



Rozpoznávanie



Koeficienty kvality klasifikácie

Funkcia náhodného výberu


Náhodná premenná



Očakávaná hodnota koeficientu

Nie tréningová chyba, ale testovacia

Odhad testovacej chyby na časti dostupných dát




Validačná (testovacia) množina dát, ktorá sa nepoužije na tréningovanie

Vzájomná validácia

Rozdeľ dáta na K skupín $\{X_1, X_2, \dots, X_K\}$

Každú skupinu použi na validáciu


Zisti priemernú chybu



$$E = \frac{1}{K} \sum_{i=1}^K E_i$$

Náhodné prevzorkovanie

dáta sa z pôvodnej množiny do testovacej
vyberajú náhodne, bez vrátenia naspäť



K-násobná vzájomná validácia

pôvodnú množinu rozdelíme na K rovnako veľkých podmnožín



Vrstvená K-násobná vzájomná validácia


množinu dát X rozdelíme tak, aby podmnožiny zachovávali distribúciu jednotlivých tried



Vzájomná validácia s vynechaním jednej vzorky

testujeme na jedinej vzorke

K-násobná vzájomná validácia, kde K je rovné počtu vzoriek



K záleží na velikosti množiny

Pre veľmi veľké množiny


$K=3$ postačuje

Pre veľmi malé množiny

validácia s vynechaním jednej vzorky

Najviac sa používa

$K=10$




Bootstrap

N vzoriek

Trénovacia množina: N vzoriek – náhodný výber (s opakovaním)

Testovacia množina: vzorky, ktoré sa nevyskytujú v trénovacej množine

K opakovaní



VV – výber bez opakovania

Alternatívny názov 0,632 bootstrap

Vzorka A má pravdepodobnosť, že ju nevyberieme do trénovacej množiny

$$1 - 1/N$$

Vyberáme N krát, teda pravdepodobnosť, že vzorka skončí v testovacej množine je

$$\left(1 - \frac{1}{N}\right)^N \approx e^{-1} = 0,368$$

Teda trénujeme na 63,2% dát

Chybová funkcia klasifikátora

Niektoré chyby klasifikácie môžu byť drahšie (majú horšie následky) ako iné

Príklad:

neodhalenie smrteľnej choroby, ktorá by sa dala ľahko liečiť liekmi, ktoré nemajú vedľajšie účinky. Teda neklasifikovanie choroby v prípade chorého človeka má horšie následky ako nasadenie liekov u zdravého človeka.

Skutočnosť \ Rozhodnutie	Neliečiť	Liečiť
Zdravý	Spávne	Malé vedľajšie účinky
Chorý	Smrteľná choroba	Správne

rôzne typy chýb:
nesprávne pozitívna klasifikácia
nesprávne negatívna klasifikácia

Skutočnosť objekt sa	Rozhodnutie - objekt sa	
	vyskytuje	nevyskytuje
vyskytuje	Správna klasifikácia Správne pozitívny výsl.	Chyba typu II Nesprávne negatívny výsl.
nevyskytuje	Chyba typu I Nesprávne pozitívny výsl.	Správna klasifikácia Správne negatívny výsl.

Cena za správne rozhodnutie: 0

Cena za nesprávne: 1 (alebo iná kladná konštanta)

funkcia straty

$$L(s, a) : S \times A \rightarrow \mathbb{R}_0^+$$

S \ A	nádor	čisté
nádor	0	1000
čisté	1	0

S \ A	tvár	nie tvár
tvár	0	1
nie tvár	1	0

$$L(s, a) = 1 - \delta_{sa}$$

$$R_\omega(\mathbf{x}) = \sum_{\psi \in A} L(\omega, \psi) P(\psi | \mathbf{x})$$

očakávaná podmienená stratu pri klasifikácii vzorky $\mathbf{x}$ patriacej triede ω


$$R = \sum_{\omega \in S} \int_{\mathcal{R}_\omega} R_\omega(\mathbf{x}) d\mathbf{x} = \sum_{\omega \in S} \sum_{\psi \in A} \int_{\mathcal{R}_\omega} L(\omega, \psi) P(\psi | \mathbf{x}) d\mathbf{x}$$

Celková očakávaná podmienená strata pri použití klasifikátora

Koeficienty kvality klasifikácie

Citlivost' testu

$$TPR = \frac{TP}{TP + FN}$$




Výlučnost testu

$$TNR = \frac{TN}{TN + FP}$$

$$FPR = \frac{FP}{FP + TN} = 1 - TNR$$


Prediktívna hodnota

$$PPH = \frac{TP}{TP + FP}$$

$$NPH = \frac{TN}{TN + FN}$$


Účinnost'

$$Eff = \frac{TP + TN}{TP + FP + TN + FN}$$




F1 skóre


$$F_{\beta} = \frac{(1 + \beta^2)(PPH.TPR)}{\beta^2 PPH + TPR}$$



$$F_1 = \frac{2PPH.TPR}{PPH + TPR}$$

ROC krivky




ROC curve






ROC krivka zo vzájomnej validácie – priemer jednotlivých ROC kriviek



AUC hodnota – integrál ROC krivky




$$CR = \frac{AUC_1 - AUC_2}{Std(AUC_1 - AUC_2)}$$

Rozpätie	Stupnica
0,5 – 0,6	zlyhávajúci
0,6 – 0,7	slabý
0,7 – 0,8	priemerný
0,8 – 0,9	dobrý
0,9 – 1,0	vynikajúci

Rozpätie	Stupnica
0,5 – 0,75	priemerný
0,75 – 0,92	dobrý
0,92 – 0,97	veľmi dobrý
0,97 – 1,0	vynikajúci

ROC krivka len po hodnotu $FPR = t_0$


t_0 – maximálna tolerovaná
hodnota FPR



Príklad: portréty

ANN – jeden výstupný neurón
hodnoty $<0,1>$ - prah

Model predicted	Portrait	Non-portrait
Ground truth		
Portrait	<i>TP</i>	<i>FN</i>
Non-portrait	<i>FP</i>	<i>TN</i>



$$\text{True positive rate} = \frac{\text{number of images correctly classified as portraits}}{\text{total number of portrait images in the set}}$$

$$\text{False positive rate} = \frac{\text{number of images falsely classified as portraits}}{\text{total number of non-portrait images in the set}}.$$

McNemarov test


Pre oba klasifikátory (K1, K2) učíme nasledovné hodnoty

n_{00} : počet vzoriek správne klasifikovaných oboma klasifikátormi

n_{01} : počet vzoriek správne klasifikovaných K1 ale nesprávne K2

n_{10} : počet vzoriek nesprávne klasifikovaných K1 ale správne K2

n_{11} : počet vzoriek nesprávne klasifikovaných oboma klasifikátormi



n_{00}	n_{01}
n_{10}	n_{11}

$$M = \frac{(|n_{01} - n_{10}| - 1)^2}{n_{01} + n_{10}}$$

χ^2 s jedným stupňom volnosti

Ak $M > 3.84$, potom s 95% spoľahlivosťou môžeme zamietnuť nulovú hypotézu, že oba klasifikátory majú rovnakú chybovosť


Viac tried

4 → 4	2 → 2	3 → 3
4 → 4	9 → 9	0 → 0
5 → 5	7 → 7	1 → 1
9 → 9	0 → 0	3 → 3
6 → 6	7 → 7	4 → 4

Matica zámen

číslica	klasifikácia										
	1	2	3	4	5	6	7	8	9	0	R
1	87	0	0	0	1	0	0	0	0	0	0
2	0	88	1	0	0	0	0	0	1	1	1
3	0	0	75	1	0	0	0	10	4	0	3
4	0	0	0	79	0	0	0	0	0	0	0
5	0	0	0	0	79	6	0	0	0	4	1
6	0	0	0	0	8	80	1	0	0	2	0
7	0	1	0	0	0	0	83	0	0	0	0
8	0	0	15	0	0	1	0	65	7	0	0
9	0	0	4	0	0	0	0	10	71	0	1
0	0	0	0	1	0	1	0	0	0	90	1

Špeciálna trieda *R* – zamietnutie každej triedy



percentuálny podiel v jednotlivých triedach

vizualizácia pomocou teplotnej mapy

Several-Class Problem

		Prediction					
		c_1	c_2	c_3	$\dots$	c_n	Total
Actual	c_1	TP_1	FN_{12}	FN_{13}	$\dots$	FN_{1n}	N_1
	c_2	FN_{21}	TP_2	FN_{23}	$\dots$	FN_{2n}	N_2
	c_3	FN_{31}	FN_{32}	TP_3	$\dots$	FN_{3n}	N_3
	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
	c_n	FN_{n1}	FN_{n2}	FN_{n3}	$\dots$	TP_n	N_n
Total		$\hat{N}_1$	$\hat{N}_2$	$\hat{N}_3$	$\dots$	$\hat{N}_n$	N

http://www.icmla-conference.org/icmla10/CFP_Tutorial_files/jose.pdf

<http://rali.iro.umontreal.ca/rali/sites/default/files/publis/SokolovaLapalme-JIPM09.pdf>