

Wewnętrzne reprezentacje w warstwach ukrytych w skierowanych sieciach neuronowych

Jarosław Piersa
Wydział Matematyki i Informatyki, UMK

2013-04-11 — 13

Czym jest sieć neuronowa?

- macierze wag $W_1..W_l$, gdzie $W_1 \in \mathbb{R}^{n \times d_1}$, $W_2 \in \mathbb{R}^{d_1 \times d_2}$, ... ,
 $W_l \in \mathbb{R}^{d_{l-1} \times d_l=1}$
- wejścia: $\bar{x} = (x_1..x_n) \in \mathbb{R}^n$
- wynik działania na \bar{x} :

$$O_{W_1..W_l}^{(1)}(x) = \sigma(W_1^{tr} \cdot x) \in R^{d_1}$$

$$O_{W_1..W_l}^{(2)}(x) = \sigma(W_2^{tr} \cdot O^{(1)}(x)) = \sigma(W_2^{tr} \cdot \sigma(W_1^{tr} \cdot x))$$


...

$$O_{W_1..W_l}^{(l)}(x) = \sigma(W_l^{tr} \cdot O^{(l-1)}(x)) = \sigma(W_l^{tr} \cdot \sigma(\dots \sigma(W_1^{tr} \cdot x) \dots))$$

- gdzie σ jest operacją braną po współrzędnych:

$$\sigma(x) = \frac{1}{1 + \exp(-x)}$$



Czym jest sieć neuronowa?



Uczenie sieci

- dane uczące: $(E^i, C^i), i = 1..p$, gdzie $E^{(i)} = (e^{(i)}_1 \dots e^{(i)}_n)$, $C^i \in (0, 1)$
- znaleźć $W_1..W_l$ (zwykle $l=3$), takie że $O'_{W_1..W_l}(E^i) \simeq C^i$ dla $i = 1..p$

Uczenie Sieci




Uczenie sieci

Przyjmujemy uproszczenie:

- kategoryzacja binarna: $C^i \in \{0, 1\}$
- $O^i(\bar{x}) = \begin{cases} 1 & \text{jeżeli } O_{W_1..W_l}(\bar{x}) \geq \frac{1}{2} \\ 0 & \text{wpu} \end{cases}$
- Cel: znaleźć W_1, \dots, W_l


Co zrobiłby człowiek?

- $$O_{n_1}(\vec{x}) = \frac{1}{1 + \exp(-\sum_j w_{j,n_1} \cdot x_j)}$$



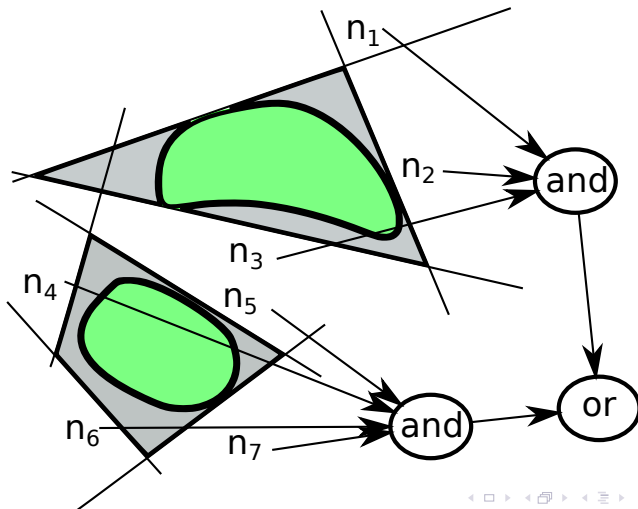
Co zrobiłby człowiek?

- $$O_{AND}(\bar{x}) = \frac{1}{1 + \exp(-\sum_j w_{n_j, and} \cdot O_{n_j}(\bar{x}))}$$



Co zrobiłby człowiek?

- $$O_{OR}(\bar{x}) = \frac{1}{1 + \exp(-\sum_j w_{and_j, or} \cdot O_{and_j}(\bar{x}))}$$



Jak uczy komputer?

Werbos (1985)

- 1 wybierz przykład E
- 2 Zapamiętaj wyniki działania na przykładzie E również w warstwach pośrednich o_j , sumy ważone in_j
- 3 Uaktualnij wagi w warstwie zewnętrznej (dla neuronu n_i):
 - Oblicz: $err_i = C_i - o_i$ oraz $\Delta_i = err_i \cdot \sigma'(in_i)$
 - Skoryguj wagi:


$$w_{j,i} = w_{j,i} + \eta \cdot I_{j,i} \cdot \Delta_i$$

- 4 Uaktualnij wagi w pozostałych warstwach (dla neuronu n_j):
 - Oblicz błąd $err_j = \sum_l w_{j,l} \cdot \Delta_l$ oraz $\Delta_j = \sigma'(in_j) \cdot err_j$
 - Uaktualnij wagi:

$$w_{k,j} = w_{k,j} + \eta \cdot I_{k,j} \cdot \Delta_j$$





Warstwa 1

- $O(x, y) = \sigma(w_1x_1 + w_2x_2 + w_0) = \frac{1}{1 + \exp(-\sum_i w_i x_i)}$




Warstwa 2

- $O_j(x, y) = \sigma(\sum_i w_{ij} \cdot O_{W_1}(\bar{x}))$




Reprezentacje


YouTube



Poprawność klasyfikacji w warstwach ukrytych



Wagi wychodzące z warstwy




Czy da się zmniejszyć ilość wag?

Wycinanie nieistotnych wag


- wybierz parametr $\theta > 0$
- dla $i = 1..l$ wykonaj
 - jeżeli $|W_i[n, m]| < \theta$ to przypisz $W_i[n, m] := 0$
- dodatkowo dla warstwy wyjściowej l
- jeżeli $|W_l[m]| < \theta$ to przypisz $W_{l-1}[1..d_{l-1}, m] := 0$

Wynik




Przypadek ekstremalny

- poprawność 99.5%
- pełne tablice wag (ok 150)



- poprawność 96%
- niezerowych wag 39%



Przypadek ekstremalny

- sieci szerokie, a płytkie
- analiza redundancji wag

