



Perceptron

Reguły uczenia

Perceptron Rosenblatta (1958)

Klasyfikator neuronowy Mark I do rozpoznawania znaków alfanumerycznych, wzorowany na biologicznej percepcji (układ wzrokowy)



Trzy warstwy:

- **S-units:** wejście, siatkówka oka, 400 fotokomórek (20x20)
- **A-units:** asocjacyjne, zbierające dane z większych obszarów (ekstrakcja cech), 512 jednostek
- **R-units:** liniowy klasyfikator uczący, 8 wyjść

Rys: wikipedia.org

Martin Riedmiller, Machine Learning (lectures)

- $S_i = \{-1, +1\}$ sygnał docierający do elementów sensorycznych
- połączenia $c_{ij} = \{-1, 0, +1\}$ elementów S_j i A_i , przypadkowo rozrzucone w pewnym obszarze, nie ulegają zmianom, realizują wstępne przetwarzanie

$$A_i = \begin{cases} +1, & \text{dla } \sum_j c_{ij} S_j \geq \Theta_i \\ -1, & \text{dla } \sum_j c_{ij} S_j < \Theta_i \end{cases}$$


- sygnał wyjściowy

$$R_i = \begin{cases} +1 & \sum_j w_{ij} A_j > N\kappa \\ -1 & \sum_j w_{ij} A_j < -N\kappa \\ 0 & \text{w pozostałych przypadkach} \end{cases}$$

- wagi w_{ij} realizowane przez potencjometry
- proces uczenia - mechaniczna regulacja wartości potencjometrów za pomocą silników elektrycznych

Perceptron współczesny

- Obecnie pod pojęciem „perceptronu” rozumie się pojedynczy neuron z wieloma wejściami (bez jednostek S).
- **Perceptron prosty**




$$y = f \left(\sum_i w_i x_i + w_0 \right)$$

Rys: Martin Riedmiller, Machine Learning (lectures)

Perceptron współczesny


Single layer perceptron

jednowarstwowa sieć jednokierunkowa w pełni połączona



Multilayer perceptron (MLP)

wielowarstwowa sieć jednokierunkowa w pełni połączona




Rys: M. Bennamoun, *Neural Computation (lecture)*
computersciencewiki.org

Neuron binarny



Perceptron prosty (binarny)

$$y = \begin{cases} 1, & \text{gdy } \sum_i w_i x_i + w_0 \geq 0 \\ 0, & \text{gdy } \sum_i w_i x_i + w_0 < 0 \end{cases}$$



Interpretacja geometryczna

- $x_1, \dots, x_n$ to współrzędne punktu w n -wymiarowej przestrzeni ($\mathbf{x} \in \mathbb{R}^n$)
- równanie $\sum x_i w_i + w_0 = 0$ definiuje płaszczyznę (hiperpłaszczyznę) rozdzielającą przestrzeń wejściową na dwie części R_1 i R_2
- wagi $\mathbf{w}$ tworzą **wektor normalny** prostopadły do hiperpłaszczyzny decyzyjnej, w_0 to przesunięcie
- perceptron prosty dzieli zbiór wektorów $\mathbf{x}_i$ na dwa podzbiory: te leżące poniżej płaszczyzny decyzyjnej ($y(\mathbf{x}_i) = 0$) oraz leżące powyżej płaszczyzny ($y(\mathbf{x}_i) = 1$)



Rys: Duda and Hart, Pattern Classification

Zadanie klasyfikacji binarnej

- **Klasyfikacja binarna** - przypisanie obiektów do jednej z 2 klas
- **Dane treningowe**: zbiór n przypadków $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$, każdy przypisany do jednego z dwóch zbiorów $\mathbb{P}$ lub $\mathbb{N}$
- **Uczenie**: procedura doboru wag $\mathbf{w}$ i wartości progowej w_0 tak aby perceptron zwracał wartość 1 dla wszystkich $\mathbf{x}_i$ ze zbioru $\mathbb{P}$, zaś wartość 0 dla wszystkich $\mathbf{x}_i \in \mathbb{N}$
- założenie: dane są spójne, tzn. $\mathbb{P} \cap \mathbb{N} = \emptyset$


Uczenie perceptronu - idea

Niech $\mathbf{x}$ należy do zbioru $\mathbb{P}$. Jeżeli perceptron popełnia błąd to

$$\sum w_i x_i + w_0 < 0$$

Jak zmienić $\mathbf{w}$ i w_0 aby zniwelować błąd?

- zwiększyć w_0



przesunięcie płaszczyzny ze zwiększeniem w_0

Rys: Riedmiller, Machine Learning (lectures)


Uczenie perceptronu - idea

Niech $\mathbf{x}$ należy do zbioru $\mathbb{P}$. Jeżeli perceptron popełnia błąd to

$$\sum w_i x_i + w_0 < 0$$

Jak zmienić $\mathbf{w}$ i w_0 aby zniwelować błąd?

- zwiększyć w_0
- jeśli $x_i > 0$ to zwiększyć w_i
- jeżeli $x_i < 0$ to zmniejszyć w_i



obrót płaszczyzny ze zmianą $\mathbf{w}$

Rys: Riedmiller, Machine Learning (lectures)

Algorytm uczenia perceptronu

Algorithm Algorytm uczenia perceptronu

Input: zbiór wektorów należących do jednego z dwóch zbiorów $\mathbb{P}$ i $\mathbb{N}$

Output: perceptron klasyfikujący wszystkie przypadki (jeżeli istnieje)

- 1: zainicjuj losowo wagi $\mathbf{w}$ oraz wartość progową w_0
- 2: **while** istnieje błędnie klasyfikowany $\mathbf{x}$ **do**
- 3: **if** $\mathbf{x} \in \mathbb{P}$ **then**
- 4: $\mathbf{w} \leftarrow \mathbf{w} + \mathbf{x}$
- 5: $w_0 \leftarrow w_0 + 1$
- 6: **else**
- 7: $\mathbf{w} \leftarrow \mathbf{w} - \mathbf{x}$
- 8: $w_0 \leftarrow w_0 - 1$
- 9: **return** $\mathbf{w}, w_0$

Kodując etykiety klas $y = \{-1, +1\}$ reguła uczenia sprowadza się do $\mathbf{w} \leftarrow \mathbf{w} + y\mathbf{x}$

👉 Perceptron visualization

Algorytm uczenia perceptronu

- Twierdzenie o zbieżności perceptronu: jeżeli zbiór wektorów $\mathbf{x}_i$ jest **liniowo separowalny** to algorytm uczenia perceptronu odnajdzie rozwiązanie w skończonej liczbie kroków
- Rozwiązanie nie jest unikatowe, kolejne uruchomienie algorytmu może znaleźć inne rozwiązanie (rezultat inicjalizacji wag i kolejności prezentacji danych treningowych)
- Możliwe cykle, gdy wektor wag się powtórzy w sekwencji uczenia to problem jest nierozwiązywalny
- Liczba błędów nie maleje monotonicznie - każda modyfikacja wag może popsuć klasyfikację poprzednio nauczonych przypadków
- Jak znaleźć najlepsze możliwe rozwiązanie nawet gdy problem nie jest liniowo separowalny?
- **Algorytm kieszeniowy** - uczenie perceptronu z zapamiętaniem wag dla których popełniono najmniej błędów

Algorithm Algorytm kieszonkowy (*pocket algorithm*)

Input: zbiór wektorów należących do jednego z dwóch zbiorów $\mathbb{P}$ i $\mathbb{N}$

Output: perceptron klasyfikujący przypadki do dwóch klas

- 1: zainicjuj losowo wagi $\mathbf{w}$ i w_0
 - 2: $t \leftarrow 0$, $t' \leftarrow t$, $\mathbf{w}' \leftarrow \mathbf{w}$, $w'_0 \leftarrow w_0$
 - 3: **for** losowo wybranego $\mathbf{x} \in \mathbb{P} \cup \mathbb{N}$ **do**
 - 4: **if** $\mathbf{x}$ poprawnie klasyfikowany **then**
 - 5: $t \leftarrow t + 1$
 - 6: **else**
 - 7: **if** $t > t'$ **then**
 - 8: $t' \leftarrow t$, $\mathbf{w}' \leftarrow \mathbf{w}$, $w'_0 \leftarrow w_0$
 - 9: $t \leftarrow 0$
 - 10: wykonaj aktualizację wag perceptronu
 - 11: **return** $\mathbf{w}'$, w'_0
-

Algorytm kieszonkowy

- Algorytm kieszonkowy ma za zadanie znaleźć najlepsze możliwe rozwiązanie nawet w przypadku problemów, które nie są liniowo separowalne
- Zapamiętuje wagi rozwiązania o najdłuższej sekwencji poprawnych klasyfikacji ale istnieje możliwość zignorowania lepszego rozwiązania o mniejszej liczbie błędów. Przeciwdziała temu alg. z zapadką, jednak wymaga on więcej nakładów obliczeniowych.
- **Algorytm kieszeniowy z zapadką** - modyfikacja algorytmu kieszeniowego, gdzie zapamiętywany jest zwycięzca tylko wtedy, gdy klasyfikuje poprawnie więcej przypadków treningowych

Algorithm Algorytm kieszonkowy z zapadką


Input: zbiór wektorów należących do jednego z dwóch zbiorów $\mathbb{P}$ i $\mathbb{N}$

Output: perceptron klasyfikujący przypadki do dwóch klas


- 1: zainicjuj losowo wagi $\mathbf{w}$ i w_0
 - 2: $t \leftarrow 0$, $t' \leftarrow t$, $\mathbf{w}' \leftarrow \mathbf{w}$, $w'_0 \leftarrow w_0$
 - 3: **for** losowo wybranego $\mathbf{x} \in \mathbb{P} \cup \mathbb{N}$ **do**
 - 4: **if** $\mathbf{x}$ poprawnie klasyfikowany **then**
 - 5: $t \leftarrow t + 1$
 - 6: **else**
 - 7: **if** $t > t'$ **then**
 - 8: **if** $\mathbf{w}$ i w_0 klasyfikują poprawnie więcej przypadków niż $\mathbf{w}'$ i w'_0 **then**
 - 9: $t' \leftarrow t$, $\mathbf{w}' \leftarrow \mathbf{w}$, $w'_0 \leftarrow w_0$
 - 10: $t \leftarrow 0$
 - 11: wykonaj aktualizację wag perceptronu
 - 12: **return** $\mathbf{w}'$, w'_0
-

Czego może się nauczyć perceptron?

- Perceptron binarny potrafi rozwiązać wyłącznie problemy liniowo separowalne
- Przykład XOR - nie jest liniowo separowalny
- Sieci połączonych neuronów mają większe możliwości
- Problem XOR można rozwiązać za pomocą 2 perceptronów prostych




Rys: Riedmiller, Machine Learning (lectures)




Algorytm wieżowy i piramidalny

Przykład algorytmów rozrastających się

1. Wytrenuj pojedynczy perceptron (np. algorytmem kieszonkowym) na danych treningowych
2. Jeżeli nie uzyskano zadowalającego rezultatu to dodaj perceptron, na którego wejście podany jest sygnał
 - z poprzedniego perceptronu (algorytm **wieżowy**)
 - ze wszystkich poprzednich perceptronów (algorytm **piramidalny**)
3. Wróć do punktu 1.




(a) Sieć wieżowa.



(b) Sieć piramidalna.

Adaline - Adaptive Linear Element

Adaline (Widrow, 1959) - jednowarstwowa sieć składająca się z perceptronów prostych. Realizacja sprzętowa z użyciem memistorów.



Reguła uczenia Widrowa-Hoffa

$$\Delta w_k = \lambda \left(y - \sum_i w_i x_i \right) x_k$$

gdzie y jest oczekiwanym sygnałem wyjściowym a $\sum_i w_i x_i$ jest aktywacją neuronu (sygnałem wyjściowym przed funkcją aktywacji), λ jest współczynnikiem uczenia

Rys: <https://sebastianraschka.com/faq/docs/diff-perceptron-adaline-neuralnet.html>



Reguła uczenia

- Reguła uczenia Widrowa-Hoffa dąży do minimalizacji błędu kwadratowego aktywacji neuronu $\mathbf{w}^T \mathbf{x}$ względem pożądanego sygnału wyjściowego y

$$E(\mathbf{x}, y) = \frac{1}{2} \left(y - \sum_i w_i x_i \right)^2$$

- funkcja kosztu E jest ciągła, więc możliwe jest uczenie metodami gradientowymi
- dla neuronów liniowych reguła jest równoważna regule delta, wówczas Adaline rozwiązuje problem aproksymacji, gdzie $y_i \in \mathbb{R}$
- dla neuronów z wyjściem progowym Adaline staje się klasyfikatorem, gdzie $y_i = \{-1, +1\}$
- **Madaline** (Many Adalines) - wielowarstwowa (z warstwą ukrytą) wersja Adaline

Adaline vs. Perceptron rule



Rys: <https://sebastianraschka.com/faq/docs/diff-perceptron-adaline-neuralnet.html>

Reguła delta

- **Reguła delta** - uogólniona reguła uczenia perceptronu dla ciągłych (różniczkowalnych) funkcji aktywacji $f(x)$

$$\Delta w_i = \lambda (y - f(\mathbf{x})) f'(\mathbf{x}) x_i$$

$\lambda > 0$ współczynnik uczenia

y to pożądany sygnał dla wejścia $\mathbf{x}$

$y \in \mathbb{R}$ dla problemu aproksymacji,

$y = \{-1, +1\}$ lub $y = \{0, 1\}$ dla klasyfikacji binarnej

- minimalizacja błędu kwadratowego E w kierunku największego spadku gradientu

$$\Delta \mathbf{w} = -\lambda \nabla_{\mathbf{w}} E$$


Dla błędu kwadratowego otrzymujemy

$$\Delta w_i = -\lambda \frac{\partial}{\partial w_i} E = -\lambda \frac{\partial}{\partial w_i} \frac{1}{2} (y - f(\mathbf{x}))^2 = \lambda (y - f(\mathbf{x})) f'(\mathbf{x}) x_i$$

Algorytm uczenia metodą gradientu prostego (*gradient descent*)

1. ustaw punkt startu $\mathbf{w}_0$ oraz współczynnik uczenia $\lambda > 0$
2. dopóki nie jest spełnione kryterium stopu wykonuj

$$\mathbf{w}_{i+1} = \mathbf{w}_i - \lambda \nabla E(\mathbf{w}_i)$$



Rys: Maja Czoków, Jarosław Piersa, Tomasz Schreiber, Wstęp do Sieci Neuronowych

Aspekty uczenia spadkiem gradientu

- Jeżeli istnieją minima lokalne to istnieje ryzyko utknięcia algorytmu w tym minimum
- Powtórzenie kilkukrotne uczenia z różnymi punktami startowymi może pozwolić uniknąć minimów lokalnych
- Trajektoria zbieżności zależy od punktu startowego
- Kryterium stopu algorytmu:
 - ustalona ilość kroków uczenia lub inne ograniczenie czasowe
 - osiągnięcie zadowalającego poziomu dokładności $E < \epsilon$
 - niewielkie zmiany w kolejnych iteracjach $||\Delta w|| < \epsilon$
- Dobór współczynnika uczenia λ jest kluczowy:
 - za duże λ : rozwiązanie może być pominięte (przeskoczone), proces uczenia może być rozbieżny
 - za małe λ : uczenie będzie powolne, algorytm może utknąć w minimum lokalnym
 - λ nie musi być stałe, współczynnik uczenia może być zmniejszany w czasie treningu lub dobierany zależnie od wypukłości funkcji błędu

Funkcje aktywacji

- **identyczność**

$$f(x) = x \quad f'(x) = 1$$

- funkcja **liniowa** - nieograniczona $f(x) \in \mathbb{R}$

$$f(x) = ax + b \quad f'(x) = a$$

- **progowa** unipolarna - nieciągła, nieróżniczkowalna

$$f(x) = \begin{cases} 1, & \text{gdy } x \geq a \\ 0, & \text{gdy } x < a \end{cases}$$



- **progowa** bipolarna

$$f(x) = \begin{cases} 1, & \text{gdy } x \geq a \\ -1, & \text{gdy } x < a \end{cases}$$

Funkcje aktywacji

- **sigmoidalna** (logistyczna) - ograniczona $f(x) \in (0, 1)$

$$f(x) = \frac{1}{1 + e^{-x}} \quad f'(x) = f(x)(1 - f(x))$$





Rys: <http://cs231n.github.io/>

Funkcje aktywacji

- **tangens hiperboliczny** - ograniczona $f(x) \in (-1, +1)$

$$f(x) = \tanh x = \frac{1 - e^{-x}}{1 + e^{-x}} \quad f'(x) = 1 - f^2(x)$$





Rys: <http://cs231n.github.io/>,
<https://www.kaggle.com/moriano/a-showcase-of-how-relus-can-speed-up-the-learning>

Funkcje aktywacji

- **ReLU** (Rectified Linear Unit) - fragmentami ciągła, brak pochodnej w 0

$$f(x) = \max(0, x) = \begin{cases} x, & \text{gdy } x \geq 0 \\ 0, & \text{gdy } x < 0 \end{cases}$$

$$f'(x) = \begin{cases} 1, & \text{gdy } x > 0 \\ 0, & \text{gdy } x < 0 \end{cases}$$



Rys: <http://cs231n.github.io/>,
<https://learnopencv.com/understanding-activation-functions-in-deep-learning/>