



Sztuczne sieci neuronowe

Krzysztof A. Cyran
POLITECHNIKA ŚLĄSKA
Instytut Informatyki, p. 311

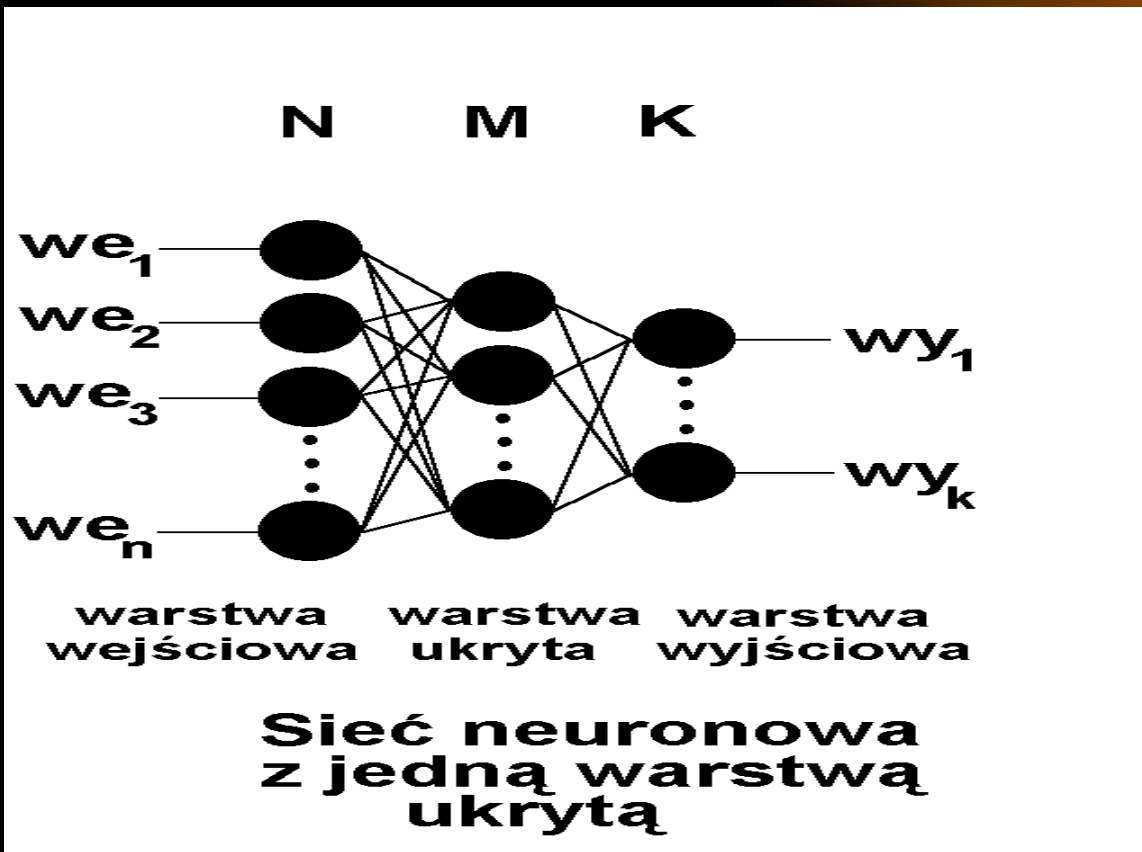
Wykład 2




PLAN:

- Repetitio (brevis)
- Perceptron Rosenblatta
- Sieci neuronowe i problem separowalności liniowej

Sieć neuronowa warstwowa



Działanie sztucznego neuronu



$$n_i = \sum_{j=1}^J w_{ij} x_j - t_i, \quad y_i = f(n_i)$$

t_i – próg aktywacji neuronu

Działanie neuronu (cd.)

Równania :

$$n_i = \sum_{j=1}^J w_{ij} x_j - t_i,$$

$$y_i = f(n_i)$$

dla uproszczenia zapisu przedstawiamy jako :

$$y_i = f\left(\sum_{j=0}^J w_{ij} x_j\right)$$

gdzie : $w_{i0} = -t_i$, $x_0 = 1$

Działanie neuronu (cd.)

Równania :

$$n_i = \sum_{j=1}^J w_{ij} x_j - t_i,$$

$$y_i = f(n_i)$$

lub jako :

$$y_i = f(n_i)$$

$$n_i = \sum_{j=0}^J w_{ij} x_j$$

gdzie : $w_{i0} = -t_i$, $x_0 = 1$

Działanie neuronu (cd.)

Przedstawmy wektory \mathbf{w}_i oraz \mathbf{x} jako :

$$\mathbf{x} = [1, x_1, \dots, x_j, \dots, x_J], \quad \mathbf{w}_i = [w_{i0}, w_{i1}, \dots, w_{ij}, \dots, w_{iJ}]$$

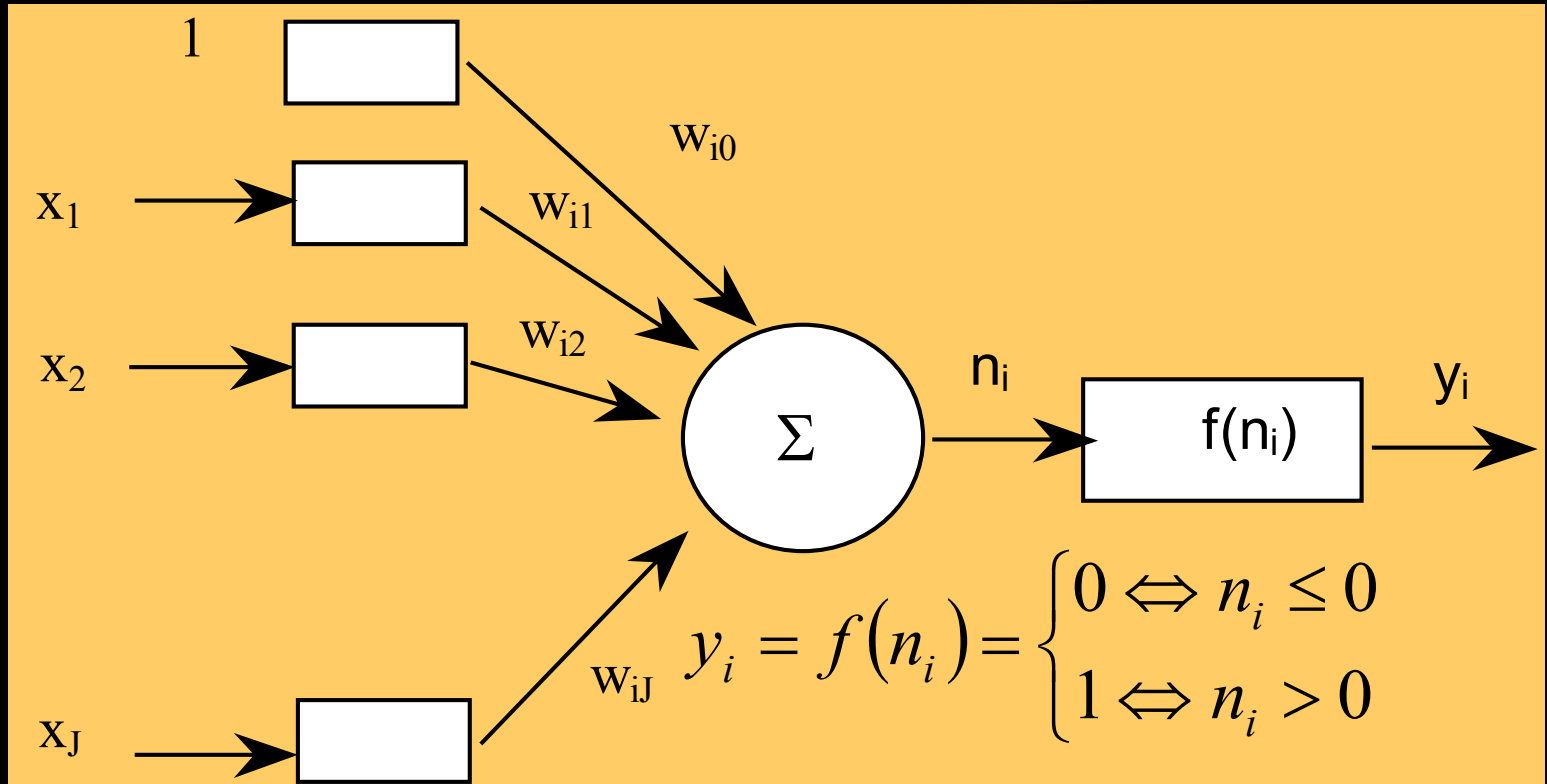
Wówczas :

$$n_i = \mathbf{w}_i * \mathbf{x}$$

lub :

$$n_i = \mathbf{w}_i^T \mathbf{x}$$

Perceptron Rosenblatta



Separowalność liniowa



- Definicja:

Problem jest *separowalny liniowo* jeżeli da się go przedstawić jako podział dychotomiczny za pomocą pewnej hiperpłaszczyzny

Perceptron Rosenblatta a separowalność liniowa

- Perceptron Rosenblatta dokonuje podziału dychotomicznego przestrzeni wejściowej $L \subset \mathbb{R}^J$, $\mathbf{x} \in L$
- W zadaniach rozpoznawania Perceptron Rosenblatta dzieli przestrzeń wejściową L na część należącą do pewnej klasy abstrakcji (obiekt rozpoznany) gdy $y_i = 1$ oraz część do niej nie należącą gdy $y_i = 0$.

Perceptron Rosenblatta a separowalność liniowa (cd.)

- Granica podziału wyznaczona jest poprzez hiperpłaszczyznę określoną w przestrzeni L równaniem:

$$\sum_{j=0}^J w_{ij} x_j = 0, \quad x_0 = 1, w_{i0} = -t_i$$

Wniosek: PR nadaje się do rozwiązywania problemów separowalnych liniowo

Przypadek 2D


- Dla wymiaru przestrzeni wejściowej $J=2$ hiperpłaszczyzną tą jest prosta o równaniu:

$$w_{i0} + w_{i1}x_1 + w_{i2}x_2 = 0$$

- Jeżeli $w_{i2} \neq 0$, wówczas:

$$x_2 = -\frac{w_{i0}}{w_{i2}} - \frac{w_{i1}}{w_{i2}}x_1$$

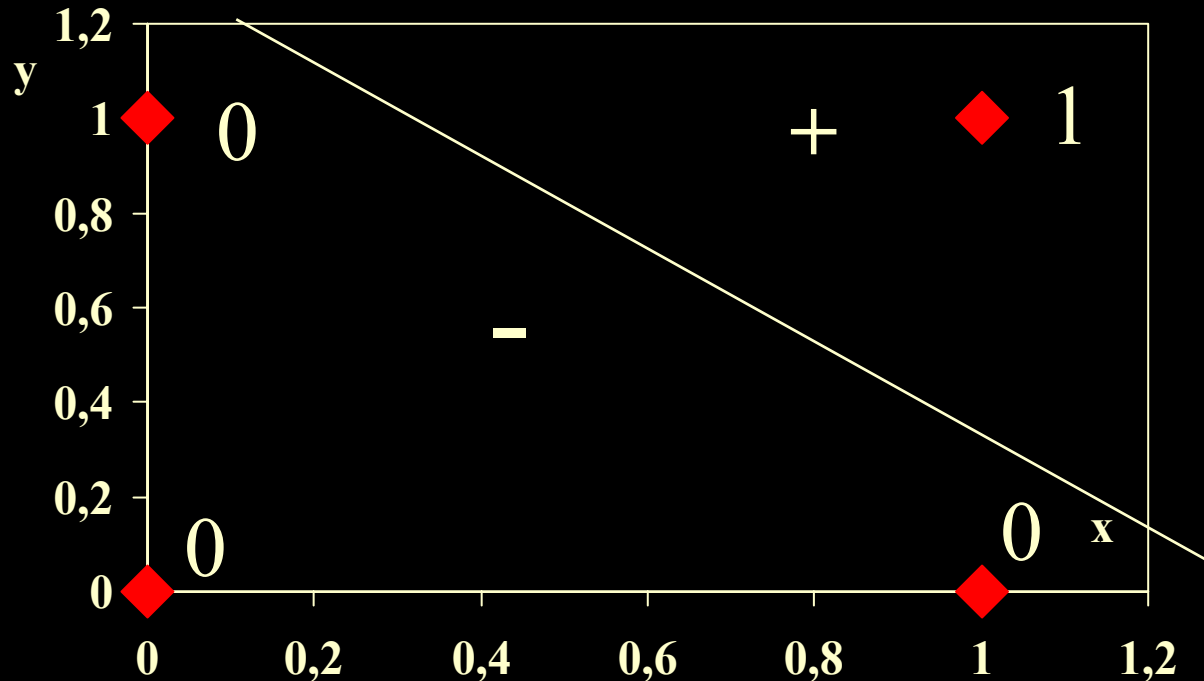
Przypadek 2D (cd.)



$$x_2 = -\frac{w_{i0}}{w_{i2}} - \frac{w_{i1}}{w_{i2}} x_1 \quad \text{tg } \alpha = -\frac{w_{i1}}{w_{i2}}$$

Perceptron Rosenblatta a separowalność liniowa (AND)


$$F = x \text{ AND } y$$



Wniosek: jest to funkcja separowalna liniowo

Perceptron Rosenblatta a separowalność liniowa (XOR)


$$F = x \text{ XOR } y$$



Wniosek: nie jest to funkcja separowalna liniowo

Sieć z warstwą ukrytą


Wprowadzenie dodatkowej warstwy elementów perceptronowych zwiększa zakres stosowalności nieliniowej sieci



Sieć perceptronów z warstwą ukrytą rozwiązuje problem (XOR)


$$F = x \text{ XOR } y$$

$$F = y_{i1} \text{ AND } y_{i2}$$




Typy zadań realizowalnych przez sieć z jedną warstwą ukrytą

- Sieć dwuwarstwowa (z jedną warstwą ukrytą) może dokonywać w przestrzeni wejściowej klasyfikacji dowolnych obszarów jednorodnych, wypukłych (tzn. takich, które powstają przez wydzielenie dowolną liczbą hiperpłaszczyzn)
- Obszary takie nazywamy SIMPLEKSAMI
- Każdej hiperpłaszczyźnie tworzącej simpleks odpowiada jeden neuron ukryty
- (W ogólności) sieć taka nie potrafi dokonywać klasyfikacji obszarów niejednorodnych ani wklęsłych



Typy zadań realizowalnych przez sieć z dwoma warstwami ukrytymi

- Sieć trójwarstwowa (z dwoma warstwami ukrytymi) może dokonywać w przestrzeni wejściowej klasyfikacji dowolnych obszarów, gdyż dowolny obszar da się przedstawić jako sumę lub różnicę pewnych simpleksów klasyfikowanych w drugiej warstwie ukrytej
- Każdemu simpleksowi odpowiada jeden neuron w drugiej warstwie ukrytej
- Neuron warstwy wyjściowej dokonuje wycięcia jednego wierzchołka hipersześcianu o wymiarze równym ilości simpleksów, a to jest zawsze problemem separowalnym liniowo



Wniosek ogólny

- Sieć nieliniowa trójwarstwowa (z dwoma warstwami ukrytymi) może realizować dowolnie złożoną klasyfikację przestrzeni wejściowej w zbiór klas abstrakcji
- Aby to mogła zrobić musi istnieć metoda odpowiedniego ustawiania hiperpłaszczyzn, poprzez modyfikacje współczynników wagowych – jest to uczenie sieci

Metoda wstecznej propagacji błędów (back propagation)

- Stosuje się ją do perceptronów wielowarstwowych
- Funkcja aktywacji: sigmoidalna

$$O_i = \frac{1}{1 + e^{-\beta n_i}}$$

- lub tangens hiperboliczny

$$O_i = \operatorname{tgh}\left(\frac{\alpha n_i}{2}\right) = \frac{1 - e^{-\alpha n_i}}{1 + e^{-\alpha n_i}}$$

Własności funkcji sigmoidalnej

- Ciągła, niemalejąca, nieliniowa,
- Różniczkowalna:

$$\frac{\partial O_i^{(l)}}{\partial n_i^{(l)}} = \beta O_i^{(l)} (1 - O_i^{(l)})$$

- Dowolnie blisko aproksymuje funkcję progową $\mathbf{1}(n_i)$:

$$\lim_{\beta \rightarrow \infty} \left(\frac{1}{1 + e^{-\beta n_i}} \right) = \mathbf{1}(n_i)$$

Własności funkcji tangensa hiperbolicznego

- Ciągła
- Niemalejąca
- Nieliniowa
- Różniczkowalna:
- Dowolnie blisko aproksymuje funkcję

$\text{sgn}(n_i)$:

$$\lim_{\alpha \rightarrow \infty} \text{tgh}\left(\frac{\alpha n_i}{2}\right) = \text{sgn}(n_i)$$