


# Struktura svazu zjemnění: Systémy o podobném stupni rozkladu


Sestrojíme graf  $\mathcal{R}$ , jehož uzly jsou proměnné a hrana mezi dvěma uzly je přítomna právě když obě proměnné jsou v jednom podsystému.



reprezentuje:

$${}^1\mathbf{S} = 123|234, \quad {}^2\mathbf{S} = 12|31|234, \quad {}^4\mathbf{S} = 123|24|34, \quad {}^3\mathbf{S} = 12|13|23|34|24$$

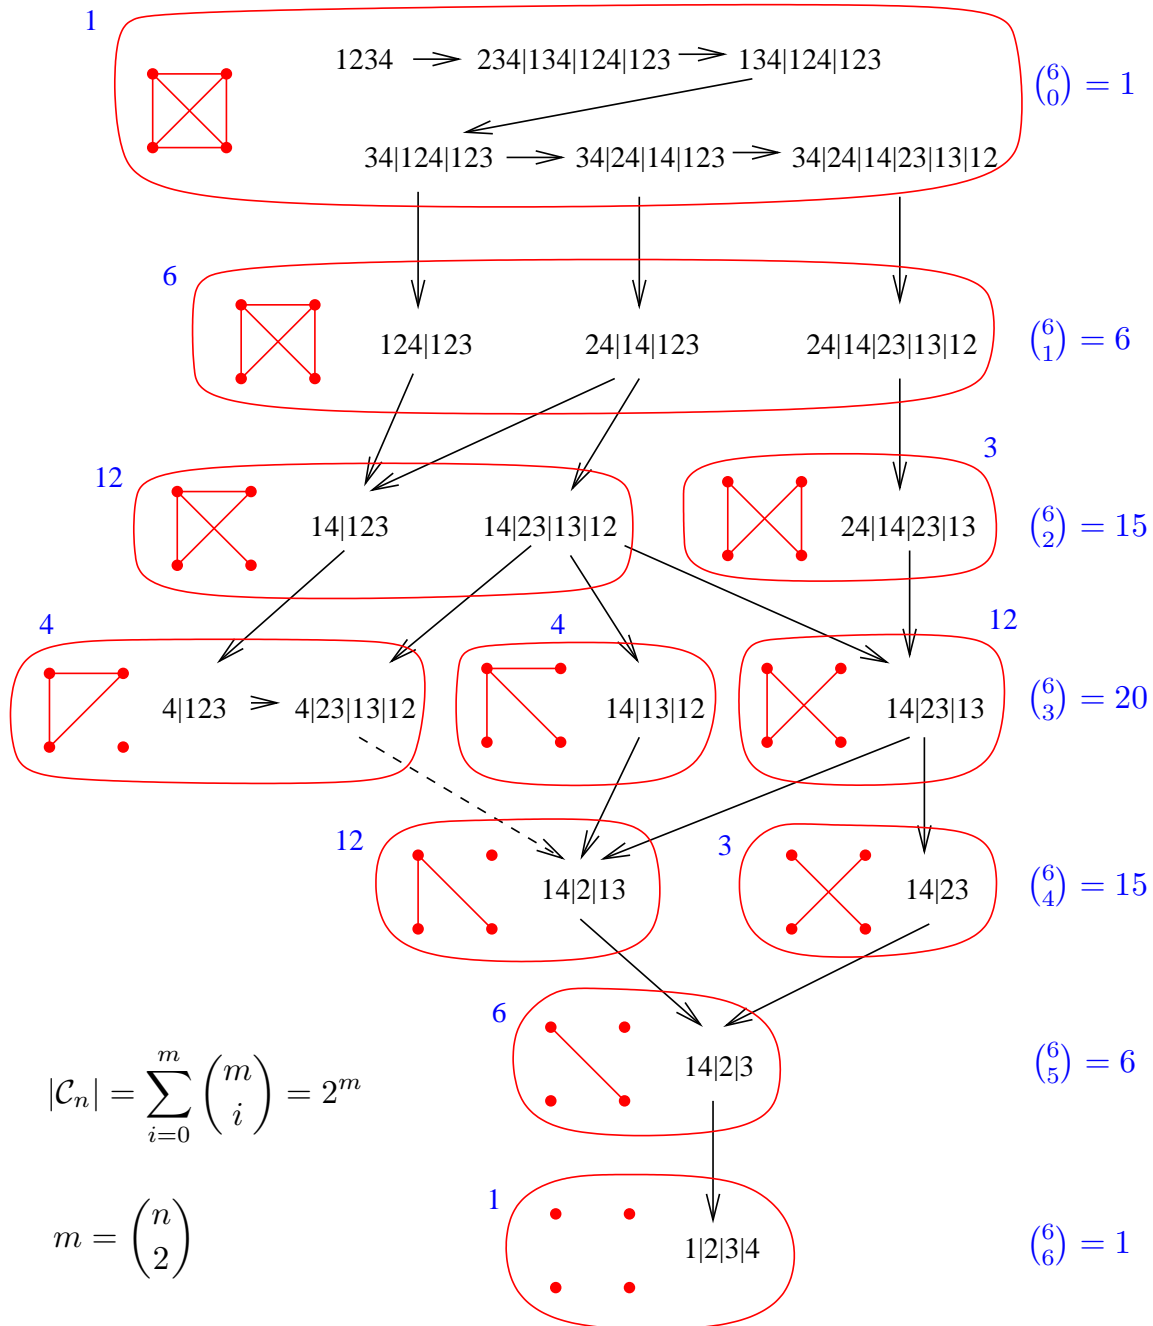
Ale rozklad  $123|24$  by měl



## Pozorování

- graf  $\mathcal{R} = (V_n, E)$  generuje třídu ekvivalence rozkladů, budeme je nazývat  **$r$ -ekvivalence**, kde  $V_n$  – množina  $n$  proměnných systému,  $E$  – množina dvojic proměnných, které jsou obě v nějakém podsystému
- ${}^1\mathbf{S}$  je nejméně dekomponovaný mezi všemi rozklady odpovídajícími grafu  $\mathcal{R}$ : graf je interpretován jako množina klik, této interpretaci budeme říkat  **$\mathcal{C}$ -hypotéza** [clique](#)
- ${}^3\mathbf{S}$  je nejvíce dekomponovaný, této interpretaci  $\mathcal{R}$  budeme říkat  **$\mathcal{P}$ -hypotéza** [pair](#)
- $\mathcal{C}$ -hypotéza a  $\mathcal{P}$ -hypotéza jsou kanonickými reprezentanty třídy ekvivalence  $r$
- $\mathcal{P}$ -hypotéza je zjemněním  $\mathcal{C}$ -hypotézy (existuje do ní cesta ve svazu zjemnění)

# Příklad: Svaz $\mathcal{C}_4/i$



- Svaz zjemnění až na  $r$ -ekvivalenci a permutace indexů proměnných značíme  $\mathcal{C}_n/i$  ( $n$  proměnných)
- Uspořádání ve smyslu zjemnění je v takovém svazu zachováno

# Počet $\mathcal{G}$ -hypotéz a $\mathcal{C}$ -hypotéz

počet proměnných  $n$

$n$	1	2	3	4	5	6	7
$ \mathcal{G}_n $	1	2	9	114	6894	7785062	2414627396434
$ \mathcal{C}_n $	1	2	8	64	1024	32768	2097152
$ \mathcal{G}_n/i $	1	2	5	20	180	?	?
$ \mathcal{C}_n/i $	1	2	4	11	34	156	1044



$\mathcal{G}_n$  — svaz zjemnění rekonstrukčních hypotéz

$\mathcal{C}_n$  — svaz zjemnění až na ekvivalenci  $r$ ,  $|\mathcal{C}_n| = 2^{\binom{n}{2}}$

$\mathcal{C}_n/i$  — svaz zjemnění až na permutace indexů

$\mathcal{C}_n/i$  — svaz zjemnění až na ekvivalenci  $r$  a permutace indexů

$$\log |\mathcal{C}_n| = \binom{n}{2}$$

$$\binom{n}{2} 2^{\binom{n}{2}} \text{ ale 'klobouk'}$$

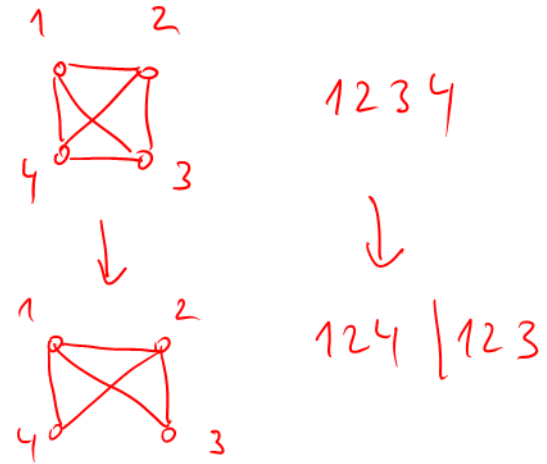
# Prohledávání svazu zjemnění $\mathcal{C}$ -hypotéz

**Vstup:**  $\mathcal{C}$ -hypotéza  $G_i$ , graf  $r(G_i)$

**Výstup:** Všechna zjemnění  $\mathcal{C}$ -hypotézy v  $\mathcal{C}$  svazu

Opakuj 1–3 pro všechny hrany grafu  $r(G_i)$ :

1. Vyjmi hranu  $(a, b)$  z grafu.
2. Každý podsystém  ${}^kS \in G_i$  obsahující  $a$  i  $b$  rozděl na dva podsystémy  ${}^kS \setminus \{a\}$  a  ${}^kS \setminus \{b\}$  a nahraď jimi  ${}^kS$ .
3. Odstraň z výsledku redundantní podsystémy



## Hierarchizované prohledávání svazu zjemnění

▷ Generuj  $\mathcal{C}$ -hypotézy včetně permutací indexů ( $\mathcal{C}_n$ )

▷ Generuj  $\mathcal{G}$ -hypotézy uvnitř každé třídy ekvivalence  $r$

nutná modifikace základní zjemňovací procedury: podmínka  $|{}^iS| \geq 2$  se nahradí podmínkou  $|{}^iS| > 2$  (pak zůstaneme v třídě  $r(G)$ )

*Laqgobuiv algorithmus Knuth*

# Shrnutí

**PA** Identifikace parametrů generativního systému z datového systému.

- volbou masky

## kritéria

1. **generativní neurčitost** = jak dobře systém generuje generované proměnné

$$H(\mathbf{G} \mid \bar{\mathbf{G}}) = H(\mathbf{S}) - H(\bar{\mathbf{G}}), \quad H(\mathbf{S}) = H(\mathbf{G}, \bar{\mathbf{G}})$$

2. **složitost** = počet vzorkovacích proměnných

**Algoritmus:** prohledávání grafu

## použití a vlastnosti

- nutná fáze modelování dynamických systémů
- existuje celá množina řešení

## poznámky

- **neparametrická metoda odhadu hustoty psti**
- **další možnosti: směs gausiánů,  $n$  nejbližších sousedů**

# Shrnutí

**PB** Zjednodušení modelu generativního systému.

- vylučováním proměnných
- redukcí rozlišení

## kritéria

1. generativní neurčitost
2. složitost = počet stavů s nenulovou pravděpodobností

jako v **PA**

**Algoritmus:** prohledávání grafu

## použití a vlastnosti

- redukce velikosti modelu před identifikací struktury
- existuje celá množina řešení

# Shrnutí

**PC** Identifikace struktury systému.

- postupným zjemňováním dekompozice

## kritéria

1. rekonstrukční neurčitost  $\Delta(\mathbf{S}^*) = L(\mathbf{S}, \mathbf{S}^*)$   
 $\mathbf{S}^*$  – rekonstrukce ze zvolených podsystémů       $\mathbf{S}$  – původní systém
2. míra dekompozice = počet podsystémů
3. statistická významnost na hladině  $\alpha$

## použití a vlastnosti

- redukce dimenze popisu
- analýza kritických vazeb a závislostí
- dolování znalostí z dat
- diagnostika systémů
- volba deskriptivních příznaků pro rozpoznávání
- existuje celá množina řešení

**Pozn** • princip maxima entropie