

# Wykład 1: Wprowadzenie do sieci neuronowych

## Historia badań nad sieciami neuronowymi.

- początki: badanie komórek ośrodkowego układu nerwowego zwierząt i człowieka, czyli *neuronów*; próby wyjaśnienia i matematycznego opisu działania błony komórkowej i całego neuronu [McCu43]
- koniec lat pięćdziesiątych i lata sześćdziesiąte: pierwsze modele pojedynczych neuronów i sieci, w tym:
  - popularny *perceptron* Rosenblatta i Wightmana [Rose65] (przeznaczony do rozpoznawania znaków alfanumerycznych)
  - pierwsze *neurokomputery* oferowane komercyjnie: *Madaline* Widrowa
- zahamowanie badań na przełomie lat '60 i '70 po publikacji książki Minsky'ego i Paperta [Mins69], wykazującej m.in. poważną ograniczoność pola zastosowań liniowych sieci neuronowych (zdolne jedynie do realizacji funkcji liniowych)
- lata '70 i początek '80: sieciami zajmuje się w świecie zaledwie kilka ośrodków (Grossberg, Hinton, Hopfield, PDP Research Group)
- początek '80: rozwój i większa dostępność komputerowych technik symulacji przyczynia się do stopniowej intensyfikacji badań
- druga połowa lat '80: "renesans" sieci:
  - fala nowych koncepcji, architektur, algorytmów uczenia;
  - ważna, monograficzna praca Rumelharta, McClellanda i PDP Research Group "*Parallel Distributed Processing. Explorations in the Microstructure of Cognition*" [Rume86], podsumowująca stan badań nad sieciami neuronowymi; w nim publikacja algorytmu nadającego się do uczenia wielowarstwowych sieci o nieliniowych neuronach (*backpropagation*) wraz z wykazaniem ich przewagi nad sieciami opartymi na perceptronach;
  - inna przyczyna wzrostu popularności: rosnące zainteresowanie ze strony specjalistów zajmujących się Sztuczną Inteligencją, wobec kryzysu nękającego tradycyjne, symboliczne techniki rozwijane w latach '60, '70 i '80 (Newell, Simon itp.)
- lata '90: dalsza rosnąca popularność;
  - rozwój sektora zastosowań w medycynie, przemyśle, edukacji i innych dziedzinach
  - coraz większa ilość przystępnych cenowo realizacji sprzętowych

## Koncepcja obliczeń neuronowych:


Definicja opisowa:

duża (1) ilość prostych (2), niezależnych jednostek obliczeniowych komunikujących się ze sobą, pracujących równoległe (3)

- (1) liczba neuronów w sieci zależy od rozmiaru zadania; w przypadku małego problemu może to być ich zaledwie kilka; w istocie chodzi o to, żeby był więcej niż jeden
- (2) w sensie "realizujących proste odwzorowanie matematyczne"
- (3) zależnie od implementacji; w praktyce większość sieci realizowana jest sekwencyjnie i programowo; rozwiązania sprzętowe i równoległe spotyka się tam, gdzie liczy się czas, w szczególności w zastosowaniach wymagających funkcjonowanie w czasie rzeczywistym (np. sterowanie)

## Inspiracja: neuron "biologiczny"

- budowa: *soma*, *akson*, *dendryty*, *synapsy*



- kluczowe znaczenie błony komórkowej w przesyłaniu sygnału; polega ono na propagacji zaburzenia różnicy potencjałów pomiędzy wnętrzem a zewnątrz komórki; przyczyną tych zaburzeń jest chwilowa utrata "szczelności" przez błonę komórkową
- zasada działania: "wpływające" dendrytami bodźce (modulowane częstotliwościowo) sumują się na błonie komórkowej i przy pomocy aksonu zakończonego synapsą przekazywane są do innego neuronu/neuronów
- neuronów mamy  $\sim 10^{10}$ , dendrytów  $\sim 10^{14}..10^{15}$
- różne rodzaje neuronów

## Neuron "sztuczny"

(dalej zwany "neuronem", inaczej *element przetwarzający (processing element)*, *jednostka (unit)* )

- drastyczne uproszczenie w porównaniu z neuronem biologicznym (precyzyjnym modelowaniem działania neuronu biologicznego zajmuje się tzw. *neuroscience*);
- podstawowe elementy składowe:
  - *wejścia (synapsy)* opatrzone *wagami* (lub wektor wag  $\mathbf{w}$  i wektor wejść  $\mathbf{x}$ ); waga synapsy podłączonej do wyjścia innego neuronu decyduje o jej ważności i jego wpływie na neuron odniesienia
  - *pobudzenie  $e$  (excitation)* neuronu jako suma ważona sygnałów wejściowych pomniejszona o *próg  $\Theta$  (threshold)*
  - *funkcja przejścia/przenosząca/aktywacji  $f$  (transfer function)*: liniowa lub (z reguły) nieliniowa (element progowy, funkcja sigmoidalna, tangens hiperboliczny); ma kluczowe znaczenie dla funkcjonowania neuronu
  - wyjście  $y$ ,
- zasada działania ([Tade93], s.27): wyjście = iloczyn skalarny wektora wejść i wektora wag "przepuszczony" przez funkcję przenoszącą

$$e = \sum_{i=1}^n w_i \cdot x_i - \theta = \mathbf{w} * \mathbf{x} - \theta \quad (0.1)$$


$$y = f(e) \quad (0.2)$$

W najprostszym przypadku, jeśli funkcja przenosząca ma postać  $y=e$ , mówimy o neuronie *liniowym*.

Dla ujednoczenia zapisu często "ukrywa się" próg  $\Theta$  w postaci wagi  $w_0 = \Theta$ , podłączonej do stałego sygnału  $x_0 = 1$ . Prowadzi to do uproszczenia formuły 1.1:

$$e = \sum_{i=0}^n w_i \cdot x_i = \mathbf{w} * \mathbf{x} \quad (0.3)$$

- symbol graficzny neuronu



- mimo uproszczenia w stosunku do neuronu biologicznego zachowana jest istota działania: ważone sumowanie sygnałów docierających przez wejścia

## Sieć neuronowa


(Sztuczna) sieć neuronowa ((artificial) neural network) wiele połączonych ze sobą neuronów.

Każda sieć ma z reguły pewną wyróżnioną grupę "dendrytów" będących jej *wejściami* i "aksonów" stanowiących *wyjście* (niekiedy wejście pokrywa się z wyjściem, np. w sieci Hopfielda)


## "Systematyka" sieci neuronowych

**Topologia (architektura)**, tj. sposób połączenia neuronów ze sobą

- *jednokierunkowe (feed forwarded)*; połączenia między neuronami nie zamykają się w cykle;  
Szczególnym przypadkiem architektury jednokierunkowej jest sieć *warstwowa*, reprezentująca zdecydowanie najpopularniejszą topologię;



- *rekurencyjne (feedback, bidirectional)*: obecność sprzężeń zwrotnych  
Np. sieć Hopfielda:



**Sposób propagacji pobudzenia** (sygnałów) przez sieć (dotyczy głównie realizacji programowych sieci ze sprzężeniami zwrotnymi)

- *synchroniczny*: bieżący stan sieci jest "zamrażany" i na jego podstawie dla każdego neuronu oblicza się nową wartość pobudzenia i wyjścia; następnie wielkości te aktualizuje się dla całej sieci w jednym kroku, jednocześnie dla wszystkich neuronów;
- *asynchroniczny*: w kolejnych krokach każdy (z reguły wybrany losowo) neuron oblicza nową wartość swojego pobudzenia i wyjścia, która jest natychmiast, tj. już w następnym kroku, "widziana" przez inne neurony podłączone do jego wyjścia;
- "*przesyłanie żetonów*" (*counter-propagation*): specyficzny model propagacji sygnału bazujący na "dyskretnym" pobudzeniu w postaci "żetonu".

### **Reguła łączenia neuronów między sobą**

- "każdy z każdym" (*fully connected*);  
w szczególności: między kolejnymi warstwami w sieciach warstwowych
- tylko z pewną grupą neuronów, najczęściej z tzw. *sąsiedztwem*

### **Charakterystyka procesu uczenia I**

- sieci uczone w sposób nadzorowany  
Algorytm uczący adaptuje sieć stosownie do wymuszeń zewnętrznych, starając się możliwie wiernie (tj. z jak najmniejszym błędem) zrealizować zadaną funkcję  
np. *backpropagation*, algorytm wstecznej propagacji błędu; każdy neuron lokalnie zmniejsza swój błąd stosując metodę spadku gradientu
- sieci uczone w sposób nienadzorowany  
Neurony nie są "skrępowane" żadnym zewnętrznym kryterium (funkcją błędu), adaptacja polega np. na:
  - wzmacnianiu połączeń (zwiększaniu wag) pomiędzy neuronami, których pobudzenia wykazują pewną korelację (np. uczenie Hebba)
  - zbliżaniu (znormalizowanego) wektora wag do (znormalizowanego) wektora wejść (np. reguła uczenia perceptronu, kwantyzator wektorów Kohonena); w takim przypadku neuron najsilniej reaguje na wektor wejść/pobudzeń, który jest najbardziej zbliżony do jego wektora wag (ten podział dotyczy zasadniczo algorytmów uczenia, jako że często sieć o danej topologii da się uczyć zarówno w sposób nadzorowany, jak i nienadzorowany)

## **Charakterystyka procesu uczenia II**

- sieci, w których na podstawie danych statystycznych opisujących zbiór uczący jednorazowo ustala się wartości wag (np. standardowy algorytm uczenia sieci Hopfielda)
- sieci, w których wychodzi się z pewnej (z reguły losowej) konfiguracji sieci (tj. wartości jej wag) i w kolejnych iteracjach, związanych z reguły z prezentacją przykładów ze zbioru uczącego, stara się dojść do konfiguracji najbardziej pożądanej, tj. takiej, która minimalizuje pewną miarę błędu

## **Charakterystyka procesu uczenia III**

- *heteroasocjacyjne* - w odpowiedzi na podanie na wejścia sieci danego wzorca na jej wyjściu ma się pojawić inny, skojarzony z nim wzorzec
- *autoasocjacyjne* - zadaniem sieci jest powielanie na wyjściu wzorca podanego na wejście; w szczególności znajdowanie "oryginałów" wzorców zaszumionych lub uszkodzonych



Przykłady znanych typów sieci i umiejscowienie w powyższej klasyfikacji

Nazwa sieci	Topologia	Propagacja pobudzenia	Łączenie neuronów	Uczenie I	Uczenie II	Uczenie III
Perceptron	warstwowa	-	każdy z każdym warstwami	nadzorowane	iteracyjne	hetero-asocjacja
SOM	warstwowa	-	każdy z każdym warstwami	nienadzorowane	iteracyjne	hetero-asocjacja
Hopfield	brak	synchroniczna lub asynchroniczna	każdy z każdym	nienadzorowane	w jednym kroku	auto-asocjacja

## Cechy sieci neuronowych:

- + rozproszony charakter przetwarzania informacji i wynikająca z niego
  - odporność na uszkodzenie/eliminację znacznej nawet części neuronów
  - odporność na uszkodzone i zaszumione wzorce
- + równoległe przetwarzanie informacji (w przypadku implementacji sprzętowych)
  - szybkość działania (w realizacji sprzętowej, wciąż raczej rzadkiej i kosztownej)
- powolność większości algorytmów uczących: często setki tysięcy iteracji
- trudności z interpretacją wiedzy nabytej przez sieć (brak lub słabe własności eksplikatywne) w związku z jej (tj. wiedzy) rozproszeniem w sieci (tzw. *distributed knowledge representation*); *czarna skrzynka, blackbox*
- zwłaszcza w uczeniu maszynowym: trudności z reprezentacją niektórych typów danych, np. cech/atributów nominalnych o wartościach nie podlegających uporządkowaniu; konieczność stosowania kodowania "*1 of n*"
- duża ilość parametrów (sieci i algorytmu uczącego), przy jednoczesnym braku ścisłych reguł do estymacji ich wartości

## Przykład: Klasyfikacja elektroencefalogramu

### Zadanie:

klasyfikacja elektroencefalogramu do jednej z trzech klas:

- normal (*norm*)
- shizophrenic (*shiz*)
- obsessive compulsive disorder (*ocd*)

### Dane wejściowe:

- postać oryginalna (*raw data*): wynik badania elektroencefalograficznego zaklasyfikowany przez grupę neurologów do jednej z trzech wyżej wymienionych klas: 19 kanałów próbkowanych z częstotliwością 128 Hz, pacjent w spoczynku
- wstępna obróbka danych (*data preprocessing*):
  - usunięcie artefaktów (np. zakłóceń wynikłych z poruszeń pacjenta)
  - usunięcie składowych o wysokich częstotliwościach (np. szumów) poprzez obróbkę filtrem dolnoprzepustowym (30 Hz)
  - spośród 19 sygnałów do dalszej obróbki wybrany został kanał  $C_Z$  (pobierany ze szczytu głowy), ponieważ wcześniejsze badania wykazały największą przydatność właśnie tego sygnału do celów diagnostycznych (można z grubsza przyjąć, iż sygnał dostarczany tym kanałem jest liniową kombinacją sygnałów dostarczanych pozostałymi kanałami)
  - pod uwagę brane jest pierwsze 250 sekund przebiegu (pacjent jest wówczas najbardziej uspokojony)

### Ekstrakcja cech:

Metoda: autoregresja (AR); polega na próbie przybliżenia przebiegu przez rekurencyjną zależność:

$$s_t = \sum_{j=1}^N \alpha_j s_{t-j} + \varepsilon_t$$

gdzie:

$s_t$  sygnał w chwili  $t$

$\varepsilon_t$  pewna zmienna losowa o rozkładzie normalnym

Szukanymi parametrami opisującymi przebieg są  $\alpha_j$  dla  $j=1..N$ ; da się je obliczyć przy użyciu pewnych metod. Stanowią one cechy (atrybuty) podawane na wejścia klasyfikatora.

[Współczynniki te mają podobną interpretację jak elementy widma częstotliwości otrzymanego np. przy pomocy FFT; posiadają jednak przewagę polegającą na niższej wrażliwości na szumy.]

Przeprowadzono testy dla N zmieniającego się od 8 do 15.

**Zbiór uczący:**

15 przypadków, po 5 z każdej z trzech klas (norm, shiz, ocd)

**Klasyfikator i jego uczenie:**

dwuwarstwowy perceptron o architekturze 8-15-3 (8 neuronów w warstwie wejściowej, 15 w warstwie ukrytej i 3 w wyjściowej)

- pełne połączenia pomiędzy warstwami (*fully connected*)
- docelowo każdy z neuronów w warstwie wyjściowej ma odpowiadać jednej klasie; w związku z tym wektory pożądanych wartości wyjść mają postać (1,0,0), (0,1,0) i (0,0,1) dla odpowiednich klas
- algorytm uczący: najprostsza wersja *backpropagation*

**Zbiór testujący:**

24 przypadki: 6 norm, 8 shiz, 10 ocd

**Wyniki testu reklasyfikującego (*confusion matrix*):** (dla jednego z testów)

		Sieć		
		norm	shiz	ocd
Ekspert	norm	6	-	-
	shiz	-	7	1
	ocd	-	1	9

**Trafność klasyfikacji:**  $(6+7+9)/24 \cong 91\%$

**Słabe punkty tej aplikacji:**

- mała licznosc zbiorow uczacego i testujacego (15, 24)
- licznosc zbioru testujacego wieksza od licznosci zbioru uczacego
- zbyt duza liczba neuronow w warstwie ukrytej sieci neuronowej (duze ryzyko uczenia sie "na pamiec": 15 przypadkow, 15 neuronow)

Tsoi A.C., So D.S.C, Sergejew A.: Classification of Electroencephalogram using Artificial Neural Networks. Technical Report, University of Queensland, Australia, March 1993