

Zkušenosti ze stáže – Clermont-Ferrand

Lukáš Havrlant



DEPARTMENT OF COMPUTER SCIENCE
PALACKÝ UNIVERSITY, OLOMOUC



evropský
sociální
fond v ČR



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenceschopnost

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Základní informace o stáži



- Datum konání stáže: 20.1.2014–1.3.2014
- Navštívené pracoviště: Université Blaise Pascal, ISIMA, Clermont-Ferrand, Francie
- Zahraniční garant: prof. Engelbert Mephu Nguifo



- ISIMA = Institut supérieur d'informatique, de modélisation et de leurs applications
- Laboratoř má přes 300 studentů a kolem 25 doktorandů.
- Zabývá se především rozhodovacími algoritmy a jejich modely.
- Laboratoř je silně propojena s komerční sférou.

- V laboratoři probíhala spousta přednášek, nicméně téměř všechny ve francouzštině.
- Setkal jsem se s prof. Abdoulaye Baniré Diallo, který tou dobou působil na Université du Québec à Montréal a navštívil jsem jeho přednášku *A probabilistic framework for gene tree reconstruction and reconciliation to a known species tree with an explicit macroevolutionary model*.
- Během stáže jsem přednesl dvě přednášky, *Search engine based on FCA* a *Bit-vector encoding and matrix decomposition*
- O druhé přednášce jsme dále diskutovali s profesorem Mephu a ostatními doktorandy.

Definition (Součin dvou binárních matic)

Mějme $n \times k$ matici A a $k \times m$ matici B , součin $A \circ B$ je definován jako

$$(A \circ B)_{i,j} = \bigvee_{l=1}^k A_{il} \cdot B_{lj}$$

Example

$$\begin{aligned} \begin{pmatrix} 0 & 1 \\ 1 & 1 \end{pmatrix} \cdot \begin{pmatrix} 1 & 1 \\ 1 & 0 \end{pmatrix} &= \begin{pmatrix} 0 \cdot 1 \vee 1 \cdot 1 & 0 \cdot 1 \vee 1 \cdot 0 \\ 1 \cdot 1 \vee 1 \cdot 1 & 1 \cdot 1 \vee 1 \cdot 0 \end{pmatrix} = \\ &= \begin{pmatrix} \max(0 \cdot 1, 1 \cdot 1) & \max(0 \cdot 1, 1 \cdot 0) \\ \max(1 \cdot 1, 1 \cdot 1) & \max(1 \cdot 1, 1 \cdot 0) \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 1 & 1 \end{pmatrix} \end{aligned}$$



- Obecně: dekompozice matic je rozklad matice na součin více maticí.
- Má smysl omezit všechny matice na binární matice, tj. matice, které obsahují pouze nuly a jedničky.
- Popis problému: máme vstupní $n \times m$ binární matici I a chceme nalézt dvě binární $n \times k$ a $k \times m$ matice A a B tak, aby platilo $I = A \circ B$ a k chceme co možná nejmenší.
- Číslo k se pak nazývá scheinův rank matice.

Nechť \mathcal{R} je množina konceptů v kontextu $\langle X, Y, I \rangle$. Zřejmě:

$$\bigcup \mathcal{R} = I.$$

Problém: nalezení minimální množiny $\mathcal{F} \subseteq \mathcal{R}$ takové, že $\bigcup \mathcal{F} = I$.

$$I = \begin{pmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & 1 & 1 \end{pmatrix} \quad I_1 = \begin{pmatrix} \mathbf{1} & \mathbf{1} & 0 \\ \mathbf{1} & \mathbf{1} & 0 \\ 0 & 1 & 1 \end{pmatrix}, \quad I_2 = \begin{pmatrix} 1 & \mathbf{1} & 0 \\ 1 & \mathbf{1} & 0 \\ 0 & \mathbf{1} & 1 \end{pmatrix}, \quad I_3 = \begin{pmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & \mathbf{1} & \mathbf{1} \end{pmatrix}.$$

Platí, že: $I_1 \cup I_2 \cup I_3 = I$, ale také $I_1 \cup I_3 = I$. Množina $\{I_1, I_3\}$ je minimální množina, která pokrývá I .

Pokud nalezneme pokrytí matice I , jsme schopni nalézt také rozklad matice I .



- Libovolnou uspořádanou množiny jsme schopni reprezentovat pomocí bit-vector kódování.
- Každý prvek můžeme reprezentovat jako bit-vector, jako podmnožinu nějakého universa. Přitom jsme schopni nalézt takové kódování c , aby pro prvky $x, y \in P$ z uspořádané množiny P platilo: $x \leq y \Leftrightarrow c(x) \subseteq c(y)$.
- Dotaz $x \leq_P y$ pak snadno vypočteme jako bitovou operaci $x \& y = ? x$.
- Nejmenší počet bitů, který potřebujeme na zakódování uspořádané množiny P je rovný 2-dimenzi množiny P .

- Uspořádanou množinu reprezentovanou maticí můžeme vidět jako formální kontext.

- Platí přitom, že

$$\dim_2 \mathbf{P} = \dim_2 \langle \mathcal{B}(P, P, \leq), \leq_C \rangle$$

- Důsledek: můžeme spočítat $\dim_2 \langle \mathcal{B}(P, P, \leq), \leq_C \rangle$ namísto $\dim_2 \mathbf{P}$.



Definition (Ferrerova 2-dimenze)

Nechť $L = \langle \mathcal{B}(X, Y, I), \leq_C \rangle$ je konceptuální svaz. Nechť \mathcal{R} je minimální množina konceptů, která pokrývá relaci $X \times Y \setminus I$. Pak Ferrerova 2-dimenze svazu L je $|\mathcal{R}|$. Označíme ji $\text{fdim}_2 C$.

Theorem

Pro uspořádanou množinu $\mathbf{P} = \langle P, \leq \rangle$:

$$\dim_2 \mathbf{P} = \text{fdim}_2 \mathcal{B}(P, P, \leq).$$

- 1 Velikost minimální množiny, kterou jsme schopni zakódovat uspořádanou množinou P je rovná $\dim_2 P$.
- 2 $\dim_2 P = \text{fdim}_2 \mathcal{B}(P, P, \leq)$.
- 3 $\text{fdim} \mathcal{B}(P, P, \leq)$ je rovna velikosti minimální množiny konceptů \mathcal{R} , která pokrývá komplementární relaci $>$.
- 4 Množinu \mathcal{R} můžeme použít pro dekompozici matice $>$.

Závěr: Velikost minimální množiny pro zakódování uspořádané množiny P je rovna Scheinovu ranku matice $>$.