

Progresivní technologie v informatice I

Umělá inteligence a strojové učení 2

Fakulta informačních technologií
České vysoké učení technické v Praze

2023/2024



Financováno
Evropskou unií
NextGenerationEU



Národní
plán
obnovy



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

Hlavní body

1 Validační data: ladění hyperparametrů

2 Základy lineární regrese

Ladění hyperparametrů (1/3)


Ted' se dostáváme ke třetí otázce: **Jak poznám, jakou mám zvolit hloubku stromu příp. jiné jeho parametry?**

- Můžeme postupovat takto:
 - 1 Data si rozdělíme na trénovací a testovací.
 - 2 Pro různé hodnoty hloubky stromu (parametr `max_depth`) naučíme rozhodovací strom na trénovacích datech
 - 3 a pro každou hloubku stromu změříme přesnost (classification accuracy) na testovacích datech.
 - 4 Vyberme tu hloubku, která dává nejmenší testovací chybu.
 - 5 Tuto hodnotu vezmeme také jako odhad chyby na reálných datech, a tedy jako objektivní míru kvality modelu.
- Je někde problém? Ano, je!
- Výsledná testovací chyba bude zpravidla příliš optimistickým odhadem skutečnosti! Výsledný model (konkrétně parametr hloubka stromu) byl vybrán na základě těchto dat a model je tedy těmto datům přizpůsobený.
- Takto bychom porušili zásadu, že **při učení modelu nesaháme na testovací data**, pokud má být testovací chyba rozumným odhadem skutečné chyby modelu.

Ladění hyperparametrů (2/3)

- Jak se s tímto problémem vypořádat?
- Obvykle se to dělá tak, že se data rozdělí ne na dvě, ale na tři podmnožiny: trénovací, **validační** (angl. **validation**) a testovací:
 - 1 Pro různé hodnoty hloubky stromu `max_depth` naučíme rozhodovací strom
 - 2 a změříme jeho chybu (přesnost) na validačních datech.
 - 3 Jako optimální hodnotu vybereme tu s nejmenší chybou (tj. s nejvyšší přesností).
 - 4 Chyba na testovacích datech, které dosud ležely ladem, je pak rozumným odhadem chyby modelu.
- Parametrům, jako je `max_depth`, které určují *tvar* nebo *komplexitu* modelu, se říká **hyperparametry modelu**.
- Určování těchto parametrů pomocí validačních dat se říká **ladění** (angl. **tuning**).
- Tento parametr nemusí být jeden, ale může jich být více. Pokud jsou spojitě, může být výpočetně složité jich otestovat *reprezentativní* množství a je třeba dělat kompromisy.

Ladění hyperparametrů (3/3)



Ladění hyperparametrů: poznámky (1/2)

- Pro představu, jaké hyperparametry jsou dostupné pro rozhodovací stromy v knihovně sklearn:

```
Init signature: DecisionTreeClassifier(criterion='gini', splitter='best', max_depth=None, min_samples_split=2, min_samples_leaf=1, min_weight_fraction_leaf=0.0, max_features=None, random_state=None, max_leaf_nodes=None, min_impurity_decrease=0.0, min_impurity_split=None, class_weight=None, presort=False)
```

- Význam těchto parametrů si vysvětlíte (a ukážete) na cvičení.
- Dělení dat na trénovací/validační/testovací podmnožiny je dobré dělat náhodně. Tj. nevybrat první půlku dat jako trénovací, další čtvrtinu jako validační a zbytek vzít jako testovací.
- V pořadí dat by mohla být nějaká zákonitost, která by znamenala, že trénovací a testovací data nebudou reprezentativní.
- Proto se postupuje tak, že se data vybírají náhodně. V sklearn je na to metoda:

```
from sklearn.model_selection import train_test_split  
Xtrain, Xtest, ytrain, ytest = train_test_split(X, y, test_size=0.25, random_state=33)
```

Ladění hyperparametrů: poznámky (2/2)

- Neexistuje žádný optimální poměr velikosti trénovací/validační/testovací množiny dat.
- Obvyklé poměry jsou takové, že 20 % dat vezmeme jako testovací množinu a ze zbytku vezmeme 20 % jako validační množinu. Co zbude, jsou trénovací data.
- Místo 20 % lze použít 25 %, nebo 30 %.
- Lze použít i sofistikovanější strategie, např. měnit velikost validační množiny a koukat se, co to dělá.
- Často používanou metodou je také **cross-validation**, o které budeme mluvit později.

Hlavní body

1 Validační data: ladění hyperparametrů

2 Základy lineární regrese

Motivační příklad

- Chceme prodat nemovitost (řekněme v Praze) a netušíme, za kolik ji máme potenciálním zájemcům nabídnout.
- Zároveň si nechceme platit žádného „realitního“ odborníka, který by nám se stanovením ceny poradil.
- Zkusíme tedy udělat vlastní průzkum realitního trhu a vytvořit model, který nám pomůže cenu stanovit.
- Napíšeme skript, který stáhne data z realitních serverů a uloží je v nějaké strukturované podobě (ideálně tabulce či více tabulkách).
- Pro jednoduchost uvažujme, že budeme znát u každé nabídky toto:
 - Y – cenu, za kterou se prodává,
 - X_1 – užitnou plochu,
 - X_2 – počet místností,
 - X_3 – vzdálenost od nejbližší zastávky metra.
- Jako vysvětlovanou proměnnou Y jsme označili veličinu, kterou pro naši nemovitost neznáme a chceme ji predikovat.
- Příznaky $X_1, \dots, X_3$ označují veličiny, které pro naši nemovitost známe a o kterých věříme, že cenu Y ovlivňují.

Formalizace úlohy

Obecně tedy chceme na základě p příznaků $X_1, \dots, X_p$ predikovat hodnotu vysvětlované proměnné Y .

V modelu lineární regrese předpokládáme **lineární závislost** vysvětlované proměnné na hodnotách příznaků.

Jelikož nedoufáme, že tato závislost je perfektní v tom smyslu, že pro stejné hodnoty $x_1, \dots, x_p$ příznaků $X_1, \dots, X_p$ dostaneme vždy stejnou hodnotu vysvětlované proměnné Y , modelujeme tuto závislost následovně:

$$Y = w_1 x_1 + \dots + w_p x_p + \varepsilon,$$

kde $w_1, \dots, w_p$ jsou nějaké neznámé koeficienty a ε je náhodná veličina.

Poznámky:

- Veličina ε odpovídá části Y , která je nevysvětlitelná pomocí hodnot příznaků a je tedy z našeho pohledu náhodná.
- Do náhodné veličiny ε se tak „schovají“ vlivy, které **neznáme** nebo cíleně **nezahrnujeme** do našeho modelu (např. stáří budovy, počet koupelen, počet oken) ale např. i chyby, nekonzistence dat a jiné podivnosti v měření příznaků.

Model lineární regrese

Obvykle ještě oddělujeme střední hodnotu náhodných vlivů a dostáváme tak:

Model lineární regrese

Hodnota vysvětlované proměnné Y v bodě $(x_1, \dots, x_p)^T$ je

$$Y = w_0 + w_1 x_1 + \dots + w_p x_p + \varepsilon,$$

kde $\mathbb{E}\varepsilon = 0$.

- Koeficient w_0 se nazývá *intercept* a odpovídá (očekávané) výchozí hodnotě Y při nulových příznacích.
- Zavedeme-li nový konstantní příznak $X_0 = x_0 = 1$ a vektorové značení

$$\vec{x} = (x_0, x_1, \dots, x_p)^T \quad \text{a} \quad \vec{w} = (w_0, w_1, \dots, w_p)^T,$$

můžeme zkráceně psát

$$Y = \vec{w}^T \vec{x} + \varepsilon.$$

- Vektor $\vec{w} = (w_0, w_1, \dots, w_p)^T$ koeficientů také někdy nazýváme **vektor vah**.

Predikce v modelu lineární regrese

Předpokládejme nyní, že už máme odhad $\hat{\vec{w}}$ vektoru koeficientů $\vec{w}$.

Hodnotu Y v konkrétním bodě $\vec{x}$ predikujeme vztahem

$$\hat{Y} = \hat{\vec{w}}^T \vec{x} = \hat{w}_0 + \hat{w}_1 x_1 + \dots \hat{w}_p x_p.$$

Skutečná hodnota Y v bodě $\vec{x}$ je přitom určena vztahem

$$Y = \vec{w}^T \vec{x} + \varepsilon$$


a je tedy náhodnou veličinou.

Z předpokladu $\mathbb{E}\varepsilon = 0$ plyne, že

$$\mathbb{E}Y = \vec{w}^T \vec{x}$$

a $\hat{Y}$ je tedy vlastně bodovým odhadem střední hodnoty $\mathbb{E}Y$ v bodě $\vec{x}$.

Vizualizace modelu lineární regrese



Modré body jsou body trénovací množiny. Červené body jsou predikce. Modré křížky odpovídají středním hodnotám bodů trénovací množiny, $(\bar{x}_i, \mathbb{E}Y_i)$. Modrá čerchovaná čára je skutečná regresní přímka daná rovnicí $y = \vec{w}^T \vec{x}$ a červená čára je přímka $\hat{y} = \hat{\vec{w}}^T \vec{x}$ určující naše predikce.

Měření chybovosti predikce pomocí ztrátové funkce

Zaměřme se nyní na problematiku odhadu vektoru parametrů modelu $\vec{w}$.

Následující úvahy jsou obecně platné pro supervizované učení nějakého modelu s parametry.

- Naším cílem je najít takovou hodnotu $\vec{w}$, aby chyba modelu byla co nejmenší.
- Tuto hodnotu pak použijeme jako odhad $\hat{w}$.
- K tomu musíme specifikovat, **co se myslí chybou modelu** a **v jakém smyslu má být nejmenší**.
- Chybu modelu nejčastěji měříme pomocí nějaké nezáporné funkce $L : \mathbb{R}^2 \rightarrow \mathbb{R}$, nazývané *ztrátová funkce* (angl. *loss function*), kterou aplikujeme na skutečnou hodnotou proměnné Y a odpovídající predikci $\hat{Y}$.
- Obvyklou volbou v případě spojitě vysvětlované veličiny bývá *kvadratická ztrátová funkce*,

$$L(Y, \hat{Y}) = (Y - \hat{Y})^2.$$

Metoda nejmenších čtverců

- Velikost chyby modelu v bodě $\vec{x}$ je tedy $L(Y, \hat{Y})$, kde Y je skutečná hodnota vysvětlované Y v bodě $\vec{x}$ a $\hat{Y} = \vec{w}^T \vec{x}$ je predikce v bodě $\vec{x}$.
- Otázkou je, v jakém bodě $\vec{x}$ bychom měli hodnotu $L(Y, \hat{Y})$ vyhodnocovat a následně minimalizovat vzhledem k $\vec{w}$.
- Zřejmě to musí být bod $\vec{x}$ z trénovací množiny, protože jinak bychom neznali skutečnou hodnotu Y v tomto bodě.
- Abychom co nejvíc využili trénovací data, budeme minimalizovat součet chyb přes všechny body trénovací množiny, tj. přes všechny dvojice $(\vec{x}_i, Y_i)$ pro $i = 1, \dots, N$.
- Součet chyb přes všechny tyto body pro kvadratickou ztrátovou funkci je

$$\text{RSS}(\vec{w}) = \sum_{i=1}^N L(Y_i, \vec{w}^T \vec{x}_i) = \sum_{i=1}^N (Y_i - \vec{w}^T \vec{x}_i)^2$$

a nazýváme ho *reziduální součet čtverců* (angl. *residual sum of squares*).

- Minimalizací tohoto výrazu získáme odhad $\hat{\vec{w}}$. Tento postup se nazývá *metoda nejmenších čtverců* (angl. *the method of least squares*).