




UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Data Mining Wykład 7

Sztuczne sieci neuronowe (SNN)

Przeływ informacji w systemie nerwowym



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU


Budowa i działanie mózgu

- Mózg składa się ze 100 miliardów (10^{11}) neuronów
- Każdy neuron jest w stanie stworzyć nawet do 10 tysięcy połączeń z innymi komórkami nerwowymi
- Neuron ma ok. 0,1 mm średnicy, a jego długość może osiągnąć kilka metrów
- Łączna długość aksonów w mózgu to 160 000 km
- Na każdy neuron przypada od 1000 do 10000 synaps
- Komórki nerwowe wysyłają i przyjmują impulsy
 - Częstotliwości 1-100Hz
 - Czasie trwania 1-2 ms
 - Szybkości propagacji 1-100 m/s
- Informacje docierają do mózgu z prędkością 100 megabajtów na sekundę
- Szybkość pracy mózgu to 10^{18} operacji/s




UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Budowa neuronu biologicznego



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Zasada działania neuronu biologicznego



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Sztuczna sieć neuronowa (SSN)

- łączy w sobie małe procesory (jednostki przetwarzania), z których każdy naśladuje funkcje pojedynczego neuronu biologicznego
- każdy procesor, podobnie jak neuron, ma poziom progowy
- aby nastąpiła transmisja sygnału poziom progowy, musi zostać przekroczony
- binarny charakter procesora można porównać do włącznika światła
- dzięki połączeniu wielu takich sztucznych neuronów, z których każdy posiada jedno wyjście, SSN może wykonywać złożone funkcje
- tworzy sztuczny „mózg” do przetwarzania informacji

UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Stosowane w SSN funkcje aktywacji (1)

Name	Input/Output Relation	Icon
Hard Limit	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$	
Symmetrical Hard Limit	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$	
Linear	$a = n$	
Saturating Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$	

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

Stosowane w SSN funkcje aktywacji (2)

Symmetric Saturating Linear	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = 1 \quad n > 1$	
Log-Sigmoid	$a = \frac{1}{1 + e^{-n}}$	
Hyperbolic Tangent Sigmoid	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
Positive Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$	
Competitive	$a = 1$ neuron with max n $a = 0$ all other neurons	

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

Uczenie SSN

Uczenie polega na automatycznym doborze wag w SSN, na podstawie zbioru przykładów nazwanym zbiorem uczącym. Zaczyna się z losowymi małymi wagami i iteracyjnie zmienia się wagi, dopóki wszystkie przykłady uczące nie zostaną poprawnie zaklasyfikowane (lub z niewielkim błędem).

Wyróżnia się dwa typy uczenia, co zależy od wykorzystanej sieci przykładów (zbioru uczącego):

- **nadzorowane** (z nauczycielem), gdy w zbiorze danych do każdej próbki podana jest poprawna klasa
- **nienadzorowane** (bez nauczyciela), zbiór danych nie ma wektora odpowiedzi.

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

Algorytm uczenia perceptronu

1. Niech $\mathbf{w}(0) = (0, \dots, 0)$ lub wartości losowe z przedziału $[-1,1], k = 0$
2. Dopóki zbiór punktów uczących pozostaje błędnie klasyfikowany tj. zbiór $A = \{x_i: y_i \neq f(\langle \mathbf{w}, x_i \rangle)\}$ pozostaje niepusty, powtarzaj:
 1. Wylosuj ze zbioru A dowolny punkt
 2. Aktualizuj wagi według następującej reguły:
 $\mathbf{w}(k+1) = \mathbf{w}(k) + \eta e x_i$
 3. $k = k + 1$

Gdzie η współczynnik uczenia $\eta \in (0,1]$, a e jest wartością błędu popełnianego na prezentowanej próbce.

UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Algorytm uczenia perceptronu - przykład

- Dany jest zbiór uczący:

$$\begin{aligned} \{x_1 = (1,2), y_1=1\} \\ \{x_2 = (-1,2), y_2=0\} \\ \{x_3 = (0,-1), y_3=0\} \end{aligned}$$

Architektura sieci:



Przestrzeń wejść:



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Konsekwencje braku wejścia x_0


Usunięcie dodatkowego wejścia powoduje, że płaszczyzna decyzyjna musi przejść przez początek układu współrzędnych, bo:

$$w_1 x_1 + w_2 x_2 = 0$$

to równanie prostej przechodzącej przez punkt $(0, 0)$.

Trzeba być pewnym, że taka sieć rozwiąże problem separacji punktu x_1 od punktów x_2 i x_3 .


Jak widać rozwiązań jest nieskończenie wiele.



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Cel uczenia

Rysunek pokazuje wektory wag, które odpowiadają granicom decyzyjnym. Wektor jest prostopadły do granicy decyzyjnej. Regula ucząca ma znaleźć wektor wag, który wskazuje w jednym ze wskazanych kierunków. Długość wektora wag nie ma znaczenia, ważny jest tylko kierunek.




UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Krok 1: Ustalenie wartości początkowych wag

Zakłada się losowe ustalenie wartości wag początkowych i tak:

$$w(0) = (1, -0.8)$$

Na wykresie zaprezentowano początkowy wektor wag i granice decyzyjne dla takich wag.



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Krok 2.1: Prezentacja punktu x_1

Pierwszym prezentowanym punktem jest $x_1 = (1, 2)$

$$f(\langle w, x_1 \rangle) = f(1 \cdot 1 + (-0.8) \cdot 2) = f(-0.6) = 0$$

Wiemy, że $y_1 = 1$, zatem sieć popełniła błąd i wskazała złą klasę dla punktu x_1 .

Jak widać na rysunku z poprzedniego slajdu granica decyzyjna jest nieprawidłowo położona w stosunku do punktu uczącego. Powinno się zatem przesunąć wektor wag nieznacznie w kierunku punktu x_1 . Można tego dokonać dodając do wektora wag wektor x_1 .

UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU


Krok 2.2: Wnioski co do poprawki wag dla x_1

Dla uproszczenia obliczeń przyjmijmy że funkcja błędu ma postać:
 $e = y_i - f(\langle \mathbf{w}, \mathbf{x}_i \rangle)$
 a współczynnik uczenia $\eta = 1$.

Jeżeli $y_1 = 1$ i $f(\langle \mathbf{w}, \mathbf{x}_1 \rangle) = 0$ to :

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \mathbf{x}_i$$

Stąd, wagi po korekcje: $\mathbf{w}(1) = (1 + 1, -0.8 + 2) = (2, 1.2)$



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Krok 2.1: Prezentacja punktu x_2

Drugim prezentowanym punktem jest $x_2 = (-1, 2)$

$$f(\langle \mathbf{w}, \mathbf{x}_2 \rangle) = f(2 \cdot (-1) + 1.2 \cdot 2) = f(0.4) = 1$$

Wiemy, że $y_2 = 0$, zatem sieć popełniła błąd i wskazała złą klasę dla punktu x_2 .

Jak widać na rysunku z poprzedniego slajdu granica decyzyjna jest nieprawidłowo położona w stosunku do punktu uczącego. Powinno się zatem odsunąć wektor wag nieznacznie od punktu x_2 .


UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Krok 2.2: Wnioski co do poprawki wag dla x_1

Jeżeli $y_1 = 0$ i $f(\langle \mathbf{w}, \mathbf{x}_2 \rangle) = 1$ to $e = y_i - f(\langle \mathbf{w}, \mathbf{x}_i \rangle) = -1$, stąd:

$$\mathbf{w}(k+1) = \mathbf{w}(k) - \mathbf{x}_i$$


Wagi po korekcje: $\mathbf{w}(2) = (2 - (-1), 1.2 - 2) = (3, -0.8)$



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Perceptron wielowarstwowy

- Ograniczenia takie eliminuje się poprzez wprowadzanie warstw ukrytych uzyskując w ten sposób strukturę nazwaną **perceptronem wielowarstwowym**.




Perceptron dwuwarstwowy

UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Perceptron wielowarstwowy


- Każdy element warstwy ukrytej dzieli przestrzeń sygnałów wejściowych na dwie półprzestrzenie rozdzielone hiperpłaszczyzną (tak jak perceptron jednowarstwowy).
- Element wyjściowy, dzieli przestrzeń sygnałów wejściowych również na dwie podprzestrzenie.
- W efekcie otrzymujemy podprzestrzeń, która jest zbiorem wielościenne wypukłym*.
- Jeśli więc jeden z dwóch zbiorów sygnałów wejściowych o wartościach odpowiednio równych 0 i 1 zawiera się w tym zbiorze wypukłym to funkcja może być zrealizowana przez perceptron dwuwarstwowy.



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU


Perceptron wielowarstwowy

- Za pomocą perceptronu dwuwarstwowego można zrealizować już więcej funkcji w tym między innymi funkcję XOR.
- Jak widać na poniższym rysunku jeden z dwóch zbiorów sygnałów wejściowych o wartości funkcji aktywacji równej 0 zawiera się w wydzielonym zbiorze wypukłym. Tak więc warunek jest spełniony.



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Algorytm uczenia elementu perceptronowego




UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

Rodzaje sieci

- Sieci jednokierunkowe – sygnał w sieci rozprzestrzenia się w jednym kierunku
 - Sieci jednowarstwowe
 - Sieci wielowarstwowe (perceptron wielowarstwowy)
- Sieci rekurencyjne


UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

Sieć jednokierunkowa jednowarstwowa




UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

Sieć jednokierunkowa wielowarstwowa



UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU


Sieć rekurencyjna jednowarstwowa



- Sieć z jedną warstwą neuronów (wyjściową)
- Sygnały wyjściowe neuronów tworzą jednocześnie wektor wyjściowy dla następnego cyklu
- Z reguły nie występuje sprzężenie zwrotne od własnego sygnału wyjściowego

UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Sieć rekurencyjna dwuwarstwowa



- Neurony 1...M stanowią warstwę wyjściową sieci
- Neurony 1...K warstwę ukrytą
- Wektor wejściowy:
 - sygnały wejściowe x
 - sygnały wyjściowe warstwy ukrytej i wyjściowej

UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Przykłady zastosowań sieci neuronowych

Funkcje pełnione przez sieć można ująć w kilka podstawowych grup:

- aproksymacji i interpolacji
- rozpoznawania i klasyfikacji wzorców
- kompresji
- predykcji i sterowania
- asocjacji

Sieć neuronowa pełni w każdym z tych zastosowań rolę **uniwersalnego aproksymatora** funkcji wielu zmiennych, realizując **funkcję nieliniową** o postaci $y = f(\mathbf{x})$, gdzie \mathbf{x} jest wektorem wejściowym, a y realizowaną funkcją wektorową wielu zmiennych.

Duża liczba zadań modelowania, identyfikacji, przetwarzania sygnałów da się sprowadzić do zagadnienia aproksymacyjnego.

UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU

Zalety i wady sztucznych sieci neuronowych

Zalety:

- Przetwarzanie równoległe
- Przy dużej liczbie elementów sieć jest odporna na uszkodzenia niewielkiej liczby elementów
- Zdolność uogólniania
- Brak założeń dotyczących rozkładów analizowanych zmiennych

Wady:

- Sieć jako „Czarna skrzynka”

UNIWERSYTET PRZYRODNICZY WE WROCŁAWIU
