

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 derivaci dostaneme danou funkcí
- ▶ 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


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