowane problemy z zakresu szeroko rozumianych badań systemowych tj. sterowania w systemach elektrycznych (inżynieria), a także wspomaganie decyzji np. marketingowej (ekonomia).

Kolejne badania podstawowe, związane będą z użyciem innych algorytmów naturalnych inspirowanych biologicznie w zastosowaniu do procesu adaptacji wag wraz ze zmianą topologii sieci, jak również stworzeniu procedur o charakterze równoległym lub rozproszonym – podejście systemów wieloagentowych.

## PODZIĘKOWANIA

Badania prezentowane tutaj są współfinansowane ze środków Unii Europejskiej w ramach Europejskiego Funduszu Społecznego, projekt „Technologie informacyjne: badania i ich interdyscyplinarne zastosowania”.

The research presented here are co-financed by European Union within European Social Fund, project „Information Technologies: Research And Their Interdisciplinary Applications”.

## LITERATURA

- [1] Arabas J., *Wykłady z algorytmów ewolucyjnych*, WNT, 2001.
- [2] Bergh V. F., Engelbrecht A., *Cooperative learning in neural networks using particle swarm optimizers*, South African Computer Journal, vol. 26, ss. 84-90, 2000.
- [3] Gál, L., Botzheim, J., Kóczy, L. T., *Improvements to the Bacterial Memetic Algorithm used for Fuzzy Rule Base Extraction*, Computational Intelligence for Measurement Systems and Applications, Istanbuł, ss. 38-43, 2008.
- [4] Gál, L., Botzheim, J., Kóczy, L. T., *Function approximation performance of Fuzzy Neural Networks based on frequently used fuzzy operations and a pair of new trigonometric norms*, IEEE International Conference on Fuzzy Systems, Barcelona, ss.1-8, 2010.
- [5] Hirota K., Pedrycz W., *Neurocomputations with fuzzy flip-flops*, Proceedings of

I Międzynarodowa Konferencja Automatyka i Technologie Informacyjne  
The First International Conference on Automatic Control and Information Technology

- International Joint Conference on Neural Networks, Nagoya, vol. 2, ss. 1867-1870, 1993.
- [6] Jones A. J., *Genetic algorithms and their applications to the design of neural networks*, Neural Computing and Applications, Springer- Verlag, ss. 32-45, 1993.
- [7] Karaboga D., Akay B., *A comparative study of Artificial Bee Colony algorithm*, Applied Mathematics and Computation, no.1, vol. 214, ss. 108-132, 2009.
- [8] Kóczy L. T., Lovassy R., *Fuzzy Flip-Flops and Neural Nets?*, IEEE International Fuzzy Systems Conference, Londyn, ss. 1-6, 2007.
- [9] Kulczycki P., Hryniewicz O., Kacprzyk J. (red.), *Techniki informacyjne w badaniach systemowych*, WNT, 2007.
- [10] Lovassy R., Kóczy L. T. and Gál L., *Multilayer Perceptron Implemented by Fuzzy Flip-Flops*, IEEE World Congress on Computational Intelligence, Hong Kong, ss. 1683-1688, 2008.
- [11] Lovassy R., Kóczy L. T. and Gál L., *Optimizing Fuzzy Flip-Flop Based Neural Networks by Bacterial Memetic Algorithm*, IFSA/EUSFLAT 2009, Lisbona, 2009.
- [12] Ozawa K., Hirota K. Kóczy L. T., *Fuzzy flip-flop*, w: *Fuzzy Logic Implementation and Applications*, Patyra M. J., Mlynek D. M., (ed.), Wiley, 1996, ss. 97-236.
- [13] Marquardt, D., *An Algorithm for Least-Squares Estimation of Nonlinear Parameters*, SIAM J. Appl. Math., vol. 11, ss. 431-441, 1963.
- [14] Meissner M., Schmuker M., Schneider G., *Optimized Particle Swarm Optimization and its application to artificial neural network training*. BMC Bioinformatics, vol. 7, ss. 125-130, 2006.
- [15] Rutkowski L., *Metody i techniki sztucznej inteligencji*, PWN, Warszawa, 2005.
- [16] Socha K., Blum C., *An ant colony optimization algorithm for continuous optimization: application to feed-forward neural network training*, Neural Computing and Applications, Springer- Verlag, vol. 16, ss. 235-247, 2007.
- [17] Whitley D., Starkweather T., Bogart C., *Genetic algorithms and neural networks: Optimizing connections and connectivity*, Technical Report Department of Computer Science, Colorado State University, ss. 89-117, 1989.
- [18] Yu B., He X., *Training Radial Basis Function Networks with Differential Evolution*, Proceedings of IEEE International Conference on Granular Computing, ss. 369-372, 2006.