

# C2142 Návrh algoritmů pro přírodovědce

## 7. Grafy.

Tomáš Raček

Jaro 2016

# Vyhledávání v databázích I

---

**Opakování.** Umíme efektivně vyhledávat a řadit objekty podle různých klíčů v případě, že je na těchto klíčích definováno uspořádání ( $\leq$ ).

**Vyhledávání molekul.** Mějme molekulu a chtějme zjistit, zdali se již vyskytuje v dané sadě sloučenin (= databázi).

- Záznamy o molekulách často obsahují jednoznačné identifikátory (řetězce znaků) → umíme.

**Problém.** Tyto informace ale nemusí být dostupné. K dispozici máme však minimálně:

- údaje o atomech (pozice, typy)
- vazby mezi atomy

# Příklad molekuly – formát MOL

---

702

-OEChem-03301510303D

9 8 0 0 0 0 0 0999 V2000  
-1.1712 0.2997 0.0000 0 0 0 0 0 0 0  
-0.0463 -0.5665 0.0000 C 0 0 0 0 0 0  
1.2175 0.2668 0.0000 C 0 0 0 0 0 0  
-0.0958 -1.2120 0.8819 H 0 0 0 0 0 0  
-0.0952 -1.1938 -0.8946 H 0 0 0 0 0 0  
2.1050 -0.3720 -0.0177 H 0 0 0 0 0 0  
1.2426 0.9307 -0.8704 H 0 0 0 0 0 0  
1.2616 0.9052 0.8886 H 0 0 0 0 0 0  
-1.1291 0.8364 0.8099 H 0 0 0 0 0 0  
1 2 1 0 0 0 0  
1 9 1 0 0 0 0  
2 3 1 0 0 0 0  
2 4 1 0 0 0 0  
2 5 1 0 0 0 0  
3 6 1 0 0 0 0  
3 7 1 0 0 0 0  
3 8 1 0 0 0 0

## Vyhledávání v databázích II

---

**Intuice.** Porovnání na základě pozic jednotlivých atomů a vazeb představuje výpočetně netriviální problém. Současné databáze navíc obsahují stovky tisíc až miliony struktur.

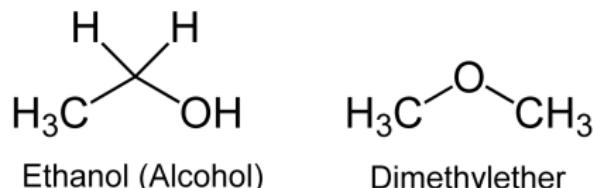
**Návrh řešení.** Provedme vyhledávání v několika fázích, které budou postupně omezovat množinu přípustných struktur. Postupujme od nejjednodušších metod po složitější.

1. jednoduché deskriptory (př. sumární vzorec)
2. využití znalosti topologie, podstruktur
3. porovnání pozic atomů v prostoru

**Příklad.** Porovnání molekul podle sumárních vzorců v rozumném čase výrazně redukuje množinu kandidátů. Nicméně samo o sobě nestačí.

## Vyhledávání v databázích III

Omezení. Pomocí sumárního vzorce nelze rozlišit izomery.



Topologie. Je nutné přidat další informace o struktuře sloučenin – propojení vazbami.

Problém. Potřebujeme nalézt vhodnou datovou strukturu pro reprezentaci molekuly.

3. fáze. Ani toto rozlišení obecně nestačí (stereoizomery), ale získané výsledky lze použít jako výchozí bod pro další algoritmy.

# Graf

---

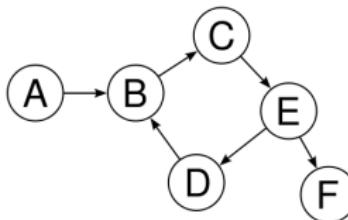
**Definice.** Graf  $G = (V, E)$ , kde  $V$  je množina uzelů (vrcholů) a  $E$  je množina hran.

## Typy grafů

- orientovaný – hrany jsou uspořádané dvojice  $(u, v)$
- neorientovaný – hrany jsou dvouprvkové podmnožiny  $\{u, v\}$

## Příklad orientovaného grafu

- $G = (V, E)$
- $V = \{A, B, C, D, E, F\}$
- $E = \{(A, B), (B, C), (C, E), (D, B), (E, D), (E, F)\}$



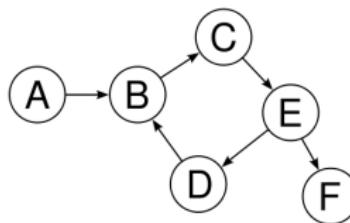
# Reprezentace grafu

## Minimální požadavky na datovou strukturu

- dotaz na existenci hrany v grafu
- sousedé daného vrcholu

Triviální řešení představuje obyčejný seznam (pole) hran. Nicméně výše zmíněné operace pak nelze implementovat efektivně.

- $G = (V, E)$
- $V = \{A, B, C, D, E, F\}$
- $E = \{(A, B), (B, C), (C, E), (D, B), (E, D), (E, F)\}$



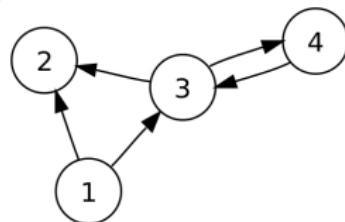
# Matice sousednosti

**Matice sousednosti.** Vytvořme pro graf  $G = (V, E)$  matici  $A$  o rozměrech  $|V| \times |V|$  s vlastností:

$$A_{i,j} = 1 \leftrightarrow (i, j) \in E$$

## Příklad

$$A = \begin{pmatrix} 0 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$



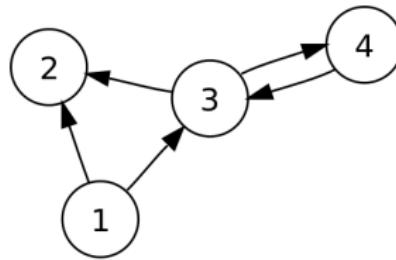
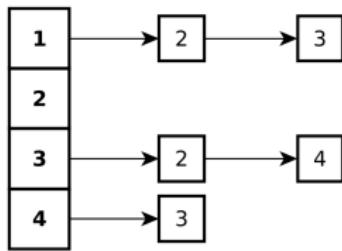
## Vlastnosti

- dotaz na přítomnost hrany je **konstatní** operace
- seznam následníků daného vrcholu v **lineárním čase**
- potřeba  $|V|^2$  paměti → vhodné pro husté grafy ( $|E| \approx |V|^2$ )

# Seznam následníků

**Seznam následníků.** Uvažme pole ukazatelů na seznamy následníků daných vrcholů.

## Příklad



## Vlastnosti

- dotaz na přítomnost hrany je **lineární** operace
- seznam následníků v **lineárním** čase
- pouze  $|V| + |E|$  paměti → vhodné pro řídké grafy ( $|E| \approx |V|$ )

# Procházení grafu

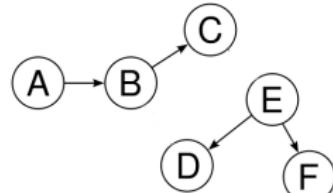
Cíl. Projít všechny vrcholy grafu dostupné ze zvoleného výchozího.

Naivní řešení. Projít postupně seznam vrcholů od začátku do konce (podobně jako u obyčejného pole).

- zjevně lineární operace
- nerespektuje strukturu grafu
- graf nemusí být souvislý → projdeme i jeho nedosažitelné části

Ideální řešení

- zachová lineární složitost
- každý vrchol projde právě jednou
- odstraní výše uvedené nedostatky



# Procházení do šířky

---

Breadth First Search (BFS) prochází graf po jednotlivých úrovních – než projde vrcholy vzdálené (co do počtu hran)  $n$  od výchozího, projde předtím všechny vrcholy vzdálené  $n - 1$ .

## Vlastnosti

- procházíme nejdříve všechny přímé následníky vrcholů
- pro uložení pořadí, ve kterém vrcholy prohledáváme, používáme **frontu**
- **lineární** složitost vzhledem k velikosti grafu –  $O(|V| + |E|)$

# Procházení do šířky – pseudokód

---

```
1: function BFS( $G, u$ ) is
2:   Nechť  $Q$  je prázdná fronta
3:   Enqueue( $Q, u$ )
4:   Označ  $u$  jako navštívený
5:   while  $Q$  není prázdná do
6:      $v \leftarrow$  Dequeue( $Q$ )
7:     for all  $(v, w) \in E$  do
8:       if  $w$  není navštívený then
9:         Označ  $w$  jako navštívený
10:        Enqueue( $Q, w$ )
11:      fi
12:    done
13:  done
14: end
```

# Procházení do hloubky

---

Depth First Search (DFS) prochází graf „dokud to jde“, pak se vrací do posledního místa, kde existuje neprozkoumaná cesta, kterou pak pokračuje dále.

## Vlastnosti

- lineární algoritmus –  $O(|V| + |E|)$
- často v rekurzivní podobě, iterativní využívá zásobník

```
1: function DFS( $G, u$ ) is
2:   Označ  $u$  jako navštívený
3:   for all  $(u, v) \in E$  do
4:     if  $v$  není navštívený then
5:       DFS( $G, v$ )
6:     fi
7:   done
8: end
```

## Procházení do hloubky (iterativně) – pseudokód

---

```
1: function DFS( $G, u$ ) is
2:   Nechť  $S$  je prázdný zásobník
3:   Push( $S, u$ )
4:   Označ  $u$  jako navštívený
5:   while  $S$  není prázdný do
6:      $v \leftarrow \text{Pop}(S)$ 
7:     for all  $(v, w) \in E$  do
8:       if  $w$  není navštívený then
9:         Označ  $w$  jako navštívený
10:        Push( $S, w$ )
11:      fi
12:    done
13:  done
14: end
```

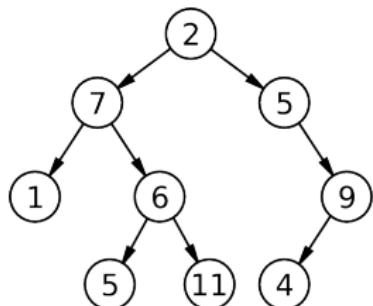
Otázka. Čím se liší pseudokód pro BFS a DFS?

# Procházení binárního stromu

BFS → procházení po úrovních

## Varianty DFS

- pre-order → 1. uzel, 2. levý podstrom, 3. pravý podstrom
- in-order → 1. levý podstrom, 2. uzel, 3. pravý podstrom
- post-order → 1. levý podstrom, 2. pravý podstrom, 3. uzel



## Pořadí procházení vrcholů

- BFS: 2, 7, 5, 1, 6, 9, 5, 11, 4
- DFS pre-order: 2, 7, 1, 6, 5, 11, 5, 9, 4
- DFS in-order: 1, 7, 5, 6, 11, 2, 5, 4, 9
- DFS post-order: 1, 5, 11, 6, 7, 4, 9, 5, 2

Otázka. Co kdybychom použili DFS in-order na BST?