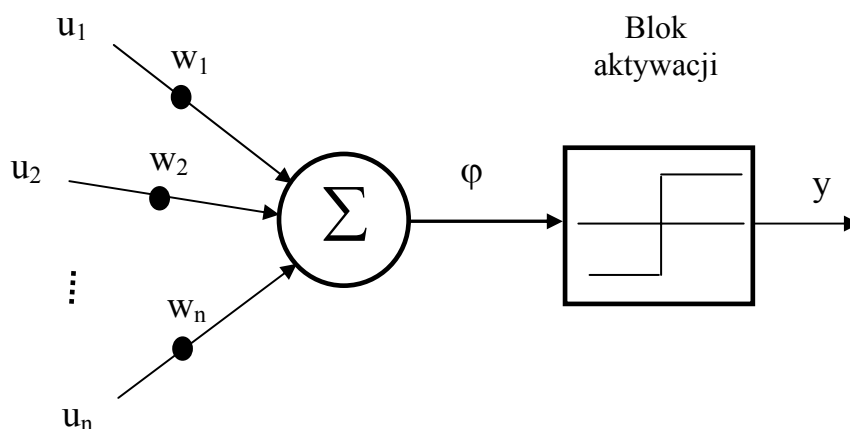



Modele neuronów. Bezgradientowe metody uczenia sieci neuronowych.

1. Perceptron - Matematyczny model neuronu



Gdzie u_1, u_2, \dots, u_n - sygnały wejściowe, w_1, w_2, \dots, w_n - wartości wag, y - sygnał wyjściowy

2. Sieć perceptronowa jednowarstwowa



Gdzie u_1, u_2, \dots, u_n - sygnały wejściowe, w_{ij} - wartości wag, y_1, y_2, \dots, y_m - sygnały wyjściowe

$$\varphi_j = \sum_{i=0}^n u_i w_{ij} \quad , \quad y_j = f(\varphi_j)$$

3. Algorytm uczenia perceptronu

- podanie danych na wejścia neuronu u_1, u_2, \dots, u_n i wyznaczenie wartości na wyjściu neuronu y_1, y_2, \dots, y_m
- porównanie odpowiedzi neuronu y_j z odpowiedziami oczekiwanymi yz_j
- obliczenie korekt wag w_{ij} według następującego wzoru (j - nr wyjścia):

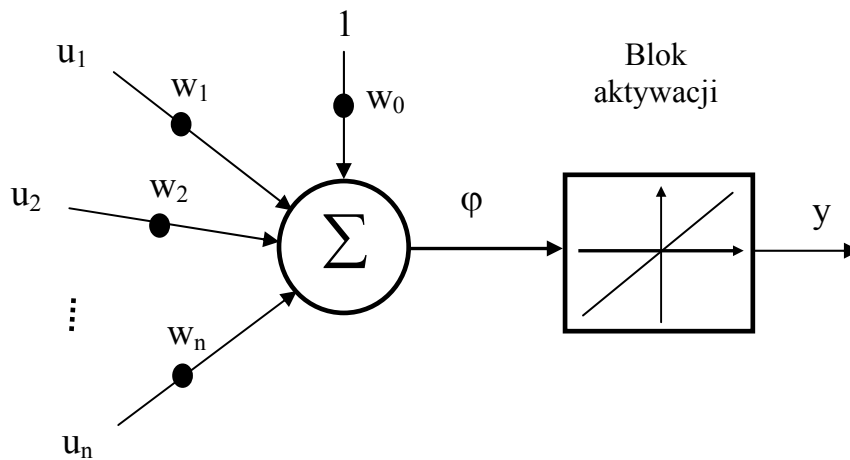
$$\Delta w_{ij}^t = \begin{cases} 0 & \text{gdy } y_j^t = yz_j^t \\ u_i^t & \text{gdy } y_j^t = 0 \text{ i } yz_j^t = 1 \\ -u_i^t & \text{gdy } y_j^t = 1 \text{ i } yz_j^t = 0 \end{cases}$$

$$\Delta w_{ij} = \sum_{t=1}^N \Delta w_{ij}^t$$

- skorygowanie wag według następującego wzoru

$$w_{ij}^{nowe} = w_{ij}^{stare} + \eta \Delta w_{ij}$$

4. Model neuronu Adaline



Gdzie u_1, u_2, \dots, u_n - sygnały wejściowe, w_1, w_2, \dots, w_n - wartości wag, y - sygnał wyjściowy

$$\varphi = \sum_{i=0}^n u_i w_i, \quad y = \varphi$$

5. Algorytm uczenia sieci Madaline metodą Widrowa-Hoffa (reguła delty)

- podanie danych na wejścia sieci u_1, u_2, \dots, u_n i wyznaczenie wartości na wyjściach sieci y_i
- porównanie odpowiedzi sieci y_i z odpowiedziami oczekiwanymi y_{zi} i wyznaczenie błędu według następującego wzoru

$$\delta_i^t = y_{zi}^t - y_i^t$$

g) obliczenie korekt wag $\mathbf{w}_0, \mathbf{w}_1, \dots, \mathbf{w}_n$ według następującego wzoru:

$$\Delta w_i^t = -2\delta_i^t u_i^t$$

$$\Delta w_i = \sum_{t=1}^P \Delta w_i^t$$

h) skorygowanie wag według następującego wzoru

$$w_i^{nowe} = w_i^{stare} - \eta \Delta w_i$$

i) Kroki od a do d powtarzane są aż suma kwadratów błędów ξ nie stanie się wystarczająco mała

$$\xi = \sum_{t=1}^P \sum_{i=1}^m (y_{zi}^t - y_i^t)^2$$

gdzie \mathbf{P} to liczba zbiorów uczących a \mathbf{m} to liczba wyjść sieci

Zadania - Perceptron

1. Wyznaczyć wektor wag $[\mathbf{w}_0 \mathbf{w}_1 \mathbf{w}_2]$, dla których neuron będzie klasyfikował elementy dwóch zbiorów $\mathbf{A}=\{\mathbf{a}_1, \mathbf{a}_2\}$ i $\mathbf{B}=\{\mathbf{b}_1, \mathbf{b}_2\}$ gdzie $\mathbf{a}_1=(1,1)$, $\mathbf{a}_2=(2,1)$, $\mathbf{b}_1=(4,3)$, $\mathbf{b}_2=(1,5)$.
2. Wyznaczyć parametrycznie granicę decyzyjną neuronu o dwóch wejściach.
3. Dokonać symulacji uczenia i testowania neuronu przy użyciu następujących instrukcji z toolboxu *neural networks*: *HARDLIM*, *LEARNP*, *TRAINP*, *RANDS* dla następujących danych
 - a) wykorzystać dane z zadania 1
 - b) $\mathbf{A}=\{\mathbf{a}_1, \mathbf{a}_2, \mathbf{a}_3\}$, $\mathbf{B}=\{\mathbf{b}_1, \mathbf{b}_2\}$ gdzie $\mathbf{a}_1=(-0.5, -0.5)$ $\mathbf{a}_2=(0.5, -1)$ $\mathbf{a}_3=(-1, 1)$, $\mathbf{b}_1=(1, 2)$ $\mathbf{b}_2=(-0.5, 2.5)$
4. Zbadać wpływ kroku uczenia η na szybkość oraz przebieg uczenia neuronu

Zadania - Adaline i Madaline

1. Zbadać czy poniższe zadania klasyfikacji możliwe są do realizacji przy użyciu perceptronu (jeżeli zadanie jest możliwe do realizacji wyznaczyć wektor wag \mathbf{w} , dla których neuron będzie klasyfikował elementy dwóch zbiorów \mathbf{A} i \mathbf{B})
 - a) $\mathbf{A}=\{\mathbf{a}_1, \mathbf{a}_2, \mathbf{a}_3\}$, $\mathbf{B}=\{\mathbf{b}_1, \mathbf{b}_2\}$ gdzie $\mathbf{a}_1=(-0.5, -0.5)$ $\mathbf{a}_2=(0.5, -1)$ $\mathbf{a}_3=(-1, 1)$, $\mathbf{b}_1=(1, 2)$ $\mathbf{b}_2=(-0.5, 2.5)$
 - b) $\mathbf{A}=\{\mathbf{a}_1, \mathbf{a}_2\}$, $\mathbf{B}=\{\mathbf{b}_1, \mathbf{b}_2\}$ gdzie $\mathbf{a}_1=(-0.5, -0.5)$ $\mathbf{a}_2=(0.5, 0.5)$, $\mathbf{b}_1=(0.3, -0.5)$ $\mathbf{b}_2=(0, 1)$
 - c) $\mathbf{A}=\{\mathbf{a}_1, \mathbf{a}_2\}$, $\mathbf{B}=\{\mathbf{b}_1, \mathbf{b}_2, \mathbf{b}_3\}$ gdzie $\mathbf{a}_1=(-0.5, -0.5)$ $\mathbf{a}_2=(-0.5, 0.5)$ $\mathbf{b}_1=(0.3, -0.5)$, $\mathbf{b}_2=(-0.1, 1)$ $\mathbf{b}_3=(-0.9, 0)$
 - d) $\mathbf{A}=\{\mathbf{a}_1, \mathbf{a}_2\}$, $\mathbf{B}=\{\mathbf{b}_1, \mathbf{b}_2\}$ gdzie $\mathbf{a}_1=(-1, -1)$ $\mathbf{a}_2=(5, 2)$, $\mathbf{b}_1=(0, 3)$ $\mathbf{b}_2=(2, -2)$

2. Zbadać czy poniższe zadanie klasyfikacji możliwe są do realizacji przy użyciu sieci jednowarstwowej (jeżeli zadanie jest możliwe do realizacji wyznaczyć wagi \mathbf{w} , dla których sieć będzie klasyfikować elementy czterech zbiorów $\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}$) $\mathbf{A}=\{a_1, a_2, a_3\}$, $\mathbf{B}=\{b_1, b_2\}$, $\mathbf{C}=\{c_1, c_2, c_3\}$, $\mathbf{D}=\{d_1, d_2\}$, gdzie $a_1=(1,12)$ $a_2=(7,18)$ $a_3=(8,16)$, $b_1=(8,6)$ $b_2=(10,8)$, $c_1=(3,5)$ $c_2=(0,2)$ $c_3=(-3,8)$, $d_1=(-5,-15)$ $d_2=(-15,-13)$

3. Wyznaczyć 10 wzorców uczących liniowo separowalnych, podzielić je na 4 klasy oraz
 - a) stworzyć perceptron składający się z 2 neuronów i nauczyć go klasyfikować dane wzorce do poszczególnych klas
 - b) zbadać zdolności uogólniające perceptronu poprzez podawanie sygnałów zbliżonych do sygnałów uczących i obserwację odpowiedzi sieci na te sygnały

4. Dane są dwa zbiory $\mathbf{A}=\{a_1, a_2, a_3\}$, $\mathbf{B}=\{b_1, b_2\}$ gdzie $a_1=(-0.5, -0.5)$ $a_2=(-0.5, 0.5)$ $a_3=(-80, 100)$, $b_1=(0.3, -0.5)$ $b_2=(-0.1, 1)$, przeprowadzić na ich podstawie uczenie perceptronu. Jakie wnioski nasuwają się po analizie procesu uczenia.