

Jednokierunkowe sieci  
wielowarstwowe

Multilayer Perceptron (MLP)

- Perceptrony jednowarstwowe potrafią rozwiązywać problemy separowalne liniowo
- Reguła delta dla sieci jednowarstwowej:


$$\Delta w_{ij} = \eta (y_j - f_j(\mathbf{x})) f_j'(\mathbf{x}) x_i$$

gdzie  $w_{ij}$  waga pomiędzy  $i$ -tym wejściem a  $j$ -tym wyjściem

- Problemy bardziej złożone (np. XOR) wymagają dodania kolejnej warstwy (nieliniowej) przetwarzania
- Każda kolejna warstwa tworzy nowy obraz danych, który może być dalej analizowany przez kolejne warstwy


$$\mathbf{y} = f(\mathbf{x}) = f^{(M)} \left( f^{(M-1)} \left( \dots f^{(1)}(\mathbf{x}) \right) \right)$$

# Jeszcze raz XOR




Rys: Duda, Hart, Pattern Classification

# Warstwa ukryta a granice decyzji



Rys: Duda, Hart, Pattern Classification


## Przykład: sieć MLP 2-4-2



Rys: Duda, Hart, Pattern Classification

## Perceptron 3 warstwowy

- Warstwy: wejściowa, ukryte, wyjściowa



- Warstwy w pełni połączone (wagi tworzą macierz)

$$\mathbf{o}^{(K)} = \sigma \left( \mathbf{W}^{(K)} \mathbf{o}^{(K-1)} \right)$$

- Waga  $w_{ij} = 0$  może być interpretowana jako brak połączenia

## MLP - oznaczenia

$M$  - liczba warstw ( $M = 3$ )

$w_{ij}^{(l)}$  - waga łącząca element  $i$  należący do warstwy  $l - 1$  oraz element  $j$  z warstwy  $l$


$z_j^{(l)}$  - aktywacja neuronu  $j$  w warstwie  $l$

$$z_j^{(l)} = \sum_i w_{ij}^{(l)} o_i^{(l-1)}$$

$o_j^{(l)}$  - sygnał wychodzący z elementu  $j$  należącego do warstwy  $l$

$$o_j^{(l)} = \sigma(z_j^{(l)}) = \sigma \left( \sum_i w_{ij}^{(l)} o_i^{(l-1)} \right)$$

$f_i(\mathbf{x}) = o_i^{(M)}$  funkcja realizowana przez MLP ( $i$ -te wyjście)



## Algorytm wstecznej propagacji błędu

(1974, 1986)

Miara błędu sieci dla pojedynczego wzorca wejściowego  $\mathbf{x}$  i pożądaney odpowiedzi  $\mathbf{y} = [y_1, \dots, y_n]$

$$E(\mathbf{x}; \mathbf{W}) = \frac{1}{2} \sum_{i=1}^n (y_i - f_i(\mathbf{x}; \mathbf{W}))^2$$

gdzie  $n$  to liczba wyjść

Minimalizacja błędu metodą spadku gradientu:

$$\Delta w = -\eta \frac{\partial E(\mathbf{x}; \mathbf{W})}{\partial w} = \eta \sum_{i=1}^n (y_i - f_i(\mathbf{x}; \mathbf{W})) \frac{\partial f_i(\mathbf{x}; \mathbf{W})}{\partial w}$$

## Zmiana wag dla warstwy wyjściowej

Dla wagi  $w_{jk}^{(M)}$  łączącej wyjście  $o_j^{(M-1)}$  z  $k$ -tym wyjściem sieci

$$\begin{aligned}\Delta w_{jk}^{(M)} &= \eta \sum_{i=1}^n (y_i - f_i(\mathbf{x}; \mathbf{W})) \frac{\partial f_i(\mathbf{x}; \mathbf{W})}{\partial w_{jk}^{(M)}} \\&= \eta (y_k - f_k(\mathbf{x}; \mathbf{W})) \frac{\partial f_k(\mathbf{x}; \mathbf{W})}{\partial w_{jk}^{(M)}} \\&= \eta (y_k - f_k(\mathbf{x}; \mathbf{W})) \frac{\partial \sigma(z_k^{(M)})}{\partial z_k^{(M)}} \frac{\partial z_k^{(M)}}{\partial w_{jk}^{(M)}} \\&= \eta (y_k - f_k(\mathbf{x}; \mathbf{W})) \sigma'(z_k^{(M)}) o_j^{(M-1)}\end{aligned}$$

$$\Delta w_{jk}^{(M)} = \eta (y_k - f_k(\mathbf{x}; \mathbf{W})) \sigma'(z_k^{(M)}) o_j^{(M-1)}$$

Niech  $\delta_i^{(M)}$  oznacza błąd „lokalny” dla warstwy  $M$

$$\delta_k^{(M)} = \sigma'(z_k^{(M)}) (y_k - f_k(\mathbf{x}; \mathbf{W}))$$

Zmiana wag dla warstwy wyjściowej:

$$\Delta w_{jk}^{(M)} = \eta \delta_k^{(M)} o_j^{(M-1)}$$

$$\Delta w_{0k}^{(M)} = \eta \delta_k^{(M)}$$

## Zmiana wag dla warstwy ukrytej ( $M - 1$ )

Dla wagi  $w_{jk}^{(M-1)}$  z warstwy ukrytej  $M - 1$ :

$$\Delta w_{jk}^{(M-1)} = -\eta \frac{\partial E(\mathbf{W})}{\partial w_{jk}^{(M-1)}} = \eta \sum_{i=1}^n (y_i - f_i(\mathbf{x}; \mathbf{W})) \frac{\partial f_i(\mathbf{x}; \mathbf{W})}{\partial w_{jk}^{(M-1)}}$$

gradient

$$\begin{aligned} \frac{\partial f_i(\mathbf{x}; \mathbf{W})}{\partial w_{jk}^{(M-1)}} &= \frac{\partial \sigma(z_i^{(M)})}{\partial z_i^{(M)}} \frac{\partial z_i^{(M)}}{\partial w_{jk}^{(M-1)}} = \sigma'(z_i^{(M)}) \frac{\partial \left( \sum_l w_{li}^{(M)} o_l^{(M-1)} \right)}{\partial w_{jk}^{(M-1)}} \\ &= \sigma'(z_i^{(M)}) w_{ki}^{(M)} \frac{\partial o_k^{(M-1)}}{\partial w_{jk}^{(M-1)}} \\ &= \sigma'(z_i^{(M)}) w_{ki}^{(M)} \sigma'(z_k^{(M-1)}) o_j^{(M-2)} \end{aligned}$$

$$\frac{\partial f_i(\mathbf{x}; \mathbf{W})}{\partial w_{jk}^{(M-1)}} = \sigma' \left( z_i^{(M)} \right) w_{ki}^{(M)} \sigma' \left( z_k^{(M-1)} \right) o_j^{(M-2)}$$

zmiana wag dla warstwy  $M - 1$

$$\begin{aligned} \Delta w_{jk}^{(M-1)} &= \eta \sum_{i=1}^n (y_i - f_i(\mathbf{x}; \mathbf{W})) \frac{\partial f_i(\mathbf{x}; \mathbf{W})}{\partial w_{jk}^{(M-1)}} \\ &= \eta \sum_{i=1}^n (y_i - f_i(\mathbf{x}; \mathbf{W})) \sigma' \left( z_i^{(M)} \right) w_{ki}^{(M)} \sigma' \left( z_k^{(M-1)} \right) o_j^{(M-2)} \\ &= \eta \sigma' \left( z_k^{(M-1)} \right) \sum_{i=1}^n w_{ki}^{(M)} \delta_i^{(M)} o_j^{(M-2)} \\ &= \eta \delta_k^{(M-1)} o_j^{(M-2)} \end{aligned}$$

$$\Delta w_{0k}^{(M-1)} = \eta \delta_k^{(M-1)} \quad \text{gdzie} \quad \delta_k^{(M-1)} = \sigma' \left( z_k^{(M-1)} \right) \sum_{i=1}^n w_{ki}^{(M)} \delta_i^{(M)}$$

Struktura wzoru w kolejnych warstwach jest taka sama

# Wsteczna propagacja błędu - podsumowanie

Funkcja realizowana przez sieć wielowarstwową

$$f_i(\mathbf{x}; \mathbf{W}) = \sigma \left( \sum_j w_{ji}^{(M)} \sigma \left( \sum_k w_{kj}^{(M-1)} \sigma \left( \sum_l w_{lk}^{(M-2)} \dots \sigma \left( \sum_n w_{nm}^{(2)} x_n \right) \right) \right) \dots \right)$$

Aktualizacja wag w dowolnej warstwie  $K$  - **uogólniona reguła delta**

$$\Delta w_{ij}^{(K)} = \eta \delta_j^{(K)} o_i^{(K-1)}$$


gdzie sygnał wejściowy  $o_i^{(1)} = x_i$

Sygnał błędu w warstwie  $K$

$$\delta_i^{(K)} = \sigma' \left( z_i^{(K)} \right) \sum_j \delta_j^{(K+1)} w_{ij}^{(K+1)}$$

sygnał błędu w warstwie wyjściowej:

$$\delta_i^{(M)} = \sigma' \left( z_i^{(M)} \right) (y_i - f_i(\mathbf{x}; \mathbf{W}))$$



# Algorytm wstecznej propagacji

1. Zainicjuj wagi **W** małymi losowymi wartościami
2. Dopóki nie spełniony warunek stopu wykonuj
  - 2.1 dla pary uczącej (**x**, **y**) oblicz sygnał od wejścia do wyjścia

$$o_i^{(K)} = \sigma \left( \sum_j w_{ji}^{(K)} o_j^{(K-1)} \right)$$

- 2.2 oblicz sygnał błędu od warstwy wyjściowej

$$\delta_i^{(M)} = \sigma'(z_i^{(M)}) (y_i - f_i(\mathbf{x}))$$

- 2.3 oblicz sygnał błędu od warstwy wyjściowej do wejściowej

$$\delta_i^{(K)} = \sigma'(z_i^{(K)}) \sum_j \delta_j^{(K+1)} w_{ij}^{(K+1)}$$

- 2.4 aktualizuj wagi

$$\Delta w_{ij}^{(K)} = \eta \delta_j^{(K)} o_i^{(K-1)}$$

Algorytm wstecznej propagacji można w łatwy sposób rozszerzyć na:

- sieci o innej strukturze połączeń: np. dodatkowe połączenia pomiędzy wejściem lub wyjściem, lub innymi warstwami ukrytymi. Dla sieci rekurencyjnych odpowiednikiem jest BPTT (wsteczna propagacja w czasie)
- dowolną liczbę warstw
- różne nieliniowości w warstwach
- różne funkcje aktywacji dla poszczególnych neuronów
- różne stałe uczenia dla każdej warstwy lub węzła
- inne funkcje kosztu, nie tylko MSE, np. Cross Entropy

## Warianty treningu

Dla zbioru zawierającego  $N$  przypadków i sieci zawierającej  $M$  wyjść

$$\hat{E} = \frac{1}{N} \sum_{i=1}^N E(\mathbf{x}_i) = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M (y_{ij} - f_j(\mathbf{x}_i))^2$$

$$\Delta \hat{W} = \sum_{i=1}^N \Delta w_i$$

### Batch gradient descent

- uśredniony błąd całego zbioru treningowego
- nie praktyczne dla dużych danych
- stabilny trening
- nie zależy od kolejności prezentacji wzorców

# Warianty treningu

## **SGD** - stochastic gradient descent (on-line)

- aktualizacja dla pojedynczego przypadku
- treningowego ( $N = 1$ ), duża szybkość działania ale i duża wariancja,
- istotna jest kolejność prezentacji przypadków

## **MiniBatch** gradient descent

- średnia z  $n$  losowych przypadków (*mini-batch*), trening on-line,
- często utożsamiany z SGD
- mniejsza wariancja niż SGD
- możliwe operacje na macierzach, łatwiejsze zrównoleglenie GPU/CPU

# Własności MLP

- **Uniwersalny aproksymator:** sieć MLP z jedną warstwą ukrytą jest w stanie aproksymować dowolną funkcję ciągłą z dowolną dokładnością.  
Dwie warstwy ukryte rozszerzają możliwości na funkcje nieciągłe.  
Klasyfikator potrafi zrealizować dowolne granice decyzji (obszary nie muszą być wypukłe ani połączone)
- Neurony ukryte: transformacja nieliniowa do przestrzeni odwzorowań, tworząca nowe cechy za pomocą nieliniowych kombinacji
- Wiele zastosowań: klasyfikacja, wielowymiarowa regresja

# Problemy I

- Optymalizacja nieliniowych funkcji zawsze sprawia problemy, tu mamy złożenie (czasem wielu) funkcji nieliniowych
- Dobór architektury sieci: Ile węzłów w warstwie ? Jakie funkcje aktywacji? Sieci ontogeniczne (rozrastające się) dostosowujące rozmiar do złożoności problemu
- Przeuczenie i generalizacja - zbyt duża liczba optymalizowanych parametrów powoduje przeuczenie, zbyt mała - może generować zbyt proste rozwiązania
- Regularyzacja - metody ograniczenia zjawiska przeuczenia, np. modyfikacje funkcji kosztu, ograniczenie liczby parametrów
- Inicjalizacja parametrów - szybkość treningu i wynik zależy od punktu startowego


## Problemy II

- Minima lokalne i plateau, wąskie „rynny” - np. wielokrotny start
- Wpływ nowych wzorców na już nauczone – zapominanie
- Dobór stałej uczenia
- Znikający gradient, eksplodujący gradient
- Przygotowanie danych uczących: normalizacja, standaryzacja, kodowanie wyjść, ...
- Ocena modelu: zbiory walidacyjne, testowe, krosvalidacja


## Znikający gradient

Szybkość uczenia (zmiany wag) drastycznie maleje w głębszych warstwach - sygnał błędu zanika

Przykład: sieć  $1 \times 1 \times 1 \times 1$



gdy  $|w_j| < 1$  wówczas  $|w_j \sigma'(z_j)| < \frac{1}{4}$



# Problem niestabilnego gradientu

- gradient w niższych warstwach zależy od wartości wag, aktywacji i gradientów w warstwach wyższych
- **eksplodujący gradient**  
gdy  $w_i \gg 1$  oraz  $z_i \approx 0$  wówczas  $|w_i \sigma'(z_i)| > 1$ , może to owocować bardzo dużymi gradientami w początkowych warstwach
- znikający i eksplodujący gradient to przypadki szczególne **problemu niestabilnego gradientu** -> wartości gradientów w poszczególnych warstwach mogą znacznie się różnić, warstwy uczą się z różnym tempem

# Specyfikacja sieci i metody treningu

- Specyfikacja modelu:
  - specyfikacja architektury
  - typ neuronów ukrytych: liniowe, sigmoidalne, ReLU, ...
  - typ neuronów wyjściowych: liniowe, sigmoidalne, softmax, ...
- Funkcja kosztu:
  - mean squared error (MSE),
  - cross-entropy (CE),
- Optymalizacja metodami spadku gradientu lub innymi:
  - SGD, RPROP, Quackprop,
  - Adam, AdaGrad, ...
- Metody regularyzacji:
  - momentum,  $L_1$ ,  $L_2$  (weight decay), ...

# Funkcja kosztu MSE

Błąd średniokwadratowy (*Mean Squared Error*)

$$J(\Theta) = \frac{1}{N} \sum (\hat{y} - y)^2$$

Gradient funkcji kosztu:

$$\frac{\partial J}{\partial \Theta} = \frac{2}{N} \sum (\hat{y} - y) \frac{\partial \hat{y}}{\partial \Theta}$$

gdzie

$\hat{y}$  - wyjścia sieci,

$\Theta$  - parametry sieci,

$y$  - oczekiwane wyjścia

# Funkcja kosztu Cross Entropy

## Cross entropy

$$J(\Theta) = - \sum y \log \hat{y}$$

- miara odległości między rozkładami  $y$  i  $\hat{y} \in (0, 1)$
- gdy  $y \approx \hat{y}$  to funkcja kosztu bliska zeru
- $J > 0$

Gradient funkcji kosztu:

$$\frac{\partial J}{\partial \Theta} = - \sum y \frac{1}{\hat{y}} \frac{\partial \hat{y}}{\partial \Theta}$$

 Wizualizacja funkcji CE


## Funkcja liniowa w warstwie wyjściowej

$$z = \mathbf{w}^T \mathbf{h} + b$$

- nieograniczone wartości  $(-\infty, +\infty)$
- jednostki nie nasycają się ale bardzo duże wartości aktywacji również mogą przysporzyć problemów w trakcie uczenia
- stabilniejsze w optymalizacji metodami gradientowymi od innych typowych funkcji nieliniowych stosowanych w sieciach
- zastosowanie wraz funkcją kosztu MSE do problemów regresji (dane wyjściowe ciągłe), modelowanie rozkładów gusowskich

## Funkcja logistyczna w warstwie wyjściowej

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



- wartości ograniczone (0, 1)
- nasycają się, aktywne uczenie tylko w okolicach  $x \approx 0$
- zastosowanie: klasyfikacja 2 klas, modelowanie rozkładu Bernoulliego, binarne wartości wyjściowe (*multi-label classification*)
- binarna funkcja kosztu Cross-Entropy, na każdym wyjściu oczekujemy stanu 0 lub 1

$$J_{CE} = - \sum y \ln \hat{y} = - [y \ln \hat{y} + (1 - y) \ln(1 - \hat{y})]$$

## Funkcja sigmoidalna w warstwie wyjściowej

- podczas minimalizacji MSE błąd zanika, gdy funkcja się nasycy (także dla niepoprawnej odpowiedzi), wówczas  $\frac{\partial \hat{y}}{\partial \Theta} \approx 0$

$$\frac{\partial J_{MSE}}{\partial \Theta} = \frac{2}{N} \sum (\hat{y} - y) \frac{\partial \hat{y}}{\partial \Theta}$$

- problem znika przy zastosowaniu kosztu Cross Entropy (CE)

$$\frac{\partial J_{CE}}{\partial \Theta} = \sum (\hat{y} - y) \frac{\partial z}{\partial \Theta}$$

gdzie  $z$  jest liniową aktywacją (*logit*) neuronu wyjściowego

## Softmax w warstwie wyjściowej

$$\text{softmax}(\mathbf{z})_i = \frac{e^{z_i}}{\sum_j e^{z_j}}$$

- wartości  $(0, 1)$  unormowane

$$\sum_i \text{softmax}(\mathbf{z})_i = 1$$


- Zastosowanie: klasyfikacja  $n$  rozłącznych klas (*multi-class classification*),  
każde wyjście sieci związane jest z jedną klasą, wartości kodowane w postaci wektora binarnego (kodowanie *one hot*)

$$[0, \dots, 0, 1, 0, \dots, 0]$$

- wartości wyjściowe sieci reprezentują rozkład prawdopodobieństw zmiennej wyjściowej

$$\hat{y}_i = P(y = i | X), \quad i = 1, \dots, n$$

## Multi-Class Classification with NN and SoftMax Function



Źródło:

[stats.stackexchange.com/questions/265905/derivative-of-softmax-with-respect-to-weights](https://stats.stackexchange.com/questions/265905/derivative-of-softmax-with-respect-to-weights)

- gradient

$$\frac{\partial \text{softmax}(\mathbf{z})_i}{\partial z_j} = \text{softmax}(\mathbf{z})_i (\delta_{ij} - \text{softmax}(\mathbf{z})_i)$$

- gradient funkcji kosztu CE gdy  $\hat{y}_i = \text{softmax}(\mathbf{z})_i$

$$\frac{\partial J_{CE}}{\partial \Theta} = \sum (\hat{y} - y) \frac{\partial z}{\partial \Theta}$$

- obliczenia się upraszczają i znika problem zanikania błędu dla nasyconych wyjść, który występował dla funkcji kosztu MSE i wyjść sigmoidalnych

- softmax dobrze współgra z funkcją kosztu *cross entropy*, błąd nie znika nawet dla dużych wartości aktywacji  $z_i$

$$\log \text{softmax}(\mathbf{z})_i = z_i - \log \sum_j e^{z_j}$$

- ważne są różnice wartości pomiędzy wyjściami a nie amplitudy poszczególnych wyjść

$$\text{softmax}(x) = \text{softmax}(x + c)$$

- minimalizacja kosztu CE powoduje zwiększenie wartości  $z_i$  na jednym z wyjść i zmniejszenie wszystkich pozostałych

$$\log \sum_k e^{z_k} \approx \max_i z_i$$

- z punktu widzenia neurobiologicznego softmax może być widziany jako realizacja mechanizmów hamowania występującego w grupach neuronów w korze, podobnie do mechanizmu zwycięzca bierze wszystko (*winner takes all*)

Dobór funkcji kosztu uzależniony jest od rozkładu wartości wyjściowych i typu neuronów wyjściowych

| Output Type | Output Distribution | Output Layer                 | Cost Function                |
|-------------|---------------------|------------------------------|------------------------------|
| Binary      | Bernoulli           | Sigmoid                      | Binary cross-entropy         |
| Discrete    | Multinoulli         | Softmax                      | Discrete cross-entropy       |
| Continuous  | Gaussian            | Linear                       | Gaussian cross-entropy (MSE) |
| Continuous  | Mixture of Gaussian | Mixture Density              | Cross-entropy                |
| Continuous  | Arbitrary           | See part III: GAN, VAE, FVBN | Various                      |

## Dobór neuronów ukrytych

- wybór funkcji realizowanych przez warstwy ukryte jest kluczowy dla przebiegu procesu uczenia
- funkcje liniowe - wiele warstw liniowych sprowadza się do pojedynczej transformacji liniowej

$$f(\mathbf{x}) = \mathbf{W}_n \mathbf{W}_{n-1} \dots \mathbf{W}_1 \mathbf{W}_1 \mathbf{x} = \mathbf{A} \mathbf{x}$$

- funkcje ograniczone: sigmoidalne i tangens hiperboliczny powodują problemy z niestabilnym gradientem, uczenie może utknąć, gdy funkcja się nasyci
- obecnie najpopularniejszym typem aktywacji w sieciach jest ReLU

# Demonstracje

-  TensorFlow playground
-  ConvNetJS - Deep Learning in your browser