

DOI: 10.5604/01.3001.0010.5220

## SZTUCZNE SIECI NEURONOWE JAKO MOTORYCZNA PAMIĘĆ ASOCJACYJNA RĘKI ROBOTA HUMANOIDALNEGO

Paweł Olszewski, Wiesław Andrzej Kamiński

Uniwersytet Marii Curie-Skłodowskiej, Instytut Informatyki/Zakład Układów Złożonych i Neurodynamiki

**Streszczenie.** Opisane badania dotyczą użycia sztucznych sieci neuronowych przy realizacji asocjacyjnej pamięci motorycznej zarządzającej ręką robota humanoidalnego. Zaproponowano model kognitywnego sterowania odwołujący się do struktur i mechanizmów przetwarzania znanych z badań neurofizjologicznych. Do realizacji asocjacji posłużono się dwiema różnymi sieciami: maszyną płynową i jednokierunkową siecią asocjacyjną podobną do BAM.

**Słowa kluczowe:** sztuczne sieci neuronowe, metody uczenia, roboty humanoidalne, manipulatory

### ARTIFICIAL NEURAL NETWORKS AS A MOTORICAL ASSOCIATIVE MEMORY FOR HUMANOID ROBOT HAND

**Abstract.** This paper relates to the artificial neural networks usage for the purpose of associative memory implementation managing humanoid robot hand. Referring to the structures and mechanisms of processing known from neurophysiological studies model of cognitive control was proposed. In the association realization process two different networks were used: a liquid state machine and a one-way associative network similar to BAM.

**Keywords:** artificial neural networks, learning systems, humanoid robots, manipulators

#### Wstęp

Symulacje mające na celu odwzorowanie pracy fragmentów mózgu stanowiły inspirację do powstania teorii sztucznych sieci neuronowych [13]. Na przestrzeni lat powstało wiele odmian sztucznych sieci neuronowych, wykazujących zróżnicowane właściwości, w tym wykorzystywane przez nas maszyny płynowe [5, 6, 10] oraz dwukierunkowe pamięci asocjacyjne [3].

Swoje badania opieramy także na tezie sugerującej istnienie w mózgu homo sapiens wyspecjalizowanej jego części odpowiedzialnej za czynności wzrokowo-motoryczne. Część taka określana jest w literaturze mianem szlaku grzbietowego. Jego istnienie sugerują liczne badania, w tym te prowadzone przez D. Milner i M. A. Goodale [1]. Badana przez nich pacjentka pomimo tego, że nie potrafi określić właściwości przedmiotów, potrafi kierować swoimi działaniami, jednocześnie nieświadomie wykorzystując te właściwości. W pracy sugerowano się również zdolnościami szlaku grzbietowego do zapamiętywania informacji charakterystycznych dla interakcji z obserwowanym obiektem.

Badania dotyczą symulacji tworzenia się w sztucznej sieci neuronowej typu asocjacyjnej pamięci adresowanej kontekstowo oraz wykorzystania jej do zarządzania ręką robota humanoidalnego. Tematyka ta jest przedmiotem rosnącego zainteresowania w wielu ośrodkach naukowych [7, 11].

Zaproponowany model kognitywnego sterowania odwołuje się do struktur i mechanizmów przetwarzania znanych z badań neurofizjologicznych kory mózgowej wraz z jej podstawowymi cechami: budową warstwową i sposobem przetwarzania informacji w neuronach [9].


Niniejsza praca opisuje szczegóły implementacyjne oraz otrzymane wyniki wraz z ich opracowaniem. Głównym celem badań jest wykazanie, dla jakich rozwiązań symulowany sztuczny ośrodek neuronalny jest w stanie rozpoznawać i właściwie reagować na pobudzenie „wzrokowe” realizując wyuczony chwyt przedmiotu.

#### 1. Manipulator robotyczny

Na potrzeby prowadzonych badań wykonano zestaw kul oraz prototyp manipulatora robotycznego (rys. 1), w którego skład wchodzi chwytak dłoniopodobny, wyposażony w pięć niezależnie sterowanych palców. Każdy z palców dysponuje liczbą stopni swobody umożliwiającą zakres ruchów zbliżony do możliwości palców ludzkiej dłoni [4], a w konsekwencji pozwala na chwytanie zróżnicowanych pod względem kształtu i wielkości przedmiotów. Elementy składowe manipulatora wykonane zostały w technologii druku trójwymiarowego wykorzystując otwarty projekt robota humanoidalnego InMoov [12]. Cały manipulator


umożliwia również ruch obrotowy nadgarstka, zgięcia stawu łokciowego, obroty barku, unoszenie manipulatora w barku oraz wychylenie manipulatora w przód i w tył (również na wysokości barku).

Prowadzone obecnie badania ograniczają się wyłącznie do wykorzystania funkcjonalności chwytaka dłoniopodobnego. Ruchy chwytaka umożliwia zestaw wbudowanych w manipulator serwomechanizmów, cięgien i przekładni zębatych. Sterowanie serwomechanizmami odbywa się z wykorzystaniem sygnałów napięciowych PWM generowanych przez zarządzający pracą chwytaka mikrokontroler AVR ATmega2560 [2].



Rys. 1. Manipulator robotyczny wyposażony w chwytak dłoniopodobny

Na potrzeby symulowanych procesów asocjacyjnych przyjęto reprezentację świata składającą się z odwzorowań siedmiu kul różniących się średnicą o 1 cm w zakresie od 4 cm do 10 cm. Tworząc reprezentację „kulistego” świata przyjęto, że konkretny obiekt charakteryzuje pojedyncza cecha (wielkość średnicy).



Rys. 2. Ilustracja poglądowa zestawu kul wykorzystywanych w badaniach, uszeregowanych względem wielkości średnicy

Przetwarzanie skojarzeniowe, interpretowane jako stan warstwy wyjściowej modelowanej sztucznej sieci neuronowej, jest używane jako zbiór sygnałów przesyłanych do mikrokontrolera

wymuszającego określone położenia serwomechanizmów prowadzące do zaciśnięcia chwytaka na wybranej kuli.

Wykorzystując skonstruowany chwytak dłoniopodobny manipulatora robotycznego dokonano odczytania sterujących wartości charakterystycznych dla chwycenia każdej z siedmiu kul należących do przygotowanego zbioru uczącego. Ponieważ w zastosowanym rozwiązaniu sprzętowym na każdy palec przypada pojedynczy serwomechanizm, każde z chwyci jest charakteryzowane przez pięć parametrów.

Otrzymane parametry poddano rzutowaniu na zbiór wartości z zakresu od 0 do 2048. Maksymalną wartość parametru sterującego rzutowano na wartość 2048, minimalną na 0, wszystkie pozostałe wartości pośrednie w sposób proporcjonalny. W rezultacie dla każdej z kul otrzymano pięć wartości z zakresu od 0 do 2048, które następnie zakodowano używając zapisu binarnego na 11 bitach. Na tej podstawie określono wielkość reprezentacji wejściowej równą 55 neuronom usytuowanym w 5 wierszach i 11 kolumnach. Dla uwydatnienia różnic w binarnych wzorcach wejściowych, ich zapis sprowadzono do reprezentacji bipolarnej, przekształcając wartości 0 na -1. Zakodowana w ten sposób reprezentacja wejściowa jest imitacją sygnału wzrokowego wykorzystywanego przez mózg między innymi w procesach chwytania przedmiotów. Symulowana sztuczna sieć neuronowa powinna w sposób analogiczny podejmować odpowiednie działania związane z właściwym chwyceniem przedmiotów charakteryzowanych przez podawane wzorce wejściowe. Reprezentacja wyjściowa została przyjęta w formie mapy kodowej dla sterownika chwytaka składającej się z 5 wierszy i 100 kolumn.

## 2. Wyniki

Na potrzeby badań posłużono się symulatorem SNNS w wersji 4.3 oraz szeregiem pomocniczych, autorskich aplikacji wspierających procesy tworzenia wzorców, opracowywania danych wynikowych oraz modyfikowania struktury sieci.

### 2.1. Pamięć asocjacyjna dwukierunkowa

W pierwszej kolejności podjęto próby wykorzystania Dwukierunkowej Pamięci Asocjacyjnej [3] do wytworzenia asocjacji pomiędzy reprezentacjami: wejściową, charakteryzującą poszczególne kule i wyjściową, kodującą parametry położenia palców, odpowiednich dla chwycenia tej kuli. Posłużono się zbiorem uczącym, składającym się z siedmiu kul bazowych. Wykorzystywana reprezentacja wyjściowa jednoznacznie określa parametry poszczególnych serwomechanizmów dla chwycenia rozpoznanej kuli. Skrajnie lewy neuron w każdym wierszu oznacza wartość 0 parametru sterującego, skrajnie prawy wartość 100, pozostałe neurony reprezentują wartości pośrednie. Pozycja pojedynczego neuronu znajdującego się w stanie aktywnym określa wartość parametru wynikowego dla powiązanego z tym parametrem serwomechanizmu (zależy od wiersza). Skonstruowane, oczekiwane mapy wyjściowe zostały sprowadzone do reprezentacji bimodalnej korzystając z wartości 1 i -1 w celu ułatwienia procesu tworzenia asocjacji [13].

Przy wykorzystaniu siedmiu wzorców bazowych skonstruowana sieć nie pozwoliła na powstanie właściwej asocjacji w żadnej z par należących do siedmioelementowego zbioru. Każda z par składała się z reprezentacji wejściowej i wyjściowej dla danej kuli, pomiędzy którymi podjęto próbę wytworzenia asocjacji.

W celu zmniejszenia ilości koniecznych do przyswojenia przez sieć informacji wybrano pięć podzbiorów zawierających jedynie trzy losowe elementy: {9,5,6}, {10,8,6}, {6,8,7}, {5,7,8}, {4,6,10}. Dla żadnego z pięciu zbiorów sieć nie była w stanie wytworzyć właściwej asocjacji pomiędzy reprezentacjami wejściową i wyjściową poszczególnych kul.

W kolejnym etapie badań wybrano jeszcze mniejszą próbę, tworząc pięć podzbiorów dwuelementowych: {8,10}, {5,7}, {5,6}, {6,10}, {4,8}. W tym przypadku dla wszystkich pięciu podzbiorów sieć właściwie wytworzyła jednoznaczna asocjację

pomiędzy reprezentacjami wejściową i wyjściową poszczególnych kul.

Badania zdolności BAM do wytworzenia asocjacji pozwoliły na stwierdzenie, iż jedynie w przypadku zbiorów dwuelementowych sieć była w stanie poprawnie nauczyć się wzorców. Z uwagi na słabe rezultaty osiągnięte przez typową realizację dwukierunkowej sieci asocjacyjnej, w dalszej części podjęto próby zrealizowania jednokierunkowej asocjacji wykorzystując do tego celu sieć perceptronową oraz algorytm uczenia nadzorowanego wstecznej propagacji błędów [13, 14].

### 2.2. Pamięć asocjacyjna jednokierunkowa

Podjęto próbę wytworzenia asocjacji jednokierunkowej dla par należących do tego samego, siedmioelementowego zbioru, który został wykorzystany w przypadku sieci BAM (dla sieci BAM asocjacja miała charakter dwukierunkowy). W tym celu posłużono się dwuwarstwową siecią perceptronową. W roli funkcji aktywacji neuronów składowych sieci użyto funkcji sigmoidalnej, bipolarnej, aby była ona w stanie udzielić właściwej odpowiedzi, zgodnej z przyjętą uprzednio bimodalną reprezentacją wyjściową. Wyniki zostały przedstawione w postaci tabeli (Tabela 1) zawierającej wielkości typowych błędów [14] odpowiedzi dla sieci neuronowych: SSE – sumy kwadratów błędów (1), MSE – średni błąd kwadratowy (2), SSE/o-units – błąd SSE podzielony przez liczbę neuronów warstwy wyjściowej.

$$SSE = \sum_{p \in \text{patterns}} \sum_{j \in \text{outputs}} (t_{pj} - o_{pj})^2 \quad (1)$$

gdzie:  $p$  – wzorec wejściowy,  $j$  – neuron wyjściowy,  $t_{pj}$  – odpowiedź oczekiwana dla wzorca  $p$  na neuronie  $j$ ,  $o_{pj}$  – odpowiedź otrzymana dla wzorca  $p$  na neuronie  $j$ .

$$MSE = \frac{SSE}{P} \quad (2)$$

gdzie:  $SSE$  – suma błędów kwadratowych,  $P$  – liczba wzorców należących do zbioru.

Tabela 1. Wyniki procesu uczenia sieci perceptronowej dla 7-el. zbioru uczącego

epoch:	SSE	MSE	SSE/o-units
Train20000:	4878.17627	696.88232	9.75635
Train18000:	9.92942	1.41849	0.01986
Train16000:	7.07407	1.01058	0.01415
Train14000:	5.79215	0.82745	0.01158
Train12000:	5.02363	0.71766	0.01005
Train10000:	4.49748	0.64250	0.00899
Train8000:	4.10826	0.58689	0.00822
Train6000:	3.80531	0.54362	0.00761
Train4000:	3.56083	0.50869	0.00712
Train2000:	3.35816	0.47974	0.00672
Train1:	3.18664	0.45523	0.00637
Test0:	3.18657	0.45522	0.00637


W początkowym etapie treningu sieci błędy odpowiedzi z uwagi na losowe wartości wag były bardzo duże (rzędu 700 w przypadku MSE), jednak już po 2 tysiącach epok wielkości błędów dynamicznie malały. W połowie treningu błędy były zbliżonej wielkości do wyników końcowych, tj. 0,6 dla MSE. Po 20 000 epok uczenia sieć była w stanie opanować asocjacje jednokierunkową zadowalającym stopniem z błędem odpowiedzi MSE równym 0,45522.

Celem kolejnego etapu badania było sprawdzenie, jak skonstruowana sieć zachowa się dla większego zbioru uczącego oraz czy będzie wykazywała zdolność do generalizowania informacji wejściowych.

W oparciu o bazowe (przed rzutowaniem na zakres 0 do 2048) wartości dla chwytów siedmiu kul dokonano dla każdego z palców przybliżenia funkcji zależności zmian parametru sterującego od wielkości chwytanej kuli (rys. 3). Następnie posłużono się otrzymanymi pięcioma funkcjami do spreparowania przybliżonych parametrów dla pośrednich wielkości kul, którymi wzbogacono plik wzorców uczących. Pozwoliło to ominąć czasochłonny proces drukowania kul oraz pomiarów odpowiadających im parametrów sterujących. Zbiór uczący został

w efekcie powiększony do 121 wzorców które, tak jak poprzednio, sprowadzono do reprezentacji bipolarnej (1,-1).

Należy mieć na uwadze, że charakter opisanych zależności jest specyficzny dla sposobu realizacji chwytania w wykorzystywanym chwytaku dłoniopodobnym manipulatora robotycznego.



Rys. 3. Przybliżone funkcje zależności wartości poszczególnych parametrów chwytaka od wielkości kuli

Ponowiono próbę wytworzenia jednokierunkowej asocjacji, korzystając z rozszerzonego w ten sposób zbioru uczącego oraz przy wykorzystaniu niezmienionej architektury sieci. Otrzymane wyniki zestawiono w formie tabeli (tabela 2).

Tabela 2. Wyniki procesu uczenia sieci perceptronowej dla 121-el. zbioru uczącego

epoch:	SSE	MSE	SSE/o-units
Train20000:	34802.78906	287.62634	69.60558
Train18000:	78.57780	0.64940	0.15716
Train16000:	55.81442	0.46128	0.11163
Train14000:	45.64680	0.37725	0.09129
Train12000:	39.57328	0.32705	0.07915
Train10000:	35.41773	0.29271	0.07084
Train8000:	32.34286	0.26730	0.06469
Train6000:	29.95017	0.24752	0.05990
Train4000:	28.02082	0.23158	0.05604
Train2000:	26.42455	0.21838	0.05285
Train1:	25.07181	0.20721	0.05014
Test0:	40.79099	0.33712	0.08158
Test1:	150.50139	1.24381	0.30100
Test2:	898.09808	7.42230	1.79620

Podobnie jak w przypadku zbioru 7-elementowego proces uczenia sieci rozbudowanego zbioru 121 reprezentacji sukcesywnie redukuje błędy odpowiedzi. Po 20 000 epokach uczenia sieć była w stanie opanować asocjację jednokierunkową w zadowalającym stopniu z błędem odpowiedzi MSE równym 0.20721. Korzystając z nauczonej sieci sprawdzono, jak radzi ona sobie z wzorcami uszkodzonymi, dla których niektóre z wartości niosących informację (-1 lub 1) zamieniono na wartości 0. Posłużono się trzema stopniami uszkodzenia. Pierwszym 10-procentowym (tabela 2/Test0), drugim 20-procentowym (tabela 2/Test1) i trzecim 40-procentowym (tabela 2/Test2). Sieć dla zbioru testowego o 10% stopniu uszkodzenia reagowała zadowalająco (błąd MSE wynosił 0,33712). Dla zbioru o stopniu uszkodzenia równym 20% odpowiedzi niemal zawsze były rozpoznawalne dla sterownika (błąd MSE na poziomie 1,24381). W przypadku uszkodzenia na poziomie 40% odpowiedzi sieci nie pozwalały na jednoznaczne określenie parametrów sterujących na potrzeby chwycenia (błąd MSE równy 7,42230).

W kolejnym etapie pracy badano wpływ procentowego udziału wzorców w zbiorach uczącym i testowym na opanowanie przez sieć zdolności do generalizowania danych spoza zbioru treningowego. W pierwszym przypadku przyjęto 80-procentowy udział wzorców (97 el.) w zbiorze uczącym i jedynie 20-procentowy udział (24 el.) w zbiorze testowym. Wyniki zostały umieszczone w tabeli (Tabela 3). Po wykonaniu 20 tys. epok uczenia uzyskano błąd MSE na poziomie 0.22709. Zbadany błąd

MSE odpowiedzi na zbiór testowy, z którego składowymi sieć nie miała do czynienia w procesie uczenia osiągnął ostatecznie poziom 30-krotnie większy i wynosił 7,56318. Warto zaznaczyć, że po tysięcznym kroku uczenia (czyli przez pozostałe 19 000 kroków) błąd MSE dla zbioru testowego nie uległ większej poprawie zmieniając się jedynie z wartości 8,35444 o niecałe 1 do przytoczonego stanu końcowego.

Tabela 3. Wyniki procesu uczenia sieci perceptronowej dla 97-el. zbioru uczącego

epoch:	SSE	MSE	SSE/o-units
Train20000:	32589.84766	335.97781	65.17970
Train18000:	68.99730	0.71131	0.13799
Train16000:	49.02469	0.50541	0.09805
Train14000:	40.10389	0.41344	0.08021
Train12000:	34.76337	0.35839	0.06953
Train10000:	31.11499	0.32077	0.06223
Train 8000:	28.42421	0.29303	0.05685
Train 6000:	26.32561	0.27140	0.05265
Train 4000:	24.62417	0.25386	0.04925
Train 2000:	23.21447	0.23932	0.04643
Train 1:	22.02811	0.22709	0.04406
Test 0:	181.51637	7.56318	0.36303

Sieć przy przyjętych założeniach i reprezentacjach jest w stanie uczyć się na pamięć wzorców ze zbioru treningowego, nie wykazuje jednak dostatecznie dobrych zdolności do interpolowania położenia palców ręki manipulatora dla kul których reprezentacje nie znalazły się w zbiorze uczącym.

### 2.3. Model maszyny płynowej

Kolejna część badań dotyczyła wykazania możliwości zastosowania teorii maszyn płynowych [5, 6, 10] na potrzeby identyfikacji wzorców, którymi pobudzano sieć.

Zrealizowana maszyna płynowa składała się z warstwy wejściowej o wymiarach identycznych jak w poprzednich badaniach oraz warstwy płynu o wymiarach warstwy wyjściowej z poprzednich badań. Warstwa płynu charakteryzowała się 60% ilością połączeń międzyneuronalnych stworzonych na zasadzie „każdy z każdym”. Wagi wszystkich połączeń w warstwie płynu zostały dobrane losowo z zakresu od -1.0 do 1.0. Jako funkcję aktywności neuronów wchodzących w skład warstwy płynowej przyjęto funkcję logistyczną mogącą przyjmować wartości z zakresu od 0,0 do 1,0. Było to poddyktowane niestabilną pracą maszyny płynowej w przypadku kiedy funkcją tą była funkcja sigmoidalna bipolarna.

Wejście, tak jak w poprzednich badanych sieciach przyjmowało charakterystykę kuli. Warstwa płynu miała za zadanie wykazać w zależności od prezentowanego wzorca zróżnicowanie w dynamice układu na tyle duże, aby można było wnioskować co do tego, którym ze wzorców sieć została pobudzona.

Przeprowadzono symulację dwóch wariantów maszyny płynowej. W pierwszym liczbę połączeń biegnących z warstwy wejściowej do warstwy płynu zredukowano do zaledwie 10% wszystkich możliwych połączeń, ustawiając ich wagi na wartość równą 1,0 (oznacza to, że informacja wejściowa dla tych połączeń przekazywana była bez zmian). W drugim przypadku liczba połączeń biegnących z warstwy wejściowej do warstwy płynu stanowiła 80% wszystkich możliwych połączeń. Ich wagi również zostały ustawione na 1,0.

Dla każdej z kul zbioru uczącego przeprowadzono 50 kroków symulacji, podając na wejście jedną, wybraną charakterystykę (wzorec wejściowy). Należy podkreślić, że wzorec wejściowy nie ulegał zmianom podczas trwania symulacji.

W celu zbadania dynamiki symulowanych układów zaproponowano odmianę miary entropii wywodzącą się z definicji entropii informacyjnej Shannona [8,10]. Przeprowadzono T=50 kroków symulacji otrzymując w każdym z kroków różny stopień aktywności na każdym z 500 neuronów warstwy płynu. W każdym kroku udział aktywności z poszczególnych zakresów jest różny i określony wzorem:

$$p_i = \frac{n_i}{N} \quad (3)$$

gdzie:  $p$  – udział aktywności z zakresu  $i$ ,  $n$  – liczba aktywności należących do określonego zakresu,  $N$  – liczba wszystkich neuronów warstwy płynu.

Udziały aktywności z poszczególnych zakresów zawsze sumują się do 1:

$$\sum_{i=1}^z p_i = \frac{n_1 + n_2 + \dots + n_z}{N} = \frac{N}{N} = 1 \quad (4)$$

gdzie:  $p$  – udział aktywności z zakresu  $i$ ,  $z$  – liczba wyszczególnionych zakresów aktywności,  $n$  – liczba aktywności należących do określonego zakresu,  $N$  – liczba wszystkich neuronów warstwy płynu.

Entropię indywidualną w każdym z kroków symulacji można wtedy wyznaczyć w oparciu o wzór:

$$S = -\sum_{i=1}^z p_i \log_{10}(p_i) \quad (5)$$

gdzie:  $p$  – udział aktywności z zakresu  $i$ ,  $n$  – liczba aktywności

Bardzo wysoka wartość entropii w danym kroku oznacza, że zaobserwowane wielkości aktywności neuronów przynależą do zdefiniowanych przedziałów aktywności w sposób zbliżony do równomiernego – mówimy o wysokim stopniu nieuporządkowania układu. Entropia indywidualna w danym kroku osiągnie wartość maksymalną równą 1 w sytuacji gdy wartości obserwowanych aktywności neuronalnych będą przynależały do zdefiniowanych zakresów w sposób idealnie równomierny. Bardzo niska wartość entropii w danym kroku oznacza, że zaobserwowane wielkości aktywności neuronów przynależą niemal wyłącznie do jednego ze zdefiniowanych przedziałów – mówimy o niskim stopniu nieuporządkowania układu. Entropia indywidualna w danym kroku osiągnie wartość minimalną równą 0 w sytuacji gdy wszystkie wartości obserwowanych aktywności neuronalnych będą przynależały wyłącznie do jednego ze zdefiniowanych zakresów.

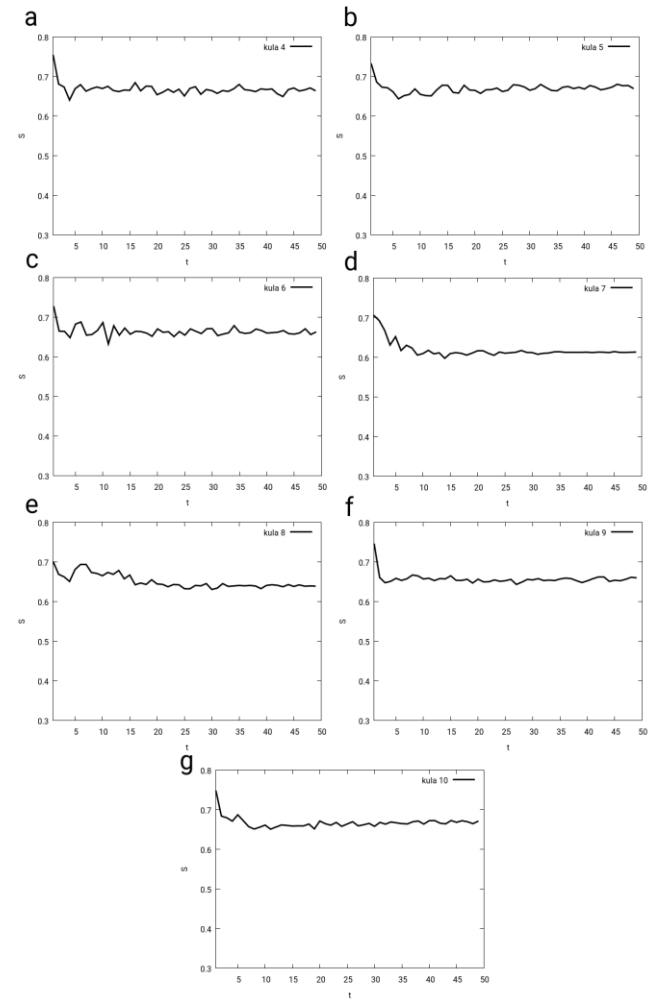
Na potrzeby prowadzonych badań przyjęto, że obserwowane wielkości aktywności neuronalnej mogą przynależać do jednego z dziesięciu zdefiniowanych przedziałów aktywności ( $z=10$ ). Przedziały te to odpowiednio aktywność z zakresu:  $\langle 0,0;0,1 \rangle$ ,  $\langle 0,1;0,2 \rangle$ ,  $\langle 0,2;0,3 \rangle$ ,  $\langle 0,3;0,4 \rangle$ ,  $\langle 0,4;0,5 \rangle$ ,  $\langle 0,5;0,6 \rangle$ ,  $\langle 0,6;0,7 \rangle$ ,  $\langle 0,7;0,8 \rangle$ ,  $\langle 0,8;0,9 \rangle$ ,  $\langle 0,9;1,0 \rangle$ . Miary entropii indywidualnej wyznaczono w oparciu o tak zdefiniowane przedziały aktywności.

Na załączonych wykresach (rys. 4) przedstawiono zmiany entropii indywidualnej w miarę upływu 50 kroków symulacji dla sieci o 10% gęstości połączeń biegnących z warstwy wejściowej do warstwy płynu. Dla kuli 7 (rys. 4d) miara entropii indywidualnej ustabilizowała się najszybciej, bo już w 15 kroku. Podobnie w przypadku kuli 8 (rys. 4e), gdzie od około 30 kroku obserwujemy jej względnie stabilny poziom. W przypadku kul 4 (rys. 4a), 5 (rys. 4b) i 6 (rys. 4c) obserwujemy zmiany ciągnące się przez cały okres trwania symulacji, charakteryzujące się większymi zmianami w pierwszych 15 krokach. W przypadku kuli 9 (rys. 4f) wysoka wartość entropii bardzo szybko została wytłumiona – od drugiego kroku nie obserwujemy wyraźnych zmian. Poza zauważalnym skokiem w okolicach 5 kroku podobnie zachowuje się również przebieg entropii dla kuli 10 (rys. 4g).

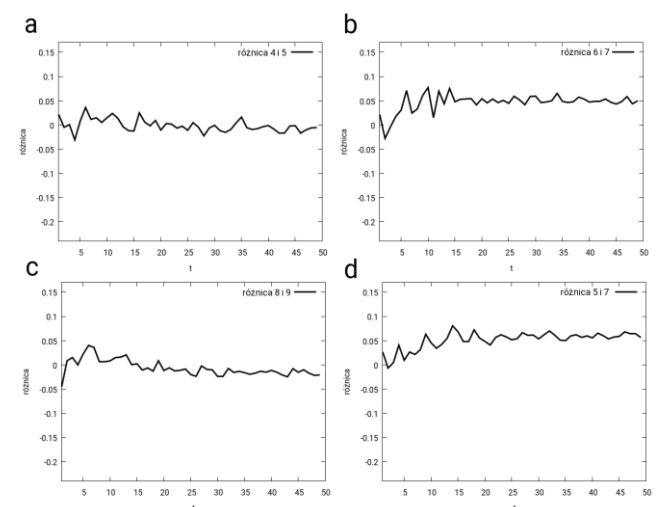
Przebiegi entropii dla wybranych par kul zostały porównane ze sobą a wyniki porównania przedstawiono na czterech wykresach (rys. 5) w postaci różnic w przebiegach tych entropii. W oparciu o te wykresy możemy stwierdzić, że poziomy na jakich utrzymuje się miara entropii dla kul 4 i 5 (rys. 5a) są podobne (wykres różnicy utrzymuje się przeważnie w okolicach 0). Podobnie wygląda sytuacja dla pary kul 8 i 9 (rys. 5c). Widoczną różnicą obserwowaną w tych parach jest charakter zachodzących zmian entropii, widoczny pod postacią nieregularnego przebiegu wykresu różnicy.

Poziomy na jakich utrzymuje się entropia dla pary kul 6 i 7 (rys. 5b), pomimo, że w początkowym stadium symulacji podobne, w dalszej części (od około 10 kroku) rozmiągają się względem siebie aż o 0,05 jednostek, utrzymując się na tym poziomie do końca symulacji. Podobnie w przypadku pary kul 5

i 7 (rys. 5d). Podobnie jak w przypadku par 4 i 5 (rys. 5a) oraz 8 i 9 (rys. 5c) obserwujemy różnice w charakterze zachodzących zmian entropii, widoczne pod postacią nieregularnych przebiegów wykresów różnic (rys. 5bd).



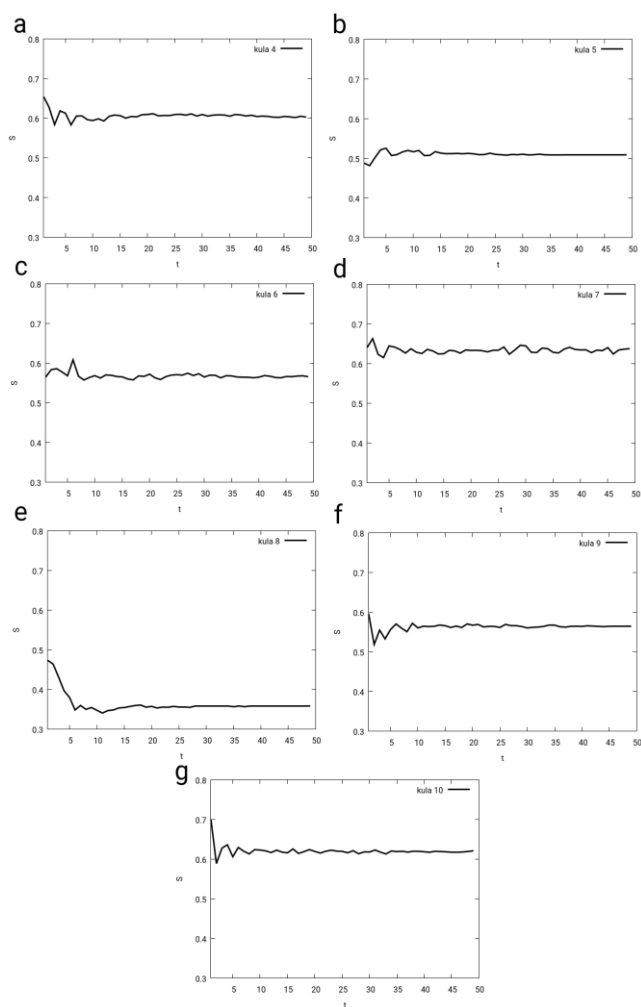
Rys. 4. Zmiany entropii w sieci o 10% gęstości połączeń z warstwy wejściowej do warstwy płynu dla wzorców wybranych kul: a – kula 4, b – kula 5, c – kula 6, d – kula 7, e – kula 8, f – kula 9, g – kula 10



Rys. 5. Różnice pomiędzy przebiegami entropii w sieci o 10% gęstości połączeń z warstwy wejściowej do warstwy płynu dla par wzorców wybranych kul: a – kule 4 i 5, b – kule 6 i 7, c – kule 8 i 9, d – kule 5 i 7

Dla maszyny płynowej o 80% gęstości połączeń z warstwy wejściowej do warstwy płynu również dokonano wyznaczenia miar entropii dla każdego z wzorców wejściowych (rys. 6). Dla wyników wygenerowanych z użyciem tej sieci zauważamy duże rozbieżności w poziomach, na jakich utrzymuje się wspomniana

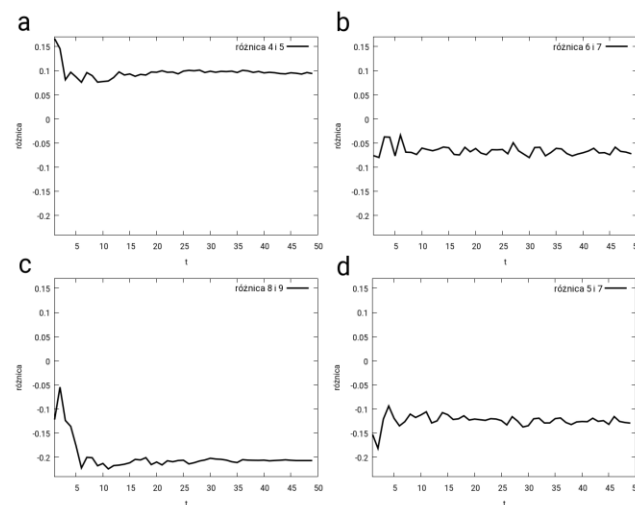
miara dla wzorców poszczególnych kul. Przebieg entropii na najwyższym poziomie (około 0,64 jednostek) obserwujemy dla kuli numer 7 (rys. 6d), a na najniższym (około 0,36 jednostek) dla kuli 8 (rys. 6e). Zauważalny jest także charakterystyczny, indywidualny dla poszczególnych wzorców kul początkowy przebieg entropii (pierwsze 15 kroków). W zależności od kuli można zaobserwować między innymi wyraźny spadek entropii nawet o około 0,12 jednostek na przestrzeni pierwszych 5 kroków (rys. 6e – kula 8), wzrost entropii na przestrzeni pierwszych 5 kroków (rys. 6b – kula 5), wyraźny pojedynczy skok wartości w okolicach 7 kroku (rys. 6c) lub równomierne wahania na przestrzeni 10 początkowych kroków (rys. 6a). Ponadto, interesująco prezentuje się cały przebieg zmian entropii dla wzorca kuli 7 – wytłumione na przestrzeni pierwszych 15 kroków wahania nawracają w okolicach 27 kroku, aby ponownie stopniowo ulegać wytłumieniu, aż do końca symulacji.



Rys. 6. Zmiany entropii w sieci o 80% gęstości połączeń z warstwy wejściowej do warstwy płynu dla wzorców wybranych kul: a – kula 4, b – kula 5, c – kula 6, d – kula 7, e – kula 8, f – kula 9, g – kula 10

Dla drugiej z omawianych maszyn płynowych, tak jak w przypadku pierwszej również wybrano cztery (identyczne jak poprzednio) pary kul i dokonano wyznaczenia różnic pomiędzy zarejestrowanymi przebiegami ich entropii (rys. 7). Na wykresach porównawczych poza różnicami wynikającymi z charakteru zmian widoczne są także znaczące przesunięcia względem osi  $y$ . Wynikają one ze znaczących różnic w poziomach na jakich średnio utrzymywały się poszczególne, porównywane przebiegi. Dla kul 4 i 5 (rys. 7a) możemy powiedzieć, że przebieg zarejestrowany dla kuli 5 (rys. 6b) charakteryzował się średnio niższą aż o 0,1 jednostek miarą entropii, niż ten odpowiadający kuli 4 (rys. 6a). Ponadto obserwowane różnice w pierwszych dwóch krokach symulacji były znacząco większe (0,15 jednostek). W przypadku porównania przebiegów entropii dla wzorców kul 8 i 9 (rys. 7c) widać, że poza początkowymi 5 krokami miara

entropii dla kuli 9 (rys. 6f) utrzymywała się średnio na poziomie aż o 0,2 jednostek wyższym niż entropia dla kuli 8. Tak samo można zauważyć, że przebiegi entropii dla kul 6 i 7 (rys. 7b) różnią się między sobą poziomami o 0,05 jednostek, a dla kul 5 i 7 (rys. 7d) o 0,1 jednostek.



Rys. 7. Różnice pomiędzy przebiegami entropii w sieci o 10% gęstości połączeń z warstwy wejściowej do warstwy płynu dla par wzorców wybranych kul: a – kule 4 i 5, b – kule 6 i 7, c – kule 8 i 9, d – kule 5 i 7

Przechodząc do podsumowania zgromadzonych dla każdej z dwóch maszyn płynowych wyników należy zaznaczyć, że dla pierwszej z nich poza samym charakterem zmian w poziomach entropii nie można mówić o bardzo wyraźnych, innych różnicach pomiędzy badanymi przebiegami. Dla większości wzorców kul utrzymują się one w okolicach podobnego poziomu (około 0,65). Ponadto entropia dla wszystkich przebadanych wzorców w początkowym stadium symulacji zawsze miała większą wartość i ulegała sukcesywnemu zmniejszeniu w miarę upływu kolejnych kroków symulacyjnych. W przypadku wyników zgromadzonych z wykorzystaniem drugiej z maszyn płynowych, poza różnicami w przebiegach zmian entropii dla poszczególnych wzorców można było zaobserwować także bardzo znaczące różnice w średnim poziomie na jakim się ona utrzymywała. Dodatkowo dla niektórych wzorców w odróżnieniu do maszyny płynowej pierwszej zaobserwowano wzrost entropii w miarę upływu kroków symulacji. Należy zaznaczyć również, że dla maszyny pierwszej charakterystyczne początkowe wahania miary entropii utrzymują się przez większą liczbę kroków, niż w przypadku maszyny drugiej, dla której ulegają one znacznie szybszemu i bardziej intensywnemu wytłumieniu. Ciekawym spostrzeżeniem jest również to, że amplitudy obserwowanych wahań entropii w przypadku obydwu maszyn są porównywalne.

Przeprowadzone badania oraz ich wyniki sugerują, że możliwe jest wykorzystanie odpowiednio skonstruowanej maszyny płynowej do dostarczenia informacji na podstawie których w sposób właściwy można by wnioskować odnośnie wzorca jakim sieć była pobudzana.

### 3. Podsumowanie

Podsumowując, w procesie badawczym skonstruowaliśmy manipulator robotyczny wyposażony w chwytak dłoniopodobny oraz zestaw siedmiu podstawowych kul różniących się średnicą o 1 cm w zakresie od 4 cm do 10 cm. Wykorzystaliśmy manipulator do stworzenia reprezentacji parametrów odpowiednich dla chwycenia poszczególnych kul. W oparciu o uzyskane parametry przybliżyliśmy wykresy zależności parametrów sterujących dla poszczególnych palców od średnicy kul. Wykazaliśmy, że dla przyjętych reprezentacji wejściowej i wyjściowej sieć BAM jest w stanie właściwie pomieścić asocjacje dla liczby kul nie większej niż dwie. Wykorzystując przybliżone funkcje zależności parametrów od średnicy kuli zwiększyliśmy zbiór uczący i wykazaliśmy, że dwuwarstwowy

perceptron wykorzystany do stworzenia jednokierunkowej asocjacji jest w stanie zadowalająco osiągnąć stawiany cel, nawet dla zbioru składającego się ze 121 elementów. Dodatkowo wykazaliśmy, że jest on w stanie z zadowalającą dokładnością rozpoznawać wzorce uszkodzone w stopniu nie większym niż 20%. Na podstawie kolejnego etapu badania udowodniliśmy, że przy dobranych reprezentacjach i sposobie uczenia sieć nie wykazuje dostatecznie dobrych zdolności do generalizowania danych spoza zbioru treningowego. Opierając się na definicji Entropii Informacyjnej Shannona zaproponowaliśmy miarę entropii lokalnej na potrzeby sztucznych sieci neuronowych. Posługując się zdefiniowaną miarą entropii wykazaliśmy, że odpowiednio skonstruowana maszyna płynowa może wykazywać charakterystyczny przebieg aktywności dla każdej z kul, a co za tym idzie pozwolić na stwierdzenie jaką kulą sieć była pobudzana.

Prowadzone badania mogą dostarczać nowej wiedzy oraz prowadzić do głębszego zrozumienia mechanizmów wyższych funkcji poznawczych w mózgu homo sapiens, a także mogą być wykorzystane do realizacji inteligentnych interfejsów robotycznych.

## Literatura

- [1] Goodale M. A., Milner A. D.: Separate visual pathways for perception and action. *Trends Neurosci* 15(1)/1992, 20.
- [2] Jabłoński T.: Kurs programowania mikrokontrolerów PIC (2), Sterowanie za pomocą PWM. *Elektronika Praktyczna* 4/2011 86.
- [3] Kosko B.: Bidirectional associative memories. *IEEE Transactions on Systems, Man and Cybernetics* 18(1)/1988, 4947.
- [4] Liu X., Zhan Q.: Description of the human hand grasp using graph theory. *Medical Engineering & Physics*, 35(7)/2013, 1020.
- [5] Maass W., Natschlagler T., Markram H.: Real-time Computing Without Stable States: A New Framework for Neural Computation Based on Perturbations. *Neural Computations* 14(11)/2002, 2531.
- [6] Muszyński S., Kamiński W.A.: Badanie właściwości asocjacyjnych maszyny LSM złożonej z neuronów Hodgkina-Huxleya. *Bio-Algorithms and Med-Systems* 1/2005, 27.
- [7] Schultz A.M., Lee S., Shea T.B., Yanco H.A.: Control of a robot arm with artificial and biological neural networks. *Materiały konferencyjne Twenty-Eighth AAAI Conference on Artificial Intelligence*, 2014.
- [8] Shannon C.E.: A mathematical theory of communication. *Bell Systems Technical Journal* 27/1948, 623.
- [9] Shipp S.: Structure and function of the cerebral cortex. *Current Biology* 17(12)/2007, R443.
- [10] Wojcik G.M., Kaminski W.A.: Liquid State Machine Built of Hodgkin-Huxley Neurons and Pattern Recognition. *Neurocomputing* 239/2003, 245.
- [11] <http://www.eyeshots.it> [26.04.2016]
- [12] InMoov - open-source 3D printed life-size robot, <http://inmoov.fr> [26.04.2016]
- [13] Kriesel D.: A Brief Introduction to Neural Networks. <http://www.dkriesel.com> [26.04.2016]
- [14] SNNS – Stuttgart Neural Network Simulator, User Manual, Version 4.2, <http://www.ra.cs.uni-tuebingen.de/SNNS/> [26.04.2016]

**Mgr Paweł Olszewski**  
e-mail: [olszewski@umcs.pl](mailto:olszewski@umcs.pl)

Absolwent studiów informatyki UMCS, obecnie nauczyciel akademicki na Wydziale Matematyki Fizyki i Informatyki Uniwersytetu Marii Curie-Skłodowskiej. Zainteresowania naukowe obejmują zagadnienia związane z systemami sztucznej inteligencji obliczeniowej oraz robotyki kognitywnej, w tym głębokie uczenie maszynowe.



**Prof. dr hab. Wiesław A. Kamiński**  
e-mail: [kaminski@kft.umcs.lublin.pl](mailto:kaminski@kft.umcs.lublin.pl)

Kierownik Zakładu Układów Złożonych i Neurodynamiki UMCS. Zainteresowania naukowe obejmują fizykę neutrin, socjorobotykę i robotykę kognitywną. Opublikował ponad 150 artykułów i doniesień naukowych, autor oraz redaktor 7 książek. Odbił staże naukowe na uniwersytetach, m.in w Tybindze, Strasburgu, Paryżu, Janinie, Atenach, Jyväskylä, Moskwie, Stanfordzie, Debreczynie i Warszawie.



otrzymano/received: 15.06.2016

przyjęto do druku/accepted: 14.08.2017