

# Výběr modelu, ROC křivka

Návod ke cvičení

Jan Hrdlička, hrdlij1@fel.cvut.cz

ZS 2010/2011

## 1 Úvod

Cílem tohoto cvičení je seznámit se způsobem výběru modelu na základě ROC analýzy. Seznámit se s ROC křivkou a způsobem jejího výpočtu. V závěru je zmíněna plocha pod křivkou, její významem pro výběr modelu a také její pravděpodobnostní interpretace.

### 1.1 ROC křivka

ROC (Receiver operating characteristic) křivka je založena na kontingenční tabulce správného resp. špatného zařazení pozitivního nebo negativního vzorku:

	Pos examples	Neg examples	
Predicted positive	TP	FP	→ PPV
Predicted negative	FN	TN	→ NPV
	↓ TPR	↓ FPR	

#### Terminologie:

TP: True positive, zásah

TN: True negative, správné zamítnutí

FP: False positive, falešný alarm, chyba 1. typu

FN: False negative, minutí, chyba 2. typu

TPR: True positive rate, Sensitivita =  $TP/(TP+FN)$

FPR: False positive rate, 1-Specifičnost =  $FP/(TN+FP)$

PPV: Positive Predictive Value =  $TP/(TP+FP)$

NPV: Negative Predictive Value =  $TN/(TN+FN)$

Mějme klasifikátor (test, model), který se snaží zařadit příklady do dvou tříd, negativní resp. pozitivní  $C \in \{0; 1\}$  a má spojitý výstup  $Y$ .

Tento výstup porovnáváme s prahem  $\theta$  a podle výsledku zařadíme příklad (provedeme rozhodnutí D) na vstupu jako pozitivní nebo negativní.

$$D = \begin{cases} 1 & \text{if } Y > \theta \\ 0 & \text{if } Y \leq \theta \end{cases} \quad (1)$$

Křivka ROC je pak grafickým znázorněním závislosti TPR na FPR pro měnící se práh  $\theta$ , její příklad je v m-file tohoto cvičení.

## 1.2 Plocha pod křivkou (Area Under the Curve)

Plocha pod ROC křivkou (AUC) je jedním z kritérií pro výběr vhodného klasifikátoru (modelu) a určuje kvalitu separace tříd v daném modelu resp. schopnost separace tříd daným klasifikátorem. AUC má také pravděpodobnostní interpretaci. Při dvou náhodně vybraných vzorcích, z nichž jeden je pozitivní  $C_i = 1$  a druhý negativní  $C_j = 0$ , je AUC pravděpodobnost, že výstup klasifikátoru  $Y_i$  u prvního vzorku je větší než výstup  $Y_j$  odpovídající druhému vzorku.

$$AUC = P\{Y_i > Y_j\}; \quad (2)$$

## 2 Zadání

### 2.1 Data

V první sekci jsou vygenerována data do dvou tříd, které nejsou plně separabilní. Každá třída má trojrozměrné normální rozdělení určené sřední hodnotou. Rozptyl je stejný pro všechny dimenze i obě třídy a je roven jedné. Experimentujte s různými nastaveními parametrů.

### 2.2 Klasifikátory, ROC křivka a AUC

K dispozici jsou 2 klasifikátory :

- Naivní Bayes předpokládající normální rozdělení dat. Jeho výstup je posteriorní pravděpodobnost příslušnosti k třídě.

- Jednoduchý klasifikátor, který pouze seče naměřené hodnoty ve všech rozměrech.

Po vybrání trénovací množiny a naučení Naivního Bayese (odhadnutí parametrů pravěpodobnostního rozdělení dat) jsou na základě výstupů z klasifikátorů zkonztruovány ROC křivky a z nich je poté spočtena přibližnou integrací AUC. Který klasifikátor je úspěšnější a proč? Jaký bod na ROC křivce byste zvolili pro konkrétní klasifikaci a proč?

### 2.3 ROC convex hull

K dispozici jsou 4 klasifikátory, které odhadnou u jednotlivých vzorků příslušnost ke třídě:

- Naivní Bayes předpokládající normální rozdělení dat.
- Rozhodovací strom
- k-Nearest Neighbors algoritmus
- Klasifikátor, rozhodující se na základě Mahalanobisovy vzdálenosti

Každý z klasifikátorů odhadne příslušnost vzorků testovací množiny. Na základě těchto rozhodnutí se spočte TPR a FPR a vynesou se do grafu. ROC convex hull je pak konvexní křivka začínající v bodě [0 0], jdoucí přes "úspěšnější" klasifikátory a končící v bodě [1 1]. Na této křivce jsou klasifikátory, které jsou nejúspěšnější pro různá vychýlení dat (toto vychýlení může být způsobeno rozdílnou apriorní pravděpodobností příslušnosti ke třídám, ale také různými cenami klasifikačních chyb).

### 2.4 ROC křivka z křížové validace

V další sekci je ROC křivka spočtená z 5-fold křížové validace. Křížová validace je v tomto případě prováděna na trénovací množině z předchozích sekcí. ROC křivka se získá tak, že po provedení křížové validace sloučíme výstupy klasifikátoru všech  $n$  testovacích množin (pro  $n$  běhů křížové validace) a z nich zkonztruujeme průměrnou ROC křivku. Tento způsob je algoritmicky snazší, ovšem předpokládá znalost konkrétních výstupů klasifikátoru, nejen odhady chyb.

## **Reference**

- [1] **Fawcett T.: An introduction to ROC analysis**  
Pattern Recognition Letters, 861-874, 2006