

PŘEDPOVĚĎ PRAVDĚPODOBNOSTI VÝSKYTU METEOROLOGICKÝCH JEVŮ

Martin Dubrovský

Ústav fyziky atmosféry ČSAV, Hradec Králové¹

1 Úvod

V rámci grantového projektu ČSAV je na našem pracovišti vyvíjen PC systém MESOMAP, jehož součástí je velmi krátkodobá předpověď ($\Delta t \sim 12$ h) pravděpodobnosti výskytu 'významných' meteorologických jevů. Tvar prognostické funkce pro vybraný jev,

$$(1.1) \quad f(\cdot) = \Pr(Y=1 | X=\cdot)$$

kde X je r -rozměrný prediktor (vysvětlující proměnná) a Y je binární prediktand (vysvětlovaná proměnná), je hledan pomocí analýzy učebního datového souboru, $T = \{(x,y)_i; i=1,\dots,N\}$. Práce na vývoji prognostických procedur se v zásadě ubírá dvěma směry:

- ▶ výběr vhodných prediktorů nesoucích co největší informaci o prediktandu,
- ▶ výběr vhodného typu prognostické funkce a způsobu nalezení jejích parametrů.

Předmětem tohoto příspěvku jsou dvě metody odhadu pravděpodobnosti prognostické funkce (1.1) a porovnání jejich úspěšnosti při aplikaci na předpověď pravděpodobnosti výskytu bouřky. První metodou je konstrukce prognostické funkce ve tvaru binárního rozhodovacího stromu (BRS). Zde prezentovaná verze konstrukčního algoritmu vychází z práce ŘEZÁČOVÉ a MOTLA (1990). Algoritmus, který mezičím doznal některých změn, je podrobně popsán v připravované publikaci (DUBROVSKÝ, 199?). Druhou metodou je konstrukce prognostické funkce metodou k -nejbližších sousedů (k NS). Vodítkem při konkretizaci algoritmu mi byl vztah (2.1) v práci ANTOCHA (1988) a vlastní fantazie.

V této práci se předpokládá, že jednotlivé složky prediktorového vektoru $X = (X_1, X_2, \dots, X_r)$ jsou měřitelné či (v případě rozhodovacího stromu) dichotomické veličiny.

2 Binární rozhodovací strom

Na Obr. 1 je jednoduchá verze binárního rozhodovacího stromu, který vstupnímu prediktorovému vektoru x přiřazuje pravděpodobnost výskytu jevu reprezentovaného binárním prediktandem. Každý průchozí uzel (bifurkaci) stromu lze chápat jako kořen podstromu a zapsat: $t_k = \{b_k(\cdot), t_{k<} t_{k>}\}$, kde $b_k(\cdot)$ je bifurkační funkce a $t_{k<} t_{k>}$ jsou dva dceřinné podstromy. Koncové uzly stromu (listy) nesou informaci o odhadu podmíněné pravděpodobnosti výskytu jevu, \hat{P}_k . Stavba BRS začíná nalezením bifurkační funkce kořenového uzlu, t_1 , s využitím datového souboru $T_1 \in \mathbb{R}^{N_1 \times r}$, a pokračuje rekurzivní bifurkací dceřinných podstromů dokud všechny větve stromu nejsou ukončeny listy.

Algoritmus konstrukce podstromu t_k z učebního souboru T_k :

1.krok: Nalezení bifurkační funkce $b_k(\cdot)$, jež co nejúčinněji (ve smyslu zavedené míry diskriminace) odděluje pravků:

T_k s výskytom jevu ($Y=1$) od prvků bez výskytu jevu ($Y=0$).

2.krok: Test významnosti diskriminace.

3.krok (a): Je-li diskriminace významná, uzel t_k se stává bifurkací s bifurkační funkcí $b_k(\cdot)$, množina T_k je rozdělena na $T_{k<} = \{(x,y)_i \in T_k | b_k(x_i) < 0\}$ a $T_{k>} = \{(x,y)_i \in T_k | b_k(x_i) \geq 0\}$. Z učebních souborů $T_{k<}$ a $T_{k>}$ jsou zkonstruovány dceřinné podstromy $t_{k<}$ a $t_{k>}$.

¹ Husova 456, 50008 Hradec Králové

(b) Je-li diskriminace nevýznamná, uzel ζ_k se stává listem a je mu přiřazena prognostická pravděpodobnost výskytu jevu:

$$(2.1) \quad \hat{P}_k = n_k / N_k$$

kde N_k a n_k je počet prvků v T_k celkem, resp. s $Y=1$.

V tomto obecném schématu konstrukčního algoritmu je třeba specifikovat:

- Míru kvality prognostické funkce a s ní související míru kvality bifurkační funkce
- Metodu řezení stromu (množinu bifurkačních funkcí)
- Kritérium pro uzavření větve (test významnosti diskriminace)

2.1 Míra kvality prognostické funkce

Je-li ztráta způsobená nepřesnou předpovědí popsána kvadratickou ztrátovou funkcí, $I(y_i, f(x_i)) = (y_i - f(x_i))^2$, kvalitu prognostické funkce $f(\cdot)$ lze vyjádřit střední kvadratickou chybou (MSE):

$$(2.2) \quad c_f^2 = E[(y - f(x))^2]$$

Názornějším vyjádřením kvality prognostické funkce může být relativní skóre úspěšnosti:

$$(2.3) \quad RV(f) = 1 - c_f^2/c_0^2$$

kde c_0^2 je střední kvadratická chyba průměrné klimatické předpovědi [$f_0(x) = n(T)/N(T) = \text{kons}(x)$] a RV se nazývá *redukce variance*.

Kvalitu bifurkační funkce lze definovat jako pokles MSE vzhledem k bifurkaci podle $b(\cdot)$:

$$(2.4) \quad w(k|b) = p_k c_k^2 - (p_{k<} c_{k<}^2 + p_{k>} c_{k>}^2)$$

kde $p_{\cdot} (\cdot = k, k<, k>)$ je pravděpodobnost, že vektor X 'padne' do uzlu t_{\cdot} a c_{\cdot}^2 je MSE daného uzlu:

$$(2.5) \quad c_{\cdot}^2 = P_{\cdot} (1 - \hat{P}_{\cdot})^2 + (1 - P_{\cdot}) \hat{P}_{\cdot}^2$$

kde P_{\cdot} je podmíněná pravděpodobnost výskytu jevu pro daný uzel.

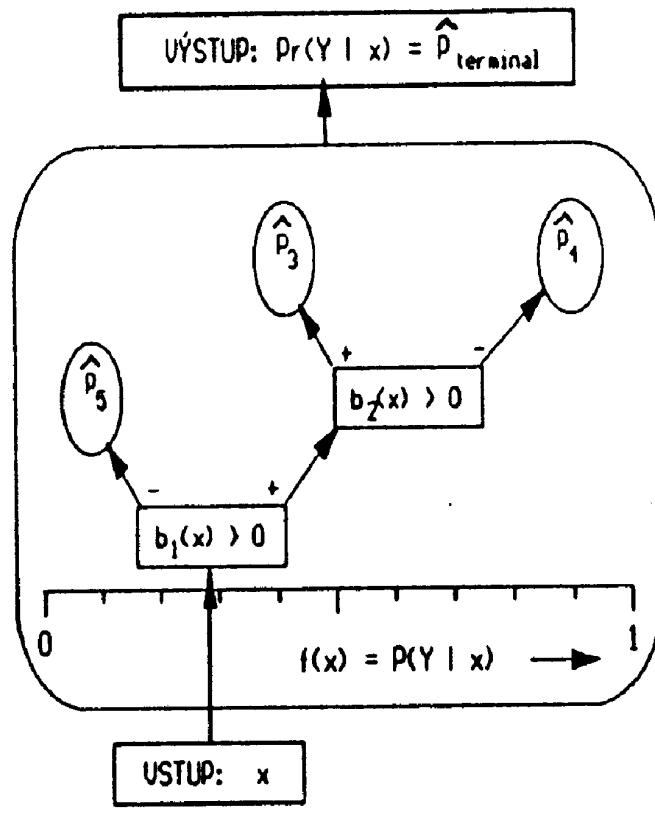
Při odhadu výše uvedených veličin z učebního souboru lze vycházet z odhadu MSE pro daný uzel:

$$(2.6) \quad \hat{c}_{\cdot}^2 = [n_{\cdot} (1 - \hat{P}_{\cdot})^2 + (N_{\cdot} - n_{\cdot}) \hat{P}_{\cdot}^2] / N_{\cdot}$$

Odhady příslušných veličin budou dále značeny stříškou. Je-li příslušná veličina odhadnuta na testovacím souboru, nezávislém na vývojovém souboru (to je ten, na kterém byla nalezena bifurkační funkce a byly odhadnuty prognostické pravděpodobnosti podle 2.1), bude odlišena čarou (\hat{c}^2' , RV' , \hat{w}' , N' , n').

2.2 Řezení stromu

Z množiny 'povolených' bifurkačních funkcí je v každém uzlu stromu hledána ta, která zajišťuje co největší míru diskriminace.



Obr. 1 Schéma binárního rozhodovacího stromu pro předpověď pravděpodobnosti výskytu jevu. b_k ($k = 1,2$) jsou bifurkační funkce průchozích uzlů (bifurkaci), \hat{P}_k ($k = 3,4,5$) jsou podmíněné pravděpodobnosti výskytu jevu příslušné koncovým uzlům (listům) rozhodovacího stromu.

2.2.1 Typ bifurkační funkce

Standardní množinou bifurkačních funkcí je množina funkcí typu

$$(2.7) \quad b(x) = x_{ix} - x^*$$

kde ix je index diskriminačního prediktoru (ix -tá složka prediktorového vektoru) a x^* je jeho kritická hodnota. V každém uzlu je bifurkační funkce volena tak, aby:

$$(2.8) \quad b_k = \arg \max_{i=1,\dots,r} [\hat{m}(k|b_i)] \quad \text{kde } b_i = x_i - \bar{x}_i^*$$

Kritické hodnoty \bar{x}_i^* jsou nalezeny jednou ze dvou metod popsaných v §2.2.2.

Je-li prediktorový vektor dobře vychovaný (v ideálním případě s normálním rozdělením) a ne příliš rozptýlený lze hledat bifurkační funkci ve tvaru

$$(2.9) \quad b_k(x) = \hat{w}_k x - x_k^*$$

kde \hat{w}_k je diskriminační vektor (výpočet viz. např. Pudil et al. (1991), rovnice 7.2-5). Kritická hodnota x_k^* je vypočtena jako kritická hodnota jednorozměrného prediktoru $z = \hat{w}_k x$ stejným způsobem jako v případě bifurkační funkce jedné proměnné. Aplikace bifurkační funkce typu (2.9) umožňuje rychlejší diskriminaci prediktorového prostoru a ve svém důsledku i vyšší kvalitu odbadu prognostické funkce. Nevýhody vzhledem k bifurkační funkci typu (2.7) jsou: (1) nutný předpoklad o 'vychovanosti' prediktorů, (2) neumožňuje redukci dimenze prediktorového vektoru.

2.2.2 Kritická hodnota bifurkační funkce

Nechť X_j je diskriminační prediktor (j -tá složka prediktorového vektoru). Jebo kritická hodnota, x_j^* , je vypočtena podle algoritmu:

Soubor T_k je náhodně rozdělen na dva stejně velké (případně lišící se o jeden prvek) podmnožiny T_k^a a T_k^b . Na každé z těchto podmnožin je nalezena kritická hodnota x_a^* , x_b^* . Toto se třikrát opakuje a výslednou kritickou hodnotou je aritmetický průměr z takto získaných šesti hodnot. Kritická hodnota prediktoru X_j na libovolné množině T_k^{\cdot} ($\cdot = a, b$) je určena jednou ze dvou metod:

momentová metoda:

$$(2.10) \quad x_{\cdot}^* = [\bar{x}_{j_0} s_{j_1} + \bar{x}_{j_1} s_{j_0}] / [s_{j_1} + s_{j_0}] ; \quad (\cdot = a, b)$$

kde \bar{x}_{j_i} a s_{j_i} ($i=0,1$) je průměr a směrodatná odchylka diskriminačního prediktoru X_j vypočtená z těch prvků T_k^{\cdot} pro něž je $y=i$.

maximální metoda je založena na nalezení hodnoty prediktoru, pro něž míra diskriminace nabývá maxima:

$$(2.11) \quad x_{\cdot}^* = \arg \max_{x^* \in R^1} [\hat{m}(k|b(x) = x_j - x^*)] ; \quad (\cdot = a, b)$$

Účinnost momentové i maximální metody v závislosti na velikosti učebního souboru, apriorní pravděpodobnosti výskytu jevu a tvaru distribuční funkce diskriminačního prediktoru byla testována jednak metodou Monte Carlo na náhodně generovaných souborech, jednak na reálných datech (viz. DUBROVSKÝ, 199?). Zde jen uvedu, že v případě dobré vychovaného diskriminačního prediktoru, a dobré (resp. špatné) separovatelného souboru ((ve skutečnosti diskriminační míry zavedené vztahem (2.4), s použitím bifurkační funkce typu (2.7)) je výhodnější použití momentové (resp. maximální) metody. V případě špatně vychovaných prediktorů je maximální metoda výhodnější vzhledem ke své robustnosti.

2.3 Kritérium pro uzavření větvě

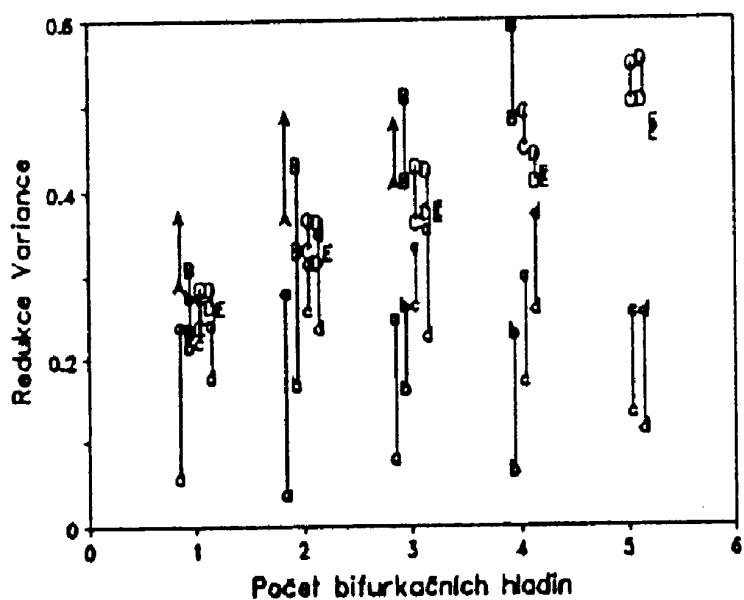
Je-li kvalita prognostické funkce odvozena od kvadratické ztrátové funkce, existuje nebezpečí, že štěpením stromu

daje k poklesu místo k růstu RV . Proto je třeba před každým štěpením stromu testovat významnost diskriminace. Testovací statistikou může být míra diskriminace vypočtená buď na vývojovém nebo nezávislém testovacím souboru, který je štěpen paralelně s vývojovým souborem. V případě statistiky vypočtené na vývojovém souboru je kritériem pro akceptování bifurkace:

$$(2.12) \quad \hat{m}(k|b_k) \geq m^*(N_k n_k r)$$

přičemž síla testu klesá s rostoucím počtem prediktorů (r), z nichž je diskriminační prediktor vybrán. V případě statistiky vypočtené na nezávislém datovém souboru je síla testu nezávislá na r . Vzhledem k tomu, že výběrová míra diskriminace vypočtená na nezávislém testovacím souboru je nestraným odhadem její skutečné hodnoty, zdá se, že vhodným kritériem minimalizujícím pravděpodobnost špatného rozhodnutí (přijetí bifurkace když $m(k|b_k) < 0$ nebo zamítnutí bifurkace když $m(k|b_k) > 0$) je splnění podmínky:

$$(2.13) \quad \hat{m}'(k|b_k) \geq 0$$



Obr. 2 Závislost redukce variance na výšce stromu (počet bifurkačních hladin). Malými (velkými) písmeny jsou vyznačeny intervaly $\langle \text{avg}(R\bar{V}) \pm s(R\bar{V}) \rangle$ [$\langle \text{avg}(R\bar{V}') \pm s(R\bar{V}') \rangle$, kde $\text{avg}(\cdot)$, $s(\cdot)$ jsou průměr a směrodatná odchylka z deseti simulací. $[N, N'] = [100, 500]$ (intervaly A-A, a-a); $[200, 500]$ (B,b); $[500, 500]$ (C,c); $[700, 300]$ (D,d); $[1000, -]$ (E,-). Prediktand = $C_{<12-24>}$.

Důsledek zanedbání testu významnosti diskriminace

je demonstrován na Obr. 2, kde je znázorněna vývoj redukce variance v závislosti na postupném, nekontrolovaném štěpení stromu. Z obrázku je patrná jednak rostoucí divergence větví $R\bar{V}$ a $R\bar{V}'$ s klesajícím N , jednak existence optimální velikosti stromu, která roste (stejně jako maximum hodnoty $R\bar{V}'$) s rostoucí velikostí vývojového souboru, přičemž překročení optimální velikosti stromu je doprovázeno poklesem kvality stromu ('Bugaboo' efekt).

3 Metoda k nejbližším sousedů

Odhad prognostické funkce metodou k nejbližším sousedů je váženým aritmetickým průměrem z těch pozorování, pro něž odpovídající x_i je mezi k 'nejbližšími' sousedy bodu, v němž odhadujeme (Antoch, 1988):

$$(3.1) \quad f(x) = \sum_{j=1,\dots,k} q_{ix_j} y_{ix_j} / \sum_{j=1,\dots,k} q_{ix_j}$$

kde q_{ix_j} je váha ix_j -tého vektoru, ix_j je index j -tého nejbližšího souseda vektoru x vybraného z učebního souboru $\{(x_i, y_i); i=1, \dots, N\}$ tak, že $\delta(x, x_{i,j-1}) \leq \delta(x, x_{i,j}) \leq \delta(x, x_{i,j+1})$. Definice vzdálenosti $\delta(x, x_{i,j})$, definice váhy q_{ix_j} a počet sousedů k je předmětem optimalizace, která probíhá opět s využitím metody Monte Carlo. Nejhouloustivějším prvkem se zdá být definice vzdálenosti. Jako nejvhodnější se ukazují dva typy vzdáleností:

(a) Mahalanobisova vzdálenost:

$$(3.2) \quad \delta(x, x_i) = (x - x_i)^T \Sigma^{-1} (x - x_i)$$

kde Σ je kovarianční matice vektoru X . Pokus o zohlednění vzájemné vazby jednotlivých složek vektoru X s prediktandem vedl k modifikaci předešlé definice:

$$(3.3) \quad \delta(x, x_i) = (x_k - x_{i,k}) c_k \Sigma_{kk}^{-1} c_k (x_i - x_i) ; (k, l \text{ jsou sčítací indexy})$$

kde $c_k (\cdot = k, l)$ je váha vyjadřující vazbu mezi prediktandem a \cdot -hou složkou vektoru X . Testování různě definovaných

vah c však zatím nevedlo k jednoznačnému zlepšení.

(b) Vzdálenost projekcí dvou bodů na nejlepší diskriminační přímku:

$$(3.4) \quad \delta(x_i) = |\hat{w} \cdot (x - x_i)|$$

kde \hat{w} je diskriminační vektor určen stejným způsobem jako pro (2.9).

Pro volbu váhy q se ukázaly jako přibližně stejně dobré: (a) $q_{ix_j} = 1$; (b) $q_{ix_j} = [1/\delta(x_i x_{ij})]^{1/2}$; (c) $q_{ix_j} = (1/j)^{1/2}$.

Ke zrobustnění metody lze složky vektoru x_i transformovat dvěma způsoby: (a) $x_{ij} \leftarrow R_j(x_i)$; (b) $x_{ij} \leftarrow F^{-1}[R_j(x_i)/(N+1)]$, kde $R_j(x_i)$ je pořadí vektoru x_i v posloupnosti tvořené prvky učebního souboru uspořádanými podle jíl. složky vektoru, N je počet individuí učebního souboru a F je distribuční funkce normálního rozdělení.

4 Aplikace na reálná data

Učební datový soubor sestává z 1058 pozorování čtyřrozměrného prediktora vektoru $[X = (ADED2, KMOD, SICP, FI)]$, kde jednotlivé složky vektoru jsou indexy instability odvozené z aerologické sondáže Praha - Libeň a čtyř různě definovaných binárních prediktandů ($A, B, C_{<12-18>}, C_{<12-24>}$) charakterizujících výskyt bouřky na daném území, v daném časovém intervalu. Pro každý ze čtyř prediktandů byla hledána prognostická funkce (1.1) jednak ve tvaru binárního stromu s bifurkační funkcí typu buď (2.7) nebo (2.9), jednak metodou k nejbližším sousedů se vzdáleností definovanou vztahem buď (3.2) nebo (3.4). Prediktorem je buď kompletní vektor $X = (ADED2, KMOD, SICP, FI)$, nebo samotný Faustův index (FI) – index s nejvyšší individuální prediktivní schopností. Mírou úspěšnosti je redukce variance vypočtená na nezávislém datovém souboru, $R\hat{V}'$. Pro každou kombinaci vstupních podmínek bylo provedeno 10 nezávislých simulací, z nichž byla spočtena průměrná hodnota a směrodatná odchylika $R\hat{V}'$. Variabilita hodnoty $R\hat{V}'$ je dána náhodným způsobem rozdělení vstupních dat na vývojový a testovací soubor, v případě konstrukce stromu má vliv též neurčitost při výpočtu diskriminační hodnoty.

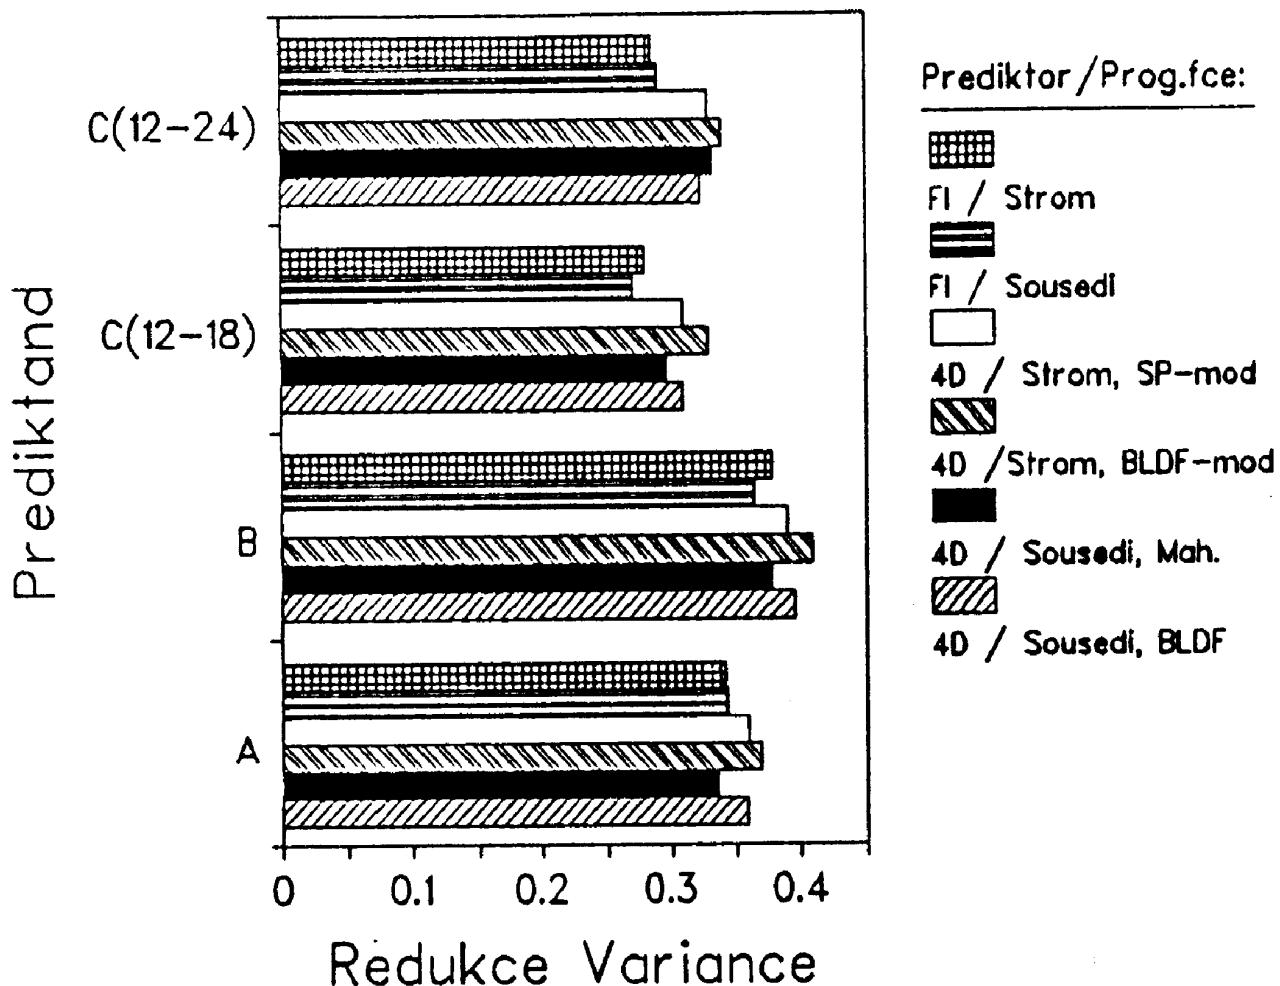
Tabulka. Výsledky 10 konstrukcí binárního rozhodovacího stromu.
 $R\hat{V}'$ je redukce variance vypočtená na testovacím souboru ($N' = N = 529$), L je počet listů stromu. $\text{avg}(\cdot)$ a $s(\cdot)$ je aritmetický průměr a směrodatná odchylika vypočtené z 10 hodnot.

		odhad diskrim. hodnoty: prediktor/bif.fce ¹⁾ :	momentové metoda			maximální metoda		
Y=	A		FI/sp	4D/sp	4D/bldf	FI/sp	4D/sp	4D/bldf
	$\text{avg}(R\hat{V}') =$ $s(R\hat{V}') =$ $\text{avg}(L) =$ $s(L) =$	0.34 0.03	0.36 0.04	0.37 0.03	0.35 0.03	0.35 0.03	0.38 0.02	
Y=	B	$\text{avg}(R\hat{V}') =$ $s(R\hat{V}') =$ $\text{avg}(L) =$ $s(L) =$	12 3	12 3	9 2	11 2	10 2	8 3
		$\text{avg}(R\hat{V}') =$ $s(R\hat{V}') =$ $\text{avg}(L) =$ $s(L) =$	0.38 0.03	0.39 0.05	0.41 0.06	0.38 0.02	0.38 0.02	0.40 0.03
		$\text{avg}(R\hat{V}') =$ $s(R\hat{V}') =$ $\text{avg}(L) =$ $s(L) =$	9 2	9 3	9 2	10 2	8 2	8 3
		$\text{avg}(R\hat{V}') =$ $s(R\hat{V}') =$ $\text{avg}(L) =$ $s(L) =$	0.28 0.04	0.31 0.04	0.33 0.03	0.29 0.03	0.30 0.05	0.31 0.03
Y=	$C_{<12-18>}$	$\text{avg}(R\hat{V}') =$ $s(R\hat{V}') =$ $\text{avg}(L) =$ $s(L) =$	8 3	9 2	7 2	9 2	9 2	7 2
		$\text{avg}(R\hat{V}') =$ $s(R\hat{V}') =$ $\text{avg}(L) =$ $s(L) =$	0.29 0.03	0.33 0.04	0.34 0.04	0.31 0.03	0.34 0.04	0.33 0.04
		$\text{avg}(R\hat{V}') =$ $s(R\hat{V}') =$ $\text{avg}(L) =$ $s(L) =$	7 2	9 3	7 2	8 2	8 1	8 3
		$\text{avg}(R\hat{V}') =$ $s(R\hat{V}') =$ $\text{avg}(L) =$ $s(L) =$	0.29 0.03	0.33 0.04	0.34 0.04	0.31 0.03	0.34 0.04	0.33 0.04

1) FI/sp: $x = FI$, bifurkační funkce typu (2.7);
4D/sp: $X = (ADED2, KMOD, SICP, FI)$, bifurkační funkce typu (2.7); 4D/bldf: $x = (ADED2, KMOD, SICP, FI)$, bifurkační funkce typu (2.9).

V Tabulce jsou výsledky simulací stavby stromu, z nichž vyplývá:
► úspěšnost stromů využívajících vícerozměrný prediktor je vyšší než při použití jediného indexu (FI). Zlepšení je ovšem malé, což lze přičíst na vrub značné vzájemné korelovanosti jednotlivých indexů instability.

► použití bifurkačních funkcí ve tvaru nejlepší lineární diskriminační funkce (2.9) dává nevýrazně (vzhledem k variabilitě



Obr. 3 Skóre úspěšnosti [Redukce Variance = $\text{avg}(R\hat{V}')$, kde $R\hat{V}'$ je redukce variance vypočtená na testovacím souboru, $\text{avg}(\cdot)$ značí průměr z 10 simulací] Binárního rozhodovacího stromu (Strom) a metody k nejbližších sousedů (Sousedl) aplikované na 4-rozměrný prediktor 4D = (ADED2, KMOD, SICP, FI) a samotný Faustův index (FI). Strom je staven buď v sp-modu (bifurkační funkce typu (2.7)) nebo bldf-modu (bifurkační funkce typu (2.9)), odhad diskriminační hodnoty je momentovou metodou. Odhad metodou kNS: $k=50$, $q_i = (1/\delta_i)^{\frac{1}{2}}$, vzdálenost δ_i je buď podle (3.2) (Mah.) nebo podle vztahu (3.4) (bldf).

hodnot $R\hat{V}'$) vyšší skóre úspěšnosti než při použití bifurkačních funkcí jedné proměnné (2.7). Toto lze opět vysvětlit značnou vzájemnou závislostí jednotlivých prediktorů. Za povšimnutí stojí nižší počet bifurkací u stromů využívajících bifurkační funkce typu *bldf*, což je v souladu s očekávaným rychlejším vyčerpáním informace obsažené ve vícerozměrném prediktoru.

Na Obr. 3 je porovnána úspěšnost odhadu prognostické funkce metodou stromu a k nejbližších sousedů. Z obrázku lze vyčíst:

- Úspěšnost obou metod aplikovaných na 4-rozměrný prediktor je vyšší než při použití nejsilnějšího jednorozměrného prediktoru, nicméně toto zvýšení je vzhledem ke značné vzájemné závislosti mezi jednotlivými indexy nevýrazné.
- Úspěšnost obou metod (BRS vs. kNS) se v rámci chyby neliší
- Využitím nejlepší lineární diskriminační funkce (*bldf*) lze u obou metod (bifurkační funkce typu (2.9) při kostrukci stromu; definice vzdálenosti vztahem (3.4) u metody kNS)) sledovat určité zlepšení, což však může být důsledek toho, že použité prediktory jsou poměrně hodné (s trohou dobré vůle s normálním rozdělením).

5 Závěr

Kvalita prognostické funkce nalezené metodou analýzy učebního souboru je dána jednak kvalitou prediktorů (tedy mírou informace o prediktandu nesené prediktorem), jednak schopností použité statistické metody extrahat z učebního souboru co nejoptimálnější prognostickou funkci. Vzhledem k tomu, že úspěšnost obou statistických metod testovaných v této práci vychází přibližně stejně, pro konečné rozhodnutí o výběru metody mohou hrát roli následující 'druhotná' kritéria:

- ▶ **rychlosť konstrukce prognostické funkce ve tvaru stromu** zabírá určitý časový interval, použití hotového stromu na konkrétní prediktorový vektor je však velice rychlé. Naproti tomu, v případě odhadu metodou k nejbližším sousedů je při každé aplikaci prognostické funkce vyhledání sousedů časově náročné.
- ▶ **náročnost na paměť počítače**: Odhad prognostické funkce metodou sousedů vyžaduje při každé aplikaci přístup k celému datovému souboru, kdežto prognostickou funkci ve tvaru stromu lze v paměti počítače uschovat mnohem úsporněji.
- ▶ **sebezdokonalování**: chceme-li, aby se prognostická funkce postupně zdokonalovala (tak jak se rozrůstá učební soubor), v případě kNS je toho dosaženo prostým přidáním nového pozorování k učebnímu souboru. V případě BRS je třeba při rozšíření učebního souboru konstruovat nový strom.
- ▶ **metoda kNS se hůře vyrovnává s rostoucí dimenzí**: v práci připravované pro publikaci (Dubrovský, 199?) je pro konstrukci stromu použit 50-ti rozměrný prediktorový vektor, s čímž se algoritmus konstrukce stromu s využitím bifurkačních funkcí typu (2.7) s přehledem vypořádal. Navíc algoritmus konstrukce BRS v sobě zahrnuje mechanismus pro redukci dimenze prediktorového vektoru. Pro kNS nastávají při rostoucí dimenzi prediktora značné potíže vzhledem k nutnosti pracovat s kovarianční maticí - v případě obou použitých definic vzdálenosti.
- ▶ **metoda kNS se hůře vyrovnává s kategorialními prediktory**

Závěrem bych chtěl dodat, že kombinace prediktorů použitá v této práci byla vybrána tak trochu subjektivně na základě vyhodnocení frekvence výskytu prediktorů v dolních uzlech stromů zkonstruovaných z učebního souboru zahrnujícího pozorované hodnoty 50 různých prediktorů. V další fázi práce se počítá jednak se zahrnutím nových druhů prediktorů do prediktorového vektoru, jednak s dalším zdokonalováním v této práci uvedených statistických metod, případně vyzkoušení jiných metod.

Literatura

- ANTOCH J., 1988: Klasifikace a regresní stromy. Sborník ROBUST 88, JČSMF, str.0-6.
- DUBROVSKÝ M., 199?: The binary decision tree: the growing algorithm and application to thunderstorm forecasting. Nabídnuto k publikaci v Studia geophysica et geodactica.
- PUDIL P., NOVOVIČOVÁ J. and BLÁHA S., 1991: Statistical approach to pattern recognition (Theory and practical solution by means of PREDITAS system). Supplement to the Journal Kybernetika 27, 78pp.
- ŘEZÁČOVÁ and MOTL, 1990: The use of the simple 1D steady-state convective cloud model in the decision tree for determining the probability of thunderstorm occurrence. Studia geoph. et geod. 34, 147-166.