

Časté množiny položek, asociační pravidla

Jiří Kléma

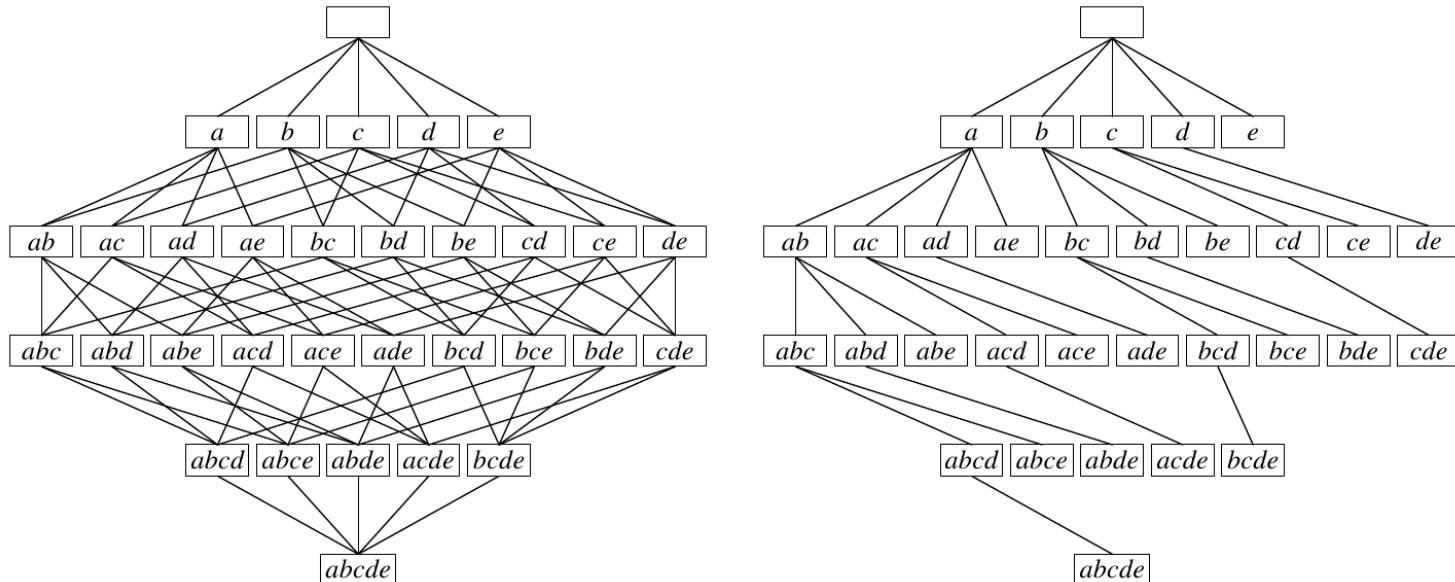
Katedra kybernetiky,
FEL, ČVUT v Praze



<http://ida.felk.cvut.cz>

Vyhledávání velkých množin položek – kategorizace přístupů (1)

- množina všech množin položek je **částečně uspořádaná**
 - lze ji popsat acyklickým grafem – Hasseovým diagramem,
 - uzly jsou množiny položek, hrana $I \rightarrow J$ pokud $I < J$ a neexistuje $K : I < K < J$,
 - v případě všech podmnožin množiny jde o **mřížku** (lattice),
 - tu lze z důvodu efektivity (každý uzel je třeba testovat jen jednou) redukovat na **strom**,
- metoda prohledávání mřížky/stromu podmnožin
 - do šířky – po úrovních, každá úroveň zahrnuje množiny položek dané délky,
 - do hloubky – přes množiny položek s identickým prefixem.



Aplikace APRIORI – příklad analýzy nákupního košíku

Transakce	Položky
t_1	Chleba, Džem, Máslo
t_2	Chleba, Máslo
t_3	Chleba, Mléko, Máslo
t_4	Pivo, Chleba
t_5	Pivo, Mléko

- Vstupní parametry: $s_{min}=30\%$ ($\alpha_{min}=50\%$ – bude použito až v dalším kroku)

i	C_i	L_i
1	{Pivo}, {Chleba}, {Džem} {Mléko}, {Máslo}	{Pivo}, {Chleba} {Mléko}, {Máslo}
2	{Pivo, Chleba}, {Pivo, Mléko} {Pivo, Máslo}, {Chleba, Mléko} {Chleba, Máslo}, {Mléko, Máslo}	{Chleba, Máslo}

Podmíněné transakční databáze – prohledávání do hloubky

- prohledávání prefixového stromu do hloubky analogií **rozděl a panuj**
 - nejprve najdi všechny velké množiny položek s daným prefixem,
 - následně totéž bez něj,
 - vede na dělení množiny transakcí (transakce s/bez daného prefixu),
- obarvení uzlů
 - modře prefix, zeleně položky s prefixem, červeně bez prefixu,
 - postup je rekurzivní, je třeba vzít v úvahu již předchozí krok s *a*.

