

O VÝHLEDÁVÁNÍ MODELU

Tomáš Havránek

SVT ČSAV, Praha

Poměrně často se můžeme ve statistice setkat se situací, kdy máme dánou množinu modelů /hypotéz/ a tuto množinu chceme rozdělit na modely, které můžeme na základě dat zamítout, a na modely, které zamítout nemůžeme /říkáme pracovně, že tyto modely akceptujeme - s vědomím jak málo toto akceptování znamená, použijeme-li jako rozhodovací pravidlo běžný test dobré shody/. Množina modelů může být snadno velká, například pro n regresorů v lineární regrese může obsahovat 2^n modelů.

Algoritmus popisovaný v tomto článku vykristalizoval postupně ze speciálních případů grafových a obecně log-lineárních hierarchických modelů v mnichozměrných kontingenčních tabulkách /Havránek, 1982a,b, 1984a,b a Edwards a Havránek, 1985a,b/. Pro práci algoritmu je důležitá využívání struktura množiny modelů daná částečným uspořádáním podle jejich vzájemných vztahů / jednodušší-složitější model/; této struktuře je věnována v článku pozornost, včetně zopakování potřebných matematických pojmu. Článek se opírá o práci /Edwards a Havránek, 1985b/, obsahuje však navíc úvod do základních pojmu teorie svazů, příklady různých svazů, se kterými se ve statistice můžeme setkat, a příklady použití algoritmu v těchto jednotlivých speciálních případech. Neobsahuje důkazy a detailní popis aplikace algoritmu na lineární regresi včetně rozboru použitých testů. V oblasti log-lineárních a grafových modelů navazuje na předcházející články publikované ve sbornících konference ROBUST /Havránek, 1982a, 1984a/.

1. ZÁKLADNÍ POJMY

Částečně uspořádaná množina je neprázdná množina X spolu s relací \leq , kde platí pro každé $x, y, z \in X$:

A1/ $x \leq x$ /reflexivnost/,

A2/ je-li $x \leq y$ a $y \leq x$, pak $x = y$ /antisimetrie/,

A3/ je-li $x \leq y$, $y \leq z$, pak $x \leq z$ /transitivita/.

Svaz je částečně uspořádaná množina (X, \leq) , pro kterou platí:

B1/ pro každé $x, y \in X$ existuje největší dolní závora /označme si ji $x \wedge y$ /,

B2/ pro každé $x, y \in X$ existuje nejménší dolní závora /označme si ji $x \vee y$ /.

Viz obr. 1: (A, \leq) je (A, \wedge, \vee) , (A, \leq, \wedge, \vee) je (A) .

Na \wedge a \vee se můžeme dívat jako na binární operace; říkáme jím průsek a spojení.

Tyto operace mají následující základní vlastnosti, které někdy bývají používány jako vlastnosti definující svaz:

C1/ $x \wedge x = x$, $x \vee x = x$,

C2/ $x \wedge y = y \wedge x$, $x \vee y = y \vee x$,

C3/ $(x \wedge y) \wedge z = x \wedge (y \wedge z)$, $(x \vee y) \vee z = x \vee (y \vee z)$,

C4/ $x \wedge (x \vee y) = x$, $x \vee (x \wedge y) = x$.

Je-li množina X konečná, nazýváme svaz (X, \leq) konečným svazem.

Svaz se nazývá distributivní, platí-li :

$$D1/ x \wedge (y \vee z) = (x \wedge y) \vee (x \wedge z),$$

$$D2/ x \vee y \vee z = x \vee y \vee x \vee z.$$

Distributivní svaz je booleovský, jestliže obsahuje nejmenší prvek 0 a největší prvek 1 a pro každé x existuje právě jediné $-x \in X$ /doplňek/ tak, že $x \wedge -x = 0$, $x \vee -x = 1$. Příklad: systém všech podmnožin konečné množiny spolu s inklusí tvoří booleovský svaz. Průsek odpovídá průniku a spojení odpovídá sjednocení.

Definujeme nyní další pojmy /obecně ve svazu/:

Prvek x je \wedge -nerozložitelný, jestliže $x = x \wedge y$ má za důsledek, že $x = y$ nebo $x = 0$. Podobně x je \vee -nerozložitelný, jestliže $x = x \vee y$ má za důsledek, že $x = y$ nebo $x = 1$. Je-li (X, \leq) konečný svaz, pak každý prvek x může být vyjádřen jako spojení \vee -nerozložitelných prvků a zároveň jako průsek \wedge -nerozložitelných prvků. Můžeme tedy napsat např. $x = e_1 \vee \dots \vee e_n$, kde e_1, \dots, e_n jsou \vee -nerozložitelné. Důležité jsou pouze taková vyjádření, kde e_1, \dots, e_n jsou nesrovnatelné; taková vyjádření jsou neredundantní.

Platí /Birkhoff, 1967, kap. IX/: Je-li konečný svaz distributivní, pak každý prvek x má jednoznačné neredundantní vyjádření $x = e_1 \vee \dots \vee e_n$, kde e_1, \dots, e_n jsou \vee -nerozložitelné. Protože operace \vee a \wedge jsou duální, platí totéž i pro \wedge -nerozložitelné prvky a operaci průseku. Pochopitelně v konečném svazu je konečný počet \vee -nerozložitelných prvků e_1, \dots, e_n a konečný počet \wedge -nerozložitelných prvků e^1, \dots, e^m . Obecně $n \neq m$.

Platí /Edwards a Havránek, 1985b/: Je-li konečný svaz distributivní, pak existuje následující jednoznačná korespondence mezi \vee -nerozložitelnými a \wedge -nerozložitelnými prvky. Označíme-li si e^i i-tý \wedge -nerozložitelný prvek, pak mu odpovídá v této korespondenci \vee -nerozložitelný prvek e_i takový, že

$$e_i = \min \{ x; x \not\leq e^i \}.$$

Důkaz je cvičení opírající se o skutečnosti z /Birkhoff, 1967, kap. IX/: Množina $I_e = \{x; x \leq e\}$ je hlavní ideál, $J_f = \{x; f \leq x\}$ hlavní filtr. Hlavní idéál je prvoideál, jestliže $X - I_e = J_f$ pro nějaké f . Podstatná je věta 8, §7, která říká, že hlavní idéál je prvoideál, právě když e je \wedge -nerozložitelné /pro \vee dostáváme vše duálně/. Stačí nyní si uvědomit, že k e^i máme hlavní ideál I_{e^i} ; $X - I_{e^i}$ je pak jednoznačně určený hlavní filtr J_{e^i} .

$$\text{Duálně platí } e^i = \max \{ x; e^i \not\leq x \}.$$

Rozkladový svaz: Uvažujeme /konečnou/ množinu Y . Nechť X je množina všech rozkladů této množiny / t.j. $x \in X$ jestliže $x = \{x_1, \dots, x_n\}$, $U x_i = Y$, $x_i \cap x_j = \emptyset$ pro $i \neq j$ /. Definujeme uspořádání \leq na X takto: $x \leq y$ pro $x = \{x_1, \dots, x_n\}$ a $y = \{y_1, \dots, y_m\}$, je-li každý $x_i \leq y_j$ pro nějaké j / y je sjemenný x /. Tento svaz (X, \leq) se nazývá rozkladový svaz. V definici jsme použili obrácené uspořádání než je obvyklé v učebnicích o teorii svazů; námi použité uspořádání se lépe hodí ve statistické aplikaci.

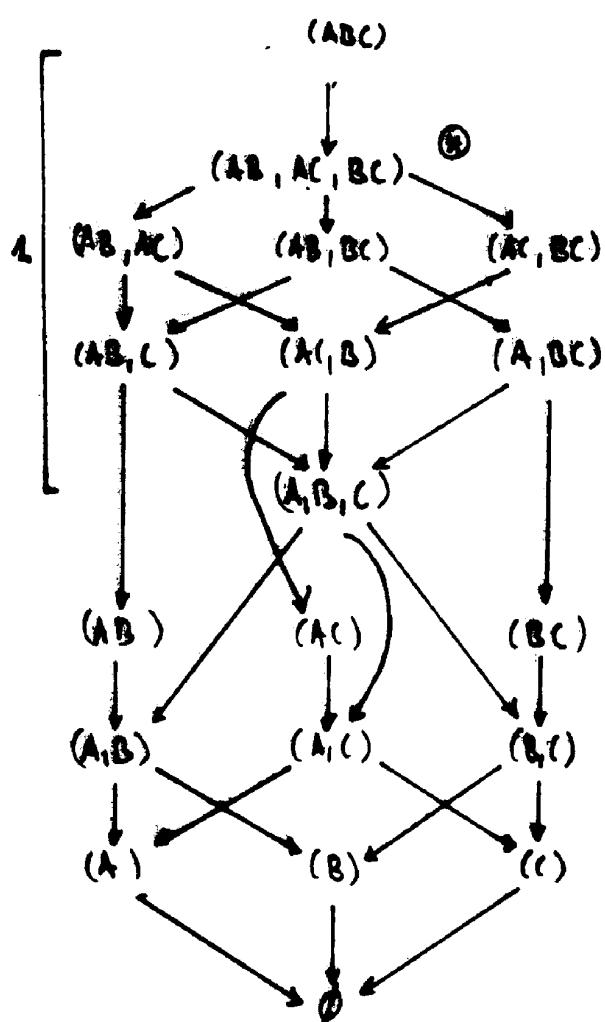
Platí slavná věta /Pudlák a Tůma, 1980/: Každý konečný svaz může být vnořen do konečného rozkladového svazu /jde o injektivní \vee, \wedge -homomorfismus/.

Protože, jak dále uvidíme, s rozkladovými svazy umíme dobře pracovat, zdálo by se, že by tato věta mohla být užitečná - uměli bychom každý konečný svaz /t.j. každou rozumnou konečnou množinu modelu/ vnořit do rozkladového svazu. Problém je ten, že zmíněná věta a její důkaz nedávají žádný konstruktivní návod, jak v konkrétním případě takové zobrazení hledat. Pro konstrukci konkrétních algoritmů se nám

zpět hodí jednoduché skutečnosti až triviality z teorie svazů.

2. PŘÍKLADY SVAZŮ V ANALÝZE DAT

2.1 Hierarchické log-lineární modely v analýze kontingenčních tabulek. Uvažujme např. kontingenční tabulku dimenze $n=4$, t.j. čtyři kategoriální veličiny A,B,C,D /při nezávislém multinomickém výstřhu/. Nechtějme, že $P_{ijkl} > 0$. Pak tyto pravděpodobnosti využívajeme v log-lineárním rozvoji jako $\log P_{ijkl} = \theta + \lambda_i^A + \lambda_j^B + \lambda_k^C + \lambda_l^D + \lambda_{ij}^{AB} + \lambda_{ik}^{AC} + \lambda_{jk}^{BC} + \lambda_{kl}^{CD} + \lambda_{ijk}^{ABC} + \lambda_{ikl}^{ACD}$. V tomto konkrétním případě jde o model podmíněně nezávislosti AB a D podmíněno C. Modely zapisujeme pomocí maximálních indexů /generujících tříd/ jako (ABC,CD) . Blíže viz /Havránek, 1982a, 1984a/. Svazové operace lze zde formálně definovat jako operace na generujících třídách, např. $(ABC,CD) \vee (ACD) = (ABC,ACD)$ a $(ABC,CD) \wedge (AB,C,D) = (AB,C,D)$. PRO $n=3$ máme množinu modelů zobrazenou na obr.1.



Obr.1 log-lineární modely pro $n=3$.
→ označuje směr nerovnosti, relace plynoucí z transitivity nezávislosti
 $e_1 \sim (CDE, A, B)$ / je $e_1 = \min\{x; x \in e_1\}$

můžeme si zkontrolovat, že např. $(AB, C) \wedge (AC, B) = (A, B, C)$ a $(AB, C) \vee (AC, B) = (AB, AC)$.

Celý svaz tedy obsahuje i modely kolapsovaných tabulek, t.j. i modely obsahující jen některé hlavní efekty; např. $(AB) / \log P_{ijkl} = \theta + \lambda_i^A + \lambda_j^B + \lambda_{ij}^{AB}$ / a $(\emptyset) / \log P_{ijkl} = \theta /$. Je to konečný distributivní svaz s nejmenším a největším prvkem (\emptyset) a (ABC) . Přehled o V-nerozložitelných a A-nerozložitelných prvcích dává tabulka 1. Tento svaz uvažuje Whittaker /1985b/.

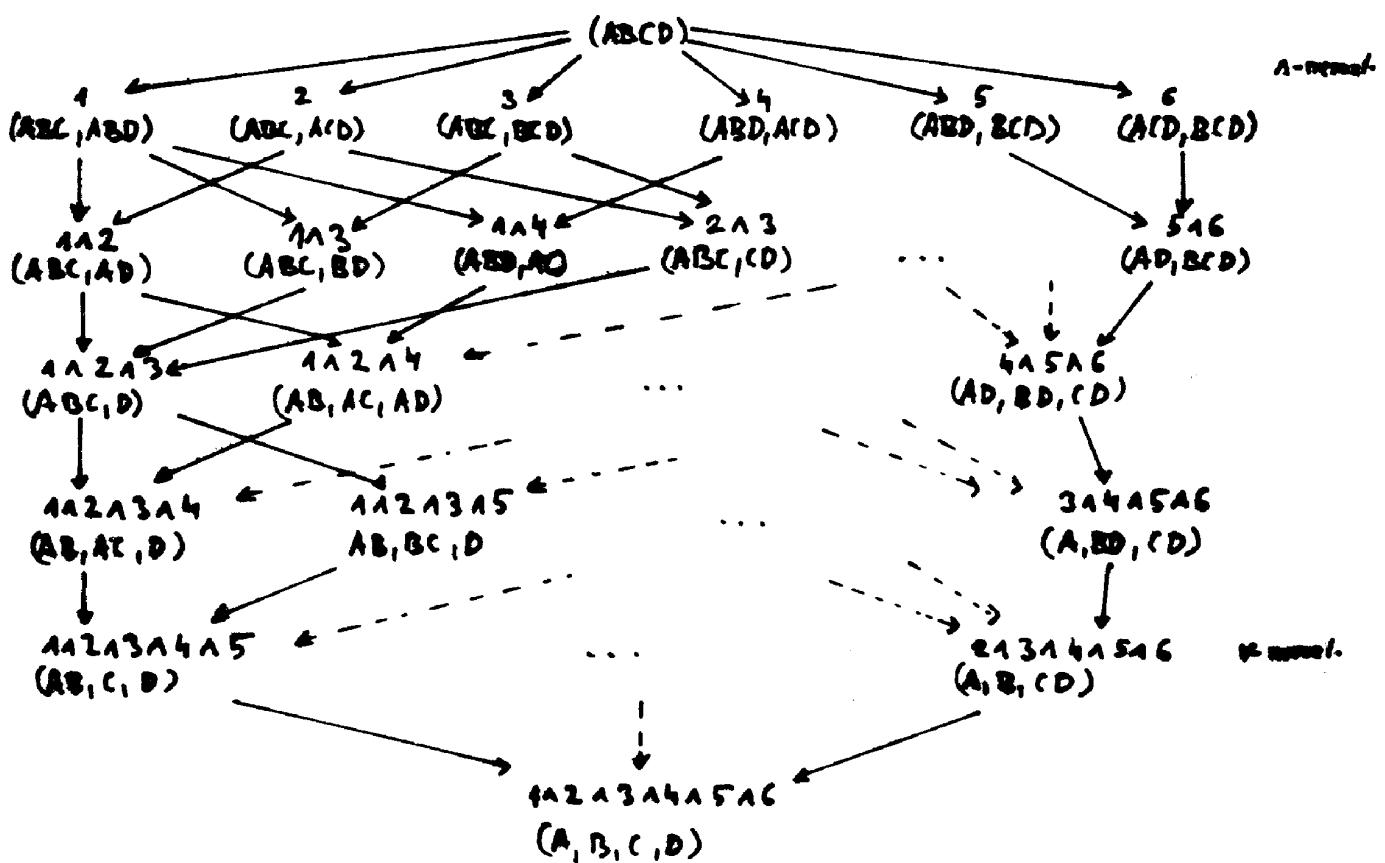
Důležitý je distributivní podsvaz označený 1 v obr.1 a obsahující pouze modely se všemi hlavními efekty $/\lambda_i^A, \lambda_j^B, \lambda_k^C/$. Tento svaz byl zkoumán v /Havránek, 1982b/ k vyjádření ostatních prvků slouží A-nerozložitelné prvky (AC, BC) , (AB, BC) a (AB, AC) a jím odpovídající V-nerozložitelné (A, BC) , (AC, B) a (AB, C) .

Obecně pro tento podsvaz a obecnou dimenzi n jsou A-nerozložitelné prvky sloužící k vyjádření ostatních právě prvky tvaru (a_1, \dots, a_k) , kde každé a_i obsahuje právě $n-1$ písmen a $k \geq 2$. Je-li $a_1^i = (a_1, \dots, a_k)$ takový A-nerozložitelný prvek, pak odpovídající V-nerozložitelný prvek je $e_1 = (b, A_1, \dots, A_g)$, kde b je množina těch písmen, které chybí postupně v a_1, \dots, a_k a A_1, \dots, A_g jsou ostatní písmena. Např. $e_1^1 = (ABCD, ABCE, ABDE)$ pro $n=5$, pak $e_1^1 = \{CDE, A, B\}$ a musí tedy obsahovat CDE /.

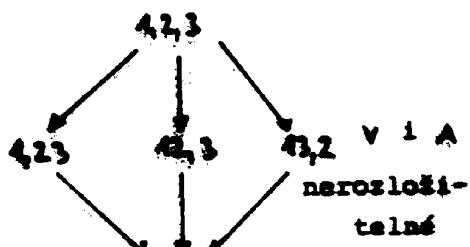
Tabulka 1.

e_i (V-nerozložitelné)		e^1 (A - nerozložitelné)
\emptyset		
A		ABC
B		BC
C		AC
AB	pouze tyto prvky se používají k vyjádření ostatních pomocí	AB
AC		AC, BC
BC		AB, BC
ABC	spojení	AB, AC
	průseků	AB, AC, BC

2.2 Grafové modely. Vynecháme z podsvazu 1 na obr.1 model Θ , dostáváme svaz grafových modelů /obsahujících hlavní efekty/. Tento svaz je booleovský /a tedy distributivní/. Obecně lze uvnitř svazu hierarchických log-lineární modelů s hlavními efekty vymezit svaz grafových modelů jako svaz obsahující /1/ úplný saturovaný model /např. pro $n=5$ model $(ABCDE)$ / a /2/ obsahující všechny modely vyjádřitelné průseky A-nerozložitelných prvků tvaru (a_1, a_2) / kde a_1 i a_2 obsahuje $n-1$ písmen/. Je-li $e^1 = (a_1, a_2)$, kde a_1 neobsahuje písmeno A_1 , pak $e_1 = (A_1 A_2, A_3, \dots, A_n)$, kde A_3, \dots, A_n jsou ostatní písmena. Např. při $n=4$ je $e^1 = (ABCD, ABCD)$ a $e_1 = (B, A, B, C)$. Na obr.2 je tento svaz, ve kterém je vyznačeno jak jsou jednotlivé modely genrovány z A-nerozložitelných prvků.



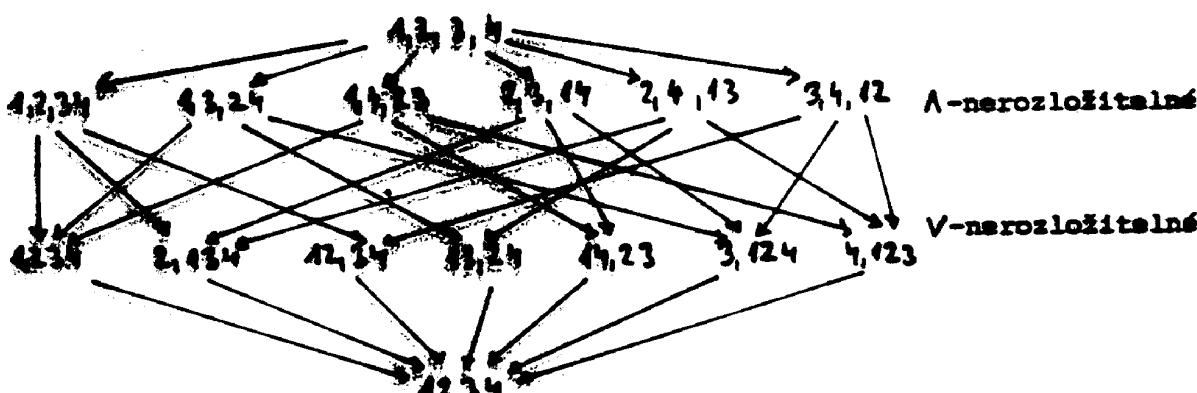
2.3 Rozkladové svazy v analýze rozptylu. Uvažujme zobecněního problému řešeného v /Cox a Spiegelvoll, 1982/. Májme t parametrů μ_1, \dots, μ_t /např. t středních hodnot v t výběrach/. Hypotézy, které nás zajímají jsou tvaru $\mu_i = \theta_{a_k}$ pro $i \in a_k, k = 1, \dots, q$ kde a_1, \dots, a_q tvoří rozklad sročiny $a = \{1, \dots, t\}$. Hypotéza /model/ je tedy dána rozkladem $\{a_1, \dots, a_q\}$ množiny $\{1, \dots, t\}$. Svaz tvo-



Chap. 3 末尾 3

obsahují dva elementy, ostatní jsou jednoelementové).

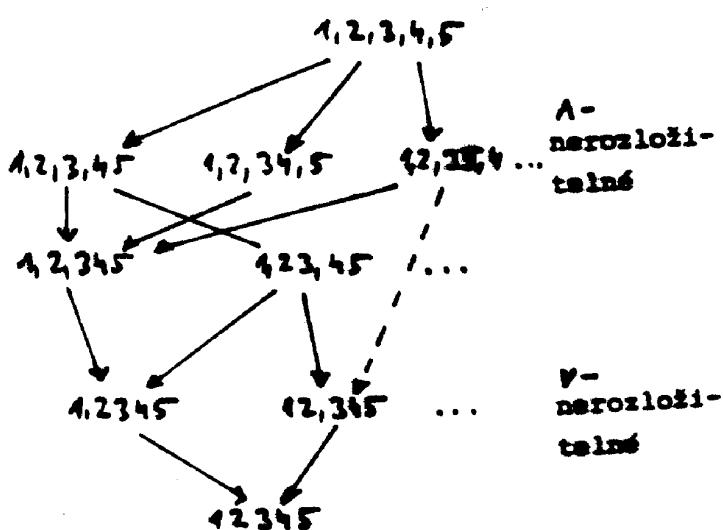
rozkladem $\{a_1, \dots, a_q\}$ množiny $\{1, \dots, t\}$. Svaz tvoří prvky $x = \{a_1, \dots, a_q\}$ spolu s uspořádáním \leq : $x \leq y$, je-li $y = \{b_1, \dots, b_s\}$ zjednodušením x . Je to konečný rozkladový svaz. Operace sjednocení a průniku mohou být popsány přímo takto: /1/ $x \vee y = \{a_1 \cup b_1, a_1 \cap b_2, \dots, a_q \cap b_s\}$ při vyneschání prázdných průniků. /2/ $x \wedge y$ dostaneme ve dvou krocích; nejdřív vytvoříme $\{a_1, \dots, a_q, b_1, \dots, b_s\}$ a pak sjednotíme nadisjuktní množiny v tomto výrazu. Modely tvaru $\{a_1, a_2\}$ jsou \vee -nerozložitelné, každý ostatní model /kromě $\{\}\}$ může být jednoznačně vyjádřen jako jejich spojení. Modely tvaru $\{a_1, \dots, a_{t-1}\}$ jsou \wedge -nerozložitelné / jedno z a_i



Chir. 4 t = 4

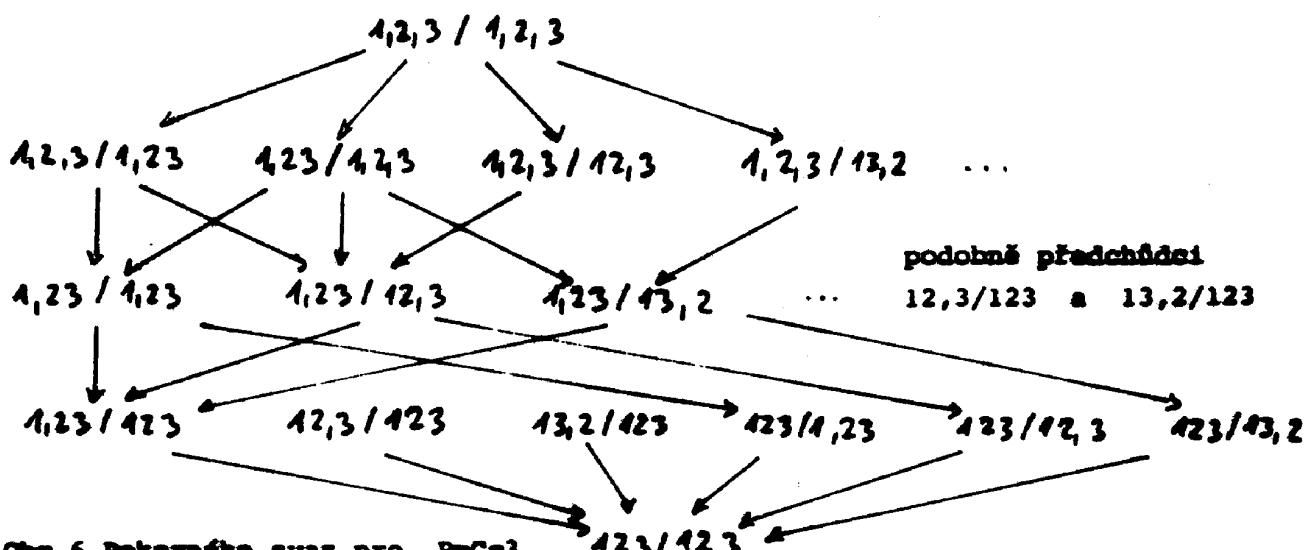
Pro $t=5$ uvádíme, že $(123,4,5) \wedge (12,3,4,5) \wedge (1,23,4,5) = (12,3,4,5) \wedge (13,2,4,5)$, takže zde není jednoznačná nereziduální reprezentace prvků pomocí přímek \wedge -nerezložitelných prvků. Svaz tedy není distributivní. Na obr.3 je tento svaz pro $t=3$, na obr.4 pro $t=4$. Vidíme, že v této dimenzi je vše ještě jednoduché. Pro $t=5$ /obr.5/ je už situace složitější mimo zde už jiné prvky než nerezložitelné.

2.4 Polterného svaz. Uvažujme kontingenční tabulku RBC. Kolapsovaná tabulka je dílce rozkladem x na $\{1, \dots, k\}$ a rozkladem y na $\{1, \dots, c\}$ /přitom uvažujeme nejméně dvoučlenné rozklady/. Při kolapsování sloužíme ty řádky/sloupce tabulky, jejichž indexy jsou ve stejných členech rozkladů. Vzniklý svaz je součinem dvou rozkladových svazů:



Obr. 5 t = 5

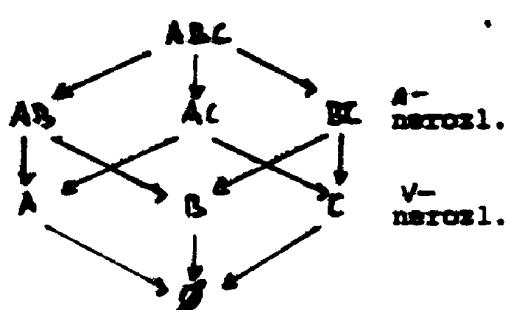
$(x_1, y_1) \leq (x_2, y_2)$ jestliže $x_1 \leq x_2$ a $y_1 \leq y_2$. Pro $R=C=3$ máme tento svaz na obr. 6



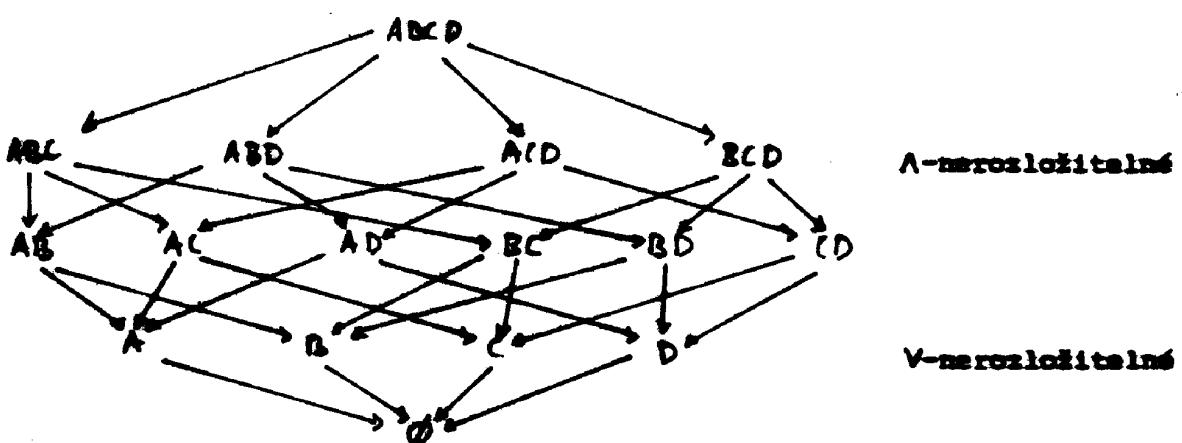
Obr. 6 Pokorného svaz pro $R=C=3$

2.5 Lineární regrese. Uvažujeme regresní modely $y = \mu + \beta_1 A + \beta_2 B + \dots + \beta_n N + e$, kde A, B, C, \dots, N jsou "nezávislé" veličiny. Při problémě vyběru "nejlepší" množiny regresorů uvažujeme modely tvaru AB , BCD atd., t.j. různé množiny regresorů. Uspořádání \subseteq je dáno inkluzí \subseteq . Operace průseku a spojení odpovídají průniku a sjednocení. Dílečitě /t.j. sloužící k vyjádření ostatních/ A -nerozložitelné

prvky jsou množiny o $n-1$ veličinách; je-li
 $e^1 = (A_1, \dots, A_{i-1}, A_{i+1}, \dots, A_n)$, kde je vymazáno
 A_i , je $e_i = A_i$. Jde o velmi jednoduchý distri-
butivní svaz. Pro $n=3$ máme tento svaz na obr.
7 - je ekvivalentní se svazem grafových modelů
pro $n=3$. Pro $n=4$ máme tento svaz na obr. 8
/zde už ekvivalence s grafovými modely nemáme/.



Obr. 7 lineární regrese, $n=3$

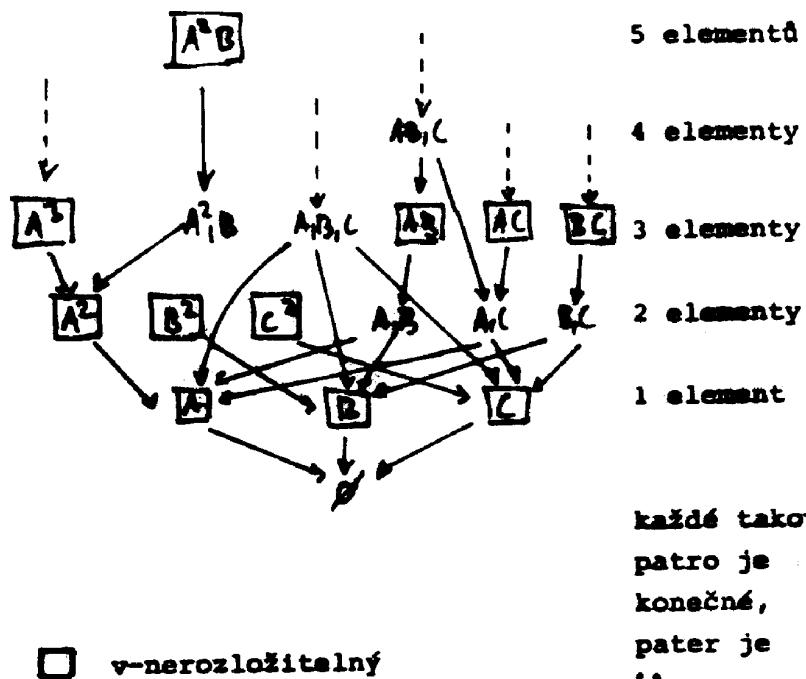


Obr. 8 lineární regrese, $n=4$.

2.6 Obecná polynomická regrese /pondíkud vyumělkovaný příklad/. Jde o regresní tvaru $y = \mu + \beta_1 A + \beta_2 A^2 + \beta_3 B + \beta_4 A \cdot B + \dots + e$. Regresory jsou tedy veličiny A, B, \dots, N ale i $A^2, B^2, A \cdot B, A^3, \dots$ atd. Předpokládejme, že jde o hierarchicky případ, t.j. je-li v modelu A^2 , je tam i A , je-li v modelu AB , je tam A i B , přítomnost

celkem 6 modelů

zápis (A^2) **znamená** (A, A^2)
atd.



A^2B znamená přítomnost AB i A^2 atd. Modely jsou popsány jako množiny maximálních elementů /regresorů/, obsažených v lineárním vyjádření modelu. Uspořádání \leq odpovídá inklusí vzhledem k celým obsaženým množinám regresorů, ne jen k maximálním prvkům, svařové operace jsou pak sjednocení a průnik. Jde o nekonečný distributivní svaz, splňující podmínu, že každý řetěz má nejmenší prvek - každý prvek má pak jednoznačné vyjádření pomocí -nerozložitelných prvků.

⁶Tyto prvky jsou zde jednoelementové modely /ve zkráceném zápisu/, t.j. (A) , (A^2) , (AC) , (BC) , ...
Viz obr.9 pro $n=3$ /nezávislé veličiny A, B, C /.

v-nerozložitelný

bychom měli u nerozložitelných prvků již v prvním patře : $A, A^2, A^3, \dots, B, B^2, \dots, AB, \dots$ atd. Celkově by bylo 2^n možných modelů.

2.7 ARMA modely jsou uvažovány v kontextu vyhledávání modelů v /Whittaker, 198/ Nechť $\{x(t)\}$ je "autoregressive moving average" proces, t.j.

$$x(t) + a_1 x(t-1) + \dots + a_p x(t-p) = e(t) + b_1 e(t-1) + \dots + b_q e(t-q), \text{ kde } \{e(t)\}$$

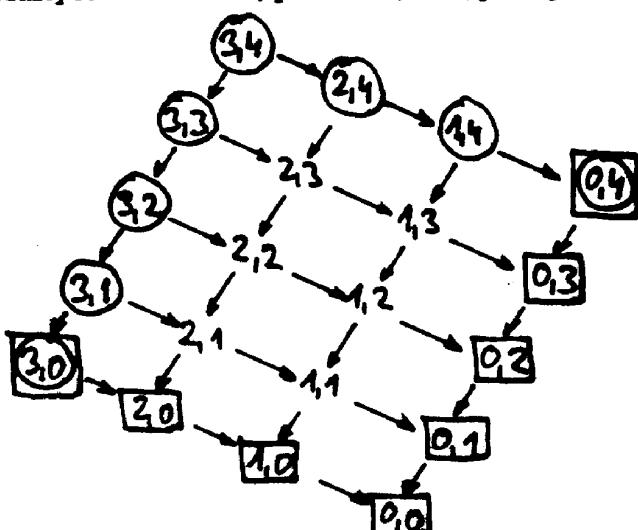
je gaussianovský bílý šum. Jde o hledání modelů s nejmenším počtem parametrů. Odpovídající svaz je při použití hierarchického principu velmi jednoduchý. Jeho prvky jsou (i,j) , t.j. dvojice nejvyšších přítomných indexů /pro $i=0, \dots, p$ a $j=0, \dots, q$ /.

Uspořádání je : $(i,j) \leq (k,l)$ je-li

$i \leq k$ a $j \leq l$. Spojení a průsek: $(i,j)v(k,l) = (\max(i,k), \max(j,l))$, $(i,j)A(k,l) = (\min(i,k), \min(j,l))$, v - nerozložitelné jsou prvky tvaru $(i,0), (0,j)$,

A-nerozložitelné jsou $(i,q), (p,j)$.

Pro $p=3, q=4$ viz obr. 10. Každý prvek lze jednoznačně vyjádřit pomocí v -nerozložitelných i Λ -nerozložitelných prvků: $(i,j) = (i,0) \vee (0,j) = (i,q) \wedge (p,j)$. Korespondence: $e_1 = \min \{ x; x \notin e^1 \}$, kde $e^1 = (i,q)$. Např. $\min \{ x; x \notin k(2,4) \} = (3,0)$, t.j. $k(1,q)$ koresponduje $(1+1,0)$, $k(p,j)$ koresponduje $(0, j+1)$. Je to analogie pokorného sveru: jde o součin dvou line-



Obr. 10 ARMA svaz

v-nerozložitelné A-nerozložitelné
zářních uspořádání Orls... & p., Orls... & p.

3. ALGORITMUS VYHLEDÁVÁNÍ MODELU

Jde tedy o rozdělení množiny modelů na modely zamítнутé a nezamítнутé /akceptované/.

vané/. Nechť (x, \mathbb{M}) je částečně uspořádaná množina modelů. Předpokládejme, že máme rozhodovací pravidlo d, které nám pro daná data M řekne zda daný model $x \in X$ máme zamítnout /r/ či akceptovat /a/ / $d(x, M) = a$ nebo r /. Přijmeme dva následující principy:

- I/ Jestliže $x \leq y$ a $d(x, M) = a$, pak bychom měli přijmout i y /tj. složitější model/. Uvažme, že takový model y je slabě akceptován /aniž bychom počítali $d(y, M)$ /.
- II/ Jestliže $x \leq y$ a $d(y, M) = r$, pak bychom měli zamítnout i x /jednodušší model/. Uvažme, že x je slabě zamítnut.

Víme-li, že model je slabě akceptován nebo slabě zamítnut, pak již nepočítáme $d(x, M)$, t.j. neptáme se v datech zda ho můžeme zamítnout či akceptovat.

Předpokládáme nyní, že (x, \mathbb{M}) je konečná. Nechť $S \subseteq X$ je /nějaká/ množina nesrovnatelných modelů. Definujeme a-duál množiny S jako množinu nejjednodušších modelů z X, které na jsou obsaženy v žádném modelu z S, t.j. $D_a(S) = \min \{x; x \leq y \text{ pro každé } y \in S\}$. Kdyby modely v S byly zamítnuté, pak $D_a(S)$ obsahuje nejjednodušší modely, které by ještě mohly být akceptovány. Podobně definujeme r-duál jako $D_r(S) = \max \{x; y \leq x, y \in S\}$. Kdyby modely v S byly akceptovány, pak $D_r(S)$ obsahuje nejsložitější modely, které by ještě mohly být zamítnuty.

Je nutné si uvědomit, že díky I/ a II/ nám přináší nejvíce informace akceptování jednoduchých modelů a zamítnutí složitých modelů.

Příklady duálů: Lineární regrese pro $n=5$. $D_a(\{\text{ABD}\}) = \{\text{E}\}$, $D_r(\{\text{ABD}\}) = \{\text{(BCDE)}, \text{(ACDE)}, \text{(ABCE)}\}$. Lineární regrese pro $n=4$ /obr.5/: $D_a(\{\text{(AB)}, \text{(AC)}\}) = \{\text{D}, \text{(B)}\}$, $D_r(\{\text{(AB)}, \text{(AC)}\}) = \{\text{(BCD)}, \text{(A)}\}$, $D_a(\{\text{(BCD)}\}) = \{\text{(A)}\}$, $D_r(\{\text{(A)}\}) = \{\text{(BCD)}\}$.

Nechť A je množina akceptovaných modelů /u určitém stadiu práce procedury/, nechť R je množina zamítnutých modelů. Předpokládáme, že nedochází ke sporu, t.j. není $x \leq y$, $y \leq x$, $y \in A$, $y \in R$ /navíc je lepší předpokládat, že každá z množin A a R je nesrovnatelná - pro vyloučení redundance/.

Platí: Nechť T je množina modelů, o kterých na základě A a R a principu I/ a II/ ještě nenímožné nic říci, t.j. $T = \{x \in X; a \leq x \text{ pro všechna } a \in A \text{ a } x \leq r \text{ pro všechna } r \in R\}$. Pak $\max(T) = D_r(A) = R$ a $\min(T) = D_a(R) = A$.

Toto lemma odůvodňuje naši snahu zkoumat duály. Jde tedy vždy o "okraje" množiny T.

3.1 Obecný algoritmus.

Vstup: data M, konečná částečně uspořádaná množina modelů (X, \mathbb{M}) , rozhodovací pravidlo d a počáteční nesrovnatelná množina modelů S_0 .

- 1/ Počáteční množina S_0 je testována /t.j. pro každé $x \in S_0$ zjistíme $d(x, M)$ /. Položíme $A = \{x; d(x, M) = a\}$, $R = \{x; d(x, M) = r\}$.
- 2/ Je-li $A = \emptyset$ jdeme na 3/, je-li $R = \emptyset$, jdeme na 4/. Jinak zvolíme mezi 3/ a 4/.
- 3/ Testujeme modely z $D_r(A) - R$. Jsou-li všechny zamítnuty, stop. Jinak upravíme A a R /t.j. přidáme akceptované a zamítnuté modely a vynescháme redundantní vzhledem k T/ a jdeme na 3/.
- 4/ Testujeme modely z $D_a(R) - A$. Jsou-li všechny akceptovány, stop. Jinak upravíme A a R a jdeme na 3/.

V bodě 2/ se můžeme rozhodovat podle toho, zda je menší $D_r(A) - R$ či $D_a(R) - A$. Výsledek je výsledek procedury /t.j. množiny A a R/ závislý na S_0 a rozhodnotích v bodě 2/. O jednoznačnosti viz 4.1.

Příklad. Lineární regrese pro $n=4$ / viz obr.8/. Položíme $S_0 = \{\text{(A)}, \text{(B)}, \text{(C)}, \text{(D)}\}$ /t.j. nejjednodušší modely/.

- 1.krok: $R = \{(A), (B), (C)\}$, $A = \{D\}$. $D_a(R) = \{D\}$, $D_r(A) = \{(ABC)\}$. $D_a(R) - A = \emptyset$. Jdi na 3/.
- 2.krok: Testujeme (ABC) , je akceptován, $R = \{(A), (B), (C)\}$, $A = \{(ABC), (D)\}$, $D_a(R) = \{(D)\}$, $D_r(A) = AB, AC, BC$.
- 3.krok: Testujeme $D_r(A) - R = \{(AB), (AC), (BC)\}$. $R = \{(AB), (C)\}$, $A = \{(AC), (D), (BC)\}$. $D_a(R) = \{\emptyset\}$, $D_r(A) = \{(AB), (C)\}$, $D_a(R) - A = \emptyset$, $D_r(A) - R = \emptyset$, stop.

Při použití algoritmu je problémem hledání duálů. Je potřebné použít jinou metodu než píšme podle definice. K tomu lze využít svazovou strukturu.

3.2 Algoritmus pro obecný /kompletní/ svaz.

a. Platí: Pro libovolné $S, T \subseteq X$, $S \neq T$ nezávisitelné, je $D_r(S \cup T) = \max\{s \wedge t; s \in D_x(S), t \in D_x(T)\}$, $D_a(S \cup T) = \min\{s \vee t; s \in D_x(S), t \in D_x(T)\}$.

b. Platí: Nechť $P \subseteq X$ jsou \wedge -nerozložitelné prvky a $Q \subseteq X$ jsou \vee -nerozložitelné prvky. Nechť $x \in X$. Pak $D_r(x) = \max\{z \in P; x \not\in z\}$, $D_a(x) = \min\{z \in Q; z \not\in x\}$.

Náms tedy návod jak hledat pro $S = \{m_1, \dots, m_k\}$ duály: Hledáme-li např. $D_r(S)$, najdeme nejprve $D_r(m_i)$ pro $i=1, \dots, k$ pomocí \wedge -nerozložitelných prvků a pak položíme $D_r(S) = \max\{s_1 \wedge \dots \wedge s_k : s_i \in D_r(m_i), \dots, s_k \in D_r(m_k)\}$.

V nekonečných svazech mohou být potíže, např díky nekonečnosti P a Q .

c. Platí: Nechť $x = x_1 \wedge \dots \wedge x_n = \wedge x_i$ /nebo $x = y_1 \vee \dots \vee y_h = \vee y_i$ / . Pak $D_a(\wedge x_i) = \min\{\bigcup D_a(x_i)\}$ a $D_r(\vee y_i) = \max\{\bigcup D_r(y_i)\}$.

Nyní, je-li (X, \leq) konečný svaz, kde tedy každé $x \in X$ lze vyjádřit pomocí \wedge -nerozložitelných i \vee -nerozložitelných prvků, vidíme, že nám stačí znát pouze r-duály pro \vee -nerozložitelné prvky a a-duály pro \wedge -nerozložitelné prvky. Pak můžeme pro každé s_i v S použít pímo C a pak skonstruovat např. $D_r(S)$ jako $\max\{s_1 \wedge \dots \wedge s_k : s_i$ jsou pímo prvky duálů \vee -nerozložitelných prvků $\}$.

Celý tento postup může být ještě dosti složitý.

3.3 Algoritmus pro konečný rozkladový svaz. Protože $D_r(x) = \max\{p \in P; x \not\in p\}$, vidíme, že $D_r(x)$ se skládá z \wedge -nerozložitelných prvků, jejichž dvou elementová složka obsahuje elementy, které v $x = \{a_1, \dots, a_k\}$ byly v různých a_i, a_j .

Podobně $D_a(x) = \min\{q \in Q; q \not\in x\}$ a tedy $D_a(x)$ se skládá z \vee -nerozložitelných prvků tvaru $\{b_1, b_2\}$ takových, že alespoň pro jedno a_i je $a_i \cap b_1$ i $a_i \cap b_2$ neprázdné.

Příklad. t. 5 /Obr. 5/. $x = \{1, 2, 345\}$ pak $D_r(x) = \{\{12, 3, 4, 5\}, \{13, 2, 4, 5\}, \{4, 2, 3, 5\}, \{35, 2, 3, 4\}, \{23, 1, 4, 5\}, \{24, 1, 3, 5\}, \{25, 1, 3, 4\}\}$ a $D_a(x) = \{\{123, 45\}, \{124, 35\}, \{125, 34\}, \{1234, 5\}, \{13, 245\}, \dots\}$.

Zde tedy máme přímý popis $D_a(m_i)$ i $D_r(m_i)$ pro každé m_i z množiny S , pro kterou bychom chtěli konstruovat duály.

3.4 Algoritmus pro konečný distributivní svaz /či svaz s odpovídající 1-1 korespondencí mezi nerozložitelnými prvky/.

Nechť e_1, \dots, e_n jsou \vee -nerozložitelné prvky a e^1, \dots, e^n jim odpovídající \wedge -nerozložitelné prvky. Je-li nyní $x = \bigvee_{j \in W} e_j$ pro nějaké $W \subseteq \{1, \dots, n\}$, pak $D_r(x) = \{e^j\}_{j \in W}$. Podobně, je-li $x = \bigwedge_{j \in W} e_j$, pak $D_a(x) = \{e_j\}_{j \in W}$.

Příklad /viz obr. 2, grafové modaly n=4/.

$$m_1 = (ABC, D) = (ABC, ABD) \wedge (ABC, ACD) \wedge (ABC, BCD)$$

e^1 e^2 e^3
 \downarrow \downarrow \downarrow
 e_1 e_2 e_3

$$D_a(m_1) = \{(A, B, CD), (A, BD, C), (AD, B, C)\}$$

podobně $m_2 = (AB, AC, AD) = e^1 \wedge e^2 \wedge (ABD, ACD) \wedge e^4$

$$D_a(m_2) = \{(A, B, CD), (A, BD, C), (A, BC, D)\} . \text{ Je-li } R = \{m_1, m_2\}, \text{ pak}$$

$$D_a(R) = \min \{s_t : s \in D_a(m_1), t \in D_a(m_2)\} = \min \{(A, B, CD), (A, BD, CD), (A, BC, CD),$$

e_1	$e_1 \vee e_2$	$e_1 \vee e_4$
e_2	$e_2 \vee e_4$	$e_3 \vee e_1$
e_3	$e_3 \vee e_2$	$e_3 \vee e_4$

$$(A, BD, C), (A, BC, BD), (AD, B, CD), (AD, BD, C), (AD, BC, D) \setminus \{(A, B, CD), (A, BD, C), (AD, BC, D)\}.$$

Příklad. AEMKA svaz, aplikujeme první krok algoritmu:

start $S_0 = \{(1, 0), (0, 1)\}$, oba V-nerozložitelné.



$D_R(A) = \{(0, 1)\}$ pro $D_a(R)$ musíme vyjádřit $(0, 1)$ pomocí A-nerozložitelných korespondující prvků: $(0, 1) = (0, 1) \wedge (1, 1)$
 A -nerozložitelný $D_a((0, 1)) = \{(1, 0), (0, 2)\}$, $D_a((0, 1)) \wedge A = \{(0, 2)\}$.

Můžeme si však takto vybrat. Díky akceptování $(1, 0)$ se pak pohybujeme rybou je po jedné větvi /viz obr.10/.

3.5 Algoritmus pro polynomální regresi / příklad nekonečného svazu/. Zřejmě jsou V-nerozložitelné prvky, je možné hledat $D_a(x) = \min \{z \in Q : z \not\in x\}$. Např. $D_a(AC, B, C) = \{(A^2), (B^2), (C^2), (AB)(AC), (BC)\}$, t.j. budeme používat pouze bod 4/.

Příklad /viz obr.9/. Testujeme $S_0 = \{(A), (B), (C)\}$. Nechť $A = \{(A)\}, R = \{(B), (C)\}$. $D_a((A)) = \{(B^2), (C), (A)\}$, $D_a((C)) = \{(C^2), (A), (B)\}$, $D_a(R) = \{(C^2), (A), (B, C), (B^2)\}$, $D_a(R) \wedge A = \{(C^2), (B, C), (B^2)\}$ atd.

Zde je otázka, zda tento algoritmus je rozumně zvládnutelný; je zde nutné doplnit zvnějšku pravidlo pro zastavení.

4. STATISTICKÉ PROBLÉMY

4.1 Vráťme se k rozhodovacímu pravidlu. Máme (x, M) konečnou částečně uspořádanou množinu modelů. Rozhodovací pravidlo d je koherentní, jestliže pro žádná data M a žádné xy se nestane, že $d(x, M) = a$ a $d(y, M) = r$, t.j. nenastane případ, že by byl akceptován jednodušší model a zamítnut složitější model. Je-li d koherentní, je výsledek práce algoritmu jednoznačný. Pro některé případy lze použít rozumně zdůvodněné koherentní pravidlo. Například pro lineární regresi lze použít pravidlo: $d(m, M) = a$, je-li $R_m^2(M) \geq 1 - (1 - R_I^2(M))(1 + F_{I-1, N-I}(n, M-n-1)/(M-n-1))$, kde R^2 je čtverec mnohonásobného koeficientu korelace /pro model m a pro model I se všemi regresory/ a N je rozsah dat M /viz Edwards a Havránek, 1985b/.

Někdy máme možnost použít jako koherentní, tak nekoherentní pravidlo; to je případ hierarchických log-lineárních modelů, kde bychom mohli použít informační statistiku /chi-kvadrát poměru věrohodnosti/ s pevnou kritickoumezí pro všechny modely /t.j. nezávislost na jednotlivých stupních volnosti/. Takové pravidlo by bylo koherentní, ale bylo by při běžném smyslu slova slabé. Použijeme-li kritickémezí

pro danou hladinu významnosti & závislé na stupních volnosti, je výsledné pravidlo nekoherentní /ale doufáme, že jen slabě nekoherentní/.

V takových případech používáme často pravidla, která nejsou koherentní, ale skoro koherentní, kde tímto výněm ménime, že doufáme, že pravděpodobnost nekoherence je malá. Ve skutečnosti o tom, nakolik jsou některé konkrétní pravidla nekoherentní, víme velmi málo. Určité drobné úvahy v tomto směru jsou v /Havránek a Pokorný, 1985/.

4.2 Dalším problémem jsou řídká data; jde zhruba řečeno o to, že pro posuzování složitějších modelů nemáme často dostatek dat. Příkladem problémů, které mohou nastat, jsou numerické problémy v regresi, je-li příliš mnoho regresorů, či numerické problémy při odhadování parametrů složitějších hierarchických log-lineárních modelů. K těmto problémům přistupuje špatná asymptotika testů v mnohorozměrných kontingenciích tabulkách právě v oblasti složitějších modelů. Celkově lze v takových situacích doporučit používat jednoduché startovací množiny / např. $S_0 = \{(A), (B), (C), (D)\}$ v lineární regresi, či $S_0 = \{(A, B, C, D)\}$ v grafových modelech / a v bodě 2/ se rozhodovat pro 4/. Je možné doufat, že se algoritmus zastaví dříve, než dojde na složité modely.

4.3 Použijeme-li jako rozhodovací pravidlo test dobré shody na hladině α a je-li tento test koherentní, platí, že množina akceptovaných modelů po skončení práce procedury $A_1 = \{x; y \in x \text{ pro některé } y \in A\}$ obsahuje platnou hypotézu /model/ s pravděpodobností $1 - \alpha$. Je to formulováno nepřesně, ale doufám, že je zřejmé o co jde. Vytváříme tedy jakouga konfidenční oblast pro skutečný model. Jsou-li testy skoro koherentní, platí toto tvrzení pouze "skoro". Průběm je jistě velikost množiny A i A_1 . To souvisí se silou použitych testů pro danou nulovou hypotézu vzhledem k blízkým jednoduším alternativám. Otázka podrobnějšího hodnocení procedur tohoto typu je otevřená. Nebylo by vhodné konstruovat pro takové situace jiná rozhodovací pravidla ?

LITERATURA

- G.Birkhoff/1967/: Lattice theory, Amer.Math.Soc.Coll.Publ.25,3rd.ed./rusky 1985/
D.R.Cox,E.Spjøtvoll /1982/: On partitioning means into groups, Scand.J.Statist. 9
147-152.
D.Edwards,T.Havránek /1985a/: A fast procedure for model search in multidimensional
contingency tables, Biometrika 72,339-351.
D.Edwards,T.Havránek /1985b/: A fast model selection procedure for large families
of models /zasláno do tisku/.
T.Havránek /1982a/: O analýze mnohorozměrných kontingenčních tabulek, ROBUST 82,
JČMF, Praha, 11-18.
T.Havránek /1982b/: Some complexity considerations concerning hypotheses in multi-
dimensional contingency tables, Trans.IX.Prague Conf.Inf.Theory,Statist.Dec.Func.
and Rand.Processes, Academia,Praha, 281-286.
T.Havránek /1984a/: O logaritmicko-lineárních modelech pro mnohorozměrná kategori-
ální data, ROBUST 84, JČSMF,Praha, 31-41.
T.Havránek /1984b/: A procedure for model search in multidimensional contingency
tables, Biométrica 40,95-100.
T.Havránek,D.Pokorný /1985/: On the GUHA approach to model search in connection to
generalized linear models, Generalized linear models, R.Gilchrist,B.Francis,J.Whit-
taker /eds./, Lecture Notes in Statistics 32, Springer-Verlag,Heidelberg.
P.Pudlák,J.Tůma /1980/: Every finite lattice can be embedded in a finite partition
lattice, Algebra Universalis 10,74-95.
J.Whittaker /1985a/: Additive elements of ARMA models, J.Time Series Analysis /v
tisku/.
J.Whittaker /1985b/: Factorisation, irreducible components and additive elements of
log-linear models /zasláno do tisku/.