

# Metoda porównywania uzyskanej informacji, przykład logiki asocjacyjnej

Владислав Євсєєв<sup>1</sup>, Jakiw Radczenko<sup>2</sup>

1. Кафедра КІТАМ, Харківський національний університет радіоелектроніки, УКРАЇНА,  
Харків, пр. Науки. 14., email: vladyslav.yevsieiv@nure.ua

2. Student 2-stopnia, wydział Elektroniki Mikrosystemów i Fotoniki, Politechnika Wroclawska, POLSKA,  
Wrocław, Stanisława Wyspiańskiego 27, email: 263371@student.pwr.edu.pl

**Streszczenie:** W dzisiejszych czasach przykład „logiki asocjacyjnej” daje ogromny impuls do rozwoju sztucznej inteligencji.

Ten przykład upraszcza zasadę działania ciężkich urządzeń zrobotyzowanych w przedsiębiorstwie w trybie offline i tworzy zasadę działania, która wykorzysta każdą kroplę informacji napływającą do systemu i podejmie właściwy krok w rozwiązywaniu problemów, które mogą się pojawić.

Badanie dotyczy branży tworzenia jednostek naneoelkronicznych przeznaczonych do wdrożenia urządzenia procesora neuronowego, będącego platformą sprzętową sieci neuronowych i złożonej architektury biomorficznej, np. symulującej pracę kolumny korowej mózgu.

**Słowa kluczowe:** sztuczna inteligencja, logika asocjacyjna, tryb autonomiczny, informacja, przemysł.

## I. WPROWADZANIE

We współczesnym świecie istnieje aktywne wprowadzanie robotów w życie z ludźmi. Robotyka - dziedzina technologiczna tworząca roboty do różnych zastosowań, takich jak: produkcja samochodów, budownictwo, przemysł i nie tylko. Jednak najnowsze osiągnięcia naukowe w dziedzinach takich jak: sztuczna inteligencja i kognitywistyka stworzyły autonomiczne roboty o wszechstronnym potencjale do rozwiązywania problemów ekonomicznych i społecznych. [1].

Potencjalnym zadaniem wykorzystania pozyskanych informacji jest konieczność opracowania takiego systemu filtrowania informacji a ich wykorzystania, aby przy względnie dowolnych zadaniach, które będą przeszkadzały w pracy, mógł je analizować i porównywać w przyszłości. Jednym z przykładów jest porównanie uzyskanych komponentów zewnętrznych otaczających robota z informacjami, które są już obecne w systemie robota [2]. Do rozwiązania tego problemu zostanie zastosowana zasada „logiki asocjacyjnej”.


## II. ANALIZA PRACY MYŚLENIA

Biomorficzna metoda przetwarzania informacji jest, coraz częściej stosowana w nowoczesnych technologiach informatycznych. To podejście informacyjne jest obecnie wykorzystywane do rozwiązywania szerokiego zakresu praktycznych problemów, w sztucznych sieciach neuronowych, za pomocą systemu uczenia maszynowego, złożonego z ogromnej liczby prostych neuronów.

Najpoważniejszym ograniczeniem wszystkich opisanych w literaturze prostych formalnych modeli neuron, jest brak modelowania w nich ukształtowanej w czasie kaskady zdarzeń, związanych z powstawaniem pamięci. Wiadomo, że w prawdziwym neuronie tworzenie śladu pamięciowego


obejmuje cały zestaw kolejno rozwijanych i współzależnych zjawisk elektrokinetycznych i biochemicznych. Zjawiska te obejmują zarówno powstawanie potencjałów w zakończeniach aksonów i dendrytach komórki (o określonym czasie życia), jak i zmiany strukturalne w komórce, w wyniku syntezy nowych białek pod kontrolą aparatu genetycznego neuronu wyzwalanego przez wzorce sygnałów wejściowych. Takie zmiany strukturalne obejmują przede wszystkim syntezę nowych receptorów mediatorowych oraz ich włączenie do błon postsynaptycznych.

Szczególną uwagę zwraca się na tzw. kolumnę korową, uniwersalny element kory nowej. Ta struktura jest uważana za moduł odpowiedzialny za wyższe funkcje nerwowe w systemie przetwarzania informacji w mózgu. Kolumna korowa zawiera dużą liczbę stosunkowo jednorodnie ułożonych komórek nerwowych z jeszcze większą liczbą połączeń i reprezentuje łącznie bardzo dużą sieć neuronowa (rys. 1).



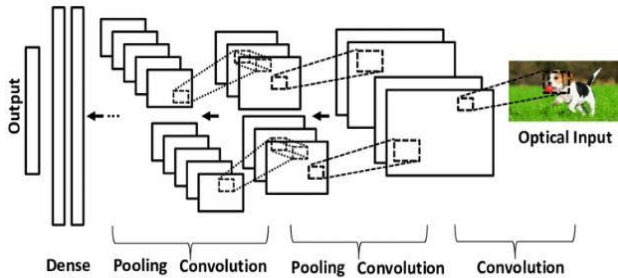
Rys.1. Kolumnowy układ kory somatosensorycznej

Bardziej żywy przykład pracy odbierania informacji przez system wizualny i jego przejścia do przejrzystej analizy każdego komponentu, możemy zobaczyć na rysunkach 2 i 3.



Rys.2. Cztery obszary Broadmana

Rysunek 2 przedstawia zależności między obszarami związanymi z pierwotną korą wzrokową a warstwami sieci neuronowej. Cztery obszary Broadmana związane z brzuszny przepływem wzrokowym. Rysunek przedstawia również schemat blokowy pokazujący tylko niektóre z wielu rzutów bezpośrednich i odwrotnych między tymi obszarami.



Rys.3. Schemat sieci neuronowej AlexNet

Rysunek 3 pokazuje system splotu warstw i sposób, w jaki zasada pozyskiwania informacji w celu uzyskania wyniku tego, co widać, jest w przybliżeniu podobna do hierarchii biologicznego układu wzrokowego.

Po dokładnym zrozumieniu zasady działania ludzkiego mózgu możemy przystąpić do wyjaśniania zasady sztucznej inteligencji i filtrowania informacji według zasady logiki asocjacyjnej [3].

Uczenie prostej informacyjnej sieci neuronowej odbywa się zwykle w warunkowym procesie próbkowania uczenia i metod głębokiego uczenia maszynowego, np. w problemach klasyfikacji i rozpoznawania wzorców. W tym przypadku uczenie sieci neuronowej odbywa się poprzez zaprogramowanie memrystorów bloku logicznego odpowiednich połączeń za pomocą impulsów powyżej napięcia progowego zgodnie z zasadami Hebba. Główna praca urządzenia po treningu jest z reguły wykonywana przez sztywną logikę. Jednak algorytm biomorficznej sieci neuronowej może być bardzo złożony ze względu na asocjacyjne samouczenie, które ma miejsce podczas głównej pracy [4].

Celem samouczenia się asocjacyjnego bloku logicznego neuroprocesora jest specjalny proces algorytmiczny, w którym biomorficzne impulsy informacyjne utworzone przez wyjście wzbudzonego neuronu w sieci neuronowej prowadzą do wzmocnienia jego połączeń synaptycznych. Wzmocnienie połączeń uszkodzonego neuronu następuje z neuronami poprzedniej warstwy, jeśli w tym momencie neurony te okazały się zbyt pobudzone i uformowały się na wyjściach impulsów informacyjnych..

W artykule przedstawiono przykład już opracowanego obwodu elektrycznego, topologii i nanotechnologii do produkcji ultradużej wielowarstwowej macierzy pamięci z pamięcią nieulotną i wysokim stopniem integracji elementów w oparciu o kombinowaną poprzeczkę memrystor-dioda [5].

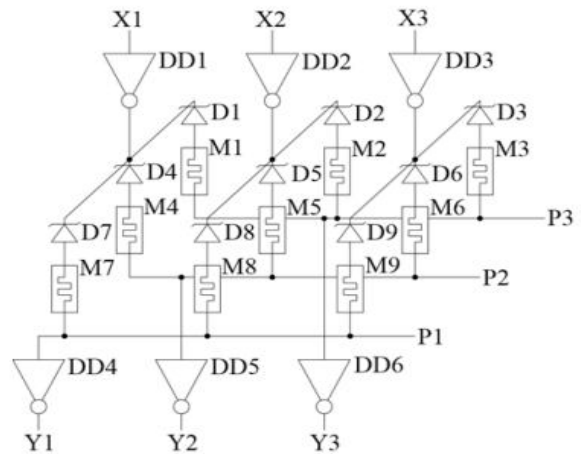
Pewną zaletą może być sprzętowa implementacja biomorficznej sieci neuronowej opartej na procesorze neuronowym, w której algorytmy obliczeń matematycznych można zastąpić wydajną pracą elektronicznej jednostki logicznej z pamięcią.

W tym artykule rozważane jest modelowanie SPICE-bloku logicznego, opracowanego na podstawie macierzy logicznej 3D do zastosowania w obwodzie procesora neuronowego o bardzo wysokim stopniu integracji neuronów w procesach asocjacyjnego samouczenia i bezwarunkowego negatywnego uczenia się.


Najbliższym analogiem bloku logicznego procesora neuronowego może być znana tablica Akerów oparta na memrystorach, która ma funkcjonalną kompletność i może być zaprogramowana do wykonywania dowolnej funkcji logicznej [6].

Musimy jednak pamiętać, że główną wadą schematu macierzy Akers jest wysoka degradacja sygnału wyjściowego, co nie pozwala na jego zastosowanie w ultra-dużych architekturach. Tablica memrystorowa Akers ma słabą integrację elementów pamięci związanych z dużą liczbą tranzystorów w komórce elementarnej [7].

Najwłaściwszym rozwiązaniem jest zastosowanie jako jednostki logicznej procesora neuronowego ultra-dużej macierzy logicznej 3D przedstawionej w [8]. Schemat elektryczny i topologię fragmentu 3D macierzy logicznej pokazano na rysunkach 4 i 5.



Rys.4. Schemat elektryczny warstwy funkcjonalnej z trzema ogniwami i połączeniami międzywarstwowymi ogniw




Rys.5. Topologia z liczbą elementów integracji

Główną zaletą projektu matrycy 3D jest wyższy stopień integracji, który uzyskuje się przez połączenie na kryształach w strukturze 3D tych samych prostopadłe zorientowanych warstw funkcjonalnych z połączonymi poprzeczkami memrystorowymi jako przełącznikami, a w konsekwencji zwartym układem komórek i komórki komórki. Brak degradacji sygnału jest ważną zaletą matrycy, którą osiąga się dzięki właściwości wzmacniającej falowników każdej warstwy [9].

Uczenie prostej informacyjnej sieci neuronowej odbywa się zwykle w warunkowym procesie próbkowania uczenia i metod głębokiego uczenia maszynowego, np. w problemach klasyfikacji i rozpoznawania wzorców. W tym przypadku uczenie sieci neuronowej odbywa się poprzez zaprogramowanie memrystorów bloku logicznego odpowiednich połączeń impulsami powyżej napięcia progowego zgodnie z regułami Hebb'a [10]. Główna praca urządzenia po treningu jest z reguły wykonywana przez sztywną logikę. Jednak algorytm biomorficznej sieci neuronowej, może być bardzo złożony ze względu na asocjacyjne samouczenie, które ma miejsce podczas głównej pracy [11].

Rysunek 6 przedstawia zastosowanie reguły Hebb'a do najprostszej sieci neuronowej składającej się z dwóch neuronów wejściowych i jednego wyjściowego.



Rys.6. Najprostsza sieć neuronowa

W takiej sieci próg pierwotnego neuronu jest ukryty w tym elemencie. W operacjach z sieciami neuronowymi próg neuronu może zostać wyjęty z jego granic i przedstawiony jako połączenie synaptyczne o wadze równej  $T$ . Ponieważ wartość wejściowa jest podana do dodatkowego neuronu, więc tylko  $-1$ .

Uczenie się sieci neuronowych odbywa się poprzez dostosowanie wag i progów neuronów. Zasada uczenia się Hebb'a zostanie zapisana w formie wyrażeń [12]:

$$w_{11}(t+1) = w_{11}(t) + x_1 y_1 \quad (1)$$

$$w_{21}(t+1) = w_{21}(t) + x_2 y_1 \quad (2)$$

$$T(t+1) = T(t) - y_1 \quad (3)$$

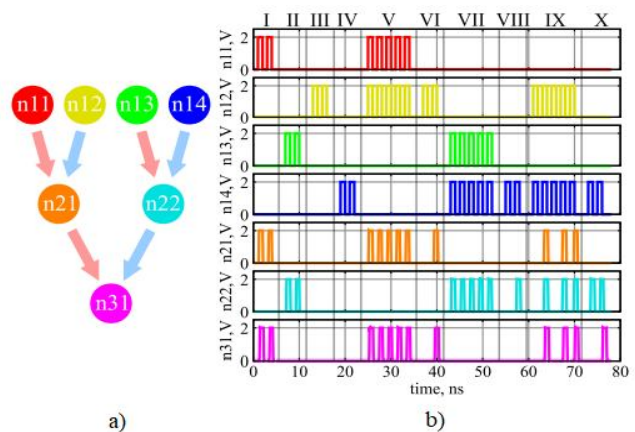
Podobnie reguła Hebb'a jest napisana dla większej sieci neuronowej [13].

Szkolenie kończy się po przesłaniu wszystkich obrazów wejściowych do sieci.

Sens asocjacyjnego samouczenia się bloku logicznego procesora neuronowego jest specjalny proces algorytmiczny, w którym biomorficzne impulsy informacyjne utworzone przez wyjście wzbudzonego neuronu w sieci neuronowej prowadzą do wzmocnienia jego połączeń synaptycznych. Wzmocnienie połączeń wzbudzonego neuronu następuje z neuronami z poprzedniej warstwy, jeśli w tym momencie neurony te były również wzbudzone i utworzyły na swoich wyjściach impulsy informacyjne.

Rysunek 7 przedstawia wyniki samouczenia asocjacyjnego w modelowaniu SPICE sprzętowej sieci neuronowej o jednorodnej strukturze warstwowej, w której sygnał rozchodzi się prostopadłe do powierzchni jak kolumna korowa mózgu. Modelowa sieć neuronowa składa się z trzech warstw neuronowych zaimplementowanych w sześciu funkcjonalnych warstwach logicznej matrycy. Połączenia między neuronami zaznaczonymi na niebiesko są początkowo słabe, a połączenia zaznaczone na czerwono są silne [14].

Impulsy w symulacjach SPICE pokazane na rysunku 7 (b) odzwierciedlają wzbudzenie neuronów. Neurony  $n11 - n14$  są danymi wejściowymi, są zasilane impulsami informacyjnymi. Wykresy pokazują przejście sygnału przez silne wiązania, zaznaczone na czerwono, w obszarach czasowych I-IV. W pierwszym przedziale czasu impulsy wejściowe podawane na neuron  $n11$ , przejść przez neuron  $n21$  do neuronu wyjściowego  $n31$ . W drugim przedziale czasu impulsy przyłożone do neuronu  $n13$  przechodzą do neuronu  $n22$  i nie padają na pierwotny neuron  $n31$ . W trzecim i czwartym przedziale czasowym impulsy przyłożone do neuronów wejściowych  $n12$  i  $n14$  nie przechodzą już przez słabe połączenia [15].



Rys.7. Samouczenie asocjacyjne w bloku logicznym procesora neuronowego:

- a) – architektura trójwarstwowej sprzętowej sieci neuronowej (czerwony - silne połączenia, niebieski - słabe);
- b) – wykresy modelowania SPICE (kolor wykresu odpowiada kolorowi neuronu)

Wynik symulacji pokazuje, że mechanizm uczenia jest przechodni i działa nie tylko pomiędzy sąsiednimi warstwami neuronów, ale rozciąga się na całą sprzętową sieć neuronową. Spadek częstotliwości impulsów neuronu wyjściowego  $n31$  na

końcu wykresu jest konsekwencją działania układu zapominającego [16]. W tym trybie następuje bezwarunkowe osłabienie wcześniej wzmocnionych wiązań, które nie były wspierane przez asocjacyjne samouczenie się w poprzednim przedziale czasowym.

### III. WNIOSKI

W pracy dokonano analizy i opracowano algorytm logiki asocjacyjnej na zasadzie porównania pracy żywego mózgu z tworzeniem sztucznego modelu 3D mózgu, którego przykładem mogą być systemy robotyczne jako autonomiczna kontrola. Rozważono również zasadę uczenia sieci neuronowej poprzez dostosowanie wag i progów neuronów, regułę Hebb'a w wersji matematycznej. Na podstawie analizy przeprowadzonej w tym artykule można stwierdzić, że asocjacyjne samouczenie się jednostki logicznej procesora neuronowego jest specjalnym procesem algorytmicznym, w którym impulsy informacyjne prowadzą do zwiększenia połączeń synaptycznych.

### BIBLIOGRAFIA

- [1] Baladron J. A. Speaking Neural Network Based on the Basal Ganglia Functional Anatomy / J. Baladron, F. H. Hamker // *Neural Networks*. 2015. Vol. 67. Pp. 1-13.
- [2] Levy Y. Logic Operations in Memory Using a Memristive Akers Array / Y. Levy, J. Bruck, Y. Cassuto, E. G. Friedman et al. // *Microelectronics Journal*. 2014. Vol. 45. No. 11. Pp. 1429-1437.
- [3] Bobylev A. N. Electrical Properties of a TiN/Ti, Al, O/TiN Memristor Device Manufactured by Magnetron Sputtering / A. N. Bobylev, S. Yu. Udovichenko // *Ukraine Microelectronics*. 2016. Vol. 45. No. 6. Pp. 396-401.
- [4] Bobylev A. N. Neuromorphic Coprocessor Prototype Based on Mixed Metal Oxide Memristors / A. N. Bobylev, A. N. Busygin, A. D. Pisarev, S. Yu. Udovichenko.
- [5] Brette R. Adaptive Exponential Integrate-and-Fire Model as an Effective Description of Neural Activity / R. Brette, W. Gerstner // *Journal of Neurophysiology*. 2005. Vol. 94. No. 5. Pp. 3637-3642.
- [6] Hodgkin A. L. A Quantitative Description of Membrane Current and Its Application to Conduction and Excitation in Nerve / A. L. Hodgkin, A. F. Huxley // *Journal of Physiology*. 1952. No. 117 (4). Pp. 500-544.
- [7] Писарев А. Д. SPICE-моделирование процессов ассоциативного самообучения и безусловного разобучения в логическом блоке нейропроцессора / А. Д. Писарев // *Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика*. 2018. Том 4. № 3. С.132-145. "A symmetrical condensed node for the TLM method," *IEEE Trans. Microwave Theory Tech.*, vol. MTT-35, pp.370-377, Apr. 2007.
- [8] Li C. Analogue Signal and Image Processing with Large Memristor Crossbars / C. Li, M. Hu, Y. Li, H Jiang et al. // *Nature electronics*. 2018. Vol. 1. Pp. 52-59.
- [9] Maevsky O. V. Complementary Memristor-Diode Cell for a Memory Matrix in Neuromorphic Processor / O. V. Maevsky, A. D. Pisarev, A. N. Busygin, S. Y. Udovichenko // *International Journal of Nanotechnology*. 2018 Vol. 15. No 4/5. Pp. 338-393.
- [10] Удовиченко С. Ю. 3D КМОП-мемристорная нанотехнология создания логической и запоминающей матриц нейропроцессора / С. Ю. Удовиченко, А. Д. Писарев, О. В. Маевский // *Наноиндустрия*. 2017. No 5. С. 26-34.
- [11] Markram H. The Blue Brain Project / N. Markram // *Nature Reviews Neuroscience*. 2006. Vol. 7. Pp. 153-160.
- [12] Markram H. The Human Brain Project / N. Markram // *Scientific American*. 2012. Vol. 306. Pp. 50-55.
- [13] Merolla P. A. A Million Spiking-Neuron Integrated Circuit with a Scalable Communication Network and Interface / P. A. Merolla et al. // *Science*. 2014. Vol. 345. No. 6197. Pp. 668-673.
- [14] Pisarev A. 3D Memory Matrix Based on a Composite Memristor-Diode Crossbar for a Neuromorphic Processor / A. Pisarev, A. Busygin, S. Udovichenko, O. Maevsky // *Microelectronic Engineering*. 2018. Vol. 198. Pp. 1-7.
- [15] Schmidhuber J. Deep Learning in Neural Networks: An Overview / J. Schmidhuber // *Neural Networks*. 2015. Vol. 61. Pp. 85-117.
- [16] Silberberg G. Stereotypy in Neocortical Microcircuits / G. Silberberg, A. Gupta, H. Markram // *Trends in Neurosciences*. 2002. Vol. 25. No. 5. Pp. 227-230.