

Uniwersytet Warszawski

Wydział Fizyki

Paweł Kopka

Nr albumu: 293323

**Poszukiwanie możliwych reprezentacji obiektów
złożonych w pamięci roboczej.
Badania symulacyjne na modelowych układach
sieci neuronowych.**

Praca magisterska
na kierunku Zastosowanie Fizyki w Biologii i Medycynie
w zakresie Neuroinformatyki

Praca wykonana pod kierunkiem
dr hab. Jarosław Żygierewicz
Zakład Fizyki Biomedycznej
Instytut Fizyki Doświadczalnej
Uniwersytet Warszawski

dr inż. Franciszek Rakowski
Instytut Biocybernetyki i Inżynierii Biomedycznej
Polskiej Akademii Nauk

Warszawa, Wrzesień 2014

Oświadczenie kierującego pracą

Oświadczam, że niniejsza praca została przygotowana pod moim kierunkiem i stwierdzam, że spełnia ona warunki do przedstawienia jej w postępowaniu o nadanie tytułu zawodowego.

Data

Podpis kierującego pracą

Oświadczenie autora (autorów) pracy

Świadom odpowiedzialności prawnej oświadczam, że niniejsza praca dyplomowa została napisana przeze mnie samodzielnie i nie zawiera treści uzyskanych w sposób niezgodny z obowiązującymi przepisami.

Oświadczam również, że przedstawiona praca nie była wcześniej przedmiotem procedur związanych z uzyskaniem tytułu zawodowego w wyższej uczelni.

Oświadczam ponadto, że niniejsza wersja pracy jest identyczna z załączoną wersją elektroniczną.

Data

Podpis autora (autorów) pracy

Streszczenie

Istnieje wiele teorii na temat istnienia reprezentacji neuronalnych obiektów w mózgu. Z artykułu *Spike-Timing Theory of Working Memory* dowiadujemy się, że w pamięci roboczej mogą się znajdować wzorce polichroniczne, odpowiadające takim reprezentacjom. W tej pracy został zaprezentowany koncept wzorca wyższego rzędu, który miałby reprezentować obiekty złożone. Został przeprowadzony szereg symulacji komputerowych sieci neuronalnej opartej o model Model Izhikevicha oraz plastyczność synaptyczną STDP. Badania przeprowadzono na dwóch topologiach sieci: homogenicznej i heterogenicznej. Różnica między dwoma sieciami polegała na wprowadzeniu większej gęstości połączeń w podsięciach dla przypadku heterogenicznego. W pracy został przedstawiony algorytm wyszukujący wzorce polichroniczne oraz hierarchiczne. Wyniki symulacji komputerowych sieci obu typów wykazały istotne statystycznie różnice między wyszukanym wzorcem hierarchicznym, a grupą losowych wzorców polichronicznych. Wykazuje to że jest możliwość przeprowadzenia symulacji, które nie zaprzeczają hipotezie. Zaobserwowane sekwencje odpaleń wzorców polichronicznych mogą być interpretowane jako model reprezentacji neuronalnej obiektu złożonego.

Słowa kluczowe

Reprezentacje neuronalne, symulacja sieci neuronowej, plastyczność STDP, model punktowy neuronu, neuronowe grupy polichroniczne, obiekty hierarchiczne

Dziedzina pracy (kody wg programu Socrates-Erasmus)

13.200

Tytuł pracy w języku angielskim

Searching for putative representation of complex objects in a working memory. Simulations of model neuronal network systems.

SPIS TREŚCI

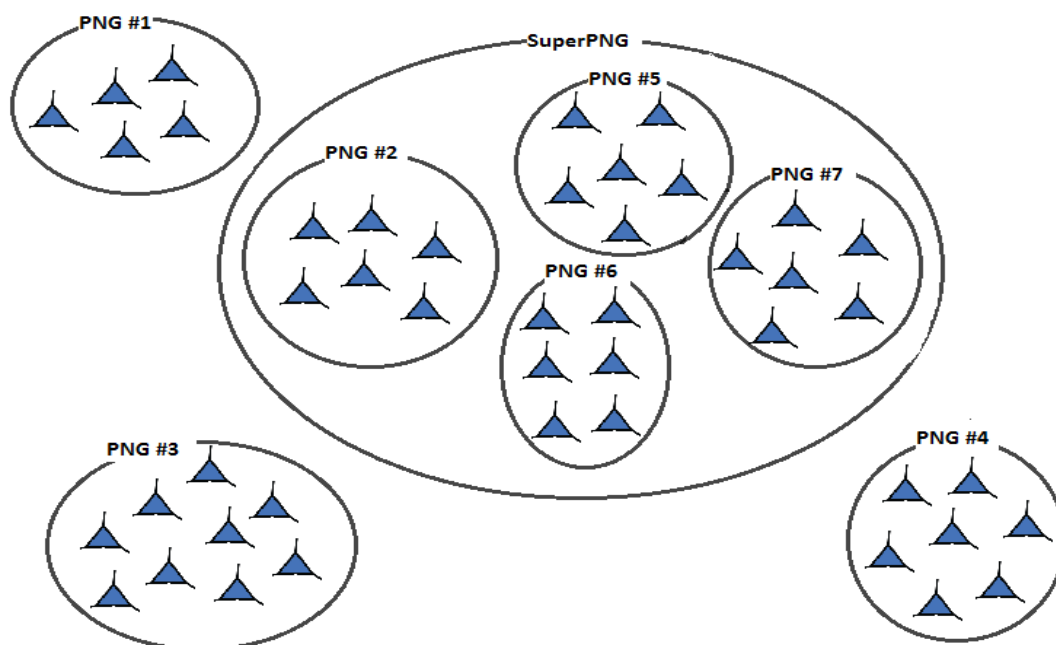
1. Wprowadzenie	3
2. Wstęp teoretyczny	5
2.1 Wzorce polichroniczne – PNG	5
2.2 Elektrofizjologia neuronu	6
2.3 Model Hodgkina – Huxleya	7
2.4 Model Izhikevicha	8
2.5 Wielkoskalowe symulacje mózgu	10
2.6 Plastyczność synaptyczna	12
2.7 Pamięć i jej rodzaje	14
2.8 Reprezentacje neuronalne	15
3. Metodologia Badań	16
3.1 Budowa sieci neuronowej.	16
3.2 Komputerowe symulacje sieci neuronowej	16
3.3 Algorytm wyszukujący wzorców polichornicznych	17
3.4 Algorytm wyszukujący wzorców hierarchicznych	18
3.5 Weryfikacja istotności statystycznej	20
4. Wyniki badań	21
4.1 Sieć homogeniczna	21
4.2 Sieć heterogeniczna	26
4.3 Analiza istotności statystycznej do wyników	31
5. Podsumowanie	36
6. Bibliografia	38

1. Wprowadzenie

Chociaż udało się uzyskać wiele odpowiedzi na pytania nurtujące ludzkość, to, mimo wszystko, nadal pozostaje wiele niewyjaśnionych zagadek. Nasz mózg jest jedną z nich. Biolodzy prowadzą badania mające na celu lepsze poznanie tej specyficznej tkanki, a w ostatnich latach dołączyli do nich również fizycy. Krokiem milowym w badaniach nad mózgiem było opisanie podstawowej komórki, z której jest on zbudowany (neuronu). Dokonali tego trzej naukowcy: A.L. Hodgkin, A.F. Huxley oraz Sir J. C. Eccles, za co w 1969 roku zdobyli nagrodę Nobla z dziedziny medycyny. Przedstawili oni dynamikę przepływu jonów przez błonę komórkową podczas generowania potencjału czynnościowego. Powstanie modelu H-H(*Hodgkin–Huxley*) stało się początkiem prób zamodelowania większych obszarów ludzkiego mózgu, który w całości składa się z około stu miliardów neuronów.

Podstawową funkcją układu nerwowego jest przetwarzanie informacji na temat otoczenia, które dociera przez zmysły do mózgu. Sygnał ten jest modyfikowany w oparciu o doświadczenia nabyte w przeszłości. System kategoryzacji bodźców środowiskowych kształtuje się dzięki przechowywaniu informacji o doświadczeniu osobniczym. Doświadczenie te – obiekty przechowywane w pamięci mają korelaty w postaci określonych fizycznych procesów neuronalnych. To podejście pozwala nam na przyjęcie, iż dla postrzeganego obrazu lub kategorii językowej istnieją odpowiednie reprezentacje neuronalne.

Główną hipotezą tej pracy jest: biologicznie realistyczna sieć neuronalna może zawierać w sobie hierarchiczny układ reprezentacji obiektów złożonych. W artykule *Spike-Timing Theory of Working Memory* [5] zaprezentowano możliwość istnienia grup neuronów w mózgu, które mogłyby odpowiadać za jedną cechę obiektu złożonego. Powyższa hipoteza, opierając się na tym artykule, zakłada, że istnieją związki między grupami, podobne do relacji między neuronami, opisane jako grupy polichroniczne (PNG). Takie struktury zostały nazwane *Super Polychronous Neuronal Groups* (SuperPNG). Graficzne przedstawienie zaproponowanej budowy hierarchicznej prezentuje rysunek 1. Występują tam trzy poziomy: pierwszy – neurony, drugi – wzorce polichroniczne i trzeci - wzorce hierarchiczne. Odpalenie w odpowiednim czasie wejściowych grup polichronicznych w SuperPNG wyzwała kaskadę aktywowania się kolejnych PNG. Przypomina to działanie wzorca polichronicznego i odpalenie jego trzech neuronów wejściowych. Dalsze przeprowadzone symulacje mają na celu weryfikację wyżej wymienionej hipotezy.



Rysunek 1. Przedstawienie graficzne hipotezy.


Symulacje były wykonywane na dwóch modelowych topologiach sieci homogenicznej i heterogenicznej. Mózg składa się z różnych struktur posiadających połączenia między sobą. Dlatego też zbudowano sieć heterogeniczną w skład której wchodzi kilka podsieci. Założono, że gęstość połączeń między komórkami w każdej podsieci będzie większa. Połączenia wewnętrzne posiadają mniejsze opóźnienia niż połączenia zewnętrzne. Z tego powodu pojawiło się kolejne pytanie: czy sieć heterogeniczna będzie posiadała takie same właściwości co sieć homogeniczna?

2. Wstęp teoretyczny

2.1 Wzorce polichroniczne - PNG

Na pytanie, jaka jest relacja między pamięcią roboczą, a pamięcią trwałą, próbują odpowiedzieć Szatmáry i Izhikevich w *Spike-Timing Theory of Working Memory* z 2010 roku. Usiłują wyjaśnić, w jaki sposób mniejsza ilość neuronów może korzystać ze znacznie większej ich ilości występującej w pamięci trwałej. Ich zdaniem obiekty są reprezentowane jako grupy neuronów, których mnogość kombinacji może być znacznie większa niż liczba komórek nerwowych w pamięci operacyjnej.

Polychronous neuronal groups (PNG)[7] zostały przedstawione przez Izhikevicha w 2006 roku jako możliwe rozwiązanie relacji między pamięcią roboczą, a pamięcią trwałą. Ta koncepcja opiera się o czas odpalania poszczególnych neuronów w danej grupie, oraz połączeń między nimi które posiadają opóźnienia. Na rysunku 2 przedstawiona jest przykładowa paczka neuronów.



Rysunek 2. Prezentacja przykładowych dwóch PNG.[5]

Część (A) przedstawia siedem neuronów, połączenia między nimi mają różne wartości opóźnienia sygnału. Można wyodrębnić dwie drogi wśród tej grupy, czarną i czerwoną. Każda z nich odpowiada za inny wzorec. Komórkami wejściowymi są $n1$ i $n2$, a w zależności od konfiguracji ich odpalania, może aktywować się jeden z dwóch schematów. Przykładowo, jeśli zostanie odpalony $n1$, a 10 ms później $n2$, to zostanie uruchomiona czerwona opcja (B) i będą kolejno działać $n1$, $n2$, $n3$, $n4$, $n5$, $n6$ i $n7$. Innym przykładem jest przypadek, gdy zmienimy kolejność między $n1$ i $n2$. Takie działanie wywoła inną sekwencję (C) $n7$, $n5$, $n3$, $n6$, $n4$, która daje nam aktywny wzorec czarny. Każde takie otwarcie podgrupy wpływa na wzmocnienie w niej połączeń synaptycznych.

Powyższy przykład pokazuje jak działają dwie PNG. Ich ilość może być większa, wszystko zależy od liczby neuronów oraz połączeń.

2.2 Elektrofizjologia neuronu

2.2.1 Potencjał spoczynkowy

Neurony są komórkami pobudliwymi oraz zdolnymi do wytwarzania i przekazywania impulsów nerwowych. Ich błona komórkowa jest spolaryzowana. Stała różnica potencjałów elektrycznych spowodowana nierównomiernym rozmieszczeniem jonów (kationów i anionów) po obu stronach błony komórkowej neuronu warunkuje utrzymanie potencjału spoczynkowego. O tym mówi równanie Goldmana [6]:

$$V_m = 58 \log \frac{P_K [K^+]_z P_{Na} [Na^+]_z + P_{Cl} [Cl^-]_w}{P_K [K^+]_w P_{Na} [Na^+]_w + P_{Cl} [Cl^-]_z} \quad (1)$$

Gdzie : P to przepuszczalność dla różnych jonów,

$[K^+]$, $[Na^+]$, $[Cl^-]$ to stężenie jonów wewnątrz lub na zewnątrz komórki.

Stała jest wynikiem równania :

$$58 = \frac{RT}{F} \quad (2)$$

Gdzie : R to stała gazowa,

T to temperatura bezwzględna,

F to stała Faradaya.


Potencjał spoczynkowy wynika z działania pomp sodowo-potasowych oraz kanałów jonowych i opisuje równowagę termodynamiczną jonów wewnątrz i na zewnątrz komórki. Działanie pompy polega na jednoczesnym wyrzucaniu jonów sodu na zewnątrz komórki oraz aktywnym wprowadzaniu jonów potasu do wnętrza komórki w stosunku 3:2. Jest to przeciwdziałanie przepływowi jonów przez błonę zgodnie z gradientem stężeń.

2.2.2 Potencjał czynnościowy

Przenoszenie informacji z jednej komórki nerwowej na drugą lub z komórki nerwowej na komórkę mięśniową czy gruczołową odbywa się dzięki potencjałom czynnościowym powstającym w błonie komórkowej. Potencjał czynnościowy będący impulsem nerwowym powstaje wskutek działania bodźców ponadprogowych powodujących krótkotrwałe zmiany potencjału spoczynkowego w błonie neuronu. Przepuszczalność błony dla jonów Na^+ znacznie wzrasta doprowadzając do całkowitej depolaryzacji błony. Również i kanały potasowe zostają otwarte, powodując wypływanie jonów potasu z komórki, przez co ubywa ładunków dodatnich wewnątrz komórki i następuje repolaryzacja przywracająca potencjał spoczynkowy. Otwarcie kanałów sodowych i potasowych jest asynchroniczne.

2.3 Model Hodgkina – Huxleya

Dzięki badaniom A.L. Hodgkina i A.F. Huxleya nad kałamarnicą posiadającą bardzo długi akson, udało się przybliżyć elektryczne własności błony synaptycznej po przez zastępczy obwód elektryczny (Rys. 3).



Rysunek 3. Obwód zastępczy przedstawiający błonę aksonu.[2]

Kondensator C_m reprezentuje błonę komórkową. Kanały potasowe oraz sodowe są przestawione w postaci gałęzi zbudowanych ze źródeł E_{Na} , E_K oraz oporników R_{Na} i R_K . Para R_L i E_L odwzorowuje resztę kanałów przybliżonych do jednego, który nie jest napięciowo zależny.

Opór można zapisać w postaci przewodności g która jest odwrotnością oporu. Przewodność g_K i g_{Na} zależy od napięcia i czasu. Kolejnym czynnikiem wpływającym na przewodność jest prawdopodobieństwo otwarcia konkretnej drogi dla jonów, które opisują parametry m, n i h . Korzystając z drugiego prawa Kirchhoffa, gdzie suma prądów w gałęziach musi być równa całkowitej wartości prądu oraz definicji pojemności, otrzymujemy następującą zależność:

$$C_M = \frac{q}{u} \quad (3)$$

$$I_C = C_M \frac{du}{dt} \quad (4)$$

$$I(t) = I_C(t) + \sum_{i=1}^N I_N(t) \quad (5)$$

$$C \frac{du}{dt} = I(t) - \sum_{i=1}^N I_N(t) \quad (6)$$

Gdzie: I_N to prądy w poszczególnych gałęziach,
 I to prąd całkowity w obwodzie,
 q ładunek zgromadzony w kondensatorze,
 u napięcie na kondensatorze.

Rozwijając powyższe rozważania można wyznaczyć sumę wartości prądów w poszczególnych kanałach z użyciem wcześniej wymienionych parametrów opisujących prawdopodobieństwo na otwarcie kanałów napięciowo zależnych.

$$\sum_{i=1}^N I_N = g_{Na} m^3 h (u - E_{Na}) + g_K n^4 (u - E_K) + g_L (u - E_L) \quad (7)$$

Wartości E_{Na} , E_K i E_L przedstawiają potencjał odwrócenia. Wraz z parametrami m , n i h Hodgkin oraz Huxley określili je doświadczalnie. Model H-H jest opisany za pomocą 4 równań:

$$\frac{dV}{dt} = \frac{[I - g_{Na} m^3 h (V - V_{Na}) - g_K n^4 (V - V_K) - g_L (V - V_L)]}{C} \quad (8)$$

$$\frac{dn}{dt} = \alpha_n(V)(1-n) - \beta_n(V)n \quad (9)$$

$$\frac{dm}{dt} = \alpha_m(V)(1-m) - \beta_m(V)m \quad (10)$$

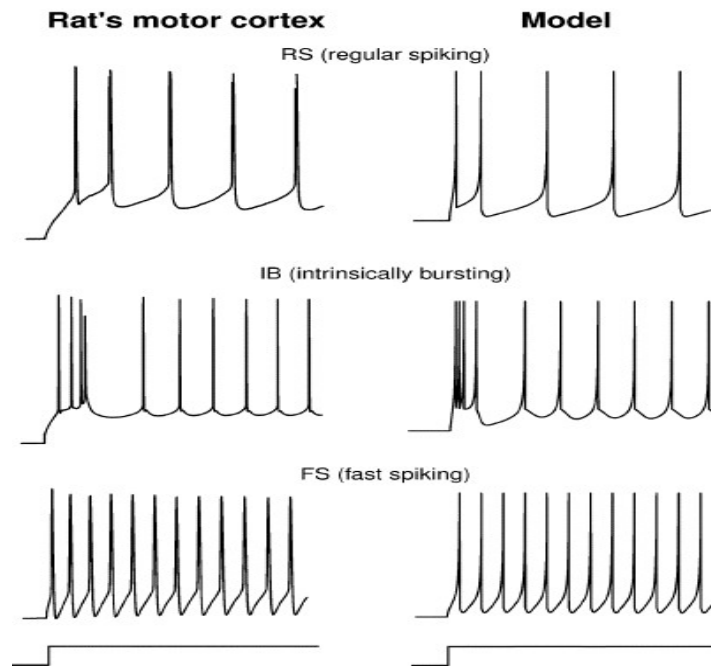
$$\frac{dh}{dt} = \alpha_h(V)(1-h) - \beta_h(V)h \quad (11)$$

Gdzie : α, β są szybkościami działania kanałów zależnych od napięcia,
 V To potencjał błony komórkowej,
 I prąd podany do neuronu.

2.4 Model Izhikevicha

Opis ruchu jonów przez błonę komórkową, wcześniej przedstawiony przez Hodgkina i Huxleya, został uproszczony przez E. I. Izhikevicha i jak twierdzi autor jest: „*kombinacją biologicznej plastyczności modelu H-H i efektywności obliczeniowej Integrate-and-fire*” [1 s.1]. Integracja wyników doświadczalnych i duża wydajność obliczeniowa dała bardzo dobre narzędzie

do symulacji większych obiektów posiadające cechy występujące w naturze. Wyniki przedstawione na rysunku 4 pokazują odpowiedzi impulsowe neuronów w modelu oraz korze ruchowej szczura.



Rysunek 4 Odpowiedź impulsowa modelu Izhikevicha oraz kory ruchowej szczura[1]

Odpowiedzi te zostały wygenerowane przez model w postaci:

$$\frac{dv}{dt} = 0.04v^2 + 5v + 140 + u + I \quad (12)$$

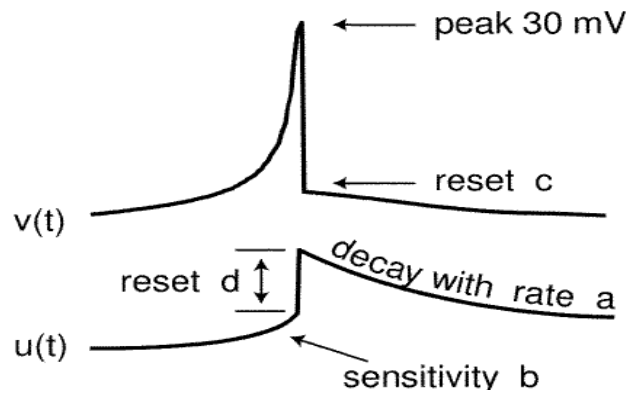
$$\frac{du}{dt} = a(bv - u) \quad (13)$$

Gdzie : v potencjał błony,

u wyznacza powrót do stanu spoczynkowego przy aktywnym kanale potasowym i nieaktywnym kanale sodowym,

I prąd podany z zewnątrz.

Gdy napięcie przekroczy próg $v \geq 30mV$, wtedy v otrzymuje wartość c . Wielkość u jest zamieniana na sumę u oraz d . Przykładową dynamikę zmiennych v i u oraz znaczenie parametrow modelu przedstawiono na rysunku 5.



Rysunek 5 Graficzne znaczniki parametrów[1]

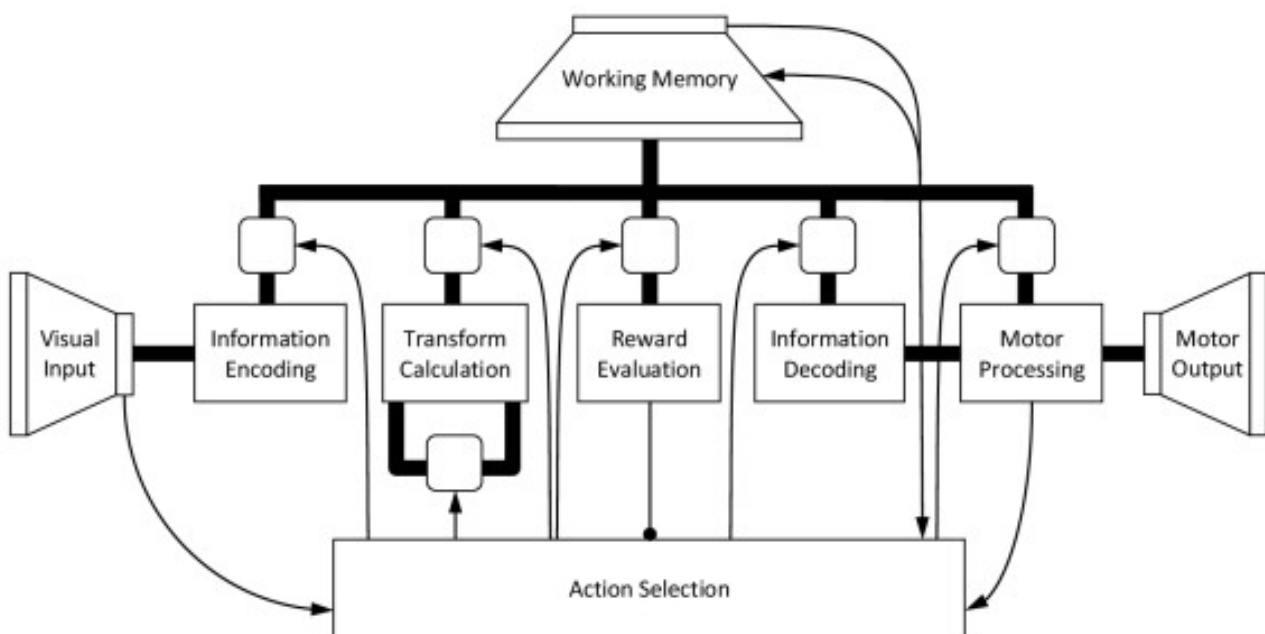
Wartości zostały obliczone przez dopasowanie początkowej dynamiki neuronów korowych. Parametr a oznacza stałą czasową powrotu do stanu równowagi, b określa wrażliwość na podprogowe fluktuacje wartości i . Wielkość c mówi do jakiej wartości jest redukowany potencjał błonowy po powstaniu impulsu. Do kształtowania modelu służy atrybut b który wpływa na kolejne impulsy wejściowe. Modyfikując wartości a , b , c i d można odtwarzać wiele trybów działania u . Pozwala to na zastosowanie tego samego formalizmu do opisu wielu rodzajów neuronów.

Izhikevich w artykule z 2003 roku przedstawił symulację z użyciem 1000 takich neuronów. Komórki zostały połączone losowo, gdzie 20% z nich stanowiły komórki hamujące, a reszta pobudzające. Ta próba pozwoliła zamodelować generację rytmu alfa oraz gamma, które są obserwowane u ludzi, a to daje podstawy do wykorzystania tego typu modeli przy opisie aktywności poszczególnych części lub całego mózgu.

2.5 Wielkoskalowe symulacje mózgu

Wielkoskalowymi modelami mózgu można nazwać takie projekty, które mają na celu przedstawienie całego mózgu lub jego konkretnego obszaru. Na świecie obecnie prowadzi się wiele projektów o tej tematyce; między innymi możemy wymienić Blue Brain oraz SPAUN. Blue Brain powstał w Szwajcarii oraz UE i w pierwszej fazie miał odpowiadać jednej kolumnie neuronalnej mózgu dwutygodniowego szczura, która przypomina budowę części mózgu innych ssaków. Taki wycinek składający się z sześciu warstw posiada około 1000 neuronów, między którymi występuje mniej więcej 1 milion synaps. Badania nad fragmentami mózgu przy użyciu mikroskopu oraz metody patch clamp pozwoliły na powstanie realistycznego modelu neuronu. Jednak symulowanie

każdej komórki oddzielnie wiąże się z ogromnymi potrzebami obliczeniowymi. Dlatego kolejny etap projektu w 2011 roku wymagał wykorzystania super-komputera (*Blue Gene*). Zwiększono symulację do 100 kolumn, a kolejnym krokiem będzie symulacja całego mózgu szczura. Docelowo planuje się symulację ludzkiego mózgu, jednak powstanie maszyny, która udźwignie takie obciążenia obliczeniowe, szacuje się na okolice roku 2020. Drugi wcześniej wymieniony projekt SPUN opiera się na populacjach neuronów. Mają one reprezentować różne partie ludzkiego mózgu odpowiadające za różne funkcje. Można wydzielić pięć najważniejszych: (1) kodowanie informacji, (2) transformacja obliczeń, (3) wynagradzanie, (4) dekodowanie informacji, (5) obsługa fizycznego ramienia. Co ważne, parametry pozostają stałe dla różniących się zadań. Sieć potrafi między innymi liczyć, zapamiętywać ciągi znaków, odpowiadać na proste pytania oraz pisać za pomocą ramienia.



Rysunek 6. Przedstawienie graficzne algorytmu działania SPAUN[8].


Oba projekty różnią się poziomem odwzorowanie mózgu. Pierwszy skupia się na samych podstawach, jakimi są neurony i relacje między nimi. Drugi zaś na pierwszym miejscu stawia konkretne obszary i ich funkcje. Można zauważyć że *Blue Brain* ma na celu wyjaśnienie działania mózgu, a SPAUN stworzenie jego kopii, która będzie potrafiła wykonywać podobne funkcje. Dlatego też wiele osób nie uważa SPAUN za model mózgu, ale przyznaje że SPAUN może znaleźć wiele zastosowań praktycznych. *Blue Brain* ma przed sobą wielką przyszłość, gdyż został przekształcony w *Human Brain Project* i stał się flagowym przedsięwzięciem w tej dziedzinie w Unii Europejskiej na najbliższe lata. Wiążą się z tym ogromne nakłady finansowe, możliwe, że będą

one wystarczające, aby stworzyć super-komputer potrzebny do zasymulowania kilkunastu miliardów neuronów.

26 Plastyczność synaptyczna

2.6.1 BCM

W roku 1982 Bienenstock, Cooper i Munro[8] przedstawili swoją teorię dotyczącą plastyczności synaps. Miała ona uzupełnić wcześniejsze wnioski Hebba[4], które nie ukazywały żadnego mechanizmu wzmacniającego lub degradującego połączenia. Zasada synaptycznej zmiany BCM bazuje na nieliniowej funkcji $\phi(y; \theta_M)$ (funkcja odpowiedzi komórki postsynaptycznej [4] Rys. 7), która przy małych wartościach aktywności postsynaptycznej $y < \theta_M$ jest ujemna. Dla wyników powyżej progu $y > \theta_M$ jest dodatnia. Modyfikowalny próg pozwala na ustabilizowanie oraz wybranie jednego wzorca. Pozwala to na wzbogacenie modelu o selektywność.



Rysunek 7. Przetawienie graficzne zasady synaptycznej zmiany BCM [8]

Autorzy przedstawili również trzy główne postulaty tej teorii:

- Zmiany wag synaptycznych są proporcjonalne do aktywności presynaptycznej
- Zmiany wag synaptycznych są proporcjonalne do nieliniowej funkcji postsynaptycznej aktywności, jeśli jest ona mniejsza, to waga ulega zmniejszeniu, w odwrotnym przypadku jest zwiększona
- Modyfikowalny próg jest funkcją liniową historii aktywności postsynaptycznej.

Wyżej przedstawione założenia zostały przetawione w formie trzech równań:

$$y = \sum_{i=1}^N w_i x_i \quad (14)$$

$$\frac{dw_i}{dt} = y(y - \theta_M) x_i - \epsilon w_i \quad (15)$$

$$\theta_M = E^p[(y/y_0)] \quad (16)$$

Gdzie : x_i - aktywność presynaptyczna,

w_i - waga synaptyczna,

y_0 – stała skalująca średnią odpowiedź neuronu,
 y - aktywność postsynaptyczna,
 θ_M - modyfikowany próg,
 $E[.]$ - przestrzenne lub czasowe uśrednienie
 ϵ - stała dla równomiernego rozkładu wagi.

Ta teoria została dwukrotnie poprawiana, najpierw przez Intratora i Coopera w 1992, dzięki czemu nazwano ją IBCM, a następnie przez Lawa i Coopera w 1994, ostatecznie, została zmieniona w następujący sposób:

$$y = \sigma \left(\sum_{i=1}^N w_i x_i \right) \quad (17)$$

$$\frac{dw_i}{dt} = \frac{y(y - \theta_M) x_i}{\theta_M} \quad (18)$$

$$\theta_M = E[y^2] \quad (19)$$

Gdzie: σ to funkcja aktywacji sigmoidalnej. Ta wersja zmniejszyła oscylację wag oraz przyspieszyła modyfikację progów przy małych wartościach.


2.6.1 Spike-timing-dependent plasticity

Z rozważań Hebba[4] i twórców BCM dotyczące uczenia się oraz poznawania powstał koncept modelu plastyczności synaps. W 2000 roku przez S. Songa, K. D. Millera i L.F. Abbotta został przedstawiony formalny opis tzw. *Hebb Learning* [4] jako STDP [3] (ang. *Spike-timing-dependent plasticity*). Ten pomysł opiera się o czas, w jakim występuje impuls przed i posynaptyczny. Główna zasada mówi, że jeśli neuron się aktywuje po tym, jak przybył do niego potencjał czynnościowy, to synapsa zostanie wzmocniona na pewien czas, a jeśli będzie odwrotnie to jej siła zostanie zdegradowana. Wystąpienie tylko jednego impulsu między dwoma połączonymi komórkami nie powoduje żadnych zmian. Rysunek 8 przedstawia wszystkie trzy przypadki. Zwiększenie lub zmniejszenie skuteczności synaps maleje eksponencjalnie w zależności od kilku parametrów:

$$F(\Delta t) = -A_- e^{\frac{-\Delta t}{\tau_-}} \quad \text{Jeśli } \Delta t \geq 0 \quad (20)$$

$$F(\Delta t) = A_+ e^{\frac{\Delta t}{\tau_+}} \quad \text{Jeśli } \Delta t < 0 \quad (21)$$

Gdzie : Δt jest różnicą w czasie wystąpienia impulsu przed i posynaptycznego, A_+ i A_- określają maksymalną zmianę synaptyczną dla obu przypadków, τ_+ i τ_- wyznaczają czas osłabienia lub wzmocnienia.



Rysunek 8 Graficzne przedstawienie działania mechanizmu STDP[5].

Model STDP można również zaimplementować w wersji on-line. Pozwala to na aktualizowanie wag w trakcie symulacji. Metoda ta opiera się o ślady jakie pozostawiają po sobie aktywacje neuronów pre i postsynaptycznych. Równania je opisujące wyglądają następująco :

$$\tau_+ \frac{dx_j}{dt} = -x_j + a_+(x_j) \sum_f \delta(t - t_j^f) \quad (22)$$

$$\tau_- \frac{dy}{dt} = -y + a_-(y) \sum_n \delta(t - t^n) \quad (23)$$

Gdzie x_j oznacza ślad zostawiony po odpaleniu neuronu presynaptycznego,

y to ślad iglicy neuronu postsynaptycznego,

t_j^f czas odpalenia komórki presynaptycznej,

t^n czas odpalenia komórki postsynaptycznej.

Wartości wagi w aktualizowane na podstawie równania opartego o wzory 22 i 23:

$$\frac{dw}{dt} = A_+(w) x(t) \sum_n \delta(t - t^n) - A_-(w) y(t) \sum_f \delta(t - t_j^f) \quad (24)$$

2.7 Pamięć i jej rodzaje

Pamięć człowieka dzielimy według czasu, jaki jest w niej przechowywana informacja. Rozróżniamy trzy rodzaje pamięci: sensoryczną, roboczą oraz trwałą. Pierwsza przetrzymuje sygnały bardzo krótko [9, str. 321]. Odpowiada za nasze zmysły i dane, jakie otrzymujemy od

świata zewnętrznego w danej chwili. Pamięć trwała to miejsce, gdzie informacje są zatrzymywane na dłuższy czas [9, str. 322]. Taka relacja wiąże się z tym, że obejmuje ona największy obszar mózgu spośród nich trzech. Część robocza jest miejscem, które łączy dwa wcześniej wymienione obszary i integruje sygnały otrzymane od naszych zmysłów razem z doświadczeniami oraz wiedzą, jaką człowiek posiadał w przeszłości. Czas przechowywania jest rząd lub dwa wielkości większy od pamięci sensorycznej [9, str. 322]. Pojemność robocza ogranicza się do kilku obiektów, została oszacowana na 7 ± 2 (magiczna liczba Millera [10]). Fizycznie jest ona znacznie mniejsza niż pamięć stała, niemniej jednak potrafi ona korzystać z całego, znacznie większego zbioru informacji znajdujących się w pamięci trwałej. Między innymi na ten temat powstała praca Spike-Timing Theory of Working Memory [5] wcześniej wspomnianego Izhikevicha oraz B. Szatmáry.

2.8 Reprezentacje neuronalne

W książce E. Nęcka [9] przedstawiona jest definicja reprezentacji poznawczej. Jest to: „umysłowy odpowiednik realnie istniejącego obiektu(...) Reprezentacja poznawcza zastępuje swój obiekt w procesach przetwarzania informacji”. Można to rozumieć jako transformację obiektu z jednej przestrzeni (realnego świata) do przestrzeni przetwarzania informacji (mózg). W tej pracy interesuje nas bardziej formalna postać, czyli reprezentacja neuronalna. Jest to przedstawienie obiektu w postaci fizycznej relacji między neuronami. Można powiedzieć, że obiekt posiada w mózgu przedstawiciela w postaci neuronów oraz połączeń między nimi.

Koncepcja reprezentacji neuronalnych dla obiektów z otaczającego nas świata jest obecnie szeroko rozpowszechniona, między innymi przez Eliasmith i Anderson w *Neural Engineering Framework* [11]. Kategoryzacja obiektów złożonych ma strukturę hierarchiczną. Można podzielić na dwa schematy hierarchiczne: “należy do” oraz “jest elementem”. Przykładem pierwszego typu może być następująca sekwencja: pies należy do kategorii ssaków, ssaki należą do kategorii zwierząt, zwierzęta do kategorii organizmów, itd. Przykładem drugiego typu jest: opona jest elementem koła, koło elementem samochodu, itd.

3. Metodologia badań

Wszystkie symulacje oraz obliczenia były prowadzone w środowisku obliczeniowym Matlab. Kod programistyczny do symulacji sieci oraz do algorytmu wyszukującego wzorce polichroniczne (3.2) był zasięgnięty z pracy [5]. Zmiany wprowadzone zostały dla symulacji sieci heterogenicznej. Algorytm wyszukujący wzorce hierarchiczne (3.3) został sporządzony przez autora pracy. Symulacje dynamiki sieci neuronowej oraz obliczenia analizy wyników były przeprowadzane na super komputerach w Interdyscyplinarnym Centrum Modelowania Matematycznego i Komputerowego Uniwersytetu Warszawskiego (ICM UW) w ramach grantu „Badanie mechanizmów powstawania i zmian pamięci u organizmów żywych”. Całkowity czas wszystkich prac zajął około 340 godziny, często z wykorzystaniem kilku procesorów jednocześnie.

3.1 Budowa sieci neuronowej

Sieć neuronowa, która służyła jako narzędzie badań w tej pracy, została zbudowana z neuronów których dynamika była opisana przez model Izhikevicha. Głównym powodem wyboru tego modelu była wydajność obliczeniowa - ten model w przeciwieństwie do modelu H-H potrzebuje mniej operacji matematycznych. Było to kluczowe zważywszy na ilość neuronów, połączeń oraz symulowanie aktywności sieci. W symulacjach przyjęto optymalne parametry przedstawione w artykule [1] odpowiadające działaniu neuronu piramidowego, te parametry pozostawały stałe podczas wszystkich symulacji: $a = 0.02$, $b = 0.2$, $c = -65mV$, $d = 2$. Ilość neuronów również była stała i wynosiła $N = 1000$ gdzie 80% z nich było neuronami pobudzającymi, a reszta hamującymi. Plastyczność synaptyczna opisana została za pomocą modelu STDP, który pozwala na dynamiczną zmianę wag synaptycznych w_{ij} między komórkami. Wartości parametrów STDP równe były $\tau_+ = \tau_- = 20 ms$, $A_+ = 0,1$ i $A_- = 0,12$. Liczba synaps na jedną komórkę wynosiła $M = 100$, a wszystkie były losowane z założeniem, że neurony hamujące nie mogą być połączone między sobą. Opóźnienia między neuronami pobudzającymi były losowane w granicach $0 ms < d_p < 20 ms$, a hamującymi miały stałą wartość $d_h = 1 ms$. Wagi początkowe dla neuronów pobudzających były równe $w_p = 1$ ale w trakcie symulacji je modyfikowano, a dla hamujących były stałe i wynosiły $w_h = -5$. Maksymalną wartość wagi ustalono na $w_{max} = 10$.


3.2 Komputerowe symulacje sieci neuronowych

W trakcie symulacji wagi połączeń synaptycznych ulegają modyfikacji. W każdej milisekundzie podawany jest prąd $I_i = 20\mu A$ do losowego neuronu i , który jest wystarczający aby aktywować komórkę. Zmieniana jest wartość napięcia według modelu Izhikevicha (wzór 12). Każde przekroczenie progu $30mV$ przez potencjał v_i generuje potencjał czynnościowy neuronu i .

Następnie ich poziom potencjału jest redukowany do $v_i = -65mV$, a impuls zostaje przekazany do komórek postsynaptycznych z odpowiednią wagą. Kolejnym krokiem jest modyfikacja wartości pochodnej wagi synaptycznej zgodnie z modelem STDP. Zgodnie z protokołem symulacji przyjętej w artykule [1] waga synaptyczna modyfikowana jest co 1 sekundę, co gwarantuje odporność na szybkie fluktuacje wag synaptycznych.

3.3 Algorytm wyszukujący wzorce polichroniczne

Grup PNG poszukiwano na podstawie wag synaptycznych powstałych po symulacji. Na początku odrzucono wszystkie słabe połączenia poniżej progu 95% maksymalnej wartości. Następnie dla każdego neuronu pobudzającego n_i dopasowano wszystkie kombinacje trzech neuronów n_j presynaptycznych spełniające wcześniejszy warunek $w_{ij} > 9.5$. Dla każdej z kombinacji przeprowadzono symulację, w której zostały pobudzone trzy neurony n_j . Jest to minimalna ilość neuronów, która może pobudzić kaskadę komórek. Czasy ich odpalania były ustalone tak, aby potencjały czynnościowe dotarły (z neuronów presynaptycznych) do neuronu postsynaptycznego w tej samej chwili, aby pozwoliło to na odpalenie neuronu n_i . Wag nie modyfikowano podczas tej operacji. Aktywności neuronów oraz ich czasy rejestrowano do momentu uzyskania czasu T_{max} , który był granicą czasową dla PNG. Następnie dla tego przebiegu czasowego poszukiwano najdłuższą ścieżkę połączeń L - od pierwszego odpalenia do ostatniego. Ścieżką połączeń jest to kaskada aktywowanych się neuronów, które mają połączenia między sobą (Rys.9). Jeśli $L > L_{max}$, to taką kaskadę zapisywano jako PNG p_k , ustalone było $L_{max} = 7$.




Rysunek 9. Przykładowa kaskada aktywności neuronów zapisana jako PNG. Czarnymi strzałkami oznaczono połączenia między neuronami. Czerwonym kolorem natomiast czas po jakim

odpala się neuron, co jest oznaczone zielonym kolorem.

3.4 Algorytm wyszukujący wzorce hierarchiczne

Podobnie jak w przypadku PNG założono, że uruchomienie trzech jednostek wejściowych aktywuje resztę wzorca. Dla losowej kombinacji trzech dowolnych grup polichronicznych uruchamiano algorytm składający się z trzech etapów: szukanie zależności między PNG(A1), ustalanie SuperPNG(A2) oraz wyszukiwanie aktywności SuperPNG w symulacji(A3).

Szukanie zależności między PNG(A1) miało na celu wyłonienie najlepsze (posiadające najlepszy współczynnik dopasowania) grupy polichroniczne jakie mogły wejść w skład SuperPNG. Na początek uruchomiono sieć dla macierzy wag W_t zapisanej w czasie t . Pobudzone zostały tylko po trzy neurony wejściowe dla każdego z wylosowanych trzech PNG. Wagi nie były modyfikowane podczas tego procesu, który trwał do $T_{max} = 150ms$. Potencjały iglicowe zostały zapisane w postaci macierzy dwumiarowej $B = n \times T_{max}$ w której wartość 0 oznaczała brak aktywności, a wartość 1 wystąpienie potencjału iglicowego dla i neuronu w czasie t . Rysunek 10 przedstawia macierz aktywności sieci neuronowej B , na którym czarnym kolorem oznaczone są wartości równe 1. K




Rysunek 10 Przykładowa macierz B dla 9 aktywowanych neuronów wejściowych.

W kolejnym etapie stworzono maski dla każdego PNG, z którymi można by porównać macierz B . Ze wzoru grupy polichronicznej m została stworzona struktura dwuwymiarowa $\mu_m = n \times T_{end}$ o wartościach 0, w której T_{end} oznaczało czas odpalenia ostatniej komórki. Wartościami 1 wypełniono μ_m aktywności neuronów w czasach $t_n - \epsilon < t < t_n + \epsilon$, gdzie ϵ był ustalonym rozmyciem czasowym. Wartość t_n to czas wystąpienie iglicy w komórce n według wzorca. Rysunek 11 przedstawia przykładową maskę μ_m . Czarny kolorem są oznaczone wartości 1. Następnie wyliczono iloczyn po elemencie B i μ_m , a później dla PNG m obliczono ilość dopasowanych odpaleń $D(t)$ w czasie $1 < t < T_{max} - T_{end}$:

$$f(t) = B(t) \cdot \mu_m \quad (25)$$

$$D(t) = \frac{\sum_{i=1}^N \sum_{k_i=1+t}^{T_{max}-T_{end}} f(t)}{r_m} \quad (26)$$

Wynik normalizowano przez ilość zdarzeń (aktywność neuronu należącego do PNG) r_m w m grupie polichronicznej, aby otrzymać wartość procentową stopnia aktywacji wzorca polichronicznego. Potem wybierano wartość maksymalną dopasowania D_{max} z $D(t)$ oraz czas wystąpienia t_{max} .



Rysunek 11. Przykładowa maska μ_m dla losowej grupy polichronicznej.

W etapie ustalania SuperPNG(A2) najpierw ponownie wybierano wartość ϵ oraz próg

graniczny D_p , który pozwalał na wybranie PNG o największym stopniu aktywacji (procencie zdarzeń definiujących PNG). Dla wszystkich PNG spełniających warunek $D_{max} > D_p$ tworzono maskę μ'_m . Która jest zmodyfikowaną μ_m poprzez wstawienie pustej maski o długości t_{max} przed pierwotną maskę μ_m . Jedynekami wypełniane były miejsca aktywności neuronów w czasach odpalenia $t_n + t_{max} - \epsilon < t < t_n + t_{max} + \epsilon$. Wszystkie PNG spełniające warunek $D_{max} > D_p$ i ich zależności czasowe określone przez macierz μ'_m tworzą polichroniczny wzorzec wyższego rzędu – SuperPNG.

Wyszukiwanie aktywności SuperPNG(A3) to etap weryfikujący SuperPNG utworzonego we wcześniejszej fazie. Wcześniej badaną sieć znów jest poddana symulacji przez 10 sekund, za pomocą losowo aktywowanych neuronów w każdej ms . Tak zarejestrowane działanie sieci było zapisane znów w postaci macierzy $B = n \times T_{max}$, gdzie $T_{max} = 10000ms$. Następnie dla każdego PNG należącego do SuperPNG, sprawdzamy współczynnik dopasowania $D(t)$. Tylko w tym przypadku zmieniamy μ' na μ'_m i korzystamy ze wzorów (25) oraz (26).

Dalej ustalany jest próg D_{PNG} , który wyznacza czy PNG można uznać za aktywny. To pozwala na ustalenie jaka część PNG z SuperPNG jest aktywna w danym czasie.

3.5 Weryfikacja istotności statystycznej

Metoda jaka została wybrana do weryfikacji hipotezy tej pracy to bootstrap. Pozwala na porównanie dwóch zestawów wyników A i B . Będzie sprawdzana różnica średnich między dwoma grupami danych :

$$r = \bar{A} - \bar{B} \quad (27)$$

Aby sprawdzić czy różnica r jest istotna statystycznie, należy sprawdzić, jakie jest prawdopodobieństwo wyąpienia r w rozkładzie R . Rozkład R estymowany jest w następujący sposób: łączymy obie grupy wyników, dzielimy losowo na dwie równe grupy A' i B' , a następnie liczymy różnice średnich dla obu grup:


$$r' = \bar{A}' - \bar{B}' \quad (27)$$

Otrzymujemy r'' które jest różnicą średnich możliwych do zaobserwowania, na skutek fluktuacji statystycznych. Powtarzamy wcześniej wymienione kroki wielokrotnie, dzięki czemu dostajemy rozkład. Następnie można oszacować prawdopodobieństwo wystąpienia wartości r w rozkładzie R .


4. Wyniki symulacji

4.1 Sieć homogeniczna

Po zbudowaniu sieci homogenicznej zgodnej z wcześniej wymienionymi parametrami, przeprowadzono kilka symulacji, każdą z innym czasem trwania. Następnie, dla już ukształtowanej struktury, został uruchomiony algorytm wyszukujący wzorców polichronicznych. Wykres na rysunku 12 przedstawia ilość grup polichronicznych w zależności od czasu symulacji sieci, w których kształtowały się wagi. Widać wzrost ilości PNG w zależności od długości symulacji. Na rysunku 13 wykres przedstawia średnią ilość zdarzeń (aktywność neuronu należącego do PNG) w tych grupach dla poszczególnych symulacji sieci. Można zauważyć zwiększającą się średnią ilość oraz wariancję zdarzeń w PNG.




Rysunek 12. Wykres przedstawia ilość PNG w sieci homogenicznej dla różnych czasów symulacji.



Rysunek 13. Wykres przedstawia średnią ilośći zdarzeń w grupie polichronicznej w zależności od czasu symulacji.

Głównym czynnikiem wpływającym na czas symulacji sieci do dalszych badań, była ilość PNG. Mnogość wzorców polichronicznych musiała być dostatecznie duża, żeby w dalszych badaniach powstała populacja odpowiednio duża do szukania SuperPNG. Ilość grup polichronicznych nie mogła być też za duża, ponieważ znacznie wydłużało to trwanie kolejnych algorytmów. Jako czas optymalny wybrano ostatecznie $T = 1000s$. Dla takiej wartości powtórzono

kilkukrotnie symulację, co przestwia wykres z rysunku 13. Z tej grupy wybierano sieć do wyszukiwań SuperPNG na podstawie ilość PNG które znalazły się najbliżej średniej ilości PNG zaobserwowanych po symulacji.




Rysunek 13. Wykres ilość PNG w sieci homogenicznej dla symulacji trwającej 1000s dla 10 powtórzeń symulacji.

Średnia ilość PNG dla dziesięciu prób wynosiła 4177 ± 1438 . Najbliżej tej wartości była próba 7, dlatego ta sieć została wybrana do badań poszukujących SuperPNG. Ze względu na bardzo dużą ilość możliwych kombinacji trzech wejściowych grup polichronicznych w całej puli istniejących PNG, wybrano pięć losowych trójelementowych kombinacji PNG. Dla każdej z kombinacji uruchomiono algorytm wyszukiwania zależności między PNG(A1). Spośród wylosowanych pięciu kombinacji wejściowych PNG wybrano jedną, dla której została osiągnięta największa średnia dopasowania D_{max} dla wszystkich PNG (por. Wzór 26).

Numer kombinacja	1	2	3	4	5
Średnia	0.014	0.082	0.119	0.058	0.198
Odchylenie standardowe	0.021	0.043	0.050	0.044	0.054

Tabela 1 Tabela przedstawia wyniki średniej dopasowania dla 5 różnych kombinacji wejściowych PNG.


Wykres z rysunku 14 przedstawia wynik najlepszych dopasowania D_{max} dla poszczególnych PNG. Można zauważyć, że niektóre grupy polichroniczne znacznie lepiej się dopasowują do aktywności sieci wyzwolonej przez trzy wejściowe PNG (grupy polichroniczne z wybranej kombinacji). Może to świadczyć o większej zależności między tymi PNG (z dużym współczynnikiem dopasowania D_{max}), a trzema PNG wejściowymi.



Rysunek 14. Wykres dopasowania poszczególnych PNG podczas wyzwolenia 9 neuronów wejściowych z 3 PNG wybranej kombinacji.


Kolejny etap to ustalanie SuperPNG(**A2**) . Próg został ustalony na wartość $D_p = 0.45$, aby wydzielić od kilku do kilkunastu PNG. Wartość rozmycia czasowego nie została zmieniona z poprzedniego etapu $\epsilon = 4$. Na tej postawie stworzono strukturę składającą się z 9 PNG.

Aby zweryfikować SuperPNG, wykonano wyszukiwanie aktywności SuperPNG(**A3**). Próg minimalnej aktywności PNG ustalono na $D_{PNG} = 0.25$. Wykres na rysunku 15 przedstawia weryfikację SuperPNG podczas symulacji 10 sekundowej. Dolna część przedstawia jaką część PNG należących do SuperPNG przekroczyła próg D_{PNG} .




Rysunek 15. Wykres górny przedstawia aktywność poszczególnych PNG. Dolny wykres przedstawia aktywność SuperPNG w 10 sekundowej symulacji sieci homogenicznej.

Dla porównania wykonano podobną symulację. Sprawdzono grupę losowych PNG w takiej samej ilości ile należało do SuperPNG. Wyniki prezentuje wykres 16.



Rysunek 16. Wykres górny przedstawia aktywność losowych PNG. Dolny wykres przedstawia aktywność grupy losowych PNG (w takiej samej ilości co SuperPNG) w 10 sekundowej symulacji sieci homogenicznej.

Innym odniesieniem dla wyników było stworzenie sztucznego SuperPNG. Polegało to na wybraniu 9 PNG z całej puli i połączeniu ich między sobą. Następnie wagi tych połączeń były stopniowo zwiększane za pomocą algorytmu uczącego. Procedura ta odpalała neuron presynaptyczny n_j oraz po czasie $t = d_{ij} + 5ms$ neuron postsynaptyczny n_i . To działanie było wielokrotnie powtarzane aż do zmaksymalizowania wagi w_{ij} . Wykres 17 przedstawia aktywność PNG oraz SuperPNG stworzonego w sposób sztuczny.



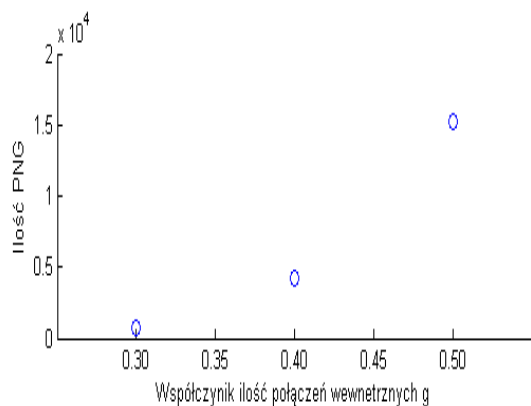
Rysunek 17. Wykres górny przedstawia aktywność PNG. Dolny wykres przedstawia aktywność sztucznie stworzonego SuperPNG w 10 sekundowej symulacji sieci homogenicznej.

4.2 Sieć heterogeniczna

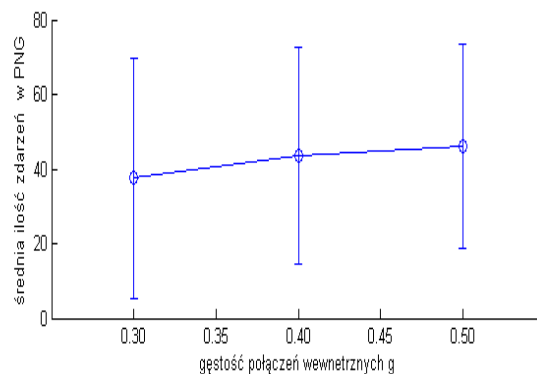
Budowa sieci heterogenicznej rozpoczęto od podzielenia wszystkich neuronów na k podsieci z_k . W każdej z nich znalazła się taka sama ilość komórek pobudzających jak i hamujących. Każda komórka n_i miała, tak jak poprzednio $M = 100$ synaps. Aby zwiększyć gęstość połączeń wewnątrz z_k struktury ustalono podział $g > 0.1$, który oznaczał, jaka część połączeń będzie łączyć komórki z tej samej podsieci. W ten sposób otrzymaliśmy Mg synaps wewnętrznych i $M(1-g)$ zewnętrznych. Wszystkie połączenia między neuronami były losowane z takim samym prawdopodobieństwem, zgodnie z założeniem, że hamujące nie mogą być połączone ze sobą. Opóźnienia w podsieci znalazły się na takim samym poziomie jak w sieci homogenicznej $0ms > d_w > 20ms$, między strukturami zwiększyły się do $20ms > d_z > 40ms$.

Sieć symulowana była przez $T = 1000s$, a w każdej ms odpalano losowo jeden neuron. Sieć składała się z 10 podsieci, a gęstość połączeń była zmienna. W kolejnym etapie uruchomiony został algorytm wyszukujący PNG. Wykres na rysunku 18 przedstawia ilość PNG w zależności od

współczynnika g . Widać na nim duży wzrost ilości grup polichronicznych wraz z gęstością połączeń w podsieciach. Następną charakterystyką na rysunku 19 prezentuje średnią ilość zdarzeń w PNG również dla współczynnika g . Średnia zdarzeń zmienia się nieznacznie dla różnych gęstości.

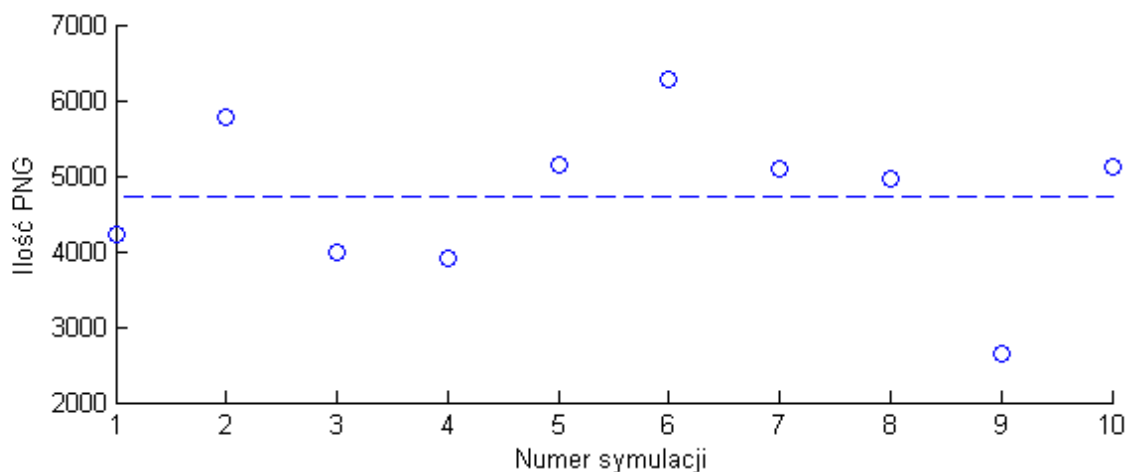


Rysunek 18. Wykres przedstawia ilość PNG w sieci heterogenicznej w zależności od gęstości połączeń w podsieciach.



Rysunek 19. Wykres przedstawia średnią ilość zdarzeń w PNG dla sieci heterogenicznej w zależności od gęstości połączeń w podsieciach.

Do dalszych badań została wybrana sieć o parametrze $g = 0.4$ z powodu optymalnej ilości grup polichronicznych. Podobnie jak w przypadku sieci homogenicznej przeprowadziliśmy 10 prób dla tej samej sieci. Wykres 20 przedstawia otrzymane wyniki.



Rysunek 20. Wykres ilość PNG w sieci heterogenicznej symulacji trwającej 1000s oraz gęstości połączeń równej 0.4 dla 10 powtórzeń symulacji.

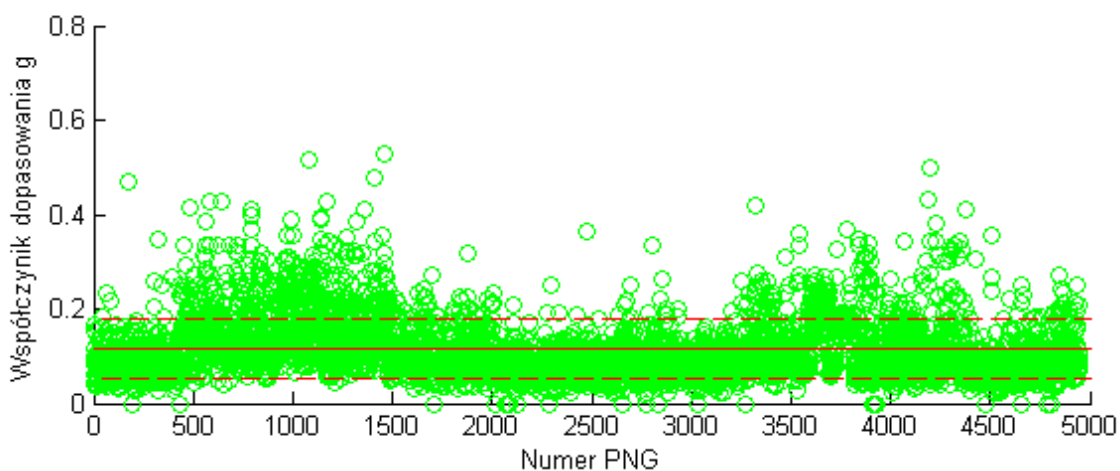
Wynik najbliższy średniej 4712 ± 1041 uzyskano dla symulacji numer 8. Ta próba została

wykorzystana do poszukiwania SuperPNG. Dla pięciu różnych kombinacji wejściowych grup polichronicznych otrzymaliśmy średnie dopasowania zawarte w tabeli 2. Największą wartość miała czwartą kombinacją, dlatego PNG z tej kombinacji wybrano na wejście potencjalnego SuperPNG.

Numer kombinacja	1	2	3	4	5
Średnia	0.022	0.076	0.063	0.115	0.065
Odchylenie standardowe	0.029	0.061	0.054	0.064	0.052


Tabela 2 Tabela przedstawia wyniki średniej dopasowania dla 5 różnych kombinacji wejściowych PNG.

Wykres 21 prezentuje najlepsze dopasowania D_{max} dla każdego PNG(A1). Podobnie jak w sieci homogenicznej występują grupy wyróżniające się dopasowaniem. Na tej podstawie był dobierany próg odcięcia PNG należących do SuperPNG.




Rysunek 21. Wykres dopasowania poszczególnych PNG podczas wyzwolenia 9 neuronów z 3 wejściowych grup polichronicznych.

Podczas ustalania SuperPNG(A2) próg ustawiono na poziomie $D_p = 0.4$. Super grupa składała się z 11 PNG, wartość rozmycia była nie zmieniona $\epsilon = 4$. Rysunek 22 przedstawia wyniki aktywności PNG należących do super grupy polichronicznej oraz aktywność SuperPNG. Minimalna wartość aktywacji PNG musiała przekroczyć $D_{PNG} = 0.25$ aby wzorzec polichroniczny można było uznać za aktywny.




Rysunek 22. Wykres górny przedstawia aktywność poszczególnych PNG. Dolny wykres przedstawia aktywność SuperPNG w 10 sekundowej symulacji sieci heterogenicznej.

Następnie powtórnie przeprowadzono algorytm (A3), tylko tym razem dla grupy losowych 11 PNG. Rysunek 23 przedstawia otrzymane wyniki.



Rysunek 23. Wykres górny przedstawia aktywność loswych PNG. Dolny wykres przedstawia aktywność grupy losowych PNG(w takiej same ilości co w SuperPNG) w 10 sekundowej symulacji sieci heterogenicznej.


Dokładnie jak przy sieci homogenicznej, zbudowano sztuczną super grupę polichorniczna składającą się z 11 PNG. Rysunek 24 przedstawia wyniki otrzymane przy użyciu algorytmu (**A3**) w symulacji 10 sekundowej sieci heterogenicznej.



Rysunek 24. Wykres górny przedstawia aktywność PNG. Dolny wykres przedstawia aktywność sztucznie stworzonego SuperPNG w 10 sekundowej symulacji sieci heterogenicznej.

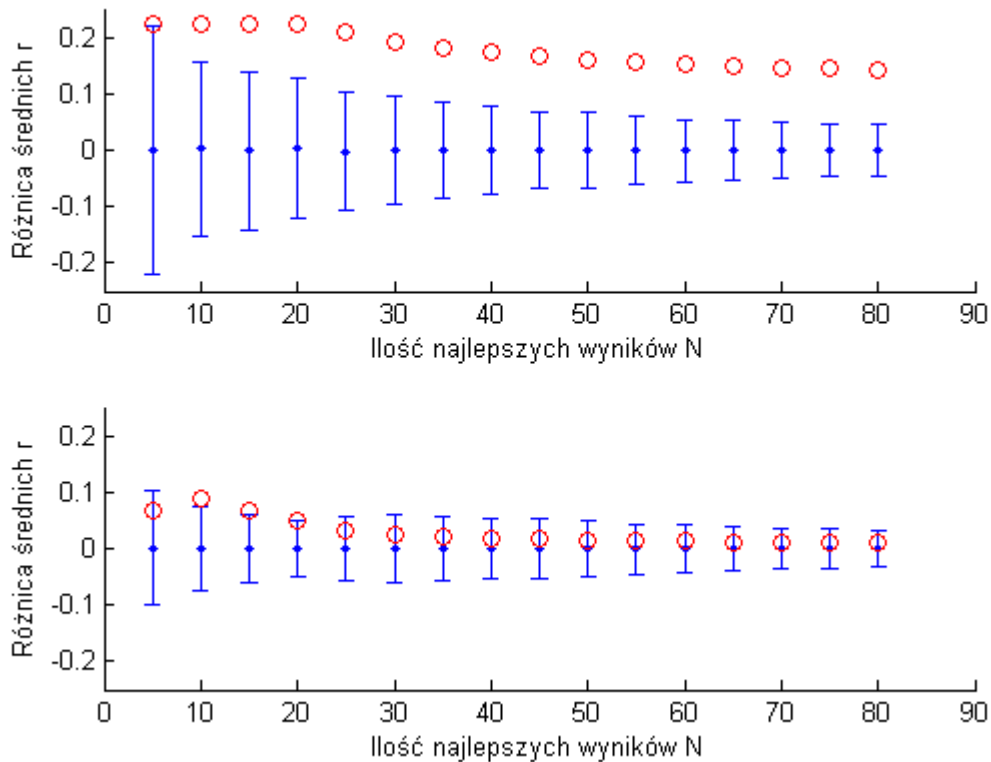
4.3 Analiza istotności statystycznej do wyników

Główną hipotezą było stwierdzenie, że istnieją neuronalne reprezentacje obiektów złożonych. W niniejszej pracy są one nazywane SuperPNG (jako wzorzec wyższego rzędu składający się z PNG). Wykonano szereg symulacji i badań dla super grup utworzonych na trzy różne sposoby. Dla sieci homogenicznej otrzymane wyniki przedstawiono są na wykresach 15, 16 i 17. Zauważalne różnice aktywność SuperPNG (między SuperPNG wyznaczonym za pomocą (A1) i (A2), losowa grupa PNG oraz sztucznie stworzonym wzorcem), zostały zbadane statystycznie za pomocą testu bootstrapowego. Policzono średnie aktywności SuperPNG w zależności od liczności(N) grupy najlepszych wyników z całej symulacji. Wykres 25 przedstawia otrzymane wyniki dla sieci homogenicznej.



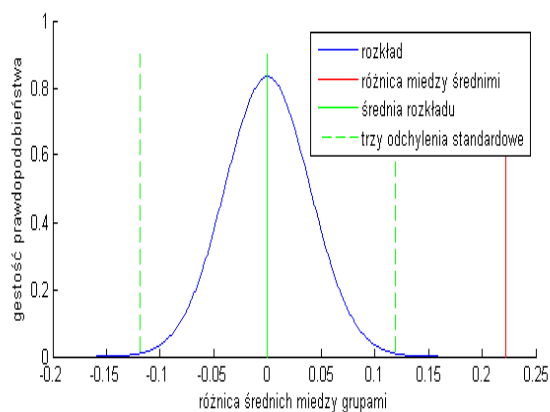
Rysunek 25. Wykres przedstawia wyniki średnich aktywności SuperPNG w zależności od liczby N (ilość najlepszych wyników z symulacji) dla sieci homogeniczej. Zielonym kolorem oznaczone są wyniki dla SuperPNG, czerwonym dla sztucznego SuperPNG, a niebieskim dla losowych PNG.

Następnie przeprowadzono kilkanaście testów bootstrapowych dla różnych wartości N . Jako hipotezę zerową zakładamy, że wyniki pochodzą z tej samej populacji, a co za tym idzie, różnica między średnimi jest nieznacząca. Najpierw porównano wyniki dla SuperPNG wyszukanego przez algorytm oraz losowe PNG (Rys. 26, górna część), a potem SuperPNG ze sztuczną super grupą (Rys. 26, dolna część). Kolorem niebieskim oznaczono szerokości rozkładu, a dokładniej jego trzy odchylenia standardowe, a kolorem czerwonym rzeczywistą różnicę między dwiema średnimi z grup (o licznosci N) wyników. Można zauważyć, że w przypadku SuperPNG oraz losowych PNG wszystkie różnice są istotne statystycznie, ponieważ prawdopodobieństwo ich wystąpienia jest mniejsze niż 5%. Natomiast w przypadku porównania ze sztucznym SuperPNG te wartości są istotne tylko dla małych N .

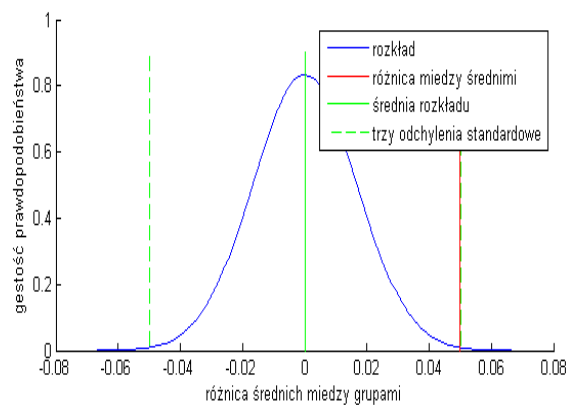


Rysunek 26. Wykresy przedstawiają wyniki otrzymane metodą bootstrap w zależności od ilości najlepszych wyników wziętych do porównania dla sieci homogeniczej. Czerwonym kolorem są zaznaczone rzeczywiste różnice między dwiema średnimi z grup (o licznosci N). Na niebiesko są zaznaczone trzy odchylenia standardowe rozkładu otrzymanego metodą bootstrapową.

Rysunki 27 i 28 przedstawiają przykładowe wyniki dla $N = 20$. Można zauważyć, że prawdopodobieństwo otrzymanej różnicy średnich w badaniach jest równe $p = 0.000143$ (dużo mniejsze niż 5%). Zatem można odrzucić hipotezę zerową dla tej pary wyników. Wyniki z wykresu 27 pokazują, że prawdopodobieństwo jest równe $p = 0.0472$. W tym przypadku również można odrzucić hipotezę zerową ponieważ prawdopodobieństwo jest poniżej 5% .




Rysunek 27. Wykres przedstawia rozkład różnic między średnimi wyników aktywności SuperPNG oraz grupy losowych PNG



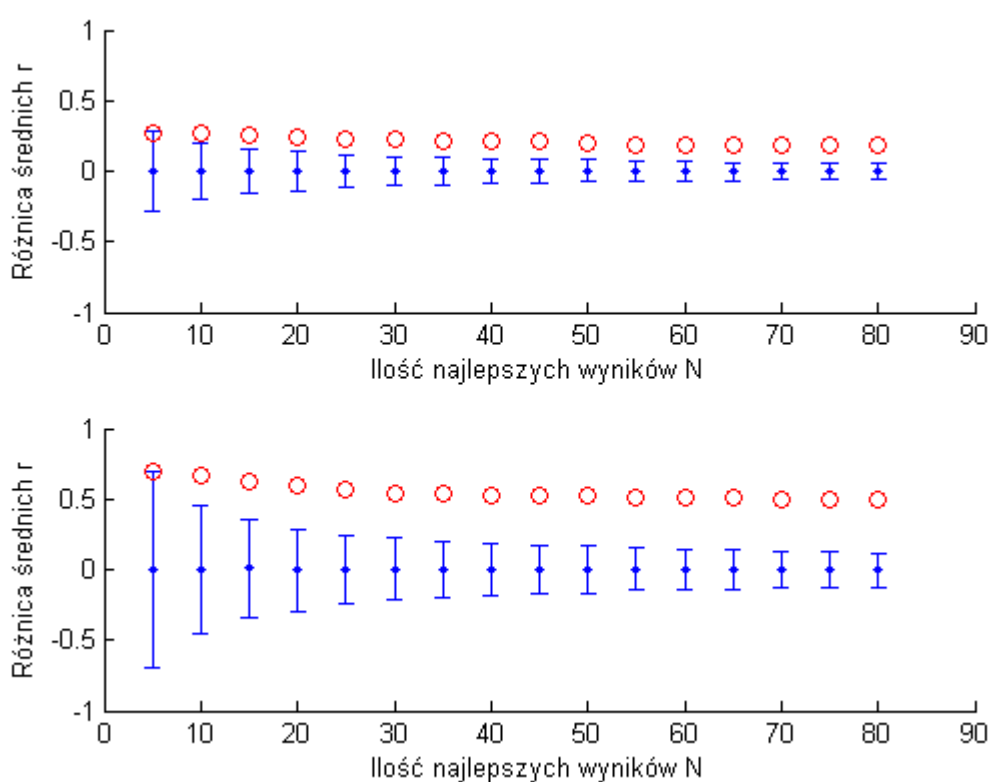
Rysunek 28. Wykres przedstawia rozkład różnic między średnimi wyników aktywności SuperPNG oraz SuperPNG stworzonego sztucznie.

Dokładnie w ten sam sposób porównano wyniki dla sieci heterogenicznej. Rysunek 29 prezentuje średnie ilość aktywowanych PNG w SuperPNG w zależności od N (liczebność najlepszych wyników). Widać, że wartości dla sztucznego SuperPNG są znacznie mniejsze niż dla SuperPNG.




Rysunek 29. Wykres przedstawia średnie wyniki aktywności SuperPNG w zależności od liczby N (ilość najlepszych wyników z symulacji) dla sieci heterogenicznej. Zielonym kolorem oznaczone są wyniki dla SuperPNG, czerwonym dla sztucznego SuperPNG, a niebieskim dla losowych PNG.

Następnie znów wykorzystano metodę bootstrapowa w zależności od liczby najlepszych wyników aktywności SuperPNG. Wykres górny (Rys. 30) prezentuje wyniki porównujące SuperPNG a grupę losowych PNG, dolny wykres zaś SuperPNG oraz sztucznie stworzoną super grupę polichroniczną. Można zauważyć, że dla obu przypadków wszystkie próby wykazały różnice istotne statystycznie. Zatem i w przypadku sieci heterogenicznej można odrzucić hipotezę zerową.

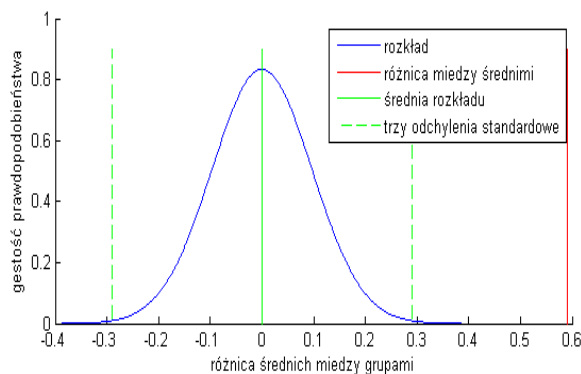


Rysunek 30. Wykresy przedstawiają wyniki otrzymane metodą bootstrap w zależności od ilości najlepszych wyników wziętych do porównania dla sieci heterogenicznej. Czerwonym kolorem są zaznaczone rzeczywiste różnice między dwiema średnimi z grup (o licznosci N). Na niebiesko są zaznaczone trzy odchylenia standardowe rozkładu otrzymanego metodą bootstrapową.

Na wykresach 31 i 32 zostały przedstawione przykłady wyników otrzymanych metodą bootstrap dla $N = 20$;



Rysunek 31. Wykres przedstawia rozkład różnic między średnimi wyników aktywności SuperPNG oraz SuperPNG stworzonego z losowych PNG dla sieci heterogenicznej.



Rysunek 32. Wykres przedstawia rozkład różnic między średnimi wyników aktywności SuperPNG oraz SuperPNG stworzonego sztucznie dla sieci heterogenicznej

4. Podsumowanie

Powyższa praca miała na celu zweryfikowanie hipotezy o możliwość istnienia neuronalnych reprezentacji mentalnych obiektów złożonych w pamięci roboczej. Przykładem neuronalnej reprezentacji jest aktywność pojedynczego neuronu lub zespołu neuronów, a przykładem mentalnego obiektu złożonego jest koń. Koń, składa się z poszczególnych anatomicznych części (np. głowa, kopyta, ogon). Aby potwierdzić możliwość hierarchicznych wzorców aktywności neuronowej przeprowadzono wiele symulacji sieci neuronowej. Neurony oraz połączenia między nimi były opisywane modelami: punktowego neuronu Izhikevicha oraz plastyczności STDP. Zapewniało to wysoką wydajność obliczeniową. Ilość operacji obliczeniowych była o rząd wielkości mniejsza w porównaniu z innymi wymienionymi modelami.

Jednym z zadań była budowa sieci heterogenicznej, która by znacznie bardziej przypominała budowę strukturę mózgu. Głównym czynnikiem, na jaki zwracaliśmy uwagę, była ilość grup polichronicznych powstałych w trakcie symulacji. Na wykresie 18 można zauważyć, że liczba PNG bardzo szybko rośnie, jeśli zwiększymy gęstość połączeń wewnątrz podsieci. Jest to wynikiem dużego prawdopodobieństwa połączenia zwrotnego. Pozwala to na bardzo łatwe spełnienie warunku minimalnej długości ścieżki PNG. Biorąc pod uwagę średnią ilość zdarzeń w grupie

polichronicznej nie widać znaczącej różnicy między siecią homogeniczną a heterogeniczną. Można zatem stwierdzić, że sieć heterogeniczna posiada, istotne ze względu na cel projektu, cechy sieci homogenicznej i można ją wykorzystać do symulacji oraz do poszukiwania reprezentacji neuronalnych obiektów złożonych.

Dla obu sieci, homogenicznej i heterogenicznej, można potwierdzić istnienie SuperPNG. Potwierdzają to różnice między aktywnością super grupy polichronicznej wytypowanych w ramach działania algorytmów (A1) i (A2), a grupą losowych PNG. Otrzymujemy dowód na powstawanie wzorca wyższego rzędu podczas symulacji, składającego się z podstawowych grup polichronicznych. Różnice między SuperPNG (wyszukanego za pomocą (A1) i (A2)) a sztucznym SuperPNG (sztucznie połączone PNG) mogły być skutkiem nie dopasowania się reszty sieci. Sztuczna ingerencja w połączenia i wagi między neuronami nie umożliwiła zaobserwowania stabilnych wzorców wyższego rzędu - SuperPNG. Mechanizmy wymuszonego (poprzez uczenie się) powstawania wzorców hierarchicznych będą przedmiotem dalszych badań.

Tak skonstruowana sieć, która opiera się o model Izhikevicha oraz o plastyczność STDP, może zawierać w sobie wzorce polichroniczne, ale również hierarchiczne wzorce polichroniczne. Ma to istotne znaczenie dla rozwoju teorii reprezentacji neuronalnych obiektów złożonych. Otrzymane wyniki mogą służyć jako podstawa do opisanie modelu wzorca hierarchicznego, odpowiadającego neuronalnej reprezentacji obiektów złożonych. Do teorii opisanej w artykule *Spike-Timing Theory of Working Memory*, gdzie powstaje hipoteza dotycząca tego, że pamięć robocza działa na zasadzie grup polichronicznych, można dołączyć również twierdzenie, że mogą występować grupy wyższego rzędu. Weryfikacja niniejszej hipotezy może zostać przeprowadzona w oparciu o kryterium funkcjonalne, to znaczy, że informacja przetwarzana w sieci jest równoważna procesom poznawczym u zwierząt (w tym u człowieka). Bezpośrednia eksperymentalna weryfikacja opisywanych mechanizmów wymaga rejestracji aktywności bardzo dużej części neuronów w fragmencie tkanki nerwowej. Obecnie znajduje się to poza możliwościami badawczymi, ale szybki rozwój optogenetyki daje perspektywę wielkoskalowej rejestracji dużej populacji neuronów.

5. Bibliografia

- [1] Izhikevich E.M., Simple Model of Spiking Neurons, IEEE Transactions on Neural Networks, 2003, Vol. 14, s. 1569-1572.
- [2] Hodgkin A.L., Huxley A.F., A quantitative description of membrane current and its application to conduction and excitation in nerve, Journal of Physiology, 1952, Vol. 117, s. 500-544.
- [3] Song, S., Miller, K. D., Abbott, L. F., Competitive Hebbian learning through spike-timing-dependent synaptic plasticity. Nature Neurosci., 2000, 3, s. 919–926.
- [4] Hebb, D. O., The Organization of Behavior: A Neuropsychological Theory, 1949
- [5] Szatmáry B., Izhikevich E.M., Spike-Timing Theory of Working Memory, PLOS Computational Biology, 2010, I. 8, e1000879 Vol. 6
- [6] Goldman DE. Potential, impedance, and rectification in membranes. J Gen Physiol 1943; 27: 37-60.
- [7] Izhikevich, E. M., Polychronization: Computation with spikes. Neural computation, 2006, 18(2), s. 245–282.
- [8] Bienenstock, E. L., Cooper, L. N, and Munro, P. W. Theory for the development of neuron selectivity: orientation specificity and binocular interaction in visual cortex. Journal of Neuroscience, 1982 s. 32–48.
- [9] E. Nęcka, J. Orzechowski, B. Szymura, Psychologia poznawcza, 2006
- [10] Miller, The Magical Number Seven, Plus or Minus Two: Some Limits on Our Capacity for Processing Information, The Psychological Review, 1956, vol. 63, s. 81-97.
- [11] Eliasmith, Anderson Neural Engineering Framework, 2003