




Hodnocení výkonnosti klasifikátoru





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

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

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

Pos je frekv. skutečně ⊕ ve všech příkladech

Skut./předv.	⊕	⊗	
⊕	60	15	75
⊗	10	15	25
	40	60	100

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

— Příklad přísného web vyhledávače



Přecisnost (*důvěra, konfidence, precision*)

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

Skut./ předv.	⊕	⊗	
⊕	0	1	1
⊗	0	999	999
	0	999	1000

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

V uvedeném příklade ani to opatření nepomůže!

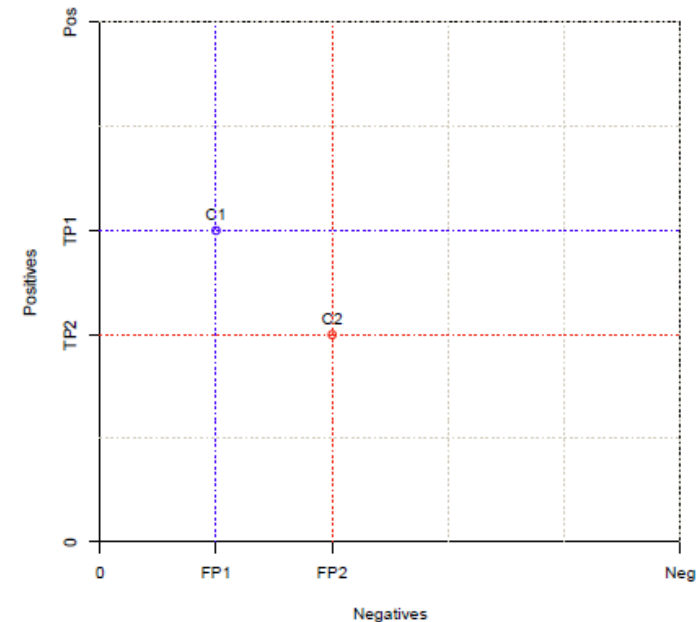
Coverage plot



Nástroj pro vizualizaci výkonu

klasifikátoru „po klas. třídách“

Klasifikátor **C1** **dominuje** nad **C2**,
pokud **C1** je lepší než **C2** na
obou třídách



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


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

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
			N

b)


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



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** !

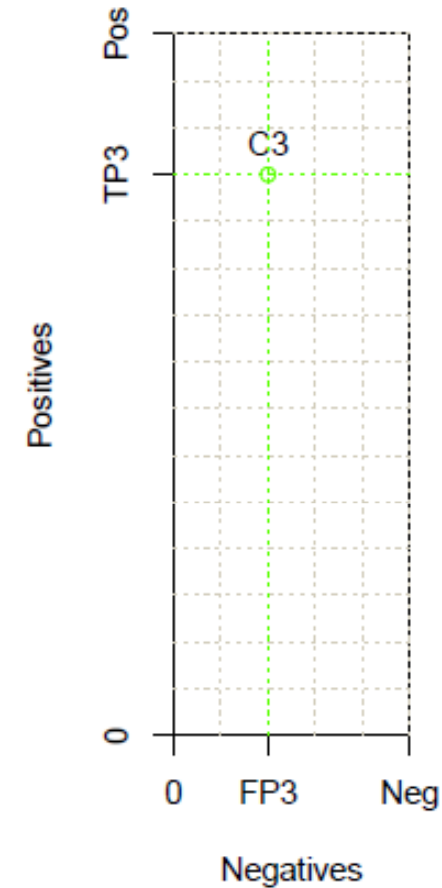

Nerovnoměrné zastoupení tříd



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) !


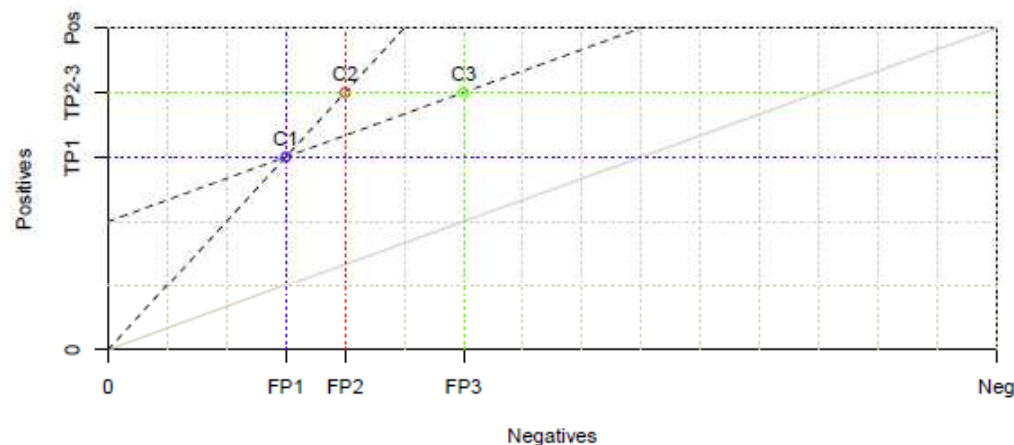


Jak srovnávat výkon klasifikátorů nad různými testovacími množinami s nerovnoměrným zastoupením tříd?

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

- ❖ **1**, mají stejnou **průměrnou přesnost**
- ❖ **Neg/Pos**, mají stejnou **(celkovou) přesnost**

Křivka ROC (Receiver Operating Char.)



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



Celková přesnost = $(a+d)/(a+b+c+d)$

- Reálný klasifikátor s různými hodnotami parametrů
- Náhodný klasifikátor

Jak vybrat parametr tak, aby klasifikátor dosahoval nejvyšší přesnosti?

Stačí využít informace o tom, že obrazy klasifikátorů o stejné přesnosti jsou spojeny čarou o směrnici 1.

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 θ 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

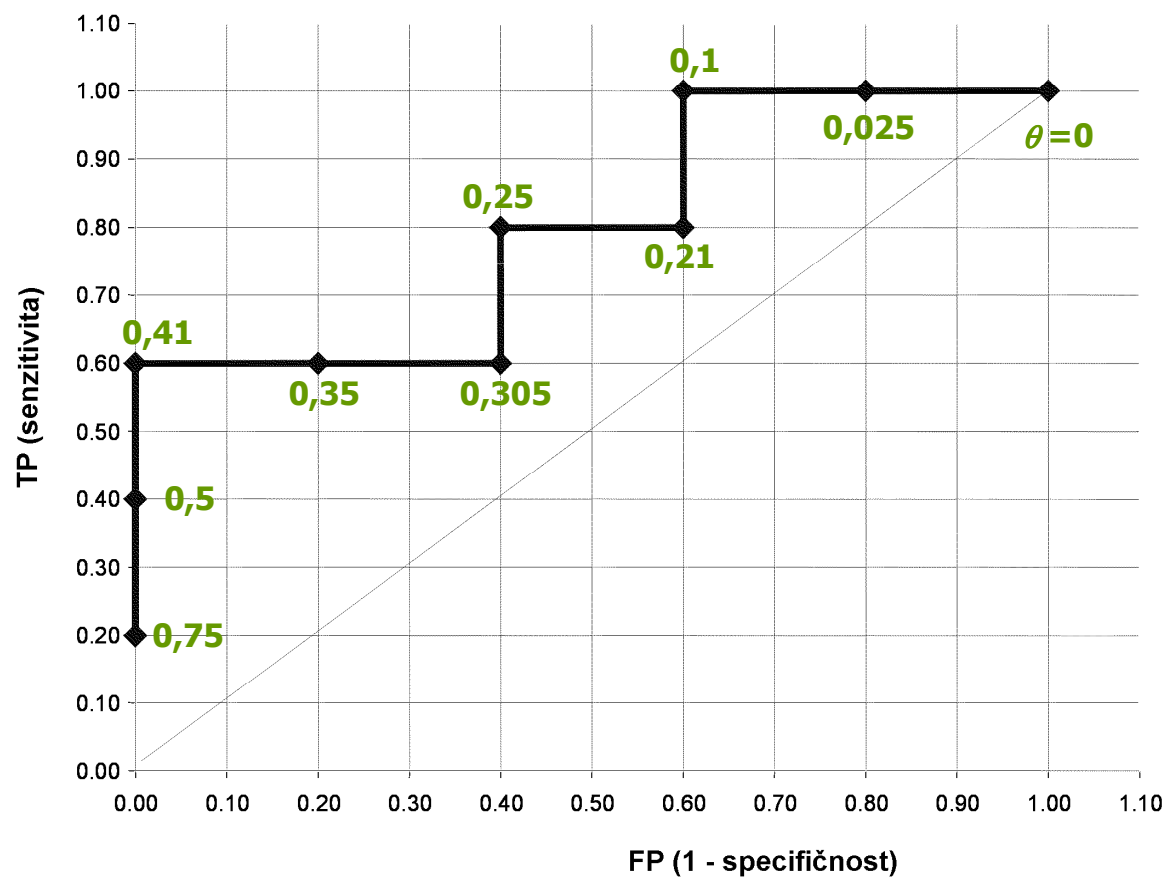


Predikce	0	0,05	0,2	0,22	0,3	0,31	0,4	0,42	0,7	0,8
Skutečná třída	0	0	1	0	1	0	0	1	1	1

Křivka ROC vznikne vypočtením hodnot TP a FP pro **všechny různé prahy θ** : 0,025; 0,1; ..; 0,75

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

ROC křivka



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 α 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.

