



# Hodnocení výkonnosti klasifikátoru



# Matrice záměn



	Předvídaný pozitivní (+)	Předvídaný negativní (X)	Frekvence podle tříd (rate)
Skutečně pozitivní (+)	<b>a</b>	<b>b</b>	<b>TPR = a/(a + b) senzitivita</b> <b>FNR = b/(a + b)</b>
Skutečně negativní (X)	<b>c</b>	<b>d</b>	<b>TNR = d/(c + d) specificita</b> <b>FPR = c/(c + d)</b>

$$\text{celková\_správnost (accuracy)} = (a + d) / (a + b + c + d)$$

$$\text{TPR} + \text{FNR} = 1, \text{TNR} + \text{FPR} = 1$$

Předv. skut.	(+)	(X)	Σ	<i>pos</i> = (a+b)/(a+b+c+d), <i>neg</i> = (c+d)/(a+b+c+d),  t.j. frekvence skutečně pozitivních/ negativních ve všech příkladech	Předv. skut.	(+)	(X)	Σ
(+)	30	20	50		(+)	30	20	50
(X)	10	40	50		(X)	10	40	50
Σ	40	60	100		Σ	40	60	100

$$\text{celková\_správnost} = \text{pos} * \text{TPR} + \text{neg} * \text{TNR}$$

# † Příklad permissivního spam filtru,



který nic nepovažuje za spam

**Celková\_správnost = Accuracy**

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

99% je skvělá, ale model je k ničemu!

Předv. Skut.	+	X	Σ
+	0	10	10
X	0	990	990
Σ	0	1000	1000

**Přesnost** (*důvěra, konfidence, precision*) =  $a / (a + c)$

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

V uvedeném příklade ani použití přesnosti nepomůže! Lepší charakteristika je

**Úplnost** (*recall*) = **senzitivita** =  $a / (a + b)$ , zde **Úplnost** = 1

**Senzitivita a specificita se běžně používají v lékařství:**

**Senzitivita** =  $a / (a + b)$  „na kolik skutečně nemocných lék zabere“

**Specificita** =  $d / (c + d)$  „jak moc zabírá lék i na zdravé“

# Příklad spam filtru



$$\begin{aligned}
 \textit{Accuracy} &= (a + d)/(a + b + c + d) \\
 &= 992/1000 = 99,2\%
 \end{aligned}$$

$$\begin{aligned}
 \textit{Přesnost} \text{ (důvěra, konfidence, precision)} \\
 &= a/(a + c) \dots = 4/6 = 66,6\%
 \end{aligned}$$

$$\textit{tpr} = 40\% \quad \textit{tnr} = 99,8\%$$

$$\textit{Accuracy} = 99,2\%$$

$$\textit{Přesnost} = 55,6\%$$

$$\textit{tpr} = 100\% \quad \textit{tnr} = 99,2\%$$

Předv. Skut.	+	X	Σ
+	4	6	10
X	2	988	990
Σ	6	994	1000

Který z obou filtrů je lepší?

Předv. Skut.	+	X	Σ
+	10	0	10
X	8	982	990
Σ	18	982	1000

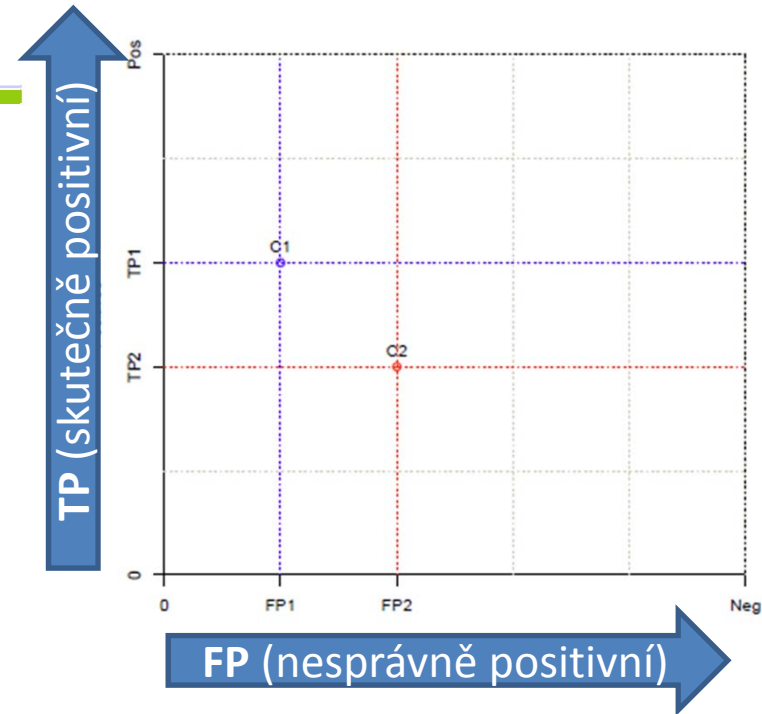
# Křivka pokrytí (coverage plot)

Nástroj pro vizualizaci výkonu klasifikátoru „po klas.třídách“ **TPR** i **FPR** :

Klasifikátor **C1** **dominuje** nad **C2**, když **C1** je **lepší** než **C2** na obou třídách, tj.

$$a / (a + b) = \mathbf{TPR1} > \mathbf{TPR2}$$

a  $c / (c + d) = \mathbf{FPR1} < \mathbf{FPR2}$



**C1**

Předv. Skut.	+	X	Σ
+	30	20	50
X	10	40	50
Σ	40	60	100


**C2**

Předv. Skut.	+	X	Σ
+	20	30	50
X	20	30	50
Σ	40	60	100

# Graf pokrytí

Lze poznat v použitém znázornění, kdy má klasifikátor **C4** pro stejná data stejnou **správnost** (*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 správnosti jako **C2** (pro **nezměněné hodnoty Pos, Neg** a **N**) pouze v případě, že počet **TNegative** je o  $x$  menší a **FP** o  $x$  větší, viz tab. b)



a)

	Předv. Skut.	+	X	$\Sigma$
C2	+	$a$	$b$	Pos
	X	$c$	$d$	Neg
	$\Sigma$			N

b)

	Předv. Skut.	+	X	$\Sigma$
C4	+	$a + x$	$b - x$	Pos
	X	$c + x$	$d - x$	Neg
	$\Sigma$			N

# Některé vlastnosti graf pokrytí





Přesvědčili jsme se, že klasifikátory, jejichž spojnice má na křivce pokrytí směrnici 1, mají stejnou správnost !

Mají-li **C1** a **C3** stejnou správnost, který z nich je lepší?

Je-li důležitější **TPR**, pak **C3** !




Lze použít graf pokrytí i v případě různé velikosti množin pozitivních a negativních příkladů ?



Jak srovnávat výkon klasifikátorů nad různými testovacími množinami, ve kterých je **nerovnoměrné zastoupení tříd** ?



# Nerovnoměrné zastoupení tříd



I zde platí, že klasifikátory **C1** a **C2**, jejichž spojnice má na grafu pokrytí směrnici 1, mají **stejnou správnost** !

Co znamená, že spojnice klasifikátorů **C1** a **C3** je na v grafu pokrytí **rovnoběžná s diagonálou**?

Takové **C1** a **C3** mají stejnou **průměrnou přesnost** (average recall) vzhledem k oběma klasifikačním třídám, tj.

$$(a/(a+b) + d/(c+d)) / 2 !$$

**Proč je tato hodnota stejná?**



# Nerovnoměrné zastoupení klasifikačních tříd a graf pokrytí

Předpokládejme, že chceme srovnat výkon 2 klasifikátorů **C1** a **C3** na jediné skupině klasifikovaných dat množnosti **N**, ve které je **Pos** pozitivně klasifikovaných příkladů a **Neg** negativně a platí, že **Pos** a **Neg** jsou různé a platí **Pos + Neg = N**. Je-li výkon **C1** charakterizován tabulkou a), pak zvýší-li klasifikátor **C4** o **x** počet **TP** oproti **C1**, může součet **Pos** být zachován jen v případě, že **FN** bude o **x** nižší, viz tabulka b). Podobně v zroste-li **FP** o **y**, musí **TN** o **y** klesnout, aby zůstala zachována hodnota **Neg**.

a)

Předv.	+	X	Σ
Skut.			
+	A	b	Pos
X	c	d	Neg
Σ			N

b)

Předv.	+	X	Σ
Skut.			
+	a + x	b - x	Pos
X	c + y	d - y	Neg
Σ			N

$$\text{Průměrná\_přesnost}(\mathbf{C3}) = 0,5 * ((a+x)/(a+b) + (d-y)/(c+d)) =$$


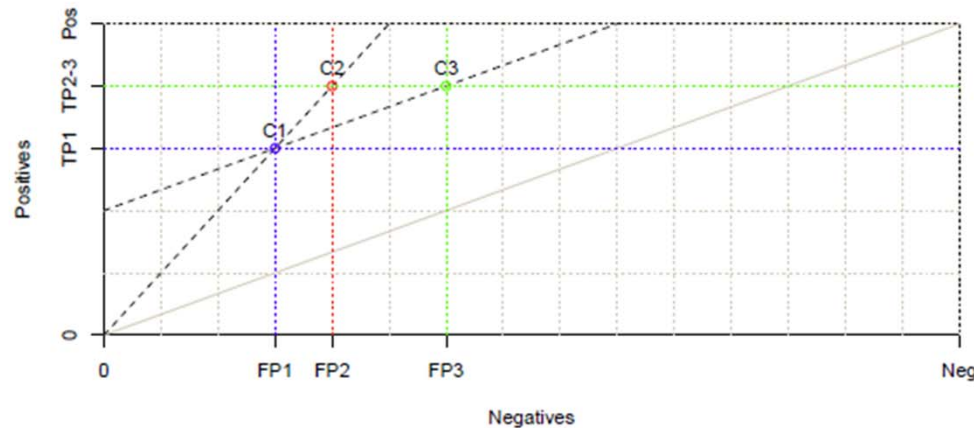
$$= 0,5*((a/(a+b)+d/(c+d)) + (x/(a+b)-y/(c+d))) = \mathbf{P\_p}(\mathbf{C1}) + 0,5* (x/(a+b)-y/(c+d))$$

Pokud  $x/(a+b)-y/(c+d) = 0$ , pak  $\text{Prům\_přesnost}(\mathbf{C3}) = \text{Prům\_přesnost}(\mathbf{C1})$ . To nastává právě když  $x/y = (a+b)/(c+d) = \mathbf{Pos/Neg}$ , tedy spojnice obrazů **C1** a **C3** je rovnoběžná s diagonálou v grafu pokrytí.

# Znázornění při nerovnoměrném zastoupení tříd?



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



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

❖ **Neg/Pos**, mají stejnou **správnost (celkovou přesnost)**


❖ **1**, mají stejnou **průměrnou přesnost**: Pro libovolný bod na takové přímce platí  $tpr = y_0 + fpr = y_0 + (1 - tnr)$ , z čehož plyne  $tpr + tnr = (y_0 + 1)$ . Z toho vyplývá, že **průměrná přesnost** je stejná pro všechny body přímky.

Takovým přímkám se říká **isomery**

# Křivka ROC (Receiver Operating Char.)



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



**správnost =**  
 $(a+d)/(a+b+c+d)$

- Vypočtené výkony klasifikátorů
- Isoméry rovnoběžné s přímkou mezi body (0,0) a (1,1).

**Jak vybrat parametr tak, aby klasifikátor dosahoval nejvyšší možné správnosti?**  
**Správný výběr** prostřednictvím isoméru (viz předchozí snímek).

# 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**.

Pro různé hodnoty  $\theta$  vzniknou různé klasifikátory. Jak volit hodnotu  $\theta$  tak, aby správnost algoritmu byla co nejvyšší?



# Příklad konstrukce ROC křivky



Pro  $\theta = 0,22$  je

TP=4, tedy TPR=0,8

FP=2, tedy FPR=0,4

Pro  $\theta = 0,3$  je

TP=3, tedy TPR=0,6

FP=2, tedy FPR=0,4

Pro  $\theta = 0,31$  je

TP=3, tedy TPR=0,6

FP=1, tedy FPR=0,2

Pro  $\theta = 0,4$  je

TP=3, tedy TPR=0,6

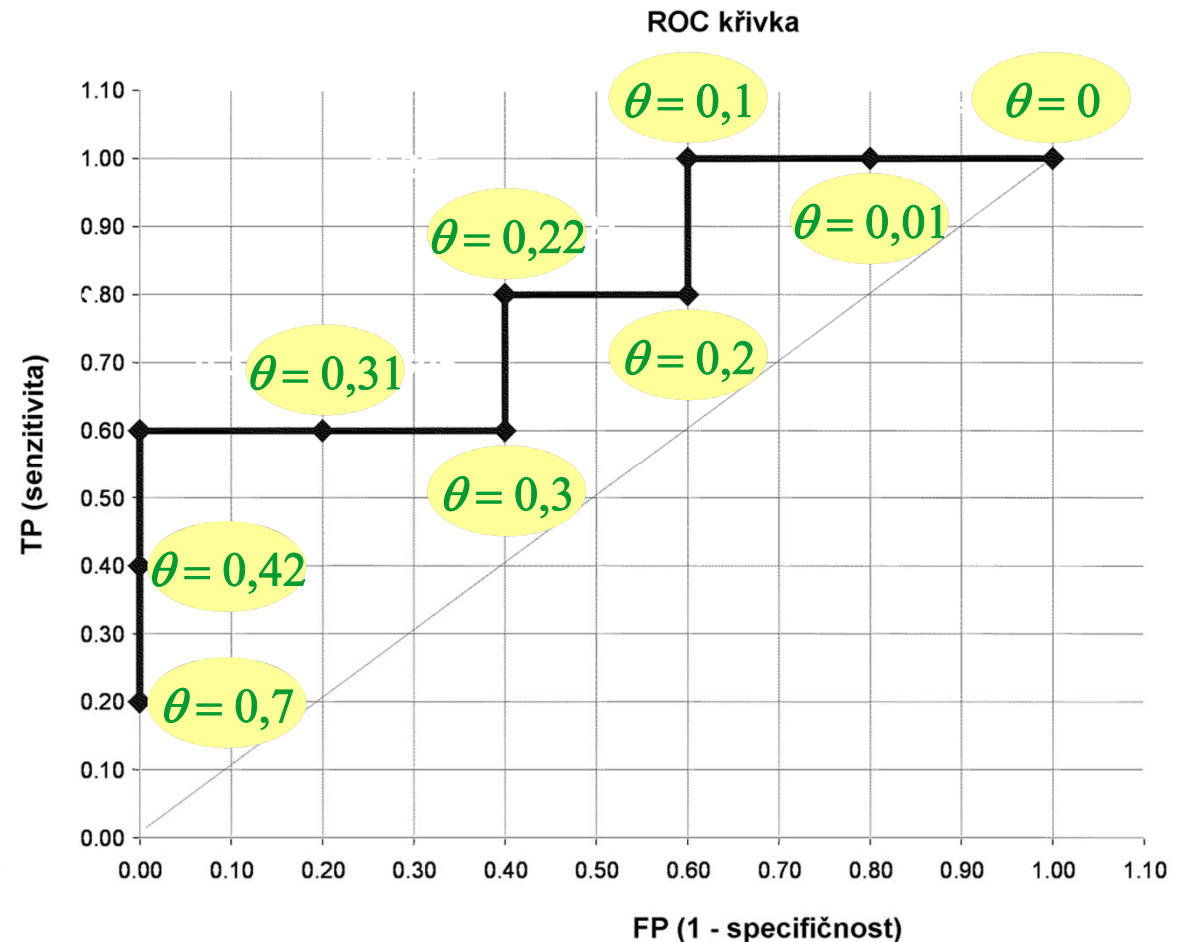
FP=0, tedy FPR=0

objekt	1	2	3	4	5	6	7	8	9	10
predikce	0	0,05	0,2	0,22	0,3	0,31	0,4	0,42	0,7	0,8
skutečnost	0	0	1	0	1	0	0	1	1	1

Pozit. klas. pro  $\theta = 0,22$

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

Užitečnost různých hodnotících funkcí (dávajících predikci) lze srovnávat podle jejich parametru **AUC** = „plocha pod křivkou“.



# Může ROC křivka pomoci při konstrukci lepších klasifikátorů?

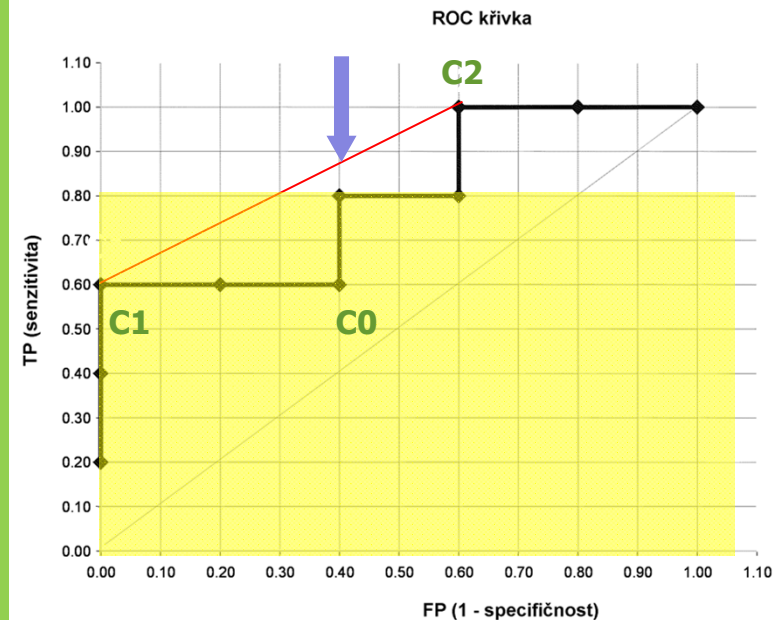


Existuje klasifikátor, který dominuje klasifikátoru **C0** a má přitom *TPR* nejméně 0,8?

**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.



Doporučení pro volbu  $\alpha$  :

$$\alpha = (FP2 - FP0) / (FP2 - FP1)$$