



# ANALÝZA A KLASIFIKACE DAT



**prof. Ing. Jiří Holčík, CSc.**

# VI. SEKVENČNÍ KLASIFIKACE

# ZAČÍNÁME

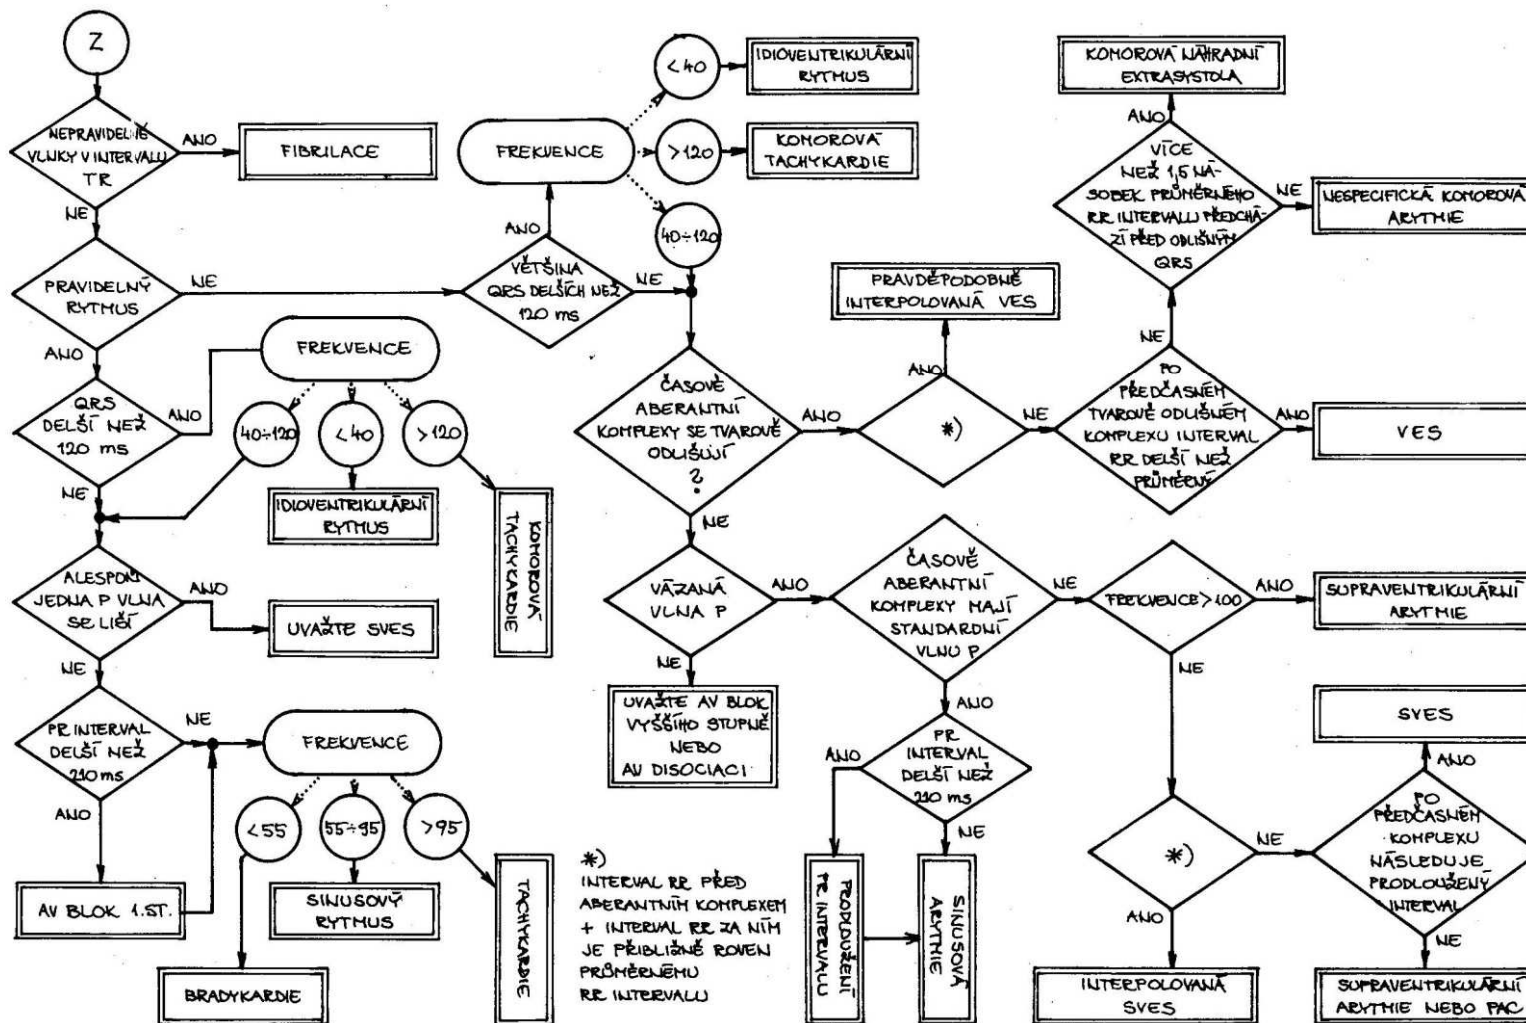
- ☑ až dosud (bayesovské klasifikátory, klasifikátory s diskriminační hranicí, s minimální vzdáleností, ...) – pevný konstantní počet příznaků
- ☑ kolik a jaké příznaky ?
  - málo příznaků – možná chyba klasifikace;
  - moc příznaků – možná nepřiměřená pracnost, vysoké náklady;
  - použít příznaky, které nesou co nejvíce informace o klasifikační úloze;

# ZAČÍNÁME

**sekvenční klasifikace** - kompromis mezi velikostí klasifikační chyby a cenou určení příznaků

→ klasifikace na základě klasifikačního stromu;

# ZAČÍNÁME




Rozhodovací strom pro klasifikaci rytmu signálu EKG

# ZAČÍNÁME

**sekvenční klasifikace** - kompromis mezi velikostí klasifikační chyby a cenou určení příznaků

- klasifikace na základě klasifikačního stromu;
- klasifikace s rostoucím počtem příznaků, přičemž okamžik ukončení klasifikační procedury stanoví klasifikátor sám podle předem daného kritéria pro kvalitu rozhodnutí (tj. na základě vlastností klasifikačních tříd, resp. obrazů v nich);

# PRINCIP



# WALDOVO KRITÉRIUM

- ☑ předpokládejme dichotomický klasifikátor obrazů popsaných příznakovými vektory  $(x_1, x_2, \dots)$ ;
- ☑ nechť  $p(x_1, x_2, \dots, x_i | \omega_1)$  a  $p(x_1, x_2, \dots, x_i | \omega_2)$  jsou  $i$ -rozměrné hustoty pravděpodobnosti výskytu obrazu  $\mathbf{x} = (x_1, x_2, \dots, x_i)$  v  $i$ -tém klasifikačním kroku v třídách  $\omega_1$  a  $\omega_2$ ;
- ☑ nechť  $A$  a  $B$  jsou konstanty ( $0 < B < 1 < A < \infty$ );



# WALDOVO KKRITÉRIUM

☑ pokud pro věrohodnostní poměr

$$\Lambda_i = \frac{p(x_1, x_2, \dots, x_i | \omega_1)}{p(x_1, x_2, \dots, x_i | \omega_2)}$$

je  $\Lambda_i \leq B$ , pak  $d_w(\mathbf{x}) = \omega_2$ , je-li  $\Lambda_i \geq A$ , pak  $d_w(\mathbf{x}) = \omega_1$ ; když  $\Lambda_i \in (B, A)$ , pokračujeme s dalším příznakem

# WALDOVO KRITÉRIUM

- ☑ jsou-li dány pravděpodobnosti chybné klasifikace

$$\alpha = \int_{\mathcal{R}_2} p(\mathbf{x} | \omega_1) d\mathbf{x} \quad \text{a} \quad \beta = \int_{\mathcal{R}_1} p(\mathbf{x} | \omega_2) d\mathbf{x}$$

můžeme určit meze A a B podle vztahů

$$A \cong \frac{1-\alpha}{\beta} \quad \text{a} \quad B \cong \frac{\alpha}{1-\beta}$$

# WALDOVO KKRITÉRIUM

## OPTIMALITA

- ☑ pro libovolné kritérium s pevným počtem  $n$  příznaků a s pravděpodobnostmi  $\alpha$  a  $\beta$  chybných rozhodnutí platí pro  $n$ , že je větší nebo rovno střední hodnotě počtu kroků podle W.k.;
- ☑ pro libovolné sekvenční kritérium je  $k$  rozhodnutí potřeba průměrný počet kroků větší než je průměrný počet kroků podle W.k.

# MODIFIKOVANÉ WALDOVO KRITÉRIUM

přes optimální vlastnosti Waldova kritéria může nastat:

- ☑ počet kroků potřebných k přijetí rozhodnutí může být pro některé obrazy příliš velký, i když střední hodnota počtu kroků pro všechny obrazy je nízká;
- ☑ střední hodnota počtu kroků potřebných k rozhodnutí může být příliš velká, požadujeme-li malé pravděpodobnosti chybných rozhodnutí;

# MODIFIKOVANÉ WALDOVO KŘITÉRIUM

## PRAXE

Po určitém počtu kroků se sekvenční výpočet přeruší a dokončí se na základě nějakého rozhodnutí vycházejícího z nějakého kritéria založeného na pevném počtu příznaků.

Přerušení:

- ☑ předepsaný počet kroků;
- ☑ zavedení proměnných hranic  $A(i)$  a  $B(i)$ .

# MODIFIKOVANÉ WALDOVO KŘITÉRIUM

Nechť  $A(i)$  a  $B(i)$  jsou nezáporné nerostoucí, resp. nekladné neklesající funkce počtu klasifikačních kroků.

Je-li  $\Lambda_i \leq e^{B(i)}$ , pak  $d_w(\mathbf{x}) = \omega_2$ , je-li  $\Lambda_i \geq e^{A(i)}$ , pak  $d_w(\mathbf{x}) = \omega_1$ ; když  $\Lambda_i \in (e^{B(i)}, e^{A(i)})$ , pokračujeme s dalším příznakem

# MODIFIKOVANÉ WALDOVO KKRITÉRIUM

## URČENÍ FUNKCÍ $A(i)$ A $B(i)$

- ☑ obvykle experimentálně;
- ☑ jestliže pro mezní funkce platí  $A(i_{\max}) = B(i_{\max})$ , pak nejpozději pro  $i = i_{\max}$  je klasifikace ukončena, přičemž střední počet potřebných kroků je menší než u W.k. za cenu snížení kvality rozhodnutí

# MODIFIKOVANÉ WALDOVO KŘITÉRIUM


## URČENÍ FUNKCÍ $A(i)$ A $B(i)$

$$A(i) = a \cdot \left(1 - \frac{i}{i_{\max}}\right)^{q_1} \quad \text{a} \quad B(i) = -b \cdot \left(1 - \frac{i}{i_{\max}}\right)^{q_2}$$

kde  $a, b > 0$  a  $q_1, q_2 \in (0, 1)$



# MODIFIKOVANÉ WALDOVO KŘITÉRIUM



# REEDOVO KRITÉRIUM

- ☑ pro obecný počet tříd zobecněný věrohodnostní poměr

$$\Lambda_i(\mathbf{x} | \omega_r) = \frac{p(x_1, x_2, \dots, x_i | \omega_r)}{\left[ \prod_{s=1}^R p(x_1, x_2, \dots, x_i | \omega_s) \right]^{1/R}}, r = 1, 2, \dots, R$$

- ☑ takto vypočítaný poměr se srovná s mezní hodnotou  $r$ -té třídy  $A(\omega_r)$ , určenou jako

$$A(\omega_r) = \frac{1 - P_{rr}}{\left[ \prod_{s=1}^R (1 - P_{rs}) \right]^{1/R}}, r = 1, 2, \dots, R$$

kde  $P_{rs}$  je pravděpodobnost, že obraz ze třídy  $\omega_s$  zatřídíme do  $\omega_r$ .

# REEDOVO KRITÉRIUM

- ☑ pokud pro třídu  $\omega_p$  platí

$$\Lambda_i(\mathbf{x}|\omega_p) \leq A(\omega_p), p=1,2,\dots,R,$$

pak předpokládáme, že obraz  $\mathbf{x}$  nepatří do třídy  $\omega_p$ , kterou lze z dalších úvah vyloučit;

- ☑ po vyloučení všech možných tříd se spočítají nové hodnoty věrohodnostních poměrů pro zbylé třídy a proces se opakuje;
- ☑ není-li možné vyloučit další třídu, zvýší se počet příznaků a klasifikace pokračuje, dokud nezbude jediná klasifikační třída;

# REEDOVO KRITÉRIUM

- ☑ pro  $R=2$  je Reedovo kritérium ekvivalentní kritériu Waldovu a má tytéž optimální vlastnosti;
- ☑ pro  $R>2$  nebyla optimalita prokázána;

# MODIFIKOVANÉ REEDOVO KRITÉRIUM

- ☑ stejně jako Waldova kritéria lze použít proměnných mezí
- ☑ proměnných práh je zpravidla definován vztahem

$$G_r(i) = g_r \cdot \left(1 - \frac{i}{i_{\max}}\right)^{q_i}, r = 1, \dots, R$$

Příprava nových učebních materiálů  
oboru Matematická biologie

je podporována projektem ESF

č. CZ.1.07/2.2.00/28.0043

# „INTERDISCIPLINÁRNÍ ROZVOJ STUDIJNÍHO OBORU MATEMATICKÁ BIOLOGIE“



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ