

# Analýza dat: lineární regrese, detekce shluků

Radek Pelánek

IV122

# Úvodní poznámky

- princip „simulovaná data“
- rozbor dvou konkrétních technik
  - lineární regrese
  - detekce shluků ( $k$ -means)
- průběžně ilustrace obecných principů z analýzy dat, pravděpodobnosti, strojového učení, ...

# Simulovaná data – jednoduchý příklad

- zvolíme parametry  $\mu, \sigma$ , počet dat  $n$
- simulovaná data = vygenerujeme  $n$  bodů z normálního rozdělení s průměrem  $\mu$  a směrodatnou odchylkou  $\sigma$
- na základě dat odhadneme parametry  $m, s$


# Simulovaná data – jednoduchý příklad

- zvolíme parametry  $\mu, \sigma$ , počet dat  $n$
- simulovaná data = vygenerujeme  $n$  bodů z normálního rozdělení s průměrem  $\mu$  a směrodatnou odchylkou  $\sigma$
- na základě dat odhadneme parametry  $m, s$

co z toho:

- ujasnění metod pro odhad parametrů
- kontrola implementace
- intuitivní výhled do vztahu mezi  $n$  a přesností odhadnutých parametrů
- u složitějších modelů i „přidané“ výsledky, které nelze (snadno) získat analyticky

# Reálná data: délka života, porodnost




Google Public Data / World Bank


# Reálná data: Old Faithful




Zdroj: Wikipedia



# Simulovaná data: generování



# Simulovaná data: vstup pro analýzu





též „syntetická“ data


- zvolíme „správné řešení“
- vygenerujeme data: „správné řešení“ + náhodný šum
- náhodný šum  $\sim$  normální rozdělení (většinou)
- algoritmu pro analýzu dat dáme pouze vygenerovaná data
- výsledek algoritmu můžeme porovnat se správným řešením

užitečný přístup z mnoha hledisek: pochopení, ladění implementace, nastavení parametrů


# Simulovaná data: lineární regrese



# Lineární regrese



# Simulovaná data: Detekce shluků



# Úkol

- k dispozici data pro lineární regresi a detekci shluků
- zkuste najít „co nejlepší“ přímku / rozdělení na shluky
  - ➊ co to znamená „co nejlepší“?
  - ➋ jak hledat?
- zkuste vymyslet ...  
žádný Google, Wikipedie, studijní materiály

# Která přímka je nejlepší?

- hledáme co nejlepší přímku  $ax + b$
- minimalizace „sumy čtverců chyb“ (sum of squared error)

$$SSE = \sum_{i=1}^n (y_i - (ax_i + b))^2$$

- proč zrovna tato funkce?


# Která přímka je nejlepší?

- hledáme co nejlepší přímku  $ax + b$
- minimalizace „sumy čtverců chyb“ (sum of squared error)

$$SSE = \sum_{i=1}^n (y_i - (ax_i + b))^2$$

- proč zrovna tato funkce?
- pragmaticicky: dobře se s tím pracuje
- teoreticky: nejlepší vysvětlení dat při předpokladu normálního šumu

# Normální rozdělení



Wikipedia

# Normální rozdělení

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

- $\mu$  – průměr
- $\sigma$  – standardní odchylka

# Metoda maximální věrohodnosti

maximum likelihood estimation

- jaká je věrohodnost (likelihood) dat, pokud jsou generována přímkou  $ax + b$ ?

$$L = \prod_i p(x_i, y_i) = \prod_i \mathcal{N}(ax_i + b, \sigma^2)(y_i)$$

- hledáme  $a, b$  tak, abychom maximalizovali
- vezmeme logaritmus (monotónní operace, zachovává maximum)
- maximalizovat  $L$  je to stejné jako minimalizovat sumu čtverců:


$$SSE = \sum_{i=1}^n (y_i - (ax_i + b))^2$$

# Jak najít přímku minimalizující SSE?

- analytické řešení „vzorečkem“ – ideální řešení, tady funguje, u složitějších problémů však nikoliv
- pro ilustraci:
  - „grid search“ – hrubá síla
  - gradient descent – postupné vylepšování

# Grid search

8 hodnot  $b$ , 7 hodnot  $a$ ; stupeň šedi  $\sim$  SSE



# Analytické řešení

$$SSE = \sum_{i=1}^n (y_i - (ax_i + b))^2$$

- hledáme minimum vzhledem k  $a, b$
- parciální derivace musí být 0

$$\frac{\partial SSE}{\partial a} = 2 \sum_{i=1}^n -y_i x_i + ax_i^2 + x_i b = 0$$

$$\frac{\partial SSE}{\partial b} = 2 \sum_{i=1}^n -y_i + ax_i + b = 0$$

# Analytické řešení

Po algebraických úpravách dostaneme:

$$a = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{n \sum x_i^2 - (\sum x_i)^2} = r_{xy} \frac{s_y}{s_x}$$

$$b = \bar{y} - a\bar{x}$$

$r_{xy}$  – korelační koeficient


$s_x, s_y$  – standardní odchylka  $x, y$

# Metoda největšího spádu

## gradient descent

- „hladová“ metoda
  - začneme s iniciálním odhadem parametrů
  - iterativně zlepšujeme
- snažíme se o co největší lokální zlepšení = úprava hodnot parametrů ve směru spádu (gradient)
- parametr „learning rate“: velikost skoku ve směru gradientu
  - příliš malý – pomalé
  - příliš velký – nestabilní (nekonverguje)

# Gradient descent: intuice



Wikipedia

# Gradient descent pro lineární regresi


$$SSE = \frac{1}{2} \sum_{i=1}^n (y_i - (ax_i + b))^2$$

gradient:

$$\frac{\partial SSE}{\partial a} = - \sum_{i=1}^n x_i(y_i - (ax_i + b))$$


$$\frac{\partial SSE}{\partial b} = - \sum_{i=1}^n (y_i - (ax_i + b))$$

# Gradient descent demo



# Detekce shluků (clustering)

Old Faithful



# Cíl shlukování

shlukování obecně:

- minimalizovat vzdálenosti v rámci shluku
- maximalizovat vzdálenosti mezi shluky

konkrétně např: minimalizace sum čtverců vzdáleností od středů shluků


# Normalizace

klíčový praktický krok: normalizace (standardizace)


- potřebujeme data dostat na stejnou „škálu“, jinak bude dominovat jedna dimenze
- z-skóre
  - odečíst průměr
  - podělit standardní odchylkou

# Význam normalizace

Old Faithful data



# Detekce shluků – simulovaná data







# Algoritmus $k$ -means

- vyber  $k$  „středů shluků“
- opakuj:
  - každý bod přiřad' do toho shluku, jehož střed je nejblíž
  - aktualizuj polohu středů – těžiště bodů přiřazených do shluku

<http://www.naftaliharris.com/blog/visualizing-k-means-clustering/>

# Algoritmus $k$ -means: ukázka



# Algoritmus $k$ -means – poznámky

- hladová metoda
- lokální optima
- role inicializace
- opakované spuštění