


Inżynieria Mechatroniczna

Podstawy Sztucznej Inteligencji i Ucznienia Głębokiego:

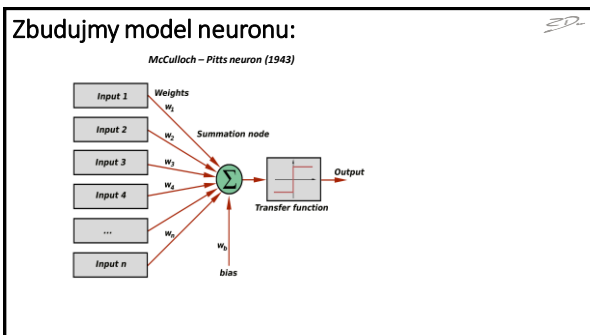
4: Sieci Neuronowe – na trzy sposoby

Ziemowit Dworakowski
AGH w Krakowie

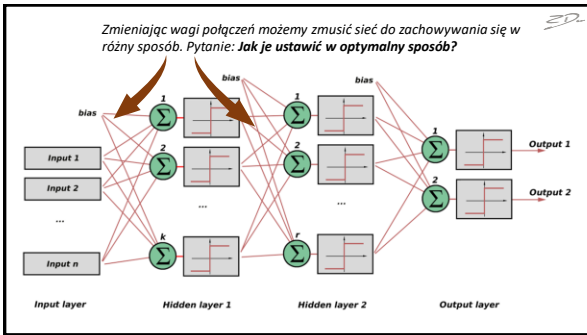
1



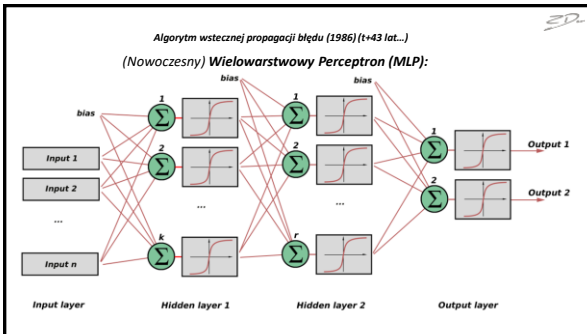
2



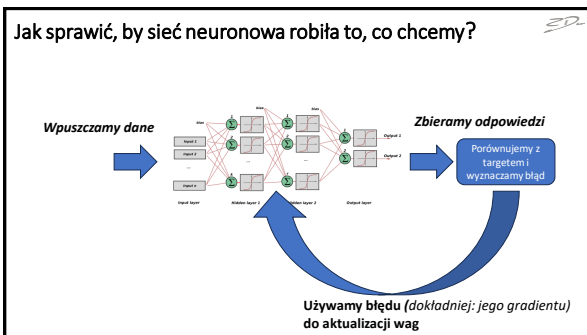
3



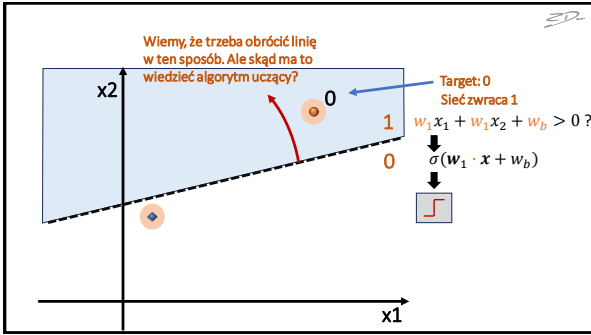
4




5



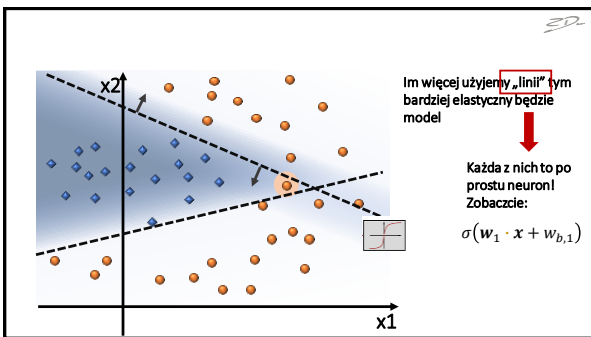
6



7





8



9


Algorytm propagacji wstecznej z zastosowaniem największego spadku gradientu

(podstawowy, bez dodatków)



10

Funkcja mapująca dane w inną przestrzeń



Będziemy potrzebować wielu stopni swobody, nieliniowości...
I możliwości modyfikowania zgodnie z zapotrzebowaniem...

11


$$y = f(\mathbf{w}, \mathbf{x})$$

Pewnie warto zbudować taką funkcję z elementów składowych:

$$y = f_1(\mathbf{x}) + f_2(\mathbf{x}) + \dots + f_n(\mathbf{x})$$

Dobrze, by dało się zarządzać nimi za pomocą parametrów:

$$y = \sigma(\mathbf{w}_1, \mathbf{x}) + \sigma(\mathbf{w}_2, \mathbf{x}) + \dots + \sigma(\mathbf{w}_n, \mathbf{x})$$



$$\sigma(\mathbf{w}, \mathbf{x}) = \frac{1}{1 + e^{-(\mathbf{w}\mathbf{x} + w_0)}}$$

12

SD

$$y = f(\mathbf{w}, \mathbf{x})$$

Pewnie warto zbudować taką funkcję z elementów składowych:

$$y = f_1(\mathbf{x}) + f_2(\mathbf{x}) + \dots + f_n(\mathbf{x})$$

Dobrze, by dało się zarządzać nimi za pomocą parametrów:

$$\begin{aligned} x'_1 &= \sigma(w_{1,1}, \mathbf{x}) + \sigma(w_{2,1}, \mathbf{x}) + \dots + \sigma(w_{n,1}, \mathbf{x}) \\ x'_2 &= \sigma(w_{1,2}, \mathbf{x}) + \sigma(w_{2,2}, \mathbf{x}) + \dots + \sigma(w_{n,2}, \mathbf{x}) \\ &\dots \end{aligned}$$

◀ W tym wektorze są nowe współrzędne!

I teraz „finalna decyzja” – kolejna nieliniowa transformacja:

$$y = \sigma(w_{n+1,1}, \mathbf{x}')$$

Jeśli chcemy, możemy to zagnieździć ponownie (y staje się x'' , itd...)

13

SD

Sieci neuronowe na trzy sposoby:

Sieć neuronowa to:

- Złożona funkcja w nieliniowy sposób mapująca dane z przestrzeni wejściowej w przestrzeń wyjściową, upraszczając etapowo ich strukturę
- Zestaw hiperpłaszczyzn w przestrzeni cech tworzący złożone i dopasowywalne do danych powierzchnie decyzyjne
- Inspirowana biologicznie sieć węzłów które potrafią przesyłać między sobą informacje, mająca emergentną umiejętność interpretacji danych

14

Rozważmy prosty wielowarstwowy perceptron (MLP):

Mamy wartość docelową t przypisaną do każdego wektora x . Stąd, możemy wyznaczyć błąd d :

$$d = \frac{1}{2}(y - t)^2$$

Teraz możemy obliczyć gradient d ze względu na wagi w :

$$\nabla d = \left[\frac{\partial d}{\partial w_1}, \frac{\partial d}{\partial w_2}, \frac{\partial d}{\partial w_3}, \dots, \frac{\partial d}{\partial w_9} \right]$$

Gradient mówi nam, w którym kierunku zmieniać wagi

Możemy je połączyć by dostać postać ekwiwalent funkcyjny sieci $f(\mathbf{w}, \mathbf{x})$

$$y = \sigma(w_8 \cdot x'_1 + w_9 \cdot x'_2 + w_7)$$

$$x'_1 = \sigma(w_3 \cdot x_1 + w_5 \cdot x_2 + w_1)$$

$$x'_2 = \sigma(w_2 \cdot x_1 + w_6 \cdot x_2 + w_2)$$

15

Rozważmy prosty wielowarstwowy perceptron (MLP):

Mamy wartość docelową t przypisaną do każdego wektora x . Stąd, możemy wyznaczyć błąd d :

$$d = \frac{1}{2}(y - t)^2$$

Teraz możemy obliczyć gradient d ze względu na wagi:

$$\nabla d = \left[\frac{\partial d}{\partial w_1}, \frac{\partial d}{\partial w_2}, \frac{\partial d}{\partial w_3}, \dots, \frac{\partial d}{\partial w_9} \right]$$

Gradient mówi nam, w którym kierunku zmieniać wagi

$y = \sigma(w_8 \cdot x'_1 + w_9 \cdot x'_2 + w_7)$

$$\frac{\partial d}{\partial w_9} = \frac{\partial d}{\partial y} \frac{\partial y}{\partial p} = \frac{\partial d}{\partial y} \frac{\partial y}{\partial p} \frac{\partial p}{\partial w_9} = (y - t) \dots$$

$\frac{\partial d}{\partial y} = y - t$

16

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

$$\frac{\partial \sigma}{\partial p} = \frac{\partial}{\partial p} (1 + e^{-p})^{-1} = \cancel{-(1 + e^{-p})^{-2}} \cdot e^{-p} \cdot \cancel{-1}$$

$$\frac{\partial \sigma}{\partial p} = \frac{1}{1 + e^{-p}} \cdot \frac{1}{1 + e^{-p}} \cdot e^{-p}$$

$$\frac{\partial \sigma}{\partial p} = \frac{e^{-p}}{1 + e^{-p}} \cdot \frac{1}{1 + e^{-p}}$$

$$\frac{\partial \sigma}{\partial p} = \frac{1 + e^{-p} - 1}{1 + e^{-p}} \cdot \frac{1}{1 + e^{-p}}$$

$$\frac{\partial \sigma}{\partial p} = \left(1 - \frac{1}{1 + e^{-p}} \right) \cdot \frac{1}{1 + e^{-p}} = (1 - y) \cdot y$$

17

Rozważmy prosty wielowarstwowy perceptron (MLP):

Mamy wartość docelową t przypisaną do każdego wektora x . Stąd, możemy wyznaczyć błąd d :

$$d = \frac{1}{2}(y - t)^2$$

Teraz możemy obliczyć gradient d ze względu na wagi:

$$\nabla d = \left[\frac{\partial d}{\partial w_1}, \frac{\partial d}{\partial w_2}, \frac{\partial d}{\partial w_3}, \dots, \frac{\partial d}{\partial w_9} \right]$$


Gradient mówi nam, w którym kierunku zmieniać wagi

$y = \sigma(w_8 \cdot x'_1 + w_9 \cdot x'_2 + w_7)$


$$\frac{\partial d}{\partial w_9} = \frac{\partial d}{\partial y} \frac{\partial y}{\partial p} = \frac{\partial d}{\partial y} \frac{\partial y}{\partial p} \frac{\partial p}{\partial w_9} = (y - t)y(1 - y) \dots$$

$y(1 - y) \leftarrow y = \sigma(p) = \frac{1}{1 + e^{-p}}$

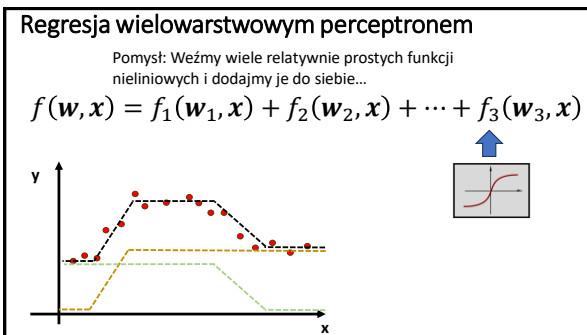
18



22



23



24

Sieci radialne (RBFN) SD

Uczone z zastosowaniem gradientowego algorytmu propagacji wstecznej błędów
Dobre we wnioskowaniu lokalnym

25

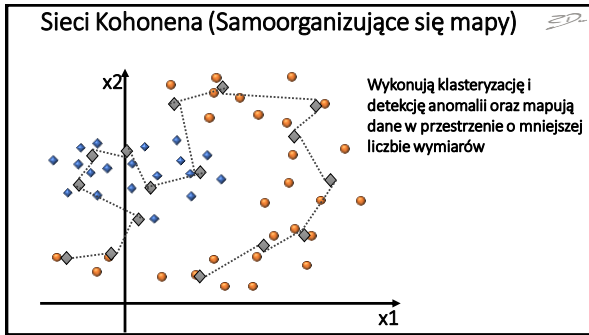
Sieci rekurencyjne SD

Dodanie połączeń rekurencyjnych pozwala sieci na zbudowanie krótkotrwałej pamięci – co przydaje się w predykcji szeregów czasowych oraz w identyfikacji

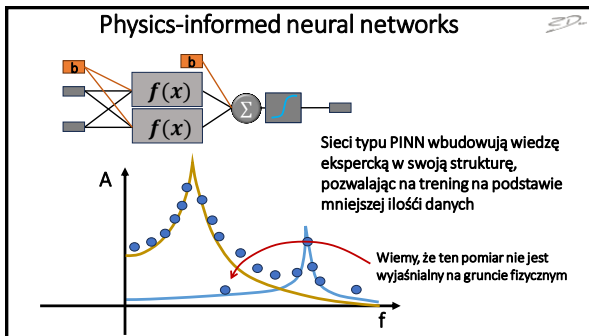
26

Sieci Kohonena (Samoorganizujące się mapy) SD

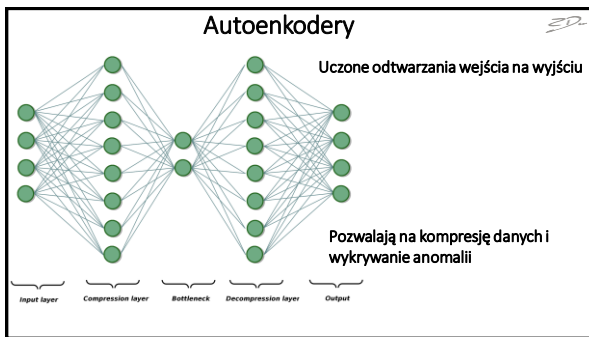
27



28



29



30

Materiał do powtórki:

SD

1. Wyjaśnij działanie sieci MLP na jeden z trzech sposobów
2. Narysuj schemat neuronu McCullocha-Pittsa i opisz jego elementy
3. Wyjaśnij dlaczego neuron McCullocha-Pittsa jest reprezentowany przez hiperpłaszczyznę w przestrzeni cech
4. Narysuj schemat sieci MLP i opisz jej elementy
5. Wyjaśnij zasadę działania algorytmu propagacji wstecznej błędu
(nie ma konieczności przedstawiania przykładowych obliczeń ani wzorów)
6. Napisz równanie sigmoidalnej funkcji aktywacji
7. Wyjaśnij podstawowy sposób ochrony przed przeuczeniem (jak w tym celu wykorzystać zbiór treningowy i walidacyjny?)
8. Wyjaśnij zasadę działania i cel stosowania sieci Kohonena, Radialnych, PINN, Autoenkoderów i Rekurencyjnych
