WYKŁAD 4

Sieci neuronowe:
Algorytmy uczenia &
Dalsze zastosowania

PLAN WYKŁADU

- Metody uczenia sieci:
  - Uczenie perceptronu
  - Propagacja wsteczna
- Zastosowania
  - Sterowanie (powtórzenie)
  - Kompresja obrazu
  - Rozpoznawanie wzorców

REGUŁA UCZENIA PERCEPTRONU (1)

Przykład: rozpoznawanie znaków

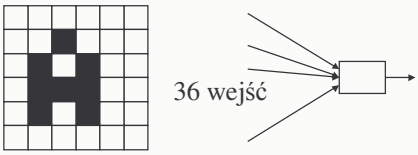

Wyjście: 1, jeśli na wejściu pojawia się litera "A", zaś 0 w p.p.

Siatka 6×6

Zadanie: dobrać wagi wejść i wartość progową tak, by uzyskać zaplanowany efekt

REGUŁA UCZENIA PERCEPTRONU (2)

- **Wejście:**
  - Ciąg przykładów uczących ze znanymi odpowiedziami
- **Proces uczenia:**
  - Inicjujemy wagi losowo
  - Dla każdego przykładu, jeśli odpowiedź jest nieprawidłowa, to

    $w_1 + = \alpha x_1$

    $w_2 + = \alpha x_2$

    $\theta - = \alpha$

    gdzie α jest równe odpowiedzi prawidłowej

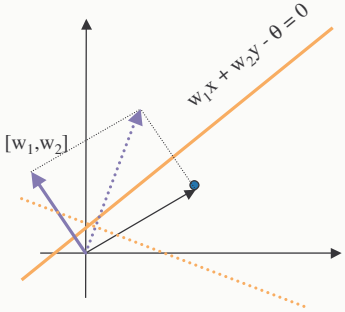

REGUŁA UCZENIA PERCEPTRONU (3)

- Często α mnoży się dodatkowo przez niewielki współczynnik uczenia
- Po wyczerpaniu przykładów, zaczynamy proces uczenia od początku, dopóki następują jakiekolwiek zmiany wag połączeń

REGUŁA UCZENIA PERCEPTRONU (4)

- Opisany schemat jest w miarę przejrzysty tylko dla pojedyńczych perceptronów, lub niewielkich sieci
- Ciężko jest stosować reguły tego typu w dla skomplikowanych modeli
  - Tymczasem np. do rozpoznawania wszystkich liter potrzeba by sieci złożonej z 26 takich perceptronów

PROPAGACJA WSTECZNA (1)

- Chcemy “wytrenować” wagi połączeń między kolejnymi warstwami neuronów
- Inicjujemy wagi losowo (na małe wartości)
- Dla danego wektora uczącego obliczamy odpowiedź sieci (warstwa po warstwie)
- Każdy neuron wyjściowy oblicza swój błąd, odnoszący się do różnicy pomiędzy obliczoną odpowiedzią **y** oraz poprawną odpowiedzią **t**

PROPAGACJA WSTECZNA (2)

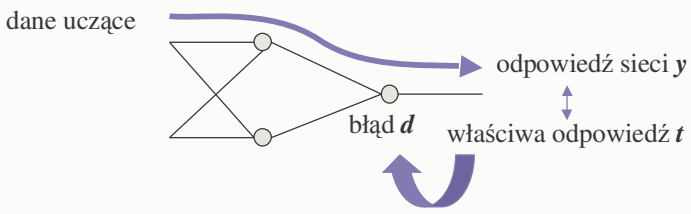

Błąd sieci definiowany jest zazwyczaj jako

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

PROPAGACJA WSTECZNA (3)

- Oznaczmy przez:
  - ***g: R*** $\rightarrow$ ***R*** – funkcję aktywacji w neuronie
  - $w_1, \ldots, w_K$ – wagi połączeń wchodzących
  - $z_1, \ldots, z_K$ – sygnały napływające do neuronu z poprzedniej warstwy
- Błąd neuronu traktujemy jako funkcję wag połączeń do niego prowadzących:

$$d(w_1,\ldots,w_K)=\frac{1}{2}\left(g\left(w_1z_1+\ldots+w_Kz_K\right)-t\right)^2$$

PRZYKŁAD (1)

- Rozpatrzmy model, w którym:
  - Funkcja aktywacji przyjmuje postać

$$g(s)=\frac{1}{1+e^{-3(s+2)}}$$

  - Wektor wag połączeń = [1;-3;2]
- Załóżmy, że dla danego przykładu:
  - Odpowiedź powinna wynosić ***t*** = 0.5
  - Z poprzedniej warstwy dochodzą sygnały [0;1;0.3]

PRZYKŁAD (2)

- Liczymy wejściową sumę ważoną:

$$s = w_1 x_1 + w_2 x_2 + w_3 x_3 = 1 \cdot 0 + (-3) \cdot 1 + 2 \cdot 0.3 = -2.4$$

- Liczymy odpowiedź neuronu:

$$y = g(s) = \frac{1}{1 + e^{-3(-2.4+2)}} = \frac{1}{1 + e^{1.2}} \approx 0.23$$

- Błąd wynosi:

$$d = \frac{1}{2}(0.23 - 0.5)^2 \approx 0.036$$

IDEA ROZKŁADU BŁĘDU

- Musimy „rozłożyć” otrzymany błąd na połączenia wprowadzające sygnały do danego neuronu
- Składową błędu dla każdego ***j***-tego połączenia określamy jako pochodną cząstkową błędu względem ***j***-tej wagi
- Składowych tych będziemy mogli użyć do zmodyfikowania ustawień poszczególnych wag połączeń

OBLICZANIE POCHODNEJ

$$\frac{\partial d(w_1,\ldots,w_K)}{\partial w_j} = (y-t)\cdot g'(s)\cdot z_j$$

$$= \frac{\partial \frac{1}{2}\left(g(w_1 z_1 + \ldots + w_K z_K) - t\right)^2}{\partial w_j}$$

$$= \frac{\partial \frac{1}{2}(y-t)^2}{\partial y} \cdot \frac{\partial g(s)}{\partial s} \cdot \frac{\partial (w_1 z_1 + \ldots + w_K z_K)}{\partial w_j}$$

PROPAGACJA WSTECZNA (4)

- Idea:
  - Wektor wag połączeń powinniśmy przesunąć w kierunku przeciwnym do wektora rozkładu błędu
- Realizacja:

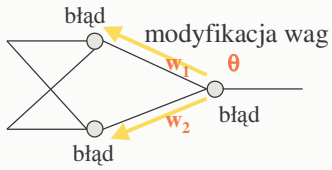

STEROWANIE (1)

Sieć neuronowa jest zwykle trenowana na modelu (symulatorze) układu, albo przez „obserwację” właściwego sposobu sterowania.

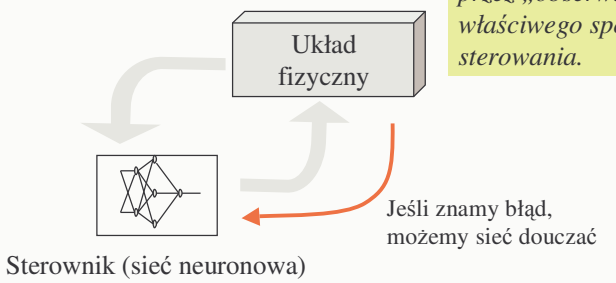

STEROWANIE (2)

Dobieranie parametrów sterownika rozmytego za pomocą neuronowego symulatora jest szybsze, tańsze i bezpieczniejsze, niż podczas pracy na rzeczywistych urządzeniach

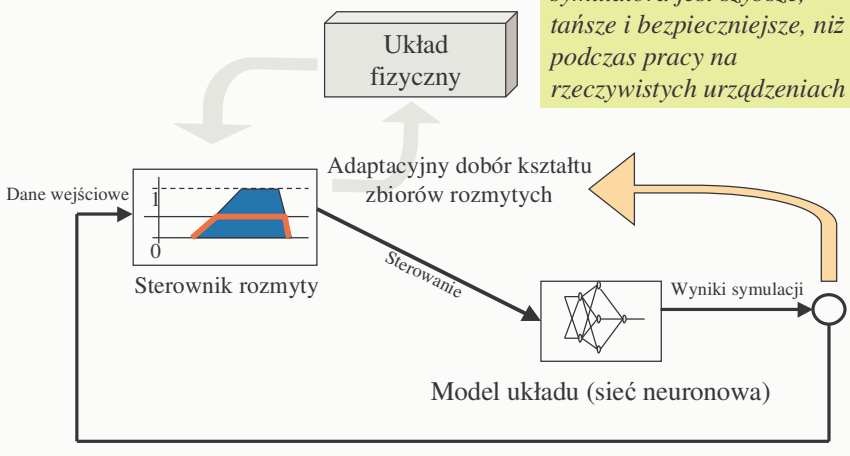

KOMPRESJA OBRAZU

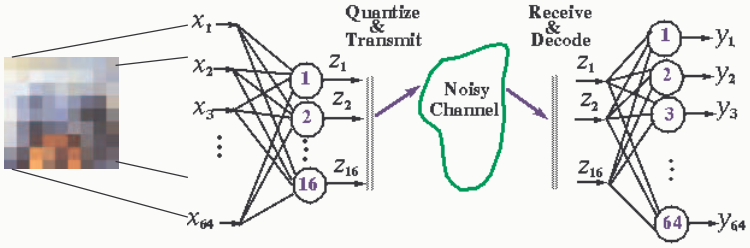

- Obraz dzielony jest na kwadraty (np. 8x8)
- Sieć neuronowa o 16 wyjściach zamienia dane wejściowe na 16 liczb
- Liczby są kwantowane i przekazywane drugiej sieci, odtwarzającej dane oryginalne
- Kryterium nauki: minimalizacja błędu rekonstrukcji

ROZPOZNAWANIE WZORCÓW

- Wzorce: obrazy, nagrania, dane personalne, sposoby prowadzenia pojazdu, etc.
- Reprezentacja:
  - Wektor cech (wejść do sieci neuronowej)
- Klasyfikacja wzorców:
  - Klasyfikacja do jednej z istniejących klas
  - Formowanie klas wzorców
- Asocjacyjne odtwarzanie wzorców
  - Odtwarzanie wzorców podobnych
  - Uzupełnianie wzorców
  - Odzyskiwanie (czyszczenie) wzorców

RÓŻNE STRUKTURY SIECI

- Wielowarstwowe skierowane
- Wielowarstwowe rekurencyjne
- Samoorganizujące się
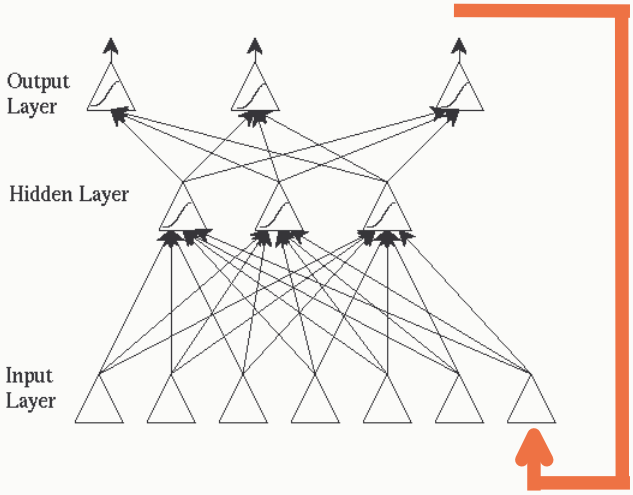
SIECI REKURENCYJNE