

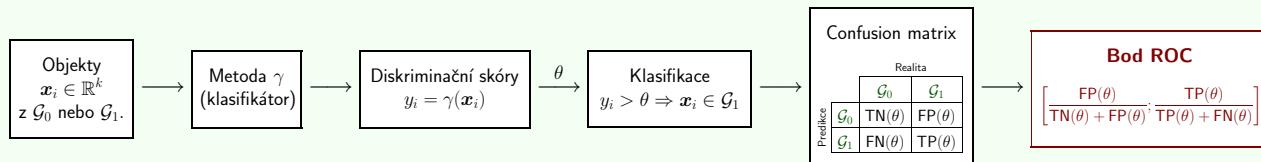
Poznámky k ROC křivkám

Martin Betinec & Luboš Prchal

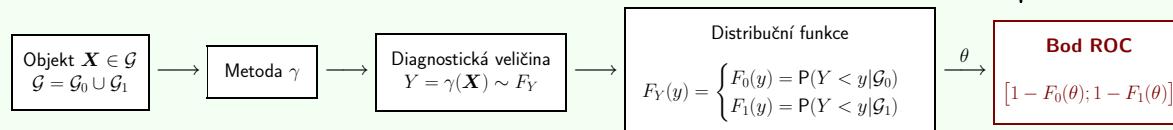
betinec@matfyz.cz & prchal@karlin.mff.cuni.cz

Tento poster je věnován vybraným otázkám, jež se týkají statistické analýzy ROC křivek, resp. užití ROC křivek např. v klasifikaci. Nejprve však náš dvojí pohled na samotnou ROC křivku:

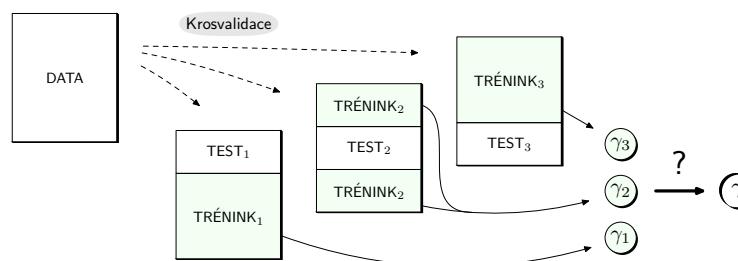
a) Bod ROC křivky jako míra úspěšnosti klasifikace – aplikovaný přístup



b) Bod ROC křivky jako vztah dvou distribucí – teoretický přístup



ROC křivka je množina ROC bodů pro všechny hodnoty $\theta \in \mathbb{R}$ – charakterizuje chování klasifikátoru.



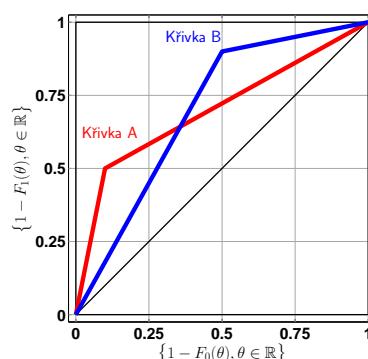
#1 Odhad ROC křivky

Většina složitějších klasifikátorů (metod γ) musí projít fází **učení** z trénovacích dat. Testovací soubor následně slouží k ověření kvality nastavení klasifikátoru.

- Každé trénování (na části dat) však typicky vyústí v jiné **nastavení** klasifikátoru – v **jiný klasifikátor** – $\gamma_1, \gamma_2, \gamma_3$.
- Z testovací fáze tudíž pro jednotlivé γ_i dostaneme rozdílné ROC křivky.

Lze na základě získaných ROC křivek hodnotit globální chování uvažované metody?

U křivek rovnocenných dle kvantit. kritérií (AUC, vzdálenost od bodu $[0, 1]$) záleží na preferencích.



#2 Shoda ROC křivek

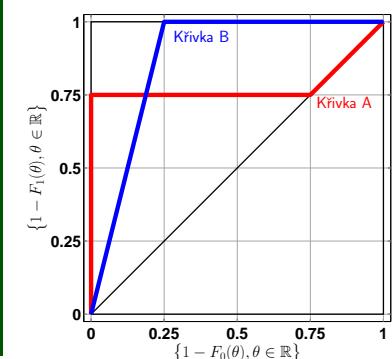
Pracujeme-li s různými metodami, jejichž kvalitu měříme ROC křivkami, vyvstává základní otázka: **Jsou ROC křivky odpovídající použitým metodám shodné?**

Některá užívaná kritéria:

- Vzdálenost od bodu $[0, 1]$
- AUC – Area Under Curve
- Preference uživatele – konzervativní × liberální metoda

Lze kombinací uvedených kritérií rozhodnout o shodě, resp. významné odlišnosti, dvou ROC křivek?

Považujeme-li TP rate $\leq 75\%$ za dostatečný, lze metodu *A* preferovat, přestože $AUC_B > AUC_A$,



#3 Výběr prediktorek

Nech je analyzovaný objekt popsán k prediktory. **Mějme** pravidlo (související s metodou γ), jak postupně odstraňovat nejméně významné prediktory.

Předpokládejme, že vyřazením **nevýznamného** prediktora **nedoje** k významné změně ROC křivky, a naopak při vyřazení **podstatného** prediktora se ROC křivka změní.

Lze analýza ROC křivek přispět k optimálnímu výběru prediktorek vzhledem ke klasifikaci?

