

Interpretace a evaluace

1. Deskriptivní úlohy

kritériem novost, zajímavost, užitečnost a srozumitelnost

Kvalitativní hodnocení:

- zřejmé znalosti, které jsou ve shodě se „zdravým selským rozumem“
- zřejmé znalosti, které jsou ve shodě se znalostmi experta z dané oblasti
- nové, zajímavé znalosti, které přinášejí nový pohled
- znalosti, které musí expert podrobit bližší analýze, neboť není zcela jasné co znamenají
- „znalosti“, které jsou v rozporu se znalostmi experta

Kvantitativní hodnocení:

- např. spolehlivost a podpora u asociačních pravidel pozor, ne vše co je statisticky významné je i zajímavé !

2. Klasifikační úlohy

kritériem úspěšnost klasifikace na datech

Testování modelů:

- testování v celých trénovacích datech
- křížová validace (cross-validation)
- leave-one-out
- bootstrap
- testování na testovacích datech

Cílem je zjistit v kolika případech došlo ke shodě resp. neshodě modelu (systému) s informací od učitele

Matice záměn (confusion matrix)

		Klasifikace systémem	
Správné zařazení		+	-
+	+	TP	FN
	-	FP	TN

- Celková správnost resp. celková chyba (overall accuracy a error)

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

$$\text{Err} = \frac{\text{FP} + \text{FN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

celková správnost $\in [\text{Acc}_{\text{def}}, \text{Acc}_{\text{max}}]$

kde

Acc_{def} ... správnost při klasifikaci všech příkladů do majoritní třídy
 Acc_{max} ... maximální možná správnost pro daná data

Chyba bez ceny

$$\text{Err} = 1 - \text{Acc}$$

Chyba s cenami

$$\text{Err} = \text{FP} * c(P,n) + \text{FN} * c(N,p)$$

- Správnost pro jednotlivé třídy

$$\text{Acc}_+ = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

$$\text{Acc}_- = \frac{\text{TN}}{\text{TN} + \text{FN}}$$

vhodnější při „nevývážených“ třídách

- Přesnost a úplnost (precision a recall)

$$\text{Přesnost} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

$$\text{Úplnost} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

lze kombinovat do tzv. F-míry

$$F = \frac{2 * \text{přesnost} * \text{úplnost}}{\text{přesnost} + \text{úplnost}} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}}$$

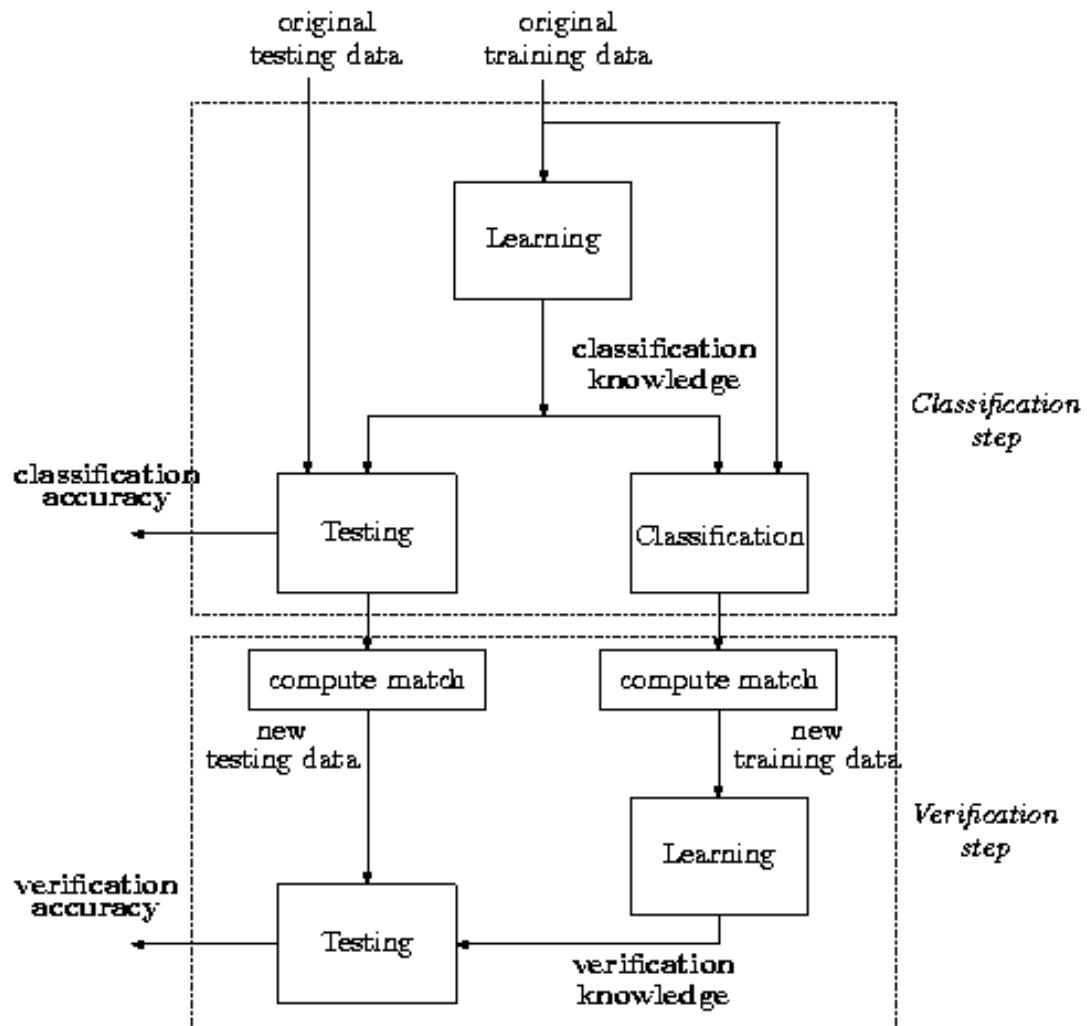
- Senzitivita a specificita (sensitivity a specificity)

$$\text{Senzitivita} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

$$\text{Specificita} = \frac{\text{TN}}{\text{TN} + \text{FP}}$$

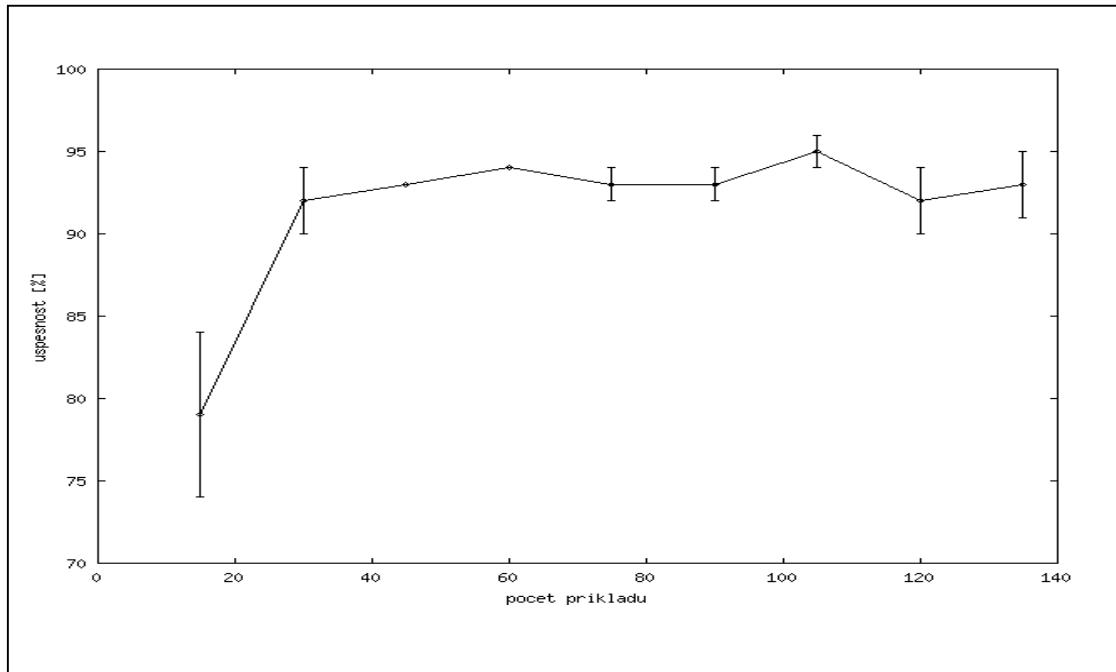
Spolehlivost klasifikace na základě meta-učení

informace o správnosti klasifikace jako nový atribut

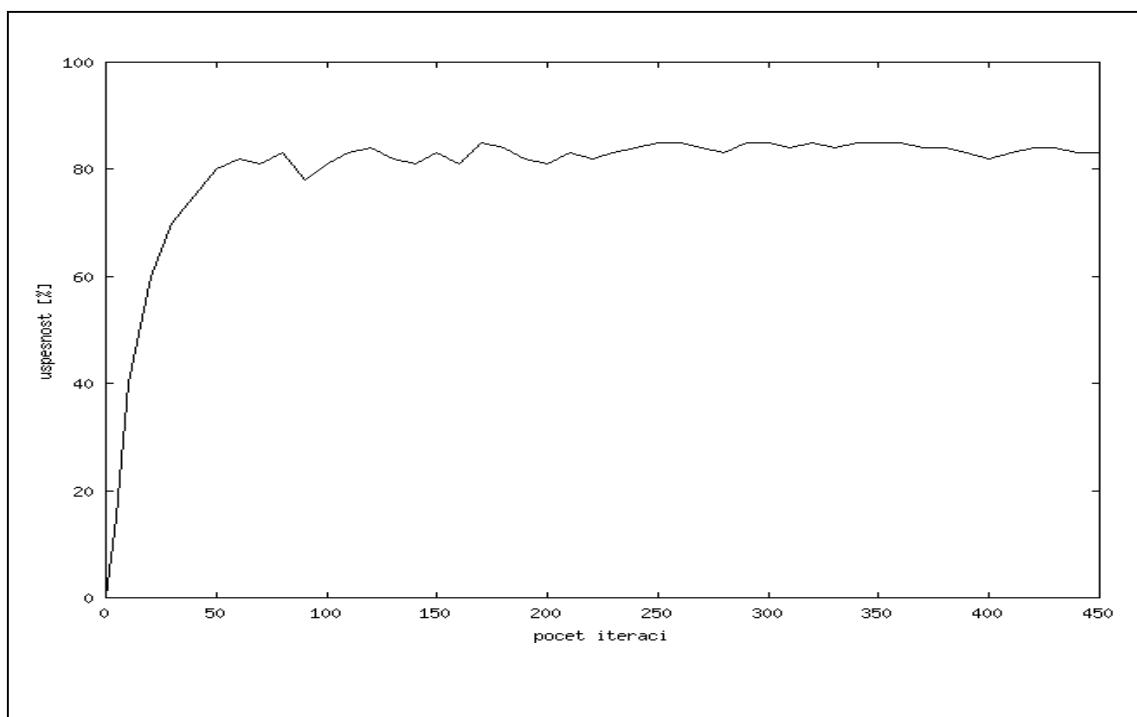


- Křivka učení (learning curve)

Vztah mezi úspěšností klasifikace a počtem příkladů

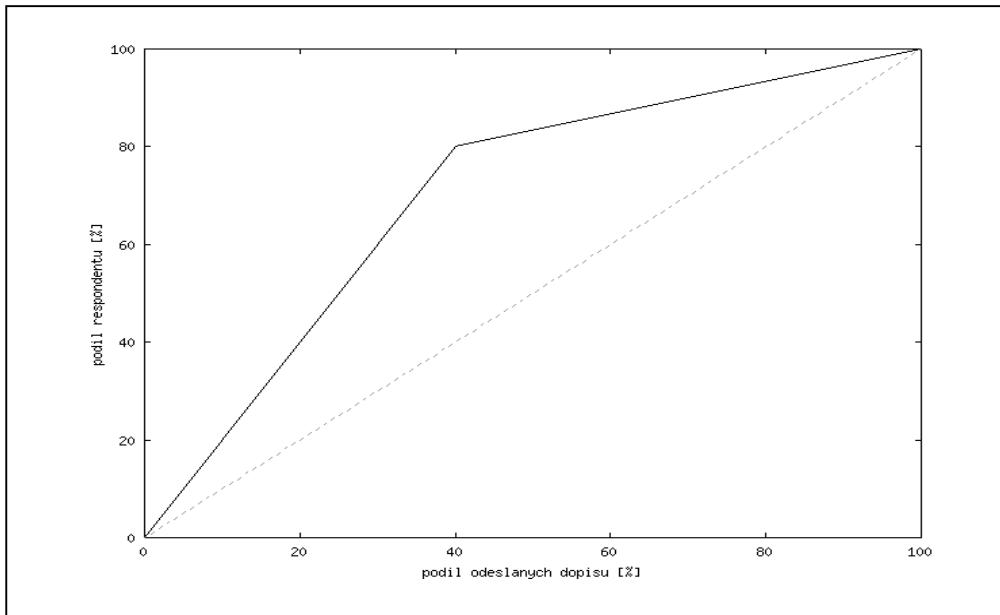


Vztah mezi úspěšností klasifikace a počtem iterací



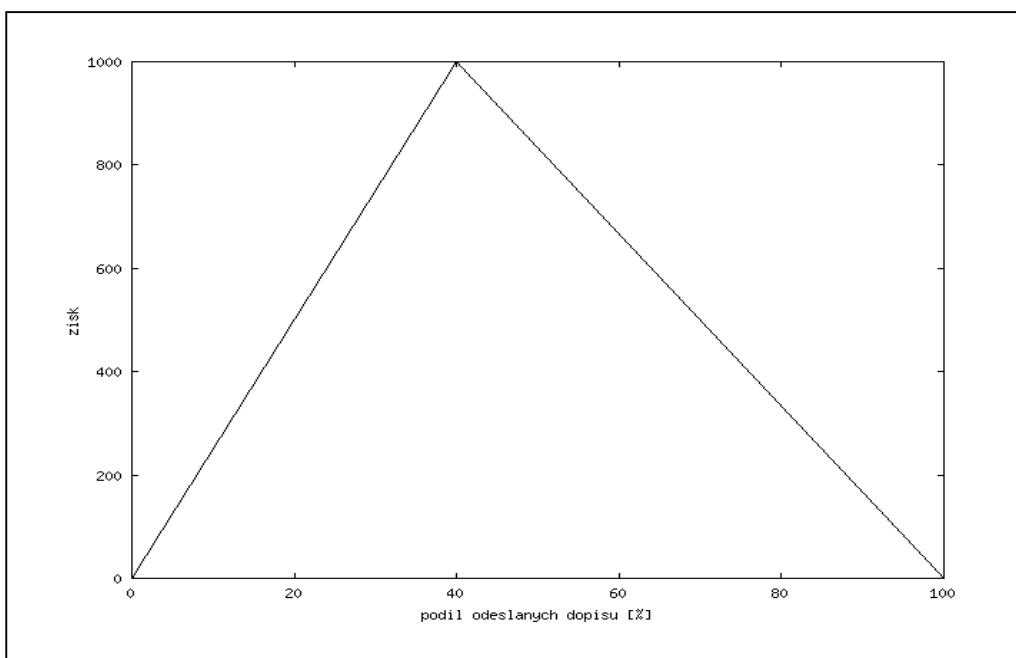
- Křivka navýšení (lift curve)

Vztah mezi počtem úspěšných klasifikací a váhou klasifikace



- Křivka návratnosti investic (ROI curve)

Vztah mezi ziskem z úspěšných klasifikací a váhou klasifikace



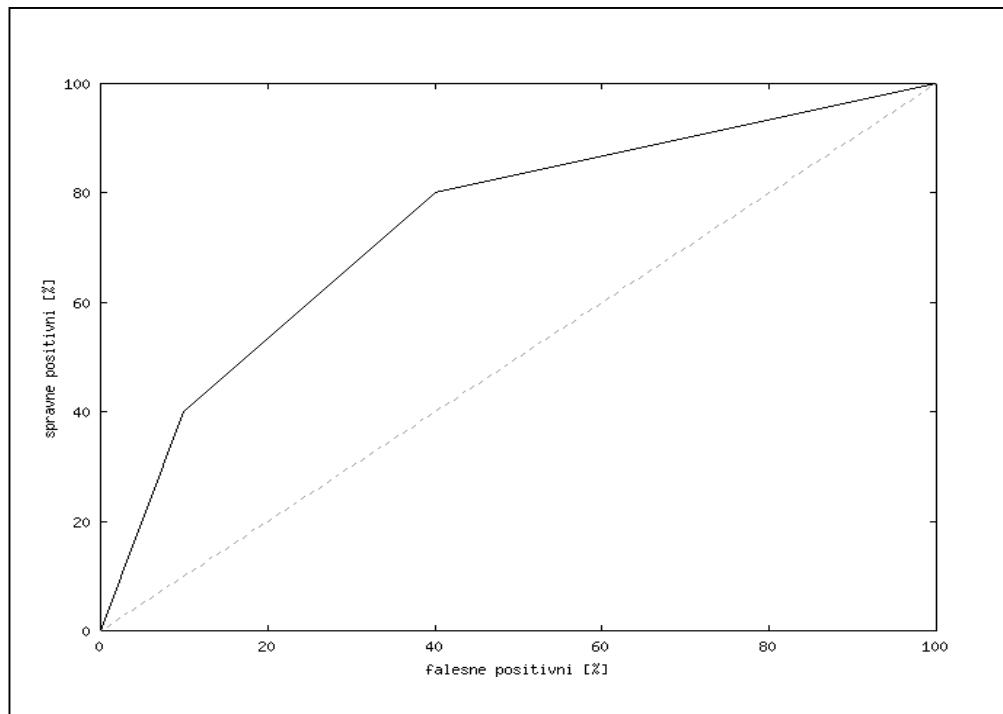
- Křivka ROC

Vztah mezi TP a FP pro různá nastavení klasifikátoru

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

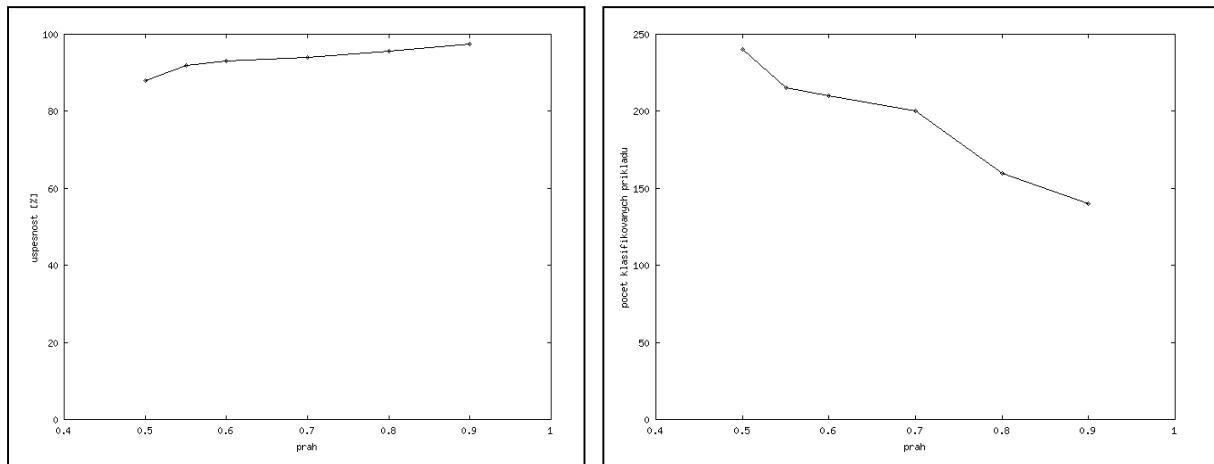
$$FP\% = \frac{FP}{FP + TN}$$

$TP\%$ = Senzitivita, $1 - FP\%$ = Specificita



Varianta (KEX)

Závislosť správnosti a počtu rozhodnutí na prahu α ,
rozhodnutí, jen když $w \geq \alpha$



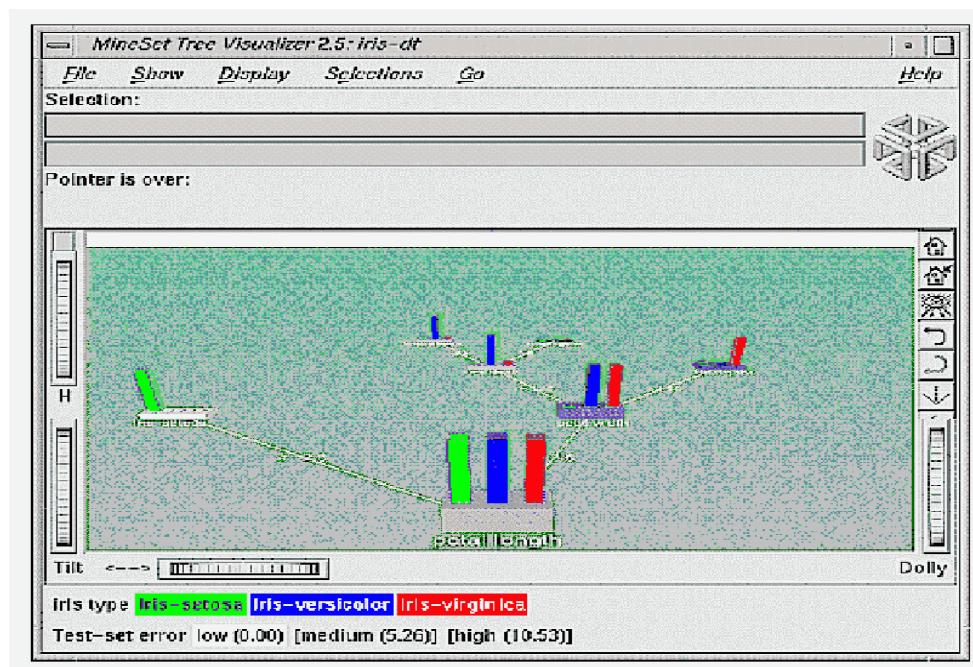
Numerické třídy (p_i predikovaná hodnota a s_i skutečná hodnota)

- $MSE = \frac{(p_1-s_1)^2 + \dots + (p_n-s_n)^2}{n}$
- $RMSE = \sqrt{\frac{(p_1-s_1)^2 + \dots + (p_n-s_n)^2}{n}}$
- $MAE = \frac{|p_1-s_1| + \dots + |p_n-s_n|}{n}$
- $RSE = \frac{(p_1-s_1)^2 + \dots + (p_n-s_n)^2}{(s_1-s')^2 + \dots + (s_n-s')^2} ,$
kde $s' = \frac{\sum_i s_i}{n}$
- $\rho = \frac{S_{ps}}{\sqrt{S_p^2 S_s^2}} ,$
kde $S_{ps} = \frac{\sum_i (p_i - p')(s_i - s')}{n-1} , \quad S_p^2 = \frac{\sum_i (p_i - p')^2}{n-1} ,$
 $S_s^2 = \frac{\sum_i (s_i - s')^2}{n-1}$

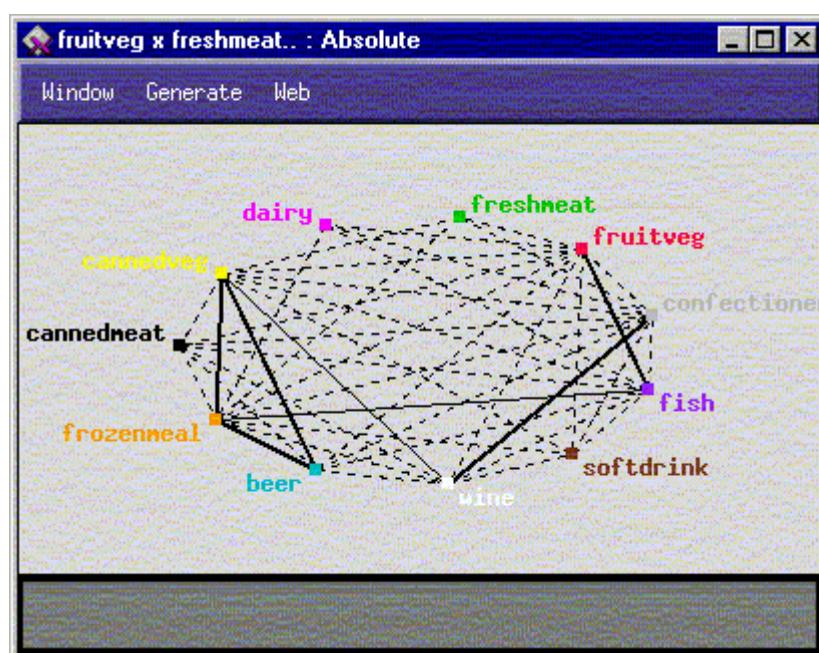
Vizualizace

1. Vizualizace modelů

- Rozhodovací stromy (MineSet)



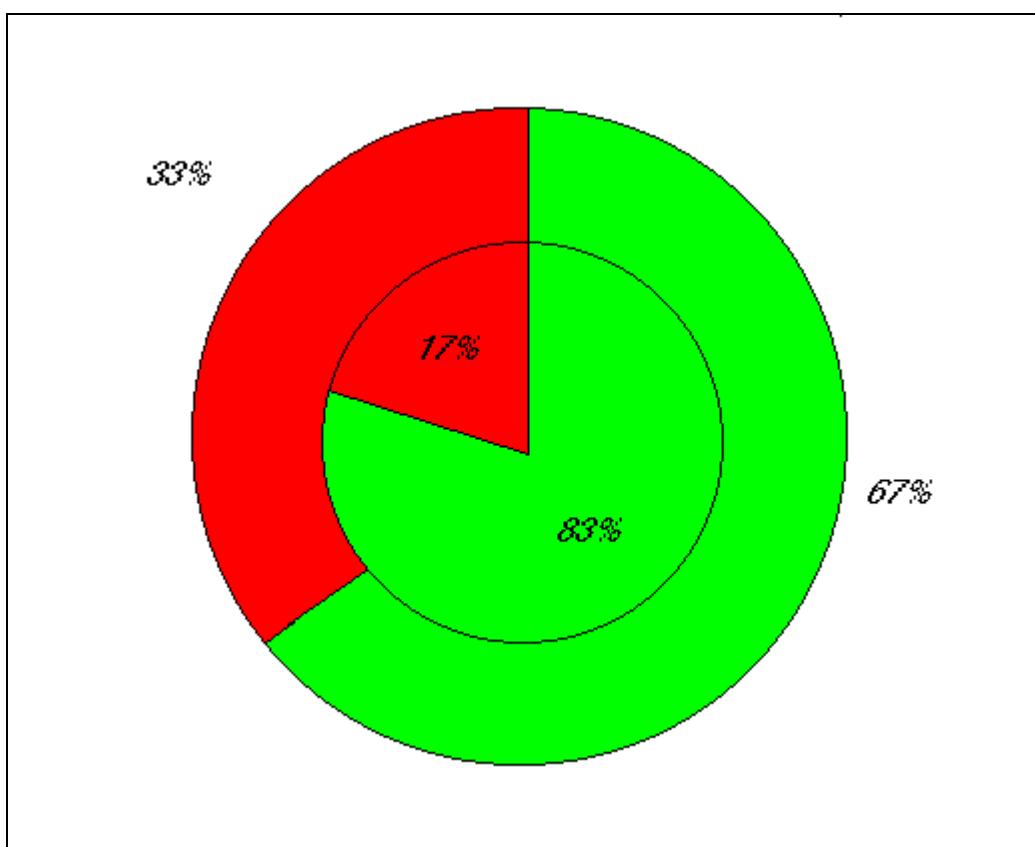
- Asociace (Clementine)



- Pravidlo

IF nezamestnany(ne) THEN uver(ano)

	uver(ano)	uver(ne)	
nezamestnany(ne)	5	1	6
nezamestnany (ano)	3	3	6
	8	4	12

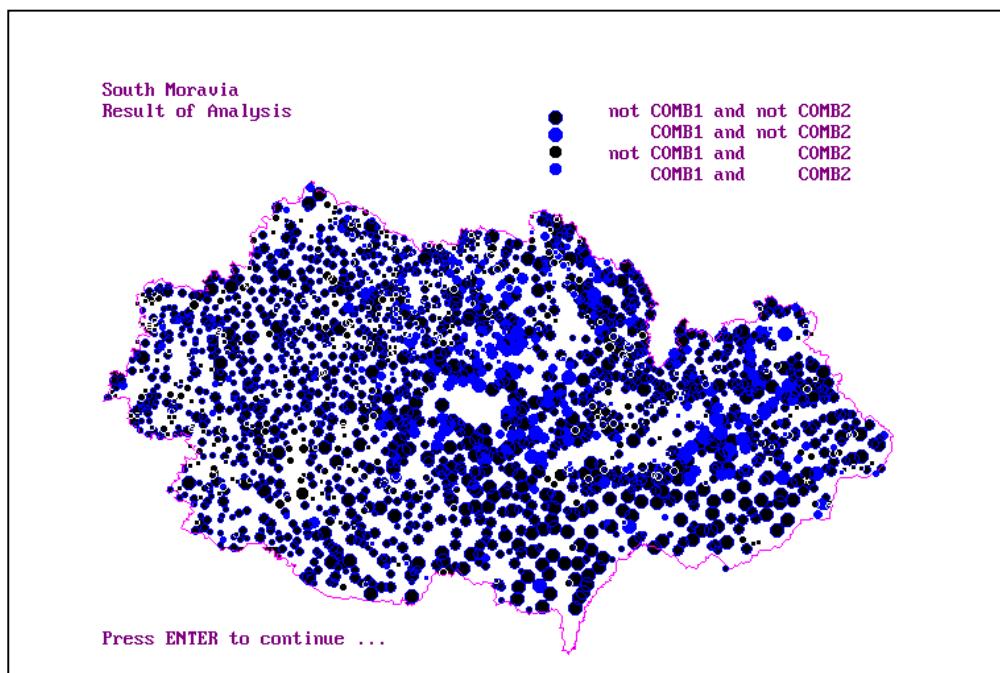


Vizualizace klasifikací

Obecné logické diagramy (Michalski)

Head Shape	Sinning	Has Tie	Holding									
round	yes	yes	swobal fb.									
	no	no	swobal fb.									
square	yes	yes	swobal fb.									
	no	no	swobal fb.									
octagon	yes	yes	swobal fb.									
	no	no	swobal fb.									
Body Shape	round	square	octagon	round	square	octagon	round	square	octagon	round	square	octagon
Jacket Color	red			yellow			green			blue		

spojení s GIS (KEX)



Porovnávání modelů

- T-test

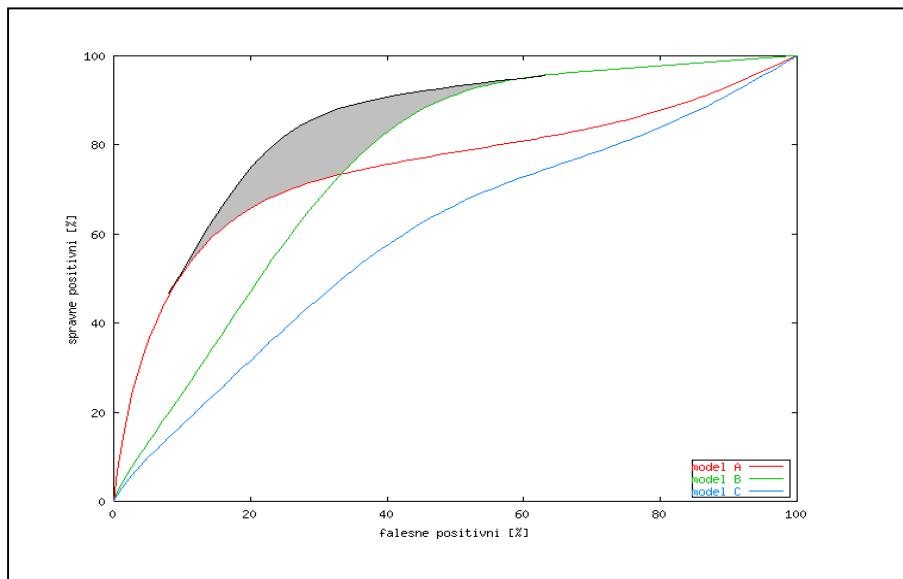
$$t(\mathbf{x}, \mathbf{y}) = \frac{x' - y'}{s(\mathbf{x}, \mathbf{y}) \sqrt{\frac{1}{m} + \frac{1}{n}}},$$

$$\text{kde } x' = \frac{\sum_i x_i}{m}, \quad y' = \frac{\sum_i y_i}{n} \quad \text{a} \quad s^2(\mathbf{x}, \mathbf{y}) = \frac{(m-1) s_x^2 + (n-1) s_y^2}{m+n-2}$$

Model A bude lepší než model B, pokud

$$t(\text{Acc}_A, \text{Acc}_B) \geq t(1 - \alpha/2, m + n - 2)$$

- ROC křivky



- Occamova břítva

minimum description length, MDL

Volba nevhodnějšího algoritmu

- charakteristiky algoritmů vs. charakteristiky dat
 - způsob reprezentace příkladů,
 - vyjadřovací síla,
 - schopnost práce s numerickými atributy,
 - schopnost práce se zašuměnými a chybějícími daty,
 - schopnost práce s maticí cen,
 - předpoklad nezávislosti mezi atributy,
 - ostrá vs. neostrá klasifikace
- empirické studie
Metaučení nad výsledky dosaženými jednotlivými systémy
 - STATLOG (1991-1994)
 - pro rozsáhlá data se hodí diskriminační analýza (lineární, kvadratická),
 - není velký rozdíl mezi „obyčejnou“ a logistickou diskriminační analýzou,
 - na rozsáhlých datech je nejpomalejší metoda k nejbližších sousedů,
 - použité algoritmy na tvorbu rozhodovacích stromů se chovaly zhruba stejně; nezdá se tedy, že by nějak zvlášť záleželo na kritériu pro volbu větvení,
 - neuronové sítě dávaly výborné výsledky u dat, kde se napoužívala matice cen.
 - METAL (2000 -)
 - důraz i na předzpracování

Kombinování modelů

různé varianty hlasování

- Bagging (bootstrap aggregating)
 - několik stejně velkých trénovacích množin pomocí náhodného výběru s opakováním (bootstrap)
 - všechny modely rovný hlas
- Boosting
 - následující model na data chybně klasifikovaná předcházejícím modelem
 - postupně se vytvářejí modely se stále větší váhou hlasu

AdaBoost algoritmus

učení

1. Přiřad' stejnou váhu všem trénovacím příkladům,
2. Pro každou iteraci (vytvářený model)
 - 2.1. Vytvoř model
 - 2.2. Spočítej chybu err na vážených datech
 - 2.3. If $err=0$ nebo $err \geq 0.5$ konec
 - 2.4. Pro každý příklad
 - If klasifikace je správně then váha $w=w*err/(1-err)$
 - 2.5. Normalizuj váhy příkladů (součet nových vah stejný jako součet původních)

klasifikace jednoho příkladu

1. Přiřad' váhy 0 všem třídám
2. Pro každý model
 - Přiřad' třídě určené modelem váhu $w=w-\log(err/1-err)$
3. Vydej třídu s nejvyšší váhou

- Stacking

rozpoznat spolehlivost jednotlivých modelů na základě meta učení

