


Propagacja wsteczna




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

$$a_j = \sigma\left(\sum_{k=0}^2 w_{jk} x_k\right) \quad j=0,1$$

$$a_2 = -1$$

$$y_j = \sigma\left(\sum_{k=0}^2 v_{jk} a_k\right) \quad j=0,1$$

$$\sigma(x) = x_+ = \max(x, 0) \quad \text{ReLU}$$



$$y_j = \sigma\left(\sum_{k=0}^2 v_{jk} a_k\right)$$

Ustalenie j_0, k_0 , $v := v_{j_0, k_0}$.

$$L(t, y) = \frac{1}{2} \|t - y\|_2^2 = \frac{1}{2} (t_0 - y_0)^2 + \frac{1}{2} (t_1 - y_1)^2 \quad t = (t_0, t_1)$$

$$L(t, y) = -\sum_{i=0}^1 t_i \log y_i \quad (0 \cdot \log 0 = 0) \quad y = (y_0, y_1)$$

$$\frac{\partial L}{\partial v} = \frac{\partial L(t, y)}{\partial y_0} \cdot \frac{\partial y_0}{\partial v} + \frac{\partial L(t, y)}{\partial y_1} \frac{\partial y_1}{\partial v} = \frac{\partial L(t, y)}{\partial y_{j_0}} \frac{\partial y_{j_0}}{\partial v} = \frac{\partial L(t, y)}{\partial y_{j_0}} \cdot \sigma'\left(\sum_{k=0}^2 v_{jk} a_k\right) a_{k_0}$$

$\rightarrow -\delta^{(2)}$

nowe $v = v - c \frac{\partial L}{\partial v}$
 \uparrow
 stara
 wersja

$$a_m = \sigma\left(\sum_{n=0}^2 w_{mn} x_n\right), m = 0, 1$$

$c = 0.01$
 $c = 0.1$
 "Optimieren"

Ustalenie m_0, n_0 , $w := w_{m_0, n_0}$.


$$\frac{\partial L}{\partial w} = \sum_{j=0}^1 \frac{\partial L(t, y)}{\partial y_j} \cdot \frac{\partial y_j}{\partial w} = \sum_{j=0}^1 \frac{\partial L(t, y)}{\partial y_j} \sigma'\left(\sum_{k=0}^2 v_{jk} a_k\right) \cdot \sum_{k=0}^2 v_{jk} \frac{\partial a_k}{\partial w} = \sum_{j=0}^1 \frac{\partial L(t, y)}{\partial y_j} \sigma'\left(\sum_{k=0}^2 v_{jk} a_k\right) v_{j m_0} \cdot \frac{\partial a_{m_0}}{\partial w} =$$

$$= \sum_{j=0}^1 \frac{\partial L(t, y)}{\partial y_j} \sigma'\left(\sum_{k=0}^2 v_{jk} a_k\right) v_{j m_0} \cdot \sigma'\left(\sum_{n=0}^2 w_{mn} x_n\right) \cdot x_{n_0}$$

$\rightarrow -\delta^{(1)}$

nowe $w = w - c \frac{\partial L}{\partial w}$

Zadanie



opisujący wp. dla wytry 2
wyjścia:



Dane: (x_i, t_i) , $i=0, 1, \dots, M-1$
↑ wejście ↑ oczekiwane wyjście (etykieta)

Kluczowy koszt: $\sum_{i=0}^{M-1} L(t_i, y_i)$
↑ wyjście sieci dla x_i

Oryginalne koszty kosztu jest zbyt kosztowne obliczenie.

• 'online learning': biernemy po kolei dane x_0, x_1, \dots, x_{M-1}
i kalkulujemy wagę po każdej;

• kompromis: 'batch learning': biernemy grupę danych $(x_0, x_1, \dots, x_{b-1})_1, \dots$
i kalkulujemy wagę po każdej grupie

• danych mamy tyle ile chcemy, dlatego wigramy ich wielkość:
warto dane wyciągnąć z zestawu po każdej epoce

```
for epoch in ... :  
  [ for x in ... :  
    shuffle(x)
```

• inicjacja wag:

wagi powinny zostać zainicjowane w któryś sposób dla różnych neuronów

- losowo

variancja

(iid)

złoto


lepszy: $w \sim N(0, \left(\frac{1}{\sqrt{785}}\right)^2)$

Nasze zadanie:

np. jeśli

$w \sim N(0, 1)$

Wzrost z neuronu j w warstwie 1: $= \sigma \left(\sum_{k=0}^{785} w_{jk} x_k \right)$



x_k - dane z brzoła,
 $E[-1, 1)$

gdyby rozkład x_k byłby równy 0, a rozkład 1:

$\sigma \left(\underbrace{390 \text{ wartości } w_{jk}} \right)$
 $\sim N(0, 390) = N(0, \sqrt{390}^2)$
 $\sigma \approx 20$
 $N(0, 1)$

