



Pulsujące sieci neuronowe (Spiking Neural Network)

ŁUKASZ ALEKSIEJEW

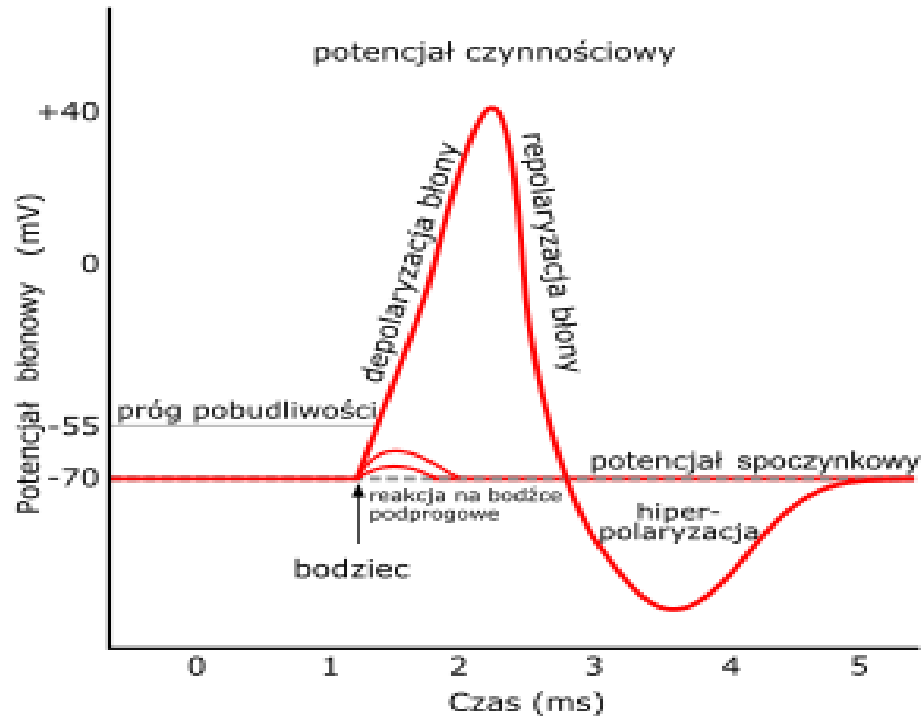
(pod kierunkiem Joanna Grabska-Chrzęstowska)

O czym będziemy mówić




1. Idea działania SNN
 2. Modele neuronów impulsowych
 3. Kodowanie informacji
 4. Topologie sieci
 5. Metody uczenia sieci
-

Idea stojąca za pulsującymi
(impulsowymi) sieciami neuronowymi

Najpierw odrobina biologii




Impuls nerwowy




Sygnały wejściowe i
wyjściowe w postaci
zbioru impulsów


Dziedzina pracy SNN

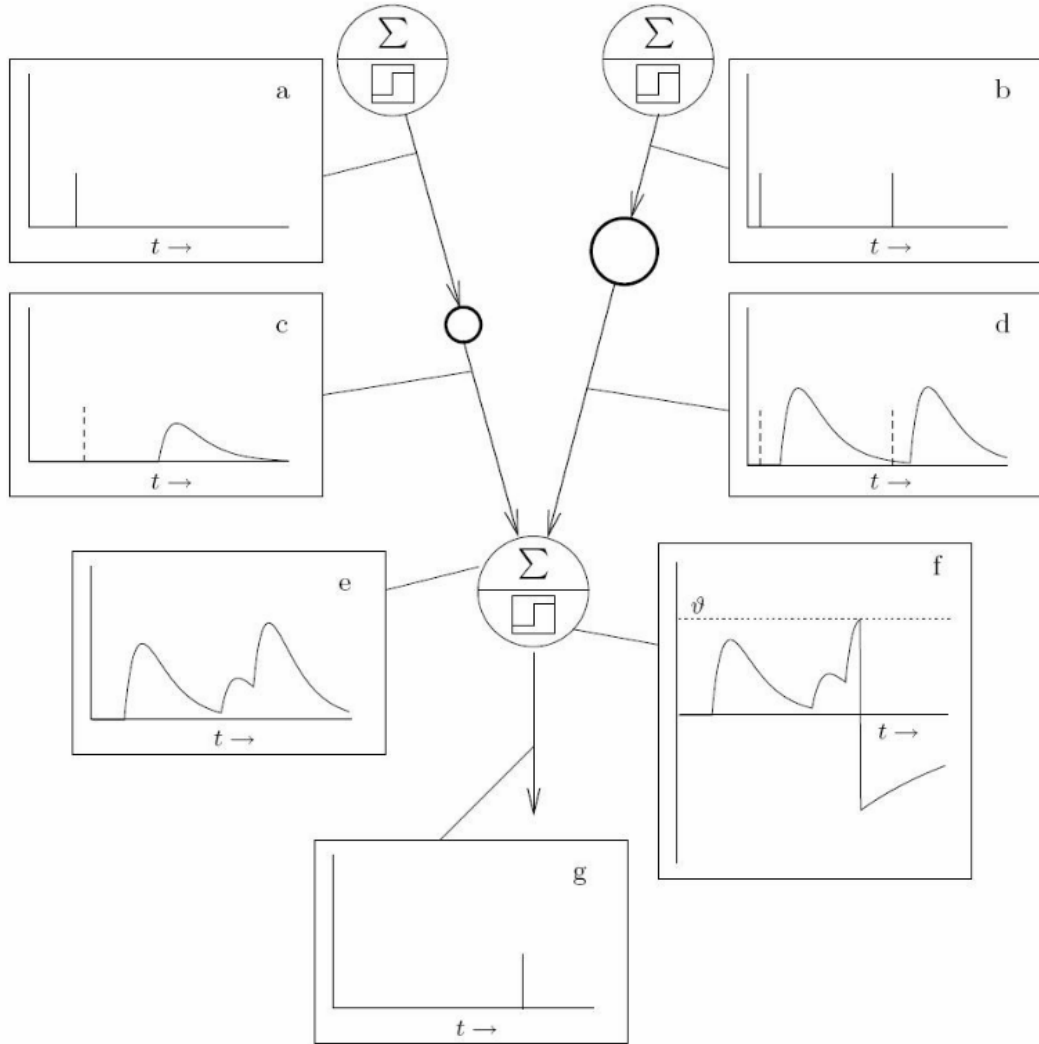


Zadanie pojedynczego neuronu



Synapsa jako nośnik wiedzy






Modele matematyczne neuronów

(Leaky) Integrate-and-fire (1907)


$$I(t) = C_m \frac{dV_m(t)}{dt}$$

$$I(t) - \frac{V_m(t)}{R_m} = C_m \frac{dV_m(t)}{dt}$$



Model Hodgkin - Huxley (1952)

nagroda Nobla w 1963




$$I = C_m \frac{dV_m}{dt} + g_K (V_m - V_K) + g_{Na} (V_m - V_{Na}) + g_l (V_m - V_l),$$

Model FitzHugh-Nagumo (1961)

$$\dot{v} = v - \frac{v^3}{3} - w + I_{\text{ext}}$$

$$\tau \dot{w} = v + a - bw.$$






Wpływ parametrów na praktyczne zachowanie


$$v' = 0.04v^2 + 5v + 140 - u + I$$

$$u' = a(bv - u)$$


**if $v = 30$ mV,
then $v \leftarrow c$, $u \leftarrow u + d$**




regular spiking (RS)




intrinsically bursting (IB)




chattering (CH)




fast spiking (FS)




thalamo-cortical (TC)




thalamo-cortical (TC)



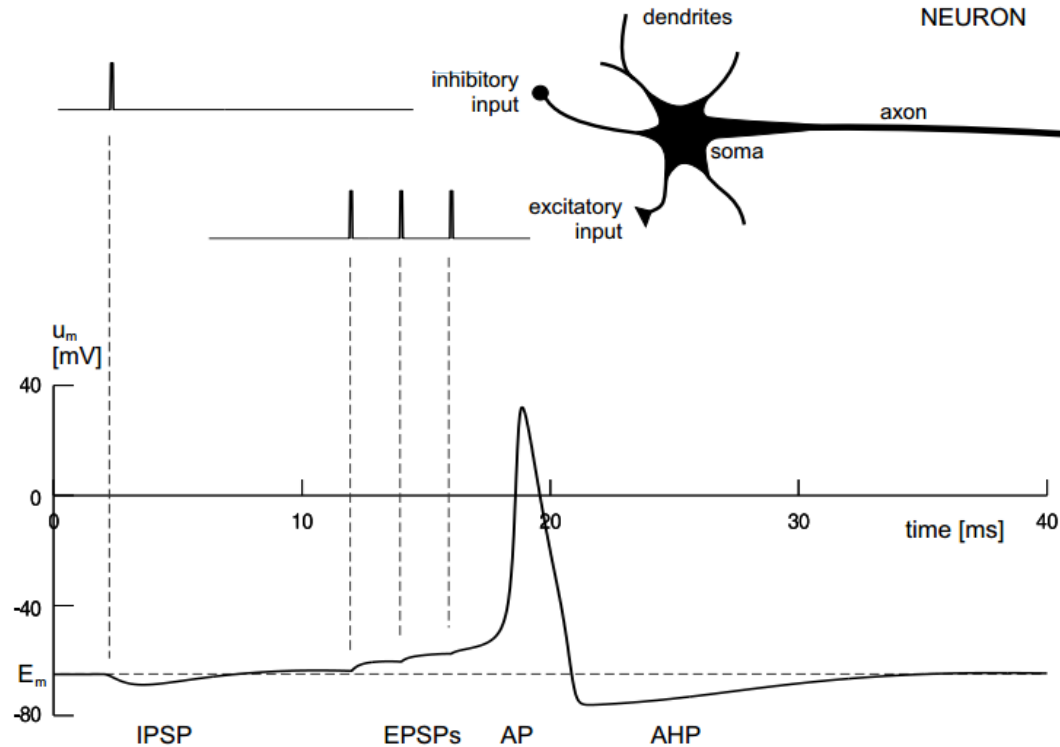
resonator (RZ)



low-threshold spiking (LTS)




Inhibitory vs Excitatory synapses



Kodowanie informacji

Kodowanie neuronowe



Ilościowe
(rate coding)

Zależne od czasu
(temporal coding)

Populacyjne
(population coding)


Kodowanie w biologicznych sieciach neuronowych

- Sieć biologiczna potrafi kodować zarówno analogowe i cyfrowe informacje
- Jest to jeden z głównych obszarów badań neurobiologii
- Kodowanie ilościowe (rezonansow, częstotliwościowe)
 - może symbolizować wartości “analogowe”
 - wykorzystanie to np. siła skurczu mięśni
 - stosunkowo wolne - wymaga dłuższej obserwacji
- Kodowanie zależne od czasu
 - wykorzystane w przetwarzaniu sygnałów pochodzących od zmysłów

Kodowanie rezonansowe

Strumień danych wejściowych zamieniany jest na ciąg impulsów generowanych w odstępach czasu proporcjonalnych do wartości poszczególnych wartości wejściowych

Wartość kodowana jest w sieci częstotliwością występowania impulsów



Kodowania zależne czasowo - time-to-first-spike

Pojedyncze dane wejściowe reprezentowane są w postaci odrębnych impulsów o czasie generacji proporcjonalnym do wartości danej.

Ograniczeniem jest interpretacja wystąpień kolejnych impulsów w neuronach

Można także kodować informacje:

kolejnością występowania impulsów


występowaniem względnych opóźnień (interwałów) między impulsami kolejnych neuronów

Kodowania zależne czasowo - kodowanie przez fazę

Wymaga pewnej synchronizacji

Wartość niesionej informacji zależy od tego, jaka sekwencja impulsów wystąpiła, kiedy sygnał referencyjny był w odpowiednim stanie.

v



Kodowania populacyjne - kodowanie synchroniczne

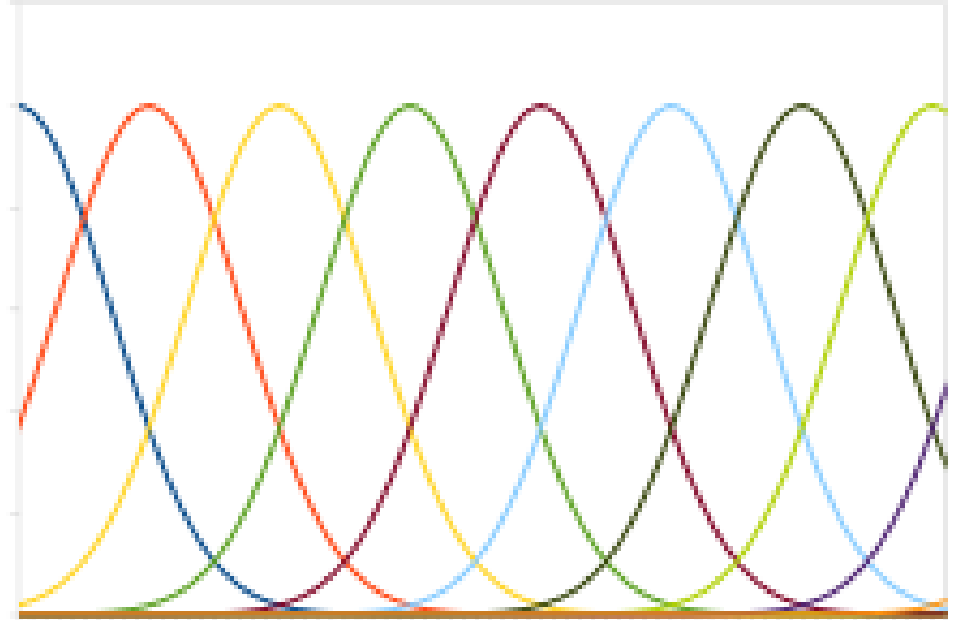
Sieć wnioskuje na podstawie impulsów od grupy neuronów w danym, synchronizowanym oknie (niektóre części mózgu posiadają zdolność synchronizacji)

Każda wartość może być kodowana inną grupą neuronów



Kodowania populacyjne - kodowanie pozycyjne

- W tym kodowaniu każdy neuron wyjściowy (lub ich grupa) odpowiada jakiejś oczekiwanej wartości na wyjściu. Za neuron “aktywny” uznaje się ten, który pulsuje z największą częstotliwością (lub grupę)
- To kodowanie jest stosowane w pozycjonowaniu stawów, oka, rozpoznawaniu koloru i dźwięku




Parse coding (autokodowanie)

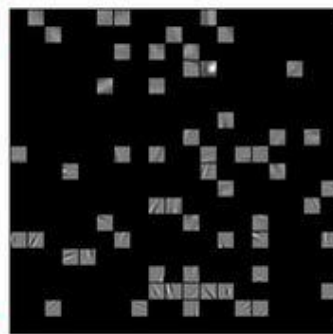
Metoda kodowania obrazów (i nie tylko) przez traktowanie ich jako złożenie kilku innych, mniejszych wzorców

Służy do zmniejszenia alfabetu kodowego względem mnogości obiektów, które może reprezentować


Przykładową metodą jest algorytm



Original



Sparse components
of patch in the red box



Reconstruction

Topologie sieci

Topologie sieci SNN



Feedforward

Rekurencyjne

Hybrydowe

Sieci feedforward

Zastosowanie w sieciach biologicznych:

układy “peryferyjne” organizmu: zmysły, sygnały do mięśni

funkcje synchronizacji impulsów

powiązania wzorców przestrzenno-czasowych

Sieci rekurencyjne

neurony lub ich grupy komunikują się przy pomocy połączeń wzajemnych

występowanie sprzężeń zwrotnych

sieć otrzymuje właściwości dynamiczne

trudne w kontroli i uczeniu

wykorzystywane w modelowaniu pamięci asocjacyjnych

Sieci hybrydowe

Grupa sieci, które przejawiają zarówno cechy rekurencyjne jak i proste (feedforward)

spośród wielu przykładów można wyróżnić dwie

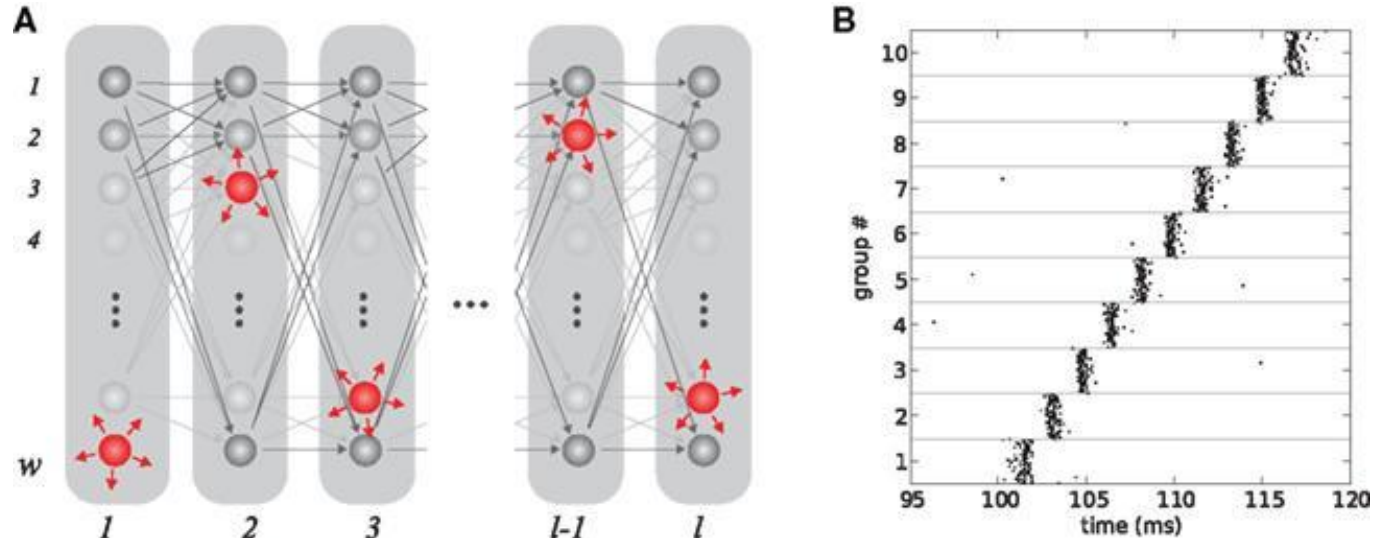
- Łańcuch pobudzeń

- Sieci rezerwuarowe

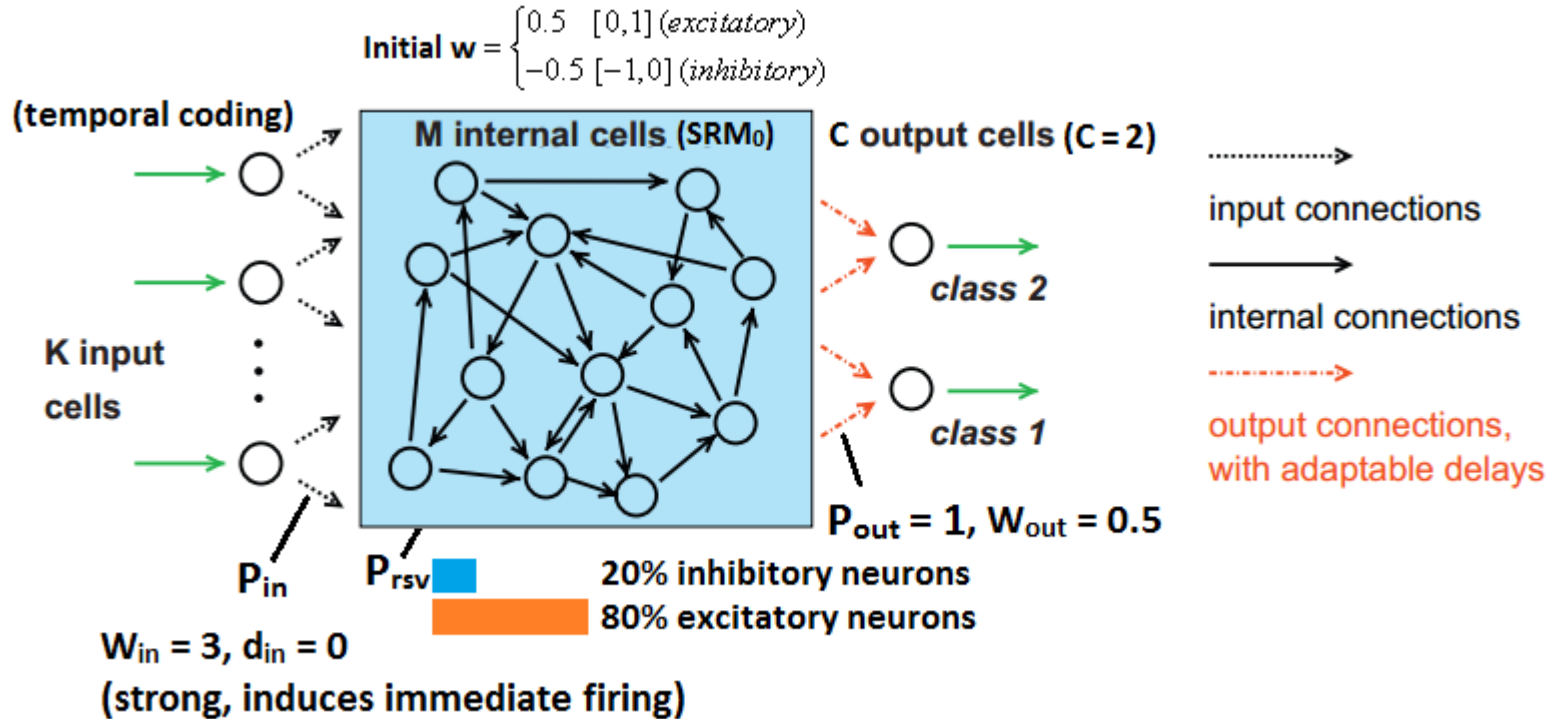
Łańcuch pobudzeń (Synfire chain)

odpowiadają za ludzki proces uczenia (asocjacje odległych w czasie wydarzeń i skojarzeń)

łańcuchy mogą się przecinać tworząc skomplikowane struktury





Sieci rezerwuarowe



LSM - Liquid State Machine

Zbiór neuronów (NCM - Neural Microcircuit) losowo połączonych ze sobą z losowymi wagami tworzący topologię rekurencyjną

Przy odpowiedniej ilości neuronów i funkcji matematycznych



Uczenie sieci

Neurons that fire together,
wire together

Przypomnienie: Reguła Hebba (1949)

Jeśli neuron A wielokrotnie lub stale brał udział w wyzwaniu impulsów neuronu B, w jednym lub drugim neuronie zachodzą zmiany zwiększające wpływ pobudzania neuronu B przez neuron A.

obserwacja biologiczna mówiąca o wzmacnianiu połączenia między neuronami, które aktywują się w niedużych odstępach czasowych

w pierwotnej wersji była to teoria zależnościach symetrycznych (nieistotne było, który neuron wygenerował impuls jako pierwszy)

znalazła pośrednie zastosowanie w uczeniu nienadzorowanym sieci Hopfielda.

jest podstawą dla metod STDP

STDP - Spike-timing-dependent plasticity

t_j^f - czasy wystąpień impulsów presynaptycznych

t_j^n - czasy wystąpień impulsów postsynaptycznych


$W(x)$ - funkcja STDP (funkcja okna uczącego)


ΔW_j - zmiana wagi j-tej synapsy


$$\Delta w_j = \sum_{f=1}^N \sum_{n=1}^N W(t_i^n - t_j^f)$$

$$W(x) = A_+ \exp(-x/\tau_+) \quad \text{for } x > 0$$

$$W(x) = -A_- \exp(x/\tau_-) \quad \text{for } x < 0$$










Wykorzystanie nienadzorowanego uczenia STDP

działanie na zasadzie samoasocjacji i wzmocnieniu występujących cech

ekstrakcja cech

klasyfikatory



SHL - Supervised Hebbian Learning

Równoległe do sieci uczącej działa proces, która dostarcza (odbiera) dodatkowy prąd do neuronów przed oczekiwanymi wystąpieniami impulsów (lub depresji)

Zwiększana jest dzięki temu szansa wystąpienia (bądź nie) impulsu w neuronie w okolicach chwili, w której był spodziewany.

W efekcie, w wypadku wygenerowania impulsu odpowiednie synapsy ulegają wzmocnieniu (osłabieniu)

Ograniczenie:

uczenie przebiega jedynie w okolicach wystąpień impulsów spodziewanych w ostatniej warstwie

SpikeProp (2000)

Próba przeniesienia metody wstecznej propagacji błędów do sieci impulsowych

ograniczenie: każdy neuron musi wystrzelić tylko raz w procesie uczenia

metoda mająca wiele późniejszych udoskonaleń (np dodatkowa modyfikacja opóźnień synaps)

Dla chęć

$$\Delta w_{hi}^k = -\eta y_h^k(t_i^a) \delta_i = -\eta \frac{y_h^k(t_i^a) \sum_j \{ \delta_j \sum_k w_{ij}^k (\partial y_i^k(t_j^a) / \partial t_i^a) \}}{\sum_{n \in \Gamma_i} \sum_l w_{ni}^l (\partial y_n^l(t_i^a) / \partial t_i^a)}$$

ych:

Dokładne informacje na <http://homepages.cwi.nl/~sbohte/publication/backprop.pdf>

Problem XOR w metodzie SpikeProp

Input patterns			Output patterns
0	0	→	16
0	6	→	10
6	0	→	10
6	6	→	16

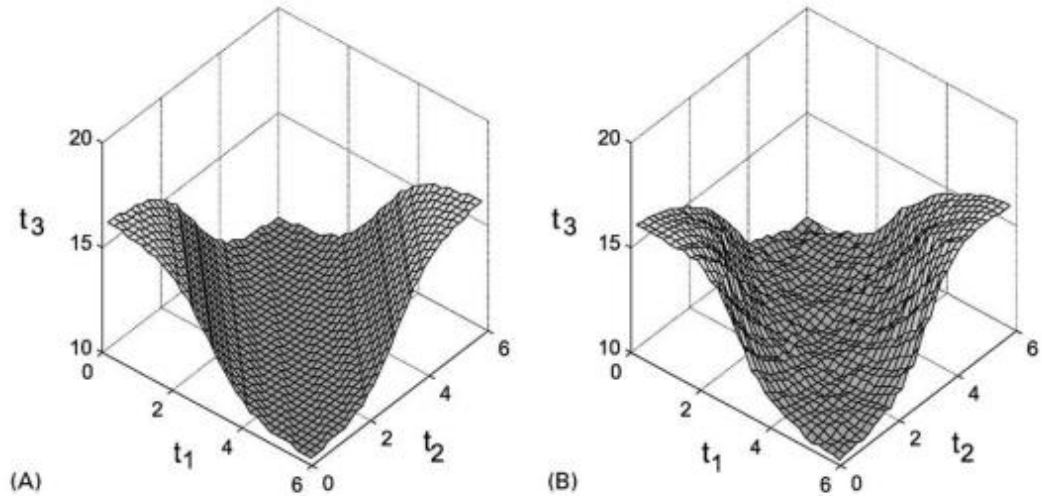


Fig. 4. Interpolated XOR function $f(t_1, t_2): [0, 6]^2 \rightarrow [10, 16]$: (A) target function; (B) network output after training. The network reached the sum squared error-criterion of 50.0 after learning 12996 randomly drawn examples from the 961 data points.

ReSuMe - Remote Supervised Method (2005)

Metoda łącząca STDP z tradycyjnym uczeniem z nauczycielem

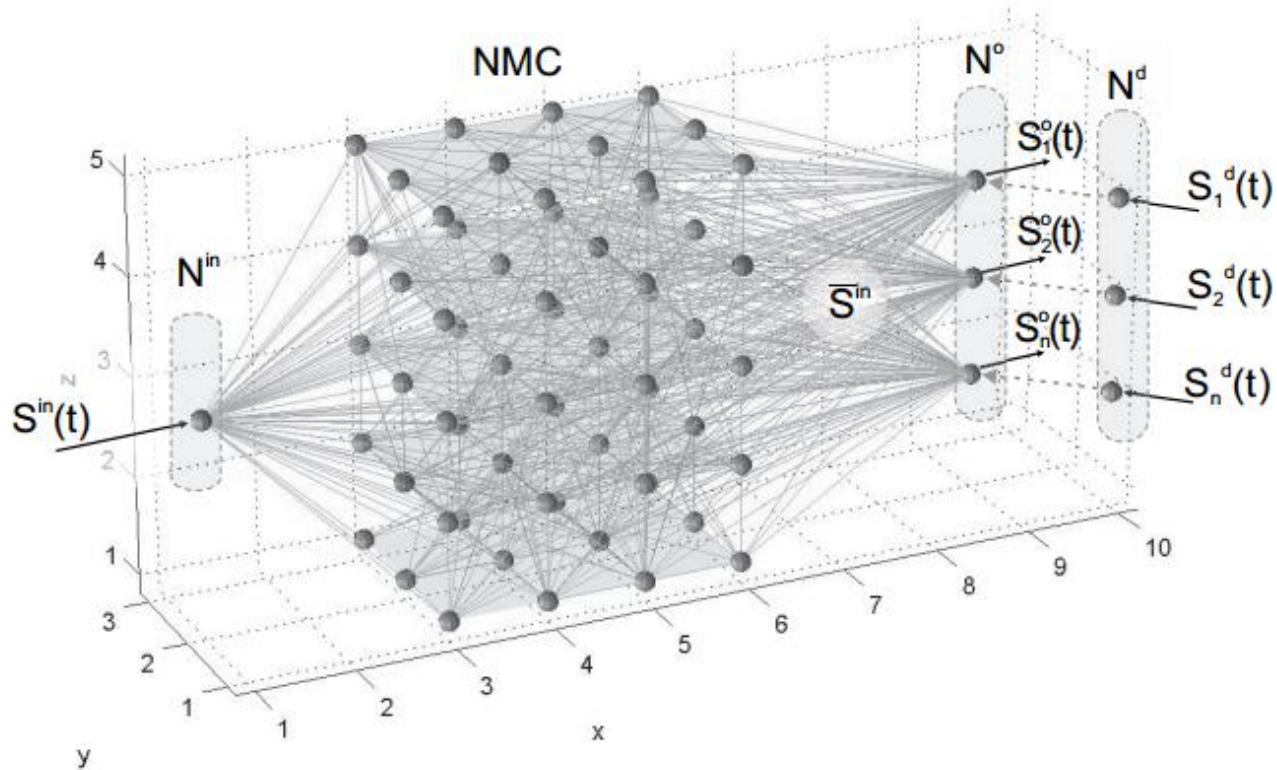
sieć składa się z trzech rodzajów neuronów: wejściowych, uczących się i nauczycieli

wartość zmiany wagi w pojedynczym eksperymencie uczącym składa się z części pochodzącej od zależności wyjścia i wejścia (STDP), a druga z zależności między $\Delta w = f(e) = f(y^d - y)$, iągniętym stanem:

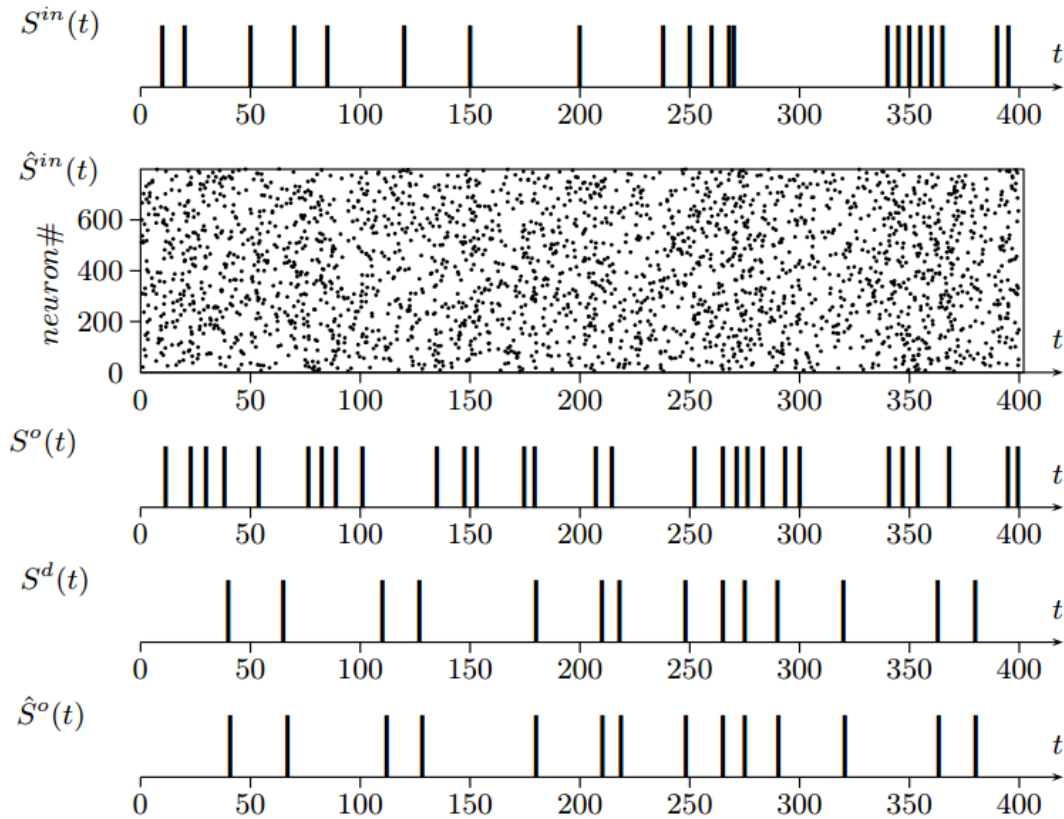
$$\Delta w = (y^d - y)x,$$

$$\Delta w = y^d x - yx. \quad \longrightarrow \quad \Delta w = \Delta w^{STDP}(S^{in}, S^d) + \Delta w^{aSTDP}(S^{in}, S^o)$$

Proponowana topologia sieci dla alg. ReSuMe



ReSuMe - działanie



Wnioski

Wykorzystanie SNN

klasyfikacja danych

mapy ssamoorganizujące się

pamięci asocjacyjne

rozpoznawanie szeregów czasowych

nawigacja przestrzenna

rozpoznawanie obrazów, zapachów, dźwięków

wyznaczanie głównych składowych ciągów impulsów

podejmowanie decyzji

Wnioski

metody przyszłościowe, dające nieporównywalnie większe możliwości obliczeniowe niż standardowe sieci neuronowe

... ale też wielokrotnie bardziej skomplikowane.

omawianie kwestii biologicznych pokrywa się w bardzo dużej mierze z kwestiami technicznymi gdyż sieci SNN są wiernym odzwierciedleniem znanych nam dziś modeli biologicznych

dużo większa trudność w kontrolowaniu procesów zachodzących wewnątrz sieci i mechanizmach uczenia

możliwość nauki sieci online i rozwiązywania problemów w dziedzinie czasu

Literatura

LITERATURA

1. Ponulak F, Kasinski A.: Introduction to spiking neural networks: Information processing, learning and applications. *Acta Neurobiol Exp (Wars)*, 2011;71(4):409-33
2. Gerstner W. and Kistler W. M.: *Spiking Neuron Models Single Neurons, Populations, Plasticity* Cambridge University Press, 2002.
3. Thorpe S., Perrinet L., Samuelidesa M.: Sparse spike coding in an asynchronous feed-forward multi-layer neural network using matching pursuit. *Neurocomputing*, 2004.
4. Xiao-Jing Wang. Decision making in recurrent neuronal circuits. *Neuron*, 2008.