

# Základy matematiky a statistiky pro humanitní obory II

Vojtěch Kovář

Fakulta informatiky, Masarykova univerzita  
Botanická 68a, 60200 Brno, Czech Republic  
xkovar3@fi.muni.cz

část 9

## Obsah přednášky

Derivace

Integrál

Parciální derivace


Strojové učení

Neuronová síť

## Derivace

- ▶ Základní pojem **diferenciálního počtu**
- ▶ Směrnice tečny ke grafu funkce v určitém bodě
  - ▶ směrnice je číslo vyjadřující sklon přímky:  $y = ax + b$
  - ▶ definována přes limitu:  $f'(a) = \lim_{x \rightarrow a} \frac{f(x) - f(a)}{x - a}$
- ▶ Pro všechny body: **nová (odvozená = derivovaná) funkce**
  - ▶ např.  $f : y = x^2 \rightarrow f' : y = 2x$
  - ▶ např.  $f : y = 4x + 1 \rightarrow f' : y = 4$
- ▶ Využití: **vyšetřování průběhu funkce**
  - ▶ kladná derivace = funkce roste
  - ▶ záporná derivace = funkce klesá
  - ▶ nulová derivace = lokální minimum nebo maximum


Příklad: derivace v tomto bodě je záporná



## Integrál

- ▶ Inverzní operace k derivaci
  - ▶ tzv. základní věta integrálního počtu
- ▶ Opět z dané funkce „vyrobíme“ jinou funkci
- ▶ Neurčitý integrál = primitivní funkce
  - ▶ množina funkcí, jejichž derivací dostaneme danou funkci
- ▶ Určitý integrál
  - ▶ změna primitivní funkce na daném intervalu
  - ▶ odpovídá ploše pod křivkou funkce
  - ▶ viz též Riemannův integrál
  - ▶ využití: výpočet obsahů, objemů, ...

## Určitý integrál: příklad



zdroj: [https://commons.wikimedia.org/wiki/File:Integral\\_as\\_region\\_under\\_curve.svg](https://commons.wikimedia.org/wiki/File:Integral_as_region_under_curve.svg)


## Parciální derivace

- ▶ U funkcí více proměnných
  - ▶ např.  $f : z = 4y - 2x + 5$
  - ▶ např.  $f : y = 4x_1 + 8x_2 + x_3 + 5x_4 - 8$
- ▶ Všechny proměnné až na jednu bereme jako konstanty
  - ▶ např.  $f(x, y) = 4y^2 - 2x + 5$
  - ▶  $\frac{df}{dy} = 8y$
  - ▶  $\frac{df}{dx} = 2$
  - ▶ směrnice tečny v bodě „ve směru dané osy“

## Strojové učení (supervised = s učitelem)

- ▶ Zobecnění z (mnoha) konkrétních příkladů
- ▶ 2 základní typy problémů:
  - ▶ Klasifikace
    - ▶ cílem je přiřadit objekt do třídy
    - ▶ na základě jeho atributů (tzv. **features**)
    - ▶ features jsou číselné nebo řetězcové hodnoty
    - ▶ často mluvíme o **vektoru hodnot**
    - ▶ např. „umět rozlišit jabka a hrušky na základě barvy a tvaru“
  - ▶ Regrese
    - ▶ cílem je na základě atributů přiřadit číselnou hodnotu
    - ▶ např. „na základě parametrů automobilu přiřadit cenu“

## Lineární regrese




## Lineární regrese

- ▶ Snažíme se co nejlépe proložit přímkou množinou bodů
  - ▶ např. ve dvourozměrném prostoru
  - ▶ přímka:  $y = ax + b$
  - ▶ snažíme se najít parametry  $a$  a  $b$
  - ▶ tak, abychom minimalizovali chybovou funkci (**loss function**)
- ▶ Chybová funkce  $e$ 
  - ▶ součet rozdílů (čtverců) odchylek od přímky
  - ▶ pro každou dvojici  $a$  a  $b$  dostaneme číselnou hodnotu chyby
  - ▶  $e$  je tedy funkcí dvou proměnných,  $a$  a  $b$
  - ▶ potřebujeme najít  $a$  a  $b$  tak, že chyba  $e(a, b)$  je minimální


## Lineární regrese

- ▶ Steepest gradient descent
  - ▶ začneme v náhodném bodě  $(a, b)$
  - ▶ spočítáme parciální derivace chybové funkce  $\frac{de}{da}$  a  $\frac{de}{db}$
  - ▶ vektor  $(\frac{de}{da}(a), \frac{de}{db}(b))$  se nazývá **gradient**
  - ▶ posuneme náš odhad  $(a, b)$  opačným směrem a opakujeme
  - ▶ (tedy  $\frac{de}{da}(a)$  říká, kam máme posunout parametr  $a$ )
  - ▶ ( $\frac{de}{db}(b)$  říká, kam máme posunout parametr  $b$ )
  - ▶ obě derivace nulové = jsme v lokálním minimu
  - ▶ a tedy chyba je nejmenší možná
  - ▶ (v některých příznivých situacích)
- ▶ Totéž lze dělat pro libovolnou funkci a libovolný počet dimenzí

## Steepest gradient descent




## Neuron



**výpočet:**  $Z = x_1 w_1 + x_2 w_2 + \dots + x_n w_n + w_0$   
(neuron je tedy jednoduchá lineární funkce)

**trénování:** optimalizace ( $w_0..w_n$ ) pomocí steepest gradient descent

## Neuronová síť



## Trénování neuronové sítě

- ▶ Backpropagation: algoritmus zpětné propagace chyby
  - ▶ začneme s náhodnými vahami  $w_{ij}$
  - ▶ provedeme výpočet na trénovacích příkladech
  - ▶ provedeme gradient descent a úpravy parametrů  $w_{ij}$
  - ▶ opakujeme, dokud nedosáhneme minima (nulových derivací podle všech parametrů  $w_{ij}$ )
- ▶ Proč „zpětná propagace“
  - ▶ chyba  $e$  je složená funkce
  - ▶ derivace složené funkce je součinem derivací jejích částí
  - ▶ např. pro  $\frac{de}{dw_{11}}$  musíme tedy nejdřív spočítat  $\frac{de}{dZ}$
  - ▶ potom  $\frac{df_3}{dy_1}$  a  $\frac{df_3}{dy_2}$
  - ▶ a nakonec  $\frac{df_1}{dw_{11}}$ ,  $\frac{df_1}{dw_{12}}$ , ...,  $\frac{df_2}{dw_{21}}$  atd.
  - ▶ postupujeme tedy zprava doleva, opačně než výpočet