


Sztuczne sieci neuronowe

Marcin Jukiewicz Andrzej Gajda

Sztuczna Inteligencja

22.05.2019



INTRODUCTION TO
THE THEORY OF
NEURAL COMPUTATION

*John Hertz
Anders Krogh
Richard G. Palmer*




A LECTURE NOTES VOLUME IN THE

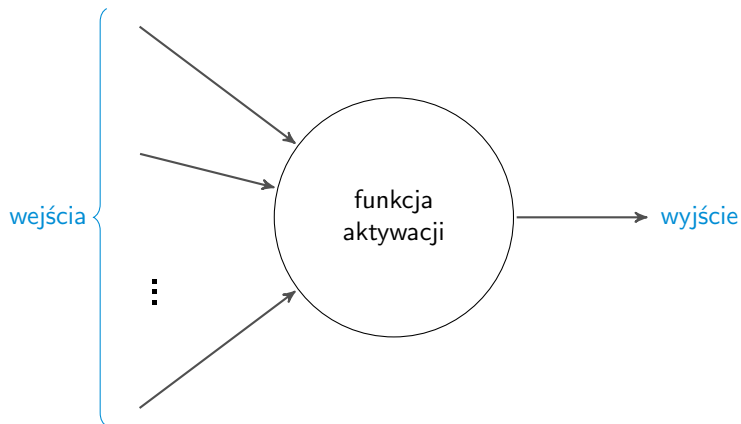
SANTA FE INSTITUTE STUDIES IN THE SCIENCES OF COMPLEXITY

- klasyfikacja
- tworzenie wzorców
- rozpoznawanie wzorców
- aproksymacja funkcji

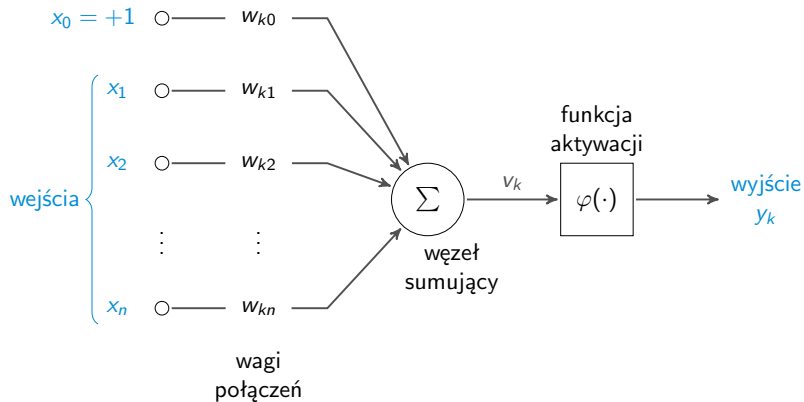
The history of these sorts of ideas in psychology originates with Aristotle. Yet as a basis for computational or neural modelling we can trace them to the paper of McCulloch and Pitts [1943]... (Hertz i in., 1990; s. 6)

- 1943 — McCulloch i Pitts: pierwszy artykuł
- ~1960 — Rosenblatt: *perceptron*
- 1974 — Werbose: *backpropagation*

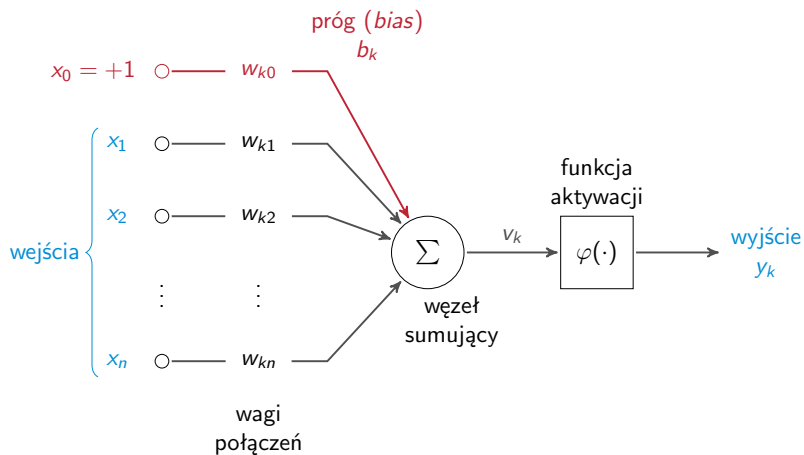




Neuron — diagram blokowy



Neuron — diagram blokowy



$$y_k = \varphi(v_k)$$


$$v_k = u_k + b_k$$

$$u_k = \sum_{i=1}^n w_{ki} x_i$$

$$b_k = x_0 w_{k0}$$


$$y_k = \varphi \left(\sum_{i=1}^n w_{ki} x_i + x_0 w_{k0} \right)$$

- y_k — wartość wyjściowa (*output*)
- $\varphi(\cdot)$ — funkcja aktywacji (*activation function*)
- v_k — potencjał aktywacji (*activation potential, induced local field*)
- u_k — wyjście węzła sumującego (*linear combiner output*)
- x_1, \dots, x_n — sygnały wejściowe (*input signals*)
- w_{k1}, \dots, w_{kn} — wagi połączeń (*synaptic weights*)
- b_k — próg aktywacji (*bias*)




$$y_k = \varphi(v_k)$$


Funkcja aktywacji ($\varphi(\cdot)$)



$$\varphi(v_k) = v_k$$




$$\varphi(v_k) = \begin{cases} 1 & \text{if } v_k \geq 0 \\ 0 & \text{if } v_k < 0 \end{cases}$$



$$\varphi(v_k) = \frac{1}{1 + \exp(-\beta v_k)}$$


- Relu:

$$\varphi(v_k) = \max(0, v_k)$$



- Softmax:

$$\varphi(v_k) = \frac{\exp(v_k)}{\sum_{j=1}^n \exp(v_j)}$$




warstwa
wejściowa
(*input layer*)

warstwa
neuronów
ukrytych
(*hidden layer*)

warstwa
neuronów
wyjściowych
(*output layer*)

- Pochodne (*derivatives*)
 - oznaczenie: $\frac{dy}{dx}$, $y'(x)$
 - pochodna cząstkowa (*partial derivative*)
oznaczenie: $\frac{\partial y}{\partial x}$
- Wektory (*vectors*)
 - oznaczenie: \mathbf{a} , \bar{a} , \overrightarrow{AB}
 - wektory jednostowe / wersory (*unit vectors*): \hat{i} , \hat{j} ...
- Macierze (*matrices*)
 - oznaczenie: \mathbf{A} , \mathbf{W} ...
 - mnożenie, dodawanie macierzy
- Gradient
 - oznaczenie: $\nabla f(x_1, \dots, x_n) = \left(\frac{\partial f}{\partial x_1}, \dots, \frac{\partial f}{\partial x_n} \right)$



3Blue1Brown

$$X = \{\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n\}$$

$$Y = \{\bar{y}_1, \bar{y}_2, \dots, \bar{y}_n\}$$

$$O = \{\bar{o}_1, \bar{o}_2, \dots, \bar{o}_n\}$$

gdzie $\bar{x}_i \in \mathbb{R}^s$, $\bar{y}_i \in \mathbb{R}^t$, $\bar{o}_i \in \mathbb{R}^t$ dla $i \in [1, n]$

- *Mean squared error / quadratic cost / maximum likelihood / sum squared error:*

$$C_{MSE}(y_i, o_i) = \frac{1}{n} \sum_{j=1}^n (o_j - y_j)^2$$

$$\nabla_{y_j} C_{MSE} = -2 \cdot (o_j - y_j)$$

$$X = \{\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n\}$$

$$Y = \{\bar{y}_1, \bar{y}_2, \dots, \bar{y}_n\}$$

$$O = \{\bar{o}_1, \bar{o}_2, \dots, \bar{o}_n\}$$

gdzie $\bar{x}_i \in \mathbb{R}^s$, $\bar{y}_i \in \mathbb{R}^t$, $\bar{o}_i \in \mathbb{R}^t$ dla $i \in [1, n]$

- *Exponential cost:*

$$C_{EXP}(\bar{y}_i, \bar{o}_i) = \tau \cdot \exp\left(\frac{1}{\tau} \sum_{j=1}^t (o_j - y_j)^2\right)$$

$$\nabla_{y_j} C_{EXP} = \frac{2}{\tau} (o_j - y_j) \cdot C_{EXP}$$

$$X = \{\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n\}$$

$$Y = \{\bar{y}_1, \bar{y}_2, \dots, \bar{y}_n\}$$

$$O = \{\bar{o}_1, \bar{o}_2, \dots, \bar{o}_n\}$$

gdzie $\bar{x}_i \in \mathbb{R}^s$, $\bar{y}_i \in \mathbb{R}^t$, $\bar{o}_i \in \mathbb{R}^t$ dla $i \in [1, n]$

- *Cross-entropy cost:*

$$C_{CE}(\bar{y}_i, \bar{o}_i) = -\frac{1}{n} \cdot \sum_{j=1}^t [y_j \ln(o_j) + (1 - y_j) \ln(1 - o_j)]$$

$$\nabla_{y_j} C_{CE} = \frac{o_j - y_j}{o_j \cdot (1 - o_j)}$$

$$\Delta W = -\eta \cdot \nabla_W$$

$$\Delta W = -\eta \cdot \nabla_{W(i)} + \alpha \Delta W(i-1)$$

- *Backpropagation* z momentem i „tarciami”

$$w_t = w_{t-1} - \eta \cdot \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon}$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \delta w_t$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) (\delta w_t)^2$$

- Stochastyczny (*stochastic*)
 - *Mini-batch*
 - *Batch* (wsad, partia, pakiet)
-
- Iteracja (*iteration*) — przejście sygnału przez sieć oraz propagacja wsteczna błędu (*forward pass, backward pass*)
 - *Epoch* — iteracja **wszystkich** przykładów uczących

- Nieliniowość (*nonlinearity*)
- Mapowanie wejście-wyjście (*input-output mapping*)
- Adaptacyjność (*adaptivity*)
- „Uzasadnienie” odpowiedzi (*evidential response*)
- Zachowanie kontekstu (*contextual information*)
- Odporność na wady (*fault tolerance*)
- *VLSI implementability* (*Very Large Scale Integrated technology*)
- Jednorodność struktury (*uniformity of analysis and design*)
- Analogia neurobiologiczna (*neurobiological analogy*)

- Duża ilość przykładów uczących
 - czas
 - moc obliczeniowa
- Ograniczone możliwości „zaprojektowania” sztucznej sieci neuronowej
- *Black box*

Dziękujemy za uwagę