

# Kształtowanie się pól recepcyjnych w biologicznie inspirowanych sieciach neuronowych.

Marcin Białaś LISI





**OŚRODEK  
PRZETWARZANIA  
INFORMACJI**  
PAŃSTWOWY INSTYTUT BADAWCZY

# O czym jest ta prezentacja ?



- ▶ Czym są impulsy nerwowe i jak je można modelować? - omówienie modelu Leaky Integrate and Fire (**LIF**)
- ▶ Jak uczą się neurony? - propozycja Donalda Hebba (1949)
- ▶ Dlaczego neuronom potrzebne są mechanizmy homeostatyczne? – skalowanie synaptyczne
- ▶ Czym jest pole recepcyjne? – zastosowanie homeostatycznej plastyczności
- ▶ Jak neurony rywalizują? – omówienie zasady winner-take-all (WTA)
- ▶ Wizualizacja wyników eksperymentów
- ▶ Wnioski
- ▶ Źródła grafik

# Synapsy i przekazywanie impulsów



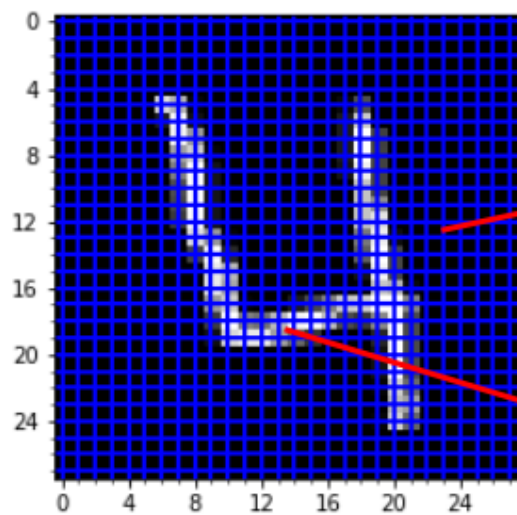
# Neurony jako urządzenia jonowe

$$\tau \frac{dU}{dt} = (U_{Rest} - U) + I(t)$$



## Reakcja neuronów sensorycznych na bodziec (stymulus) zewnętrzny






$P=0$

$P=0.25$

Kodowanie  
impulsów  
wejściowych

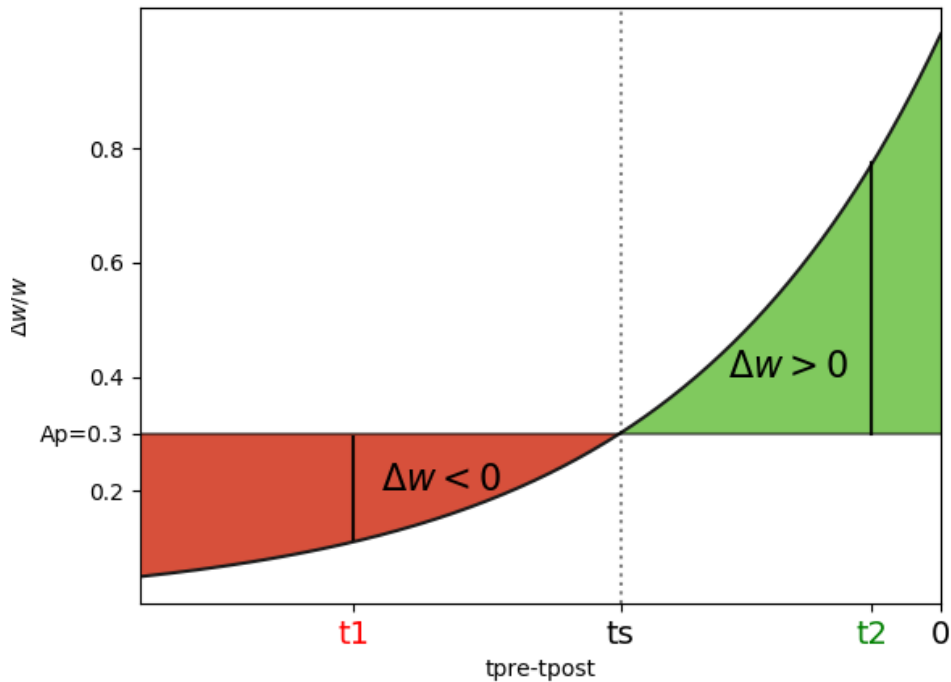
# Paradygmat uczenia Hebb'a (1949)



*"When an axon of cell A is near enough to excite cell B and repeatedly or persistently takes part in firing it, some growth process or metabolic change takes place in one or both cells such that A's efficiency, as one of the cells firing B, is increased."*

$$\frac{dw_{AB}}{dt} \approx COR(t_A, t_B)$$

# Homeostatyczna plastyczność



$$\frac{dw}{dt} = \eta(A_+(t) - R(t) * w)$$


$A_+(t)$  – współczynnik hebbowski

$R(t) * w$  – współczynnik skalowania zależny od aktywności neuronu


$R(t)$  – duże przy dużej aktywności neuronu, maleje wykładniczo z czasem gdy neuron jest mało aktywny



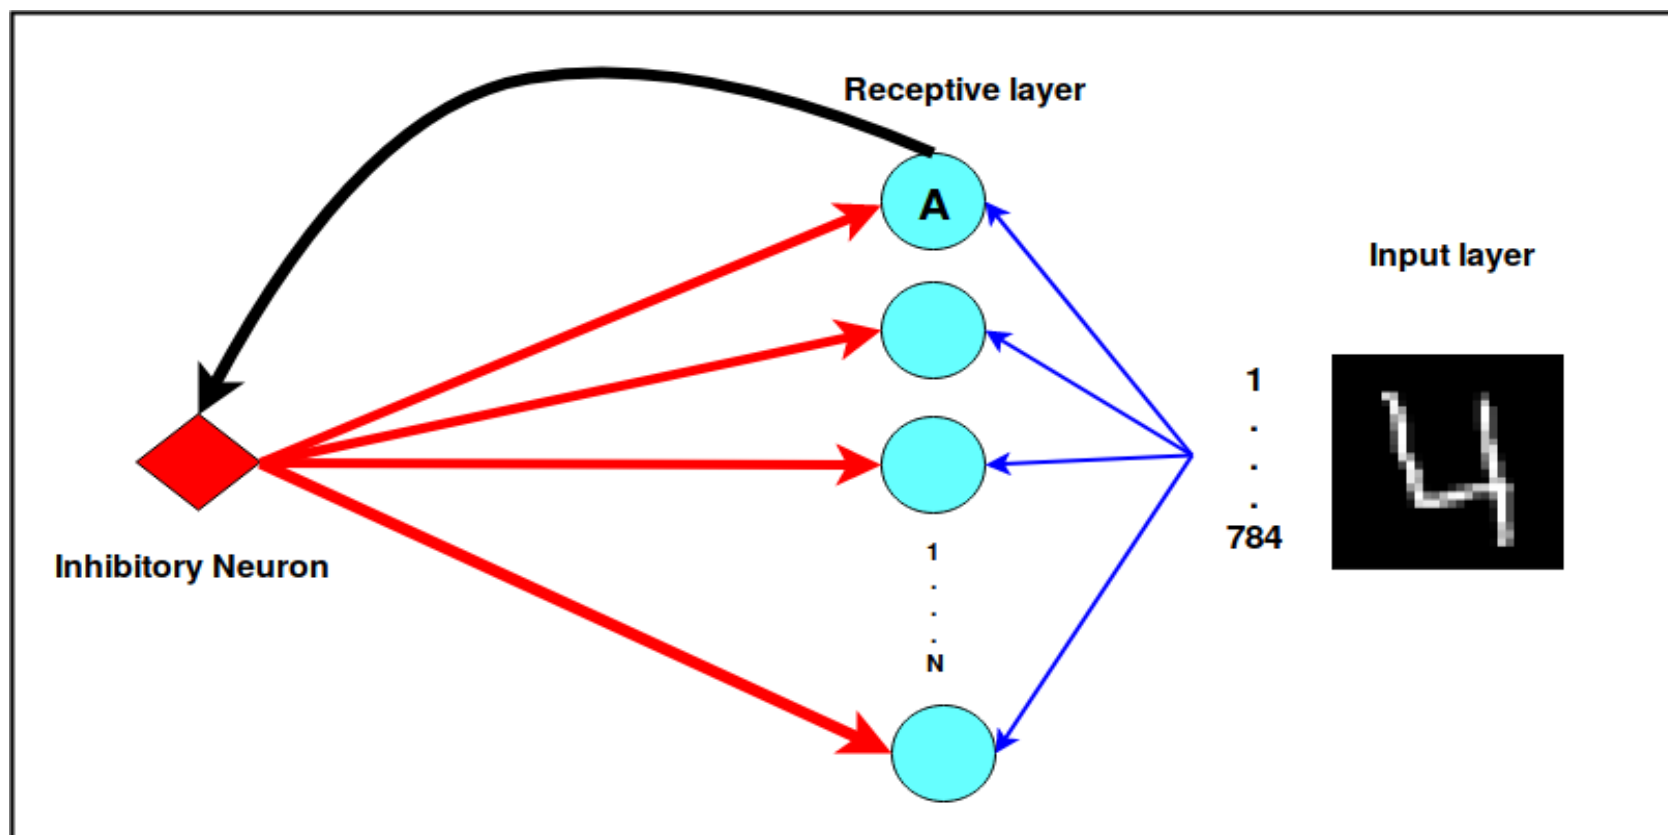
Demonstracja działania algorytmu uczącego, neuronom prezentowana jest 6, z lewej strony impulsy wejściowe po prawo wartości wag neuronu.




Dwóm neuronom w sieci prezentowane są dwie cyfry  
8 i 0.




# Współzawodnictwo i synapsy hamujące




Dwóm neuronom w sieci prezentowane są dwie cyfry  
8 i 0 z dodanym mechanizmem rywalizacji





Pole  
recepcyjne –  
principal  
components






Pole recepcyjne i bodźce dla których reaguje receptor.

# Budowanie klasyfikatora

- Uczenie zakończone
- Prezentacja zbioru uczącego dla sieci z ustalonymi wagami
- Dla każdej prezentowanej cyfry wybierany jest najsilniejszy receptor
- Na koniec określa się dla jakich cyfr receptor reagował najczęściej.
- Do receptora przypisywana jest cyfra


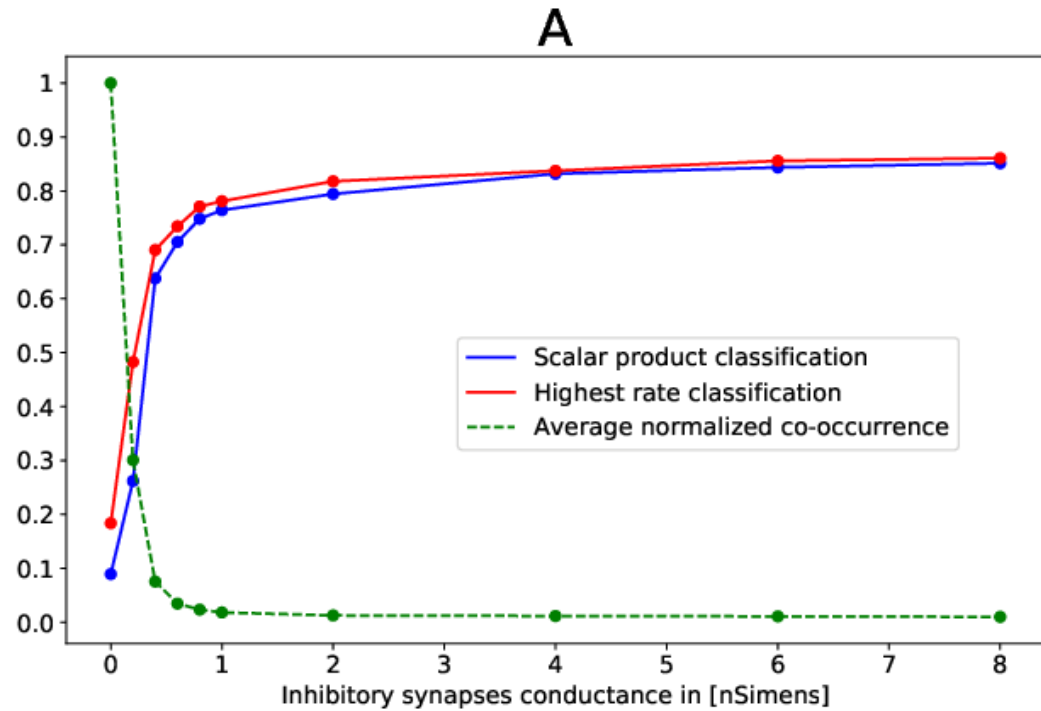
# Wyniki klasyfikacji na dzień dzisiejszy 😊

0	972	0	1	0	0	0	3	2	2	0
1	0	1115	4	3	0	1	5	2	3	1
2	10	0	996	3	1	0	1	8	13	0
3	1	1	6	951	0	28	0	8	10	4
4	3	0	3	0	932	0	5	1	0	38
5	11	1	4	20	2	834	7	2	6	3
6	17	1	1	0	1	3	932	0	3	0
7	2	7	19	1	8	1	1	953	2	33
8	18	2	11	23	8	39	5	7	858	3
9	15	5	2	12	30	8	0	18	4	915
	0	1	2	3	4	5	6	7	8	9


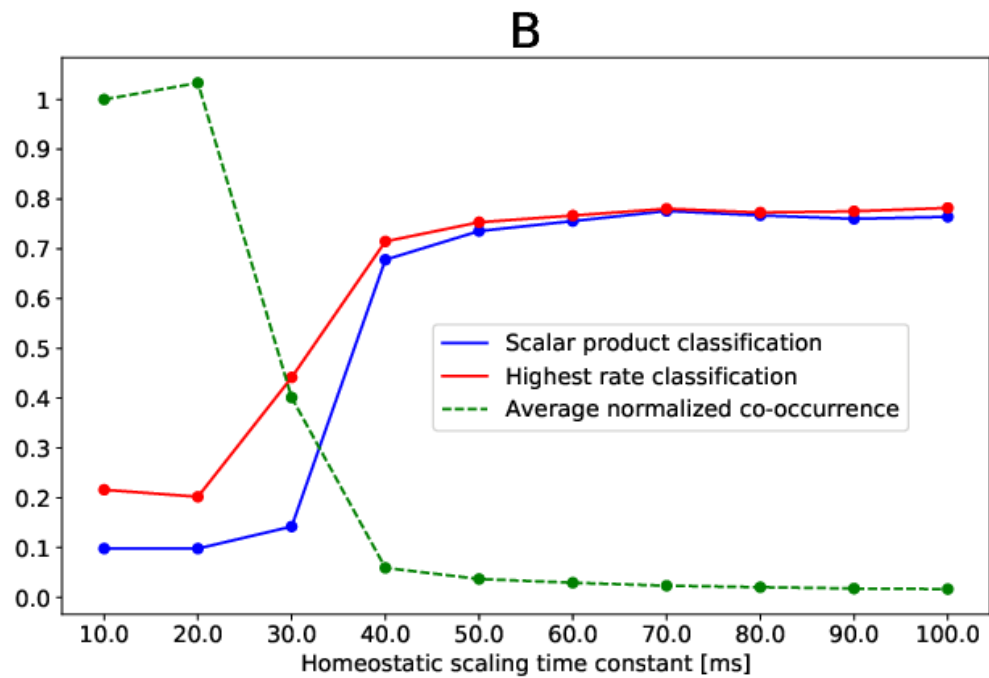




# Wpływ współczynnika hamowania na uczenie



# Wpływ skalowania na uczenie



# Wnioski

$$\frac{dw}{dt} = \eta(A_+(t) - R(t) * w)$$

- Zaproponowana plastyczność zapewnia zbieżność ale punkt stabilny ma charakter oscylacyjny (wagi cały czas pływają w wąskim zakresie)
- Rzadka reprezentacja zbioru treningowego
- Dominujący wpływ czynnika skalującego i wzajemnej rywalizacji neuronów na wyniki klasyfikacji
- Dla dużych sieci  $R(t)$  – staje się małe i warto je podbić o wartość stałą  $R(t)' = R(t) + \mu$
- Uzależnienie współczynnika skalowania od bieżącej wagi - w tej postaci może mieć wpływ na performance.

Dziękuję z uwagą 😊

# Źródła obrazków slajd 4 i 5

- ▶ <https://nobaproject.com/modules/neurons>