




# Hodnocení výkonnosti klasifikátoru





# Matice záměn



	Předvídaný pozitivní	Předvídaný negativní	Přesnost podle tříd (rate)
Skutečně pozitivní	a	b	<b>TPR</b> = $a / (a + b)$ <b>senzitivita</b> $FNR = b / (a + b)$
Skutečně negativní	c	d	<b>TNR</b> = $d / (c + d)$ <b>specifická</b> $FPR = c / (c + d)$ fr.falešných alarmů

**Přesnost (accuracy)** =  $(a + d) / (a + b + c + d)$

Skut./ předv.	⊕	⊗	
⊕	30	20	<b>50</b>
⊗	10	40	<b>50</b>
	<b>40</b>	<b>60</b>	<b>100</b>

**pos** =  
 $= (a + b) / (a + b + c + d)$ ,  
 t.j. frekvence skutečně pozitivních ve všech příkladech

Skut./ předv.	⊕	⊗	
⊕	60	20	<b>80</b>
⊗	10	10	<b>20</b>
	<b>70</b>	<b>30</b>	<b>100</b>

$accuracy = pos * TPR + neg * TNR$



# Příklad permissivního spam filtru,

který nic nepovažuje za spam

$$\textit{Accuracy} = (a + d) / (a + b + c + d)$$

99% je skvělá, ale model je k ničemu!

Skut./ předv.	⊕	⊗	
⊕	0	10	<b>10</b>
⊗	0	990	<b>990</b>
	<b>0</b>	<b>1000</b>	<b>1000</b>

**Precisnost** (*důvěra, konfidence, precision*)

$$= a / (a + c)$$

„podíl správně klasifikovaných objektů ve všech příkladech klasifikovaných jako ⊕“ se používá jako doplňující informace k **TPR** v případě velmi nerovnoměrného poměru mezi *Pos* a *Neg*.

V uvedeném příklade ani to opatření nepomůže!



# Příklad spam filtru

**Accuracy** =  $(a + d) / (a + b + c + d)$   
99,2%

**Precisnost** (*důvěra, konfidence, precision*)  
=  $a / (a + c)$  ... 66,6 %

**tpr** = 40 %      **tnr** = 98,8 %

**Accuracy** = 99,2 %

**Precisnost** = 55,6 %


**tpr** = 100 %      **tnr** = 99,5 %

Skut./ předv.	⊕	⊗	
⊕	4	6	<b>10</b>
⊗	2	988	<b>990</b>
	<b>6</b>	<b>994</b>	<b>1000</b>

Skut./ předv.	⊕	⊗	
⊕	10	0	<b>10</b>
⊗	8	982	<b>990</b>
	<b>18</b>	<b>982</b>	<b>1000</b>

# Coverage plot

Nástroj pro vizualizaci výkonu klasifikátoru „po klas. Třídách“:  
 Klasifikátor **C1** **dominuje** nad **C2**,  
 pokud **C1** je lepší než **C2** na  
 obou třídách,  $TPR1 = a / (a + b) > TPR2$   
 a  $FPR1 = c / (c + d) < FPR2$



**C1**

Skut./ předv.	⊕	⊗	
⊕	30	20	<b>50</b>
⊗	10	40	<b>50</b>
	<b>40</b>	<b>60</b>	<b>100</b>

**C2**


Skut./ předv.	⊕	⊗	
⊕	20	30	<b>50</b>
⊗	20	30	<b>50</b>
	<b>40</b>	<b>60</b>	<b>100</b>

# Coverage plot

Lze poznat v použitém znázornění, kdy má klasifikátor **C4** stejnou **přesnost** (*accuracy*) jako **C2** ?

$$accuracy = (a+d)/(a+b+c+d)$$

Je-li výkon **C2** charakterizován tabulkou a), pak zvýší-li klasifikátor **C4** o  $x$  počet **True\_Positive**, může **C4** dosáhnout stejné přesnosti jako **C2** pouze v případě, že počet **True\_Negative** je o  $x$  menší, viz tab. b)





a)

C2 Skut/ předv.	⊕	⊗	
⊕	a	b	Pos
⊗	c	d	Neg
			<b>N</b>

b)

C3 Skut/ předv.	⊕	⊗	
⊕	$a+x$	$b-x$	Pos
⊗	$c+x$	$d-x$	Neg
			<b>N</b>




Přesvědčili jsme se, že klasifikátory, jejichž spojnice má na „coverage plot“ směrnici 1, mají stejnou přesnost !

Mají-li **C1** a **C3** stejnou přesnost, který z nich je lepší? Je-li důležitější **TPR**, pak **C3** !



# Nerovnoměrné zastoupení tříd





I zde platí, že klasifikátory, jejichž spojnice má na „coverage plot“ směrnici 1, mají stejnou přesnost !

Co znamená, že spojnice klasifikátorů **C1** a **C3** je na „coverage plot“ rovnoběžná s diagonálou?

**C1** a **C3** mají stejnou **průměrnou přesnost** (average recall), tj.  $(\mathbf{a}/(\mathbf{a}+\mathbf{b}) + \mathbf{c}/(\mathbf{c}+\mathbf{d})) / 2$  ! Proč?






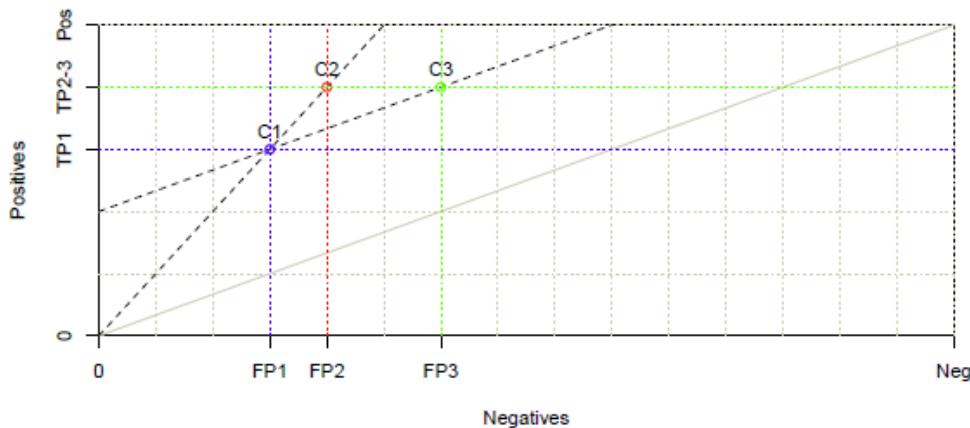
Jak srovnávat výkon klasifikátorů nad různými testovacími množinami s nerovnoměrným zastoupením tříd?



# Nerovnoměrné zastoupení tříd?



Vhodným řešením je **normalizace**, tj. hodnoty na osách budou **TPR** a **FPR**. Výsledkem je **ROC zobrazení**.



U **ROC** platí, že klasifikátory, jejichž spojnice má směrnici


- ❖ **Neg/Pos**, mají stejnou **(celkovou) přesnost**
- ❖ **1**, mají stejnou **průměrnou přesnost**: Pro libovolný bod na této přímce platí  $tpr = y_0 + fpr = y_0 + (1 - tnr)$ , z čehož plyne  $tpr + tnr = (y_0 + 1) \rightarrow$  hodnota stejná pro vš.body přímky.

Takovým přímkám se říká **isomery**

# Křivka ROC (Receiver Operating Char.)



	Předvídaný pozitivní	Předvídaný negativní	Přesnost podle tříd (rate)
Skutečně pozitivní	a	b	<b>TPR</b> = $a / (a + b)$ <b>senzitivita</b> $FNR = b / (a + b)$
Skutečně negativní	c	d	<b>TNR</b> = $d / (c + d)$ <b>specifičnost</b> $FPR = c / (c + d)$



**Přesnost =**  
 $(a+d)/(a+b+c+d)$



**Jak vybrat parametr tak, aby klasifikátor dosahoval nejvyšší možné (průměrné) přesnosti?**  
Pomohou vlastnosti isomér z předchozího snímku!





# Křivka ROC (Receiver Operating Char.)



- ❖ Srovnání modelů neprovádíme v jediném bodě
- ❖ **Vhodné u modelů, které přímo neklasifikují, ale odhadují pravděpodobnost příslušnosti k některé ze tříd.**
- ❖ Např. mějme klasifikační algoritmus, který predikuje **pravděpodobnost příslušnosti k pozitivní třídě  $p(\mathbf{x}(i))$** . O diskrétní klasifikaci rozhoduje parametr  $\theta$  pro hodnotu prahu:
  - ❖ Je-li pro objekt  $i$  hodnota  $p(\mathbf{x}(i)) > \theta$ , zařadíme objekt popsaný vektorem nezávislých veličin  $\mathbf{x}(i)$  mezi pozitivní příklady,
  - ❖ je-li menší, označíme jej jako negativní.




# Příklad konstrukce ROC křivky



Predikce	0	0,05	0,2	0,22	0,3	0,31	0,4	0,42	0,7	0,8
Skutečná třída	0	0	1	0	1	0	0	1	1	1

Křivka ROC vznikne vypočtením hodnot  $TP$  a  $FP$  pro **všechny různé prahy**  $\theta$ : 0, 0,01; 0,1; ..; 0,75

Užitečnost různých hodnotících funkcí lze hodnotit pomocí parametru **AUC** = „plocha pod křivkou“





# Může ROC křivka pomoci při konstrukci lepších klasifikátorů?



Existuje klasifikátor, který dominuje klasifikátoru **C0** a má přitom *TPR* nejméně 0,8?

Ano, lze jej zkonstruovat jako klasifikátor kombinující rozhodnutí **C1** s pravděpodobností  $\alpha$  a **C2** s pravděpodobností  $(1 - \alpha)$ :

- pro  $\alpha = 1$  je výsledný klasifikátor totožný s **C1**,
- pro  $\alpha = 0$  zase **C2**.

Tato kombinace dává všechny možnosti na spojnici bodů **C1** a **C2** – můžeme tedy pracovat s **konvexním obalem** původní ROC křivky, na kterém nalezneme vhodnou hodnotu.

