

Prioritní fronta a příklad použití v úloze hledání nejkratších cest

Jan Faigl

Katedra počítačů
Fakulta elektrotechnická
České vysoké učení technické v Praze

Přednáška 11

B0B36PRP – Procedurální programování

Přehled témat

- Část 1 – Prioritní fronta (Halda)

- Popis

- Prioritní fronta spojovým seznamem

- Prioritní fronta polem

- Halda

- Část 2 – Příklad využití prioritní fronty v úloze hledání nejkratší cesty v grafu

- Popis úlohy

- Návrh řešení

- Implementace pq haldou s push() a update()

- Příklad implementace

- Část 3 – Zadání 10. domácího úkolu (HW10)

Část I

Část 1 – Prioritní fronta (Halda)

Prioritní fronta

- Fronta

- První vložený prvek je první odebraný prvek

FIFO

- Prioritní fronta

- Některé prvky jsou při vyjmutí z fronty preferovány

Některé vložené objekty je potřeba obsloužit naléhavěji, např. fronta pacientů u lékaře.

- Operace **pop()** odebírá z fronty prvek s nejvyšší prioritou

Vrchol fronty je prvek s nejvyšší prioritou.

Alternativně též prvek s nejnižší hodnotou

- Rozhraní prioritní fronty může být identické jako u běžné fronty, avšak specifikace upřesňuje chování dílčích metod

Prioritní fronta – specifikace rozhraní

- Prioritní frontu můžeme implementovat různě složitě a také s různými výpočetními nároky, např.
 - Polem nebo spojovým seznamem s modifikací funkcí **push()** nebo **pop()** a **peek()**

Základní implementace fronty viz předchozí přednáška.

- Například tak, že ve funkci **pop()** a **peek()** projdeme všechny dosud vložené prvky a najdeme prvek nejprioritnější
- S využitím pokročilé datové struktury pro efektivní vyhledání prioritního prvku (halda)
- Prioritní prvek může být ten s nejmenší hodnotou, pak
 - Metody **pop()** a **peek()** vrací nejmenší prvek dosud vložený do fronty
 - Hodnoty prvků potřebujeme porovnávat, proto potřebujeme funkci pro porovnávání prvků

Obecně můžeme realizovat například ukazatelem na funkci

Prioritní fronta – příklad rozhraní

- V implementaci spojového seznamu upravíme funkce `peek()` a `pop()`
Využijeme přímo kód lec10/queue_linked_list.h,a lec10/queue_linked_list.c
- Prvek fronty `queue_entry_t` rozšíříme o položku určující prioritu
Alternativně můžeme specifikovat funkce porovnání datových položek

```
typedef struct entry {
    void *value;
    // Nová položka
    int priority;
    struct entry *next;
} queue_entry_t;

typedef struct {
    queue_entry_t *head;
    queue_entry_t *end;
} queue_t;
```

- Rozhraní funkcí je identické frontě až na specifikaci priority při vložení prvku do fronty

```
void queue_init(queue_t **queue);
void queue_delete(queue_t **queue);
void queue_free(queue_t *queue);

int queue_push(void *value, int priority,
               queue_t *queue);

void* queue_pop(queue_t *queue);
_Bool queue_is_empty(const queue_t *queue);
void* queue_peek(const queue_t *queue);
```

lec11/priority_queue.h

Prioritní fronta spojovým seznamem 1/4

- Ve funkci `push()` přidáme pouze nastavení priority

```
int queue_push(void *value, int priority, queue_t *queue)
{
    ...
    if (new_entry) { // fill the new_entry
        new_entry->value = value;
        new_entry->priority = priority;
    ...
}
```

`lec11/priority_queue.c`

Prioritní fronta spojovým seznamem 2/4

- `peek()` lineárně prochází seznam a vybere prvek s nejnižší prioritou

```
void* queue_peek(const queue_t *queue)
{
    void *ret = NULL;
    if (queue && queue->head) {
        ret = queue->head->value;
        int lowestPriority = queue->head->priority;
        queue_entry_t *cur = queue->head->next;
        while (cur != NULL) {
            if (lowestPriority > cur->priority) {
                lowestPriority = cur->priority;
                ret = cur->value;
            }
            cur = cur->next;
        }
    }
    return ret;
}
```

lec11/priority_queue.c

Prioritní fronta spojovým seznamem 3/4

- Podobně `pop()` lineárně prochází seznam a vybere prvek s nejnižší prioritou, je však nutné zajistit propojení seznamu po odebírání prvku

```
void* queue_pop(queue_t *queue)
{
    void *ret = NULL;
    if (queue->head) { // having at least one entry
        queue_entry_t* cur = queue->head->next;
        queue_entry_t* prev = queue->head;
        queue_entry_t* best = queue->head;
        queue_entry_t* bestPrev = NULL;
        while (cur) {
            if (cur->priority < best->priority) {
                best = cur; // update the entry with
                bestPrev = prev; // the lowest priority
            }
            prev = cur;
            cur = cur->next;
        }
        ...
    }
    lec11/priority_queue.c
```

- Proto si při procházení pamatujeme předchozí prvek `bestPrev`

Prioritní fronta spojovým seznamem 4/4

- Po nalezení největšího (nejmenšího) prvku propojíme seznam

```
void* queue_pop(queue_t *queue)
{
    ...
    while (cur) { ... } // Finding the best entry

    if (bestPrev) { // linked the list after
        bestPrev->next = best->next; // best removal
    } else { // best is the head
        queue->head = queue->head->next;
    }
    ret = best->value; //retrieve the value
    if (queue->end == best) { //update the list end
        queue->end = bestPrev;
    }
    free(best); // release queue_entry_t
    if (queue->head == NULL) { // update end if last
        queue->end = NULL; // entry has been
    } // popped
}
return ret;
```

lec11/priority_queue.c

Prioritní fronta spojovým seznamem – příklad použití 1/2

- Inicializaci fronty provedeme polem textových řetězců a priorit

```
queue_t *queue;
queue_init(&queue);
char *values[] = { "2nd", "4th", "1st", "5th", "3rd" };
int priorities[] = { 2, 4, 1, 5, 3 };
const int n = sizeof(priorities) / sizeof(int);
for (int i = 0; i < n; ++i) {
    int r = queue_push(values[i], priorities[i], queue);
    printf("Add %2i entry '%s' with priority '%i' to the queue\n",
           i, values[i], priorities[i]);
    if (r != QUEUE_OK) {
        fprintf(stderr, "Error: Queue is full!\n");
        break;
    }
}
printf("\nPop the entries from the queue\n");
while(!queue_is_empty(queue)) {
    char* pv = (char*)queue_pop(queue);
    printf("%s\n", pv);
    // Do not call free(pv);
}
queue_delete(&queue);
```

lec11/demo-priority_queue.c

Prioritní fronta spojovým seznamem – příklad použití 2/2

- Hodnoty jsou neuspořádané a očekáváme jejich uspořádaný výpis při odebírání funkcí `pop()`

```
char *values[] = { "2nd", "4th", "1st", "5th", "3rd" };
int priorities[] = { 2, 4, 1, 5, 3 };
...
while(!queue_is_empty(queue)) {
    // Do not call free(pv);
```

- V tomto případě nevoláme `free()` neboť vložené textové řetězce jsou textovými literály
- Příklad výstupu (v tomto případě preferujeme nižší hodnoty):

```
make && ./demo-priority_queue
Add 0 entry '2nd' with priority '2' to the queue
Add 1 entry '4th' with priority '4' to the queue
Add 2 entry '1st' with priority '1' to the queue
Add 3 entry '5th' with priority '5' to the queue
Add 4 entry '3rd' with priority '3' to the queue
```

```
Pop the entries from the queue
1st
2nd
3rd
4th
5th
```

`lec11/priority_queue.h, lec11/priority_queue.c`
`lec11/demo-priority_queue.c`

Prioritní fronta polem – rozhraní

- V případě implementace prioritní fronty polem můžeme využít jedno pole pro hodnoty a druhé pole pro uložení priority daného prvku

Implementace vychází z lec10/queue_array.h,

a lec10/queue_array.c

```
typedef struct {
    void **queue;      // Pole ukazatelů na jednotlivé prvky
    int *priorities; // Pole hodnot priorit jednotlivých prvků
    int count;
    int start;
    int end;
} queue_t;
```

- Další rozhraní (jména a argumenty funkcí) mohou zůstat identické jako u implementace spojovým seznamem

Viz snímek 8

Prioritní fronta polem 1/3

- Funkce `push()` je až na uložení priority identická s verzí bez priorit

```
int queue_push(void *value, int priority, queue_t *queue)
{
    if (queue->count < MAX_QUEUE_SIZE) {
        queue->queue[queue->end] = value;

        // store priority of the new value entry
        queue->priorities[queue->end] = priority;

        queue->end = (queue->end + 1) % MAX_QUEUE_SIZE;
        queue->count += 1;
    } else {
        ret = QUEUE_MEMFAIL;
    }
    return ret;
}
```

`lec11/priority_queue-array.c`

- Funkce `peek()` a `pop()` potřebují prvek s nejnižší (nejvyšší) prioritou

- Nalezení prvku z „čela“ fronty realizujeme funkcí `getEntry()`, kterou následně využijeme jak v `peek()`, tak v `pop()`

Prioritní fronta polem 2/3

- Nalezení nejmenšího (největšího) prvku provedeme lineárním prohledáním aktuálních prvků uložených ve frontě (poli)

```
static int getEntry(const queue_t *queue)
{
    int ret = -1;
    if (queue->count > 0) {
        for (int cur = queue->start, i = 0; i < queue->count; ++i) {
            if (
                ret == -1 ||
                (queue->priorities[ret] > queue->priorities[cur])
            ) {
                ret = cur;
            }
            cur = (cur + 1) % MAX_QUEUE_SIZE;
        }
    }
    return ret;
}
```

lec11/priority_queue-array.c

Prioritní fronta polem 2/3

- Funkce `peek()` využívá lokální (static) funkce `getEntry()`

```
void* queue_peek(const queue_t *queue)
```

```
{
```

```
    return queue_is_empty(queue) ? NULL : queue->queue[getEntry(queue)];
```

```
}
```

- Ve funkci `pop()` musíme zajistit zaplnění místa, pokud je odebíráno prvek z prostředka fronty (pole).

```
void* queue_pop(queue_t *queue)      Případnou mezeru zaplníme prvkem ze startu
```

```
{
```

```
    void *ret = NULL;
```

```
    int bestEntry = getEntry(queue);
```

```
    if (bestEntry >= 0) { // entry has been found
```

```
        ret = queue->queue[bestEntry];
```

```
        if (bestEntry != queue->start) { //replace the bestEntry by start
```

```
            queue->queue[bestEntry] = queue->queue[queue->start];
```

```
            queue->priorities[bestEntry] = queue->priorities[queue->start];
```

```
        }
```

```
        queue->start = (queue->start + 1) % MAX_QUEUE_SIZE;
```

```
        queue->count -= 1;
```

```
}
```

```
    return ret;
```

```
}
```

Prioritní fronta polem – příklad použití

- Použití je identické s implementací spojovým seznamem

```
make && ./demo-priority_queue-array
ccache clang -c priority_queue-array.c -O2 -o priority_queue-
array.o
ccache clang priority_queue-array.o demo-priority_queue-array.o
-o demo-priority_queue-array
Add 0 entry '2nd' with priority '2' to the queue
Add 1 entry '4th' with priority '4' to the queue
Add 2 entry '1st' with priority '1' to the queue
Add 3 entry '5th' with priority '5' to the queue
Add 4 entry '3rd' with priority '3' to the queue

Pop the entries from the queue
1st
2nd
3rd
4th
5th
```

`lec11/priority_queue-array.h, lec11/priority_queue-array.c`
`lec11/demo-priority_queue-array.c`

Prioritní fronta spojovým seznamem nebo polem a výpočetní náročnost

- V naivní implementaci prioritní fronty jsme zohlednění priority „odložili“ až do doby, kdy potřebujeme odebrat prvek z fronty
- Při odebrání (nebo vrácení) nejmenšího prvku v nejnepříznivějším případě musíme projít všechny položky
- To může být v případě mnoha prvků **výpočetně náročné** a raději bychom chtěli „udržovat“ prvek připravený
 - Můžeme to například udělat zavedením položky **head**, ve které bude aktuálně nejnižší (nejvyšší) vložený prvek do fronty
 - Prvek **head** aktualizujeme v metodě **push()** porovnáním hodnoty aktuálně vkládaného prvku
 - Tím zefektivníme operaci **peek()**
 - V případě odebrání prvku, však musíme frontu znova projít a najít nový prvek

Alternativně můžeme použít sofistikovanější datovou strukturu, která nám umožní efektivně udržovat hodnotu nejmenšího prvku a to jak při operaci vložení **push()** tak při operaci vyjmutí **pop()** prvku z prioritní fronty.

Halda

- Halda je dynamická datová struktura, která má „tvar“ binárního stromu a uspořádání prioritní fronty
- Každý prvek haldy obsahuje hodnotu a dva potomky, podobně jako binární strom
- **Vlastnosti haldy**
 - Hodnota každého prvku je menší než hodnota libovolného potomka
 - Každá úroveň haldy je plná, kromě poslední úrovně, která je zaplněna zleva doprava
- Prvky mohou být odebrány pouze přes kořenový uzel
- Vlastnost haldy zajišťuje, že **kořen je vždy prvek s nejnižším/nejvyšším ohodnocením**

Binární plný strom

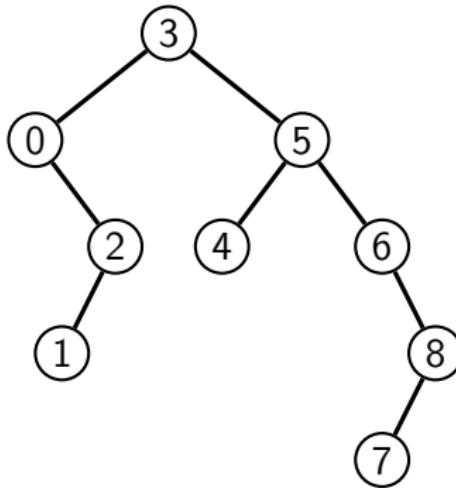
V případě binárního plného stromu je složitost procházení následníku úměrná hloubce stromu, která je v případě n prvků úměrná $\log_2(n)$. Složitost operací `push()`, `pop()`, `peek()` tak můžeme očekávat nikoliv $O(n)$, ale $O(\log n)$.

Binární vyhledávací strom vs haldy

Binární vyhledávací strom

- Může obsahovat prázdná místa
- Hloubka stromu se může měnit

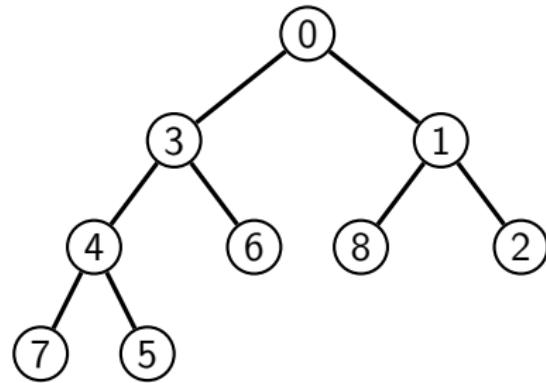
Přestože jsme raději, pokud je strom vyvážený. To je však implementačně náročnější než implementace haldy.



Halda

- Binární plný strom
- Kořen stromu je vždy prvek s nejnižší (nejvyšší) hodnotou
- Strom splňuje vlastnost haldy

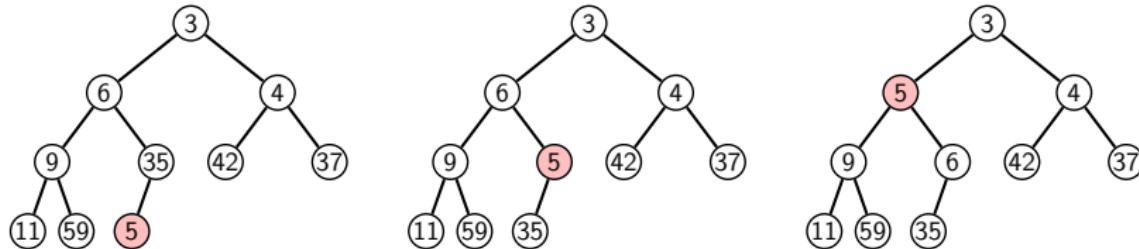
Heap property



Halda – přidání prvku **push()**

- Po každém provedení operace **push()** musí být splněny vlastnosti haldy
- Prvek přidáme na konec haldy, tj. na první volnou pozici (vlevo) na nejnižší úrovni haldy
- Zkontrolujeme, zdali je splněna podmínka haldy, pokud ne, zameníme prvek s nadřazeným prvkem (předkem)

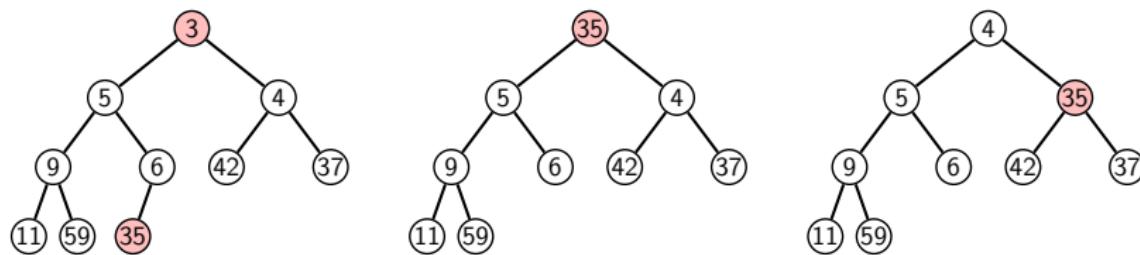
V nejnepříznivějším případě prvek „probublá“ až do kořene stromu



Halda – odebrání prvku **pop()**

- Při operaci **pop()** odebereme kořen stromu
- Prázdné místo nahradíme nejpravějším listem
- Zkontrolujeme, zdali je splněna podmínka haldy, pokud ne, zaměníme prvek s potomkem a postup opakujeme

V nejnepříznivějším případě prvek „probublá“ až do listu stromu



- Jak zjistit nejpravější list
 - V případě implementace spojovou strukturou (nelineární) můžeme explicitně udržovat odkaz
 - Binární plný strom můžeme efektivně reprezentovat pole, pak poslední prvek v poli je nejpravější list

Prioritní fronta haldou

- Prvky ukládáme do haldy a při každém vložení / odebrání zajišťujeme, aby platily vlastnosti **haldy**
- Operace **peek()** má konstantní složitost a nezáleží na počtu prvků ve frontě, nejnižší prvek je vždy kořen

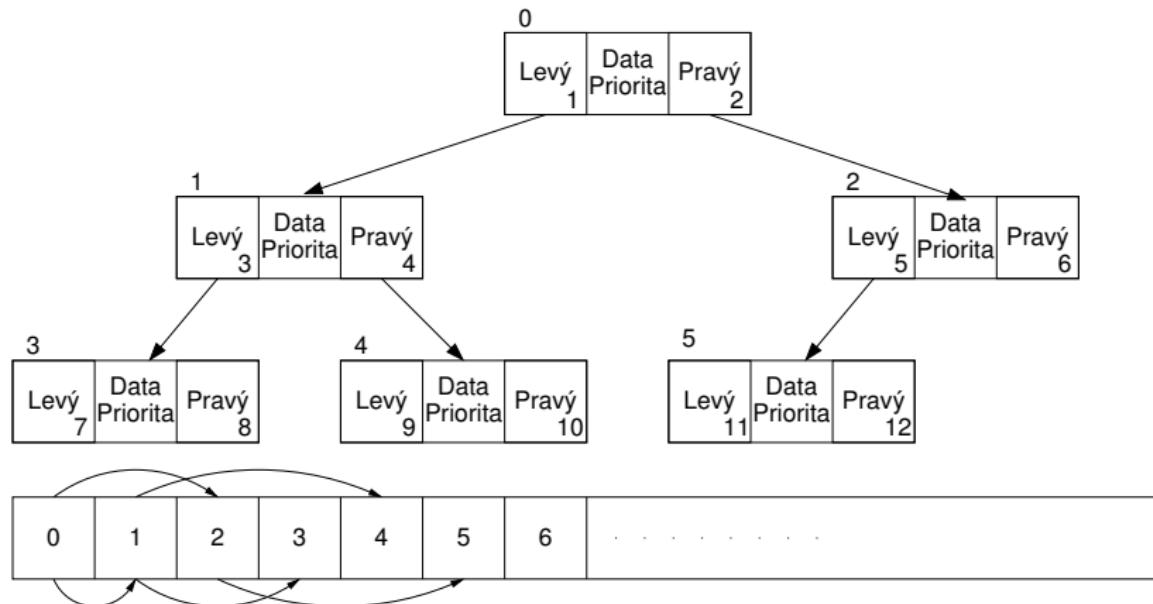
Asymptotická složitost v notaci velké O je $O(1)$.

- Operace **push()** a **pop()** udržují vlastnost haldy záměnami prvku až do hloubky stromu

Pro binární plný strom je hloubka stromu $\log_2(n)$, kde n je aktuální počet prvků ve stromu, odtud složitost operace $O(\log(n))$.

Reprezentace binárního stromu polem

- Binární plný strom můžeme reprezentovat lineární strukturou
 - V případě známého maximální počtu prvků v haldě, pak jednoduše předalokovaným polem položek



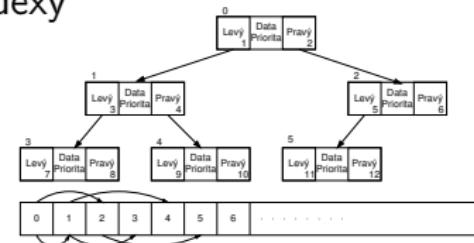
Halda jako binární plný strom reprezentovaný polem

- Pro definovaný maximální počet prvků v haldě, si předalokujeme pole o daném počtu prvků
- Binární **plný strom** má všechny vrcholy na úrovni rovné hloubce stromu co nejvíce vlevo
- Kořen stromu je první prvek s indexem 0, následníky prvku na pozici i lze určit jako prvky s indexy

■ levý následník: $i_{\text{levý}} = 2i + 1$

■ pravý následník: $i_{\text{pravý}} = 2i + 2$

Podobně lze odvodit vztah pro předchůdce



- Kořen stromu reprezentuje nejprioritnější prvek

(např. s nejmenší hodnotou nebo maximální prioritou)

Operace vkládání a odebírání prvků

- I v případě reprezentace polem pracují operace vkládání a odebírání identicky
 - Funkce `push()` přidá prvek jako další prvek v poli a následně propaguje prvek směrem nahoru až **je splněna vlastnost haldy**
 - Při odebrání prvku funkcí `pop()` je poslední prvek v poli umístěn na začátek pole (tj. kořen stromu) a propagován směrem dolů až **je splněna vlastnost haldy**
- Pouze dochází k vzájemnému zaměňování hodnot na pozicích v poli Z indexu prvku v poli vždy můžeme určit jak levého a pravého následníka, tak i předcházející prvek (rodič) ve stromové struktuře.
- Hlavní výhodou reprezentace polem je přístup do předem alokovaného bloku paměti
- Všechny prvky můžeme jednoduše projít v jedné smyčce
Relativně jednoduše můžeme implementovat funkci ověřující, zdali naše implementace operací `push()` a `pop()` zachovávají podmínky haldy.

Příklad implementace pq_is_heap()

- Pro každý prvek haldy musí platit, že jeho hodnota je menší než hodnota levého a pravého následníka

```
typedef struct {
    int size;      // the maximal number of entries
    int len;       // the current number of entries
    int *cost;     // array with entries (costs)
    int *label;    // array with vertex labels
} pq_heap_s;

_Bool pq_is_heap(pq_is_heap *pq, int n)
{
    _Bool ret = true;
    int l = 2 * n + 1; // left successor
    int r = l + 1;     // right successor
    if (l < pq->len) {
        ret = (pq->cost[l] < pq->cost[n]) ? false : pq_is_heap(heap, l);
    }
    if (r < pq->len) {
        ret = ret
            &&
            ( (pq->cost[r] < pq->cost[n]) ? false : pq_is_heap(heap, r) );
    }
    return ret;
}
```

Příklad implementace push()

- Prvek přidáme na konec pole a iterativně kontrolujeme, zdali je splněna vlastnost haldy

```
#define GET_PARENT(i) ((i-1) >> 1)

_Bool pq_push(pq_heap_s *pq, int label, int cost)
{
    _Bool ret = false;
    if (pq && pq->len < pq->size && label >= 0 && label < pq->size) {
        pq->cost[pq->len] = cost; //add the cost to the next free slot
        pq->label[pq->len] = label; //add vertex label

        int cur = pq->len; // index of the entry added to the heap
        int parent = GET_PARENT(cur);
        while (cur >= 1 && pq->cost[parent] > pq->cost[cur]) {
            pq_swap(pq, parent, cur); // swap parent<->cur
            cur = parent;
            parent = GET_PARENT(cur);
        }
        pq->len += 1;
        ret = true;
    }
    // assert(pq_is_heap(pq, 0));
    return ret;
}
```

Příklad volání pop()

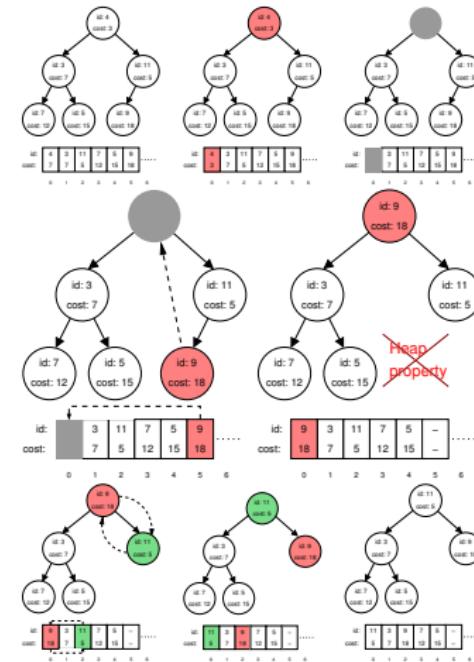
- Halda je reprezentovaná binárním polem
- Nejmenší prvek je kořenem stromu
- Voláním pop() odebíráme kořen stromu
- a na jeho místo umístíme poslední prvek
- Strom však nesplňuje podmínu haldy
- Pro provedeme záměnu s následníky

V tomto případě volíme pravého následníka, neboť jeho hodnota je nižší než hodnota levého následníka.

- A strom opět splňuje vlastnost haldy
- Záměny provádíme v poli a využíváme vlastnosti plného binárního stromu

Levý potomek prvku halda na pozici i je $2i + 1$, pravý potomek je na pozici $2i + 2$

Obdobně postupujeme při push() záměny však provádíme směrem nahoru a z indexu prvku určujeme předchodce (dělením 2)

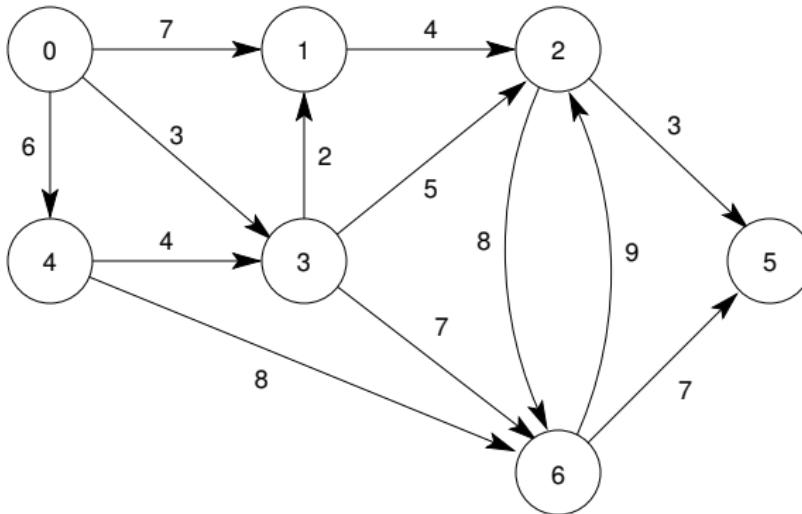


Část II

Část 2 – Příklad využití prioritní fronty
v úloze hledání nejkratší cesty v grafu

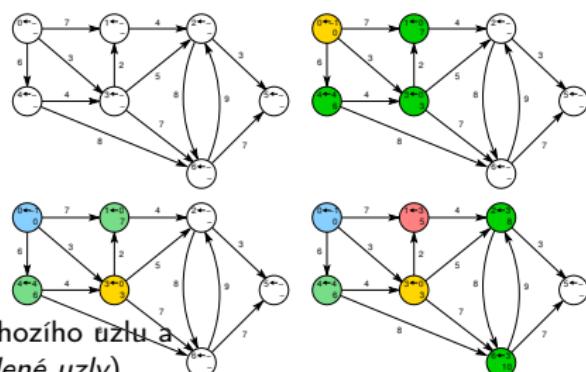
Hledání nejkratší cesty v grafu

- Uzly grafu mohou reprezentovat jednotlivá místa
- Hrany pak reprezentují cestu jak se mezi místy pohybovat
- Ohodnocení (cena) hrany pak může například odpovídat náročnosti pohybu mezi dvě sousedními uzly
- Cílem je nalézt nejkratší cestu z nějakého konkrétního uzlu (0) do všech ostatních uzlů



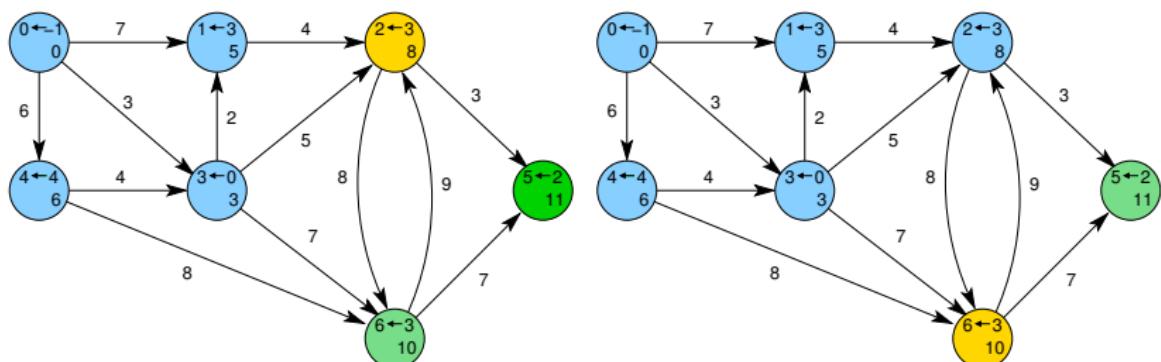
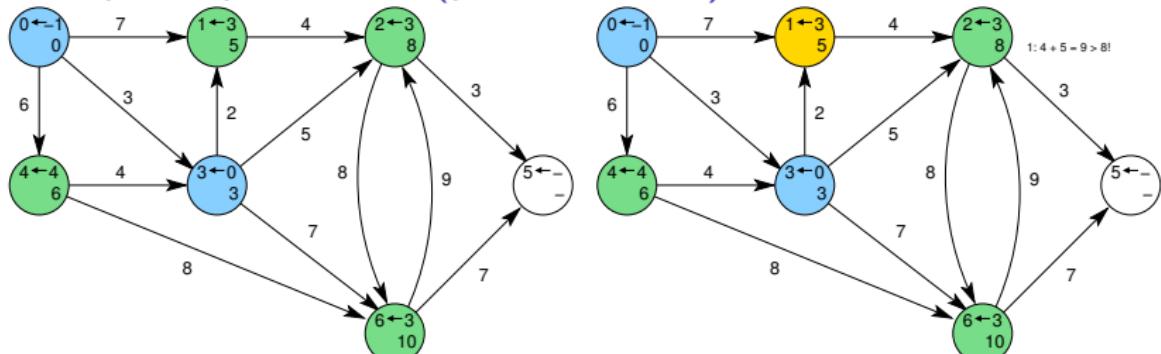
Dijkstrův algoritmus

- Nechť graf má pouze kladné ohodnocení hran, pak pro každý uzel
 - nastavíme aktuální cenu nejkratší cesty z výchozího uzlu
 - dále udržujeme odkaz na bezprostředního předchůdce na nejkratší cestě ze startovního uzlu
- Hledání cesty je postupná aktualizace ceny nejkratší cesty do jednotlivých uzlů
 - Začneme z výchozího uzlu (cena 0) a aktualizujeme ceny následníků
 - Následně vybereme takový uzel
 - Již do něj existuje nějaká cesta z výchozího uzlu
 - Má aktuálně nejnižší ohodnocení
 - Postup opakujeme dokud existuje nějaký dosažitelný uzel.
 - Tj. uzel do kterého vede cesta z výchozího uzlu a má již ohodnocení a předchůdce (zelené uzly).



Ohodnocení uzlů se může pouze snižovat, cena hran je nezáporná.
Tzn. nemůže existovat kratší cesta.

Příklad postupu řešení (pokračování)



Příklad přístupu řešení úlohy hledání nejkratších cest v grafu

Řešení úlohy se skládá z

- **Vstupních dat** (grafu) – paměťová reprezentace a načtení hodnot

Formát vstupního souboru

- Vstupní graf je zadán jako seznam hran
- Dalším vstupem je výchozí uzel

from to cost – Viz 9. přednáška

Pro jednoduchost budeme uvažovat 1. uzel (0)

- **Výstupních dat** (nejkratší cesty) – paměťová reprezentace a uložení (výpis)

Formát výstupního souboru

- Všechny nejkratší cesty vypíšeme jako seznam vrcholů s cenou (délkou) nejkratší cesty a bezprostředním předchůdcem (indexem) uzlu na nejkratší cestě

label cost parent

- **Algoritmu** hledání cest – Dijkstrův algoritmus

- Algoritmus je relativně přímočarý v každém kroku expandujeme uzel s aktuálně nejkratší cestou z výchozího uzlu

V každém kroku potřebujeme nejmenší prvek – použijeme prioritní frontu

Vstupní graf, reprezentace grafu a řešení

- Graf je zadán jako seznam hran v souboru, který můžeme načíst funkcí `load_graph_simple()` z `lec09/load_simple.c`
- Graf je seznam hran

```
typedef struct {
    int from;
    int to;
    int cost;
} edge_t;
```

<pre><code>typedef struct { edge_t *edges; int num_edges; int capacity; } graph_t;</code></pre>	<code>lec09/graph.h</code>	0 5 74 1 6 56 2 8 11 2 9 27 2 4 31 2 3 41 2 1 26 3 5 24 3 9 12 4 9 13 ...
---	----------------------------	---

- Navíc využijeme toho, že jsou hrany uspořádané
 - Hrany vycházející z uzlu určíme jako index první hrany a počet hran
- Pro vlastní řešení potřebujeme u každého uzlu uložit cenu nejkratší cesty (`cost`) a předcházející uzel na nejkratší cestě `parent`

```
typedef struct {
    int edge_start;
    int num_edges;
    int parent;
    int cost;
} node_t;
```

Datová reprezentace

- Řešení implementujeme v modulu `dijkstra`
- Všechny potřebné datové struktury implementujeme jako strukturu `dijkstra_t`

```
typedef struct {
    graph_t *graph;
    node_t *nodes;
    int num_nodes;
    int start_node;
} dijkstra_t;
```

- Pro alokaci použijeme `malloc()`, `allocate_graph()` a inicializujeme položky struktury na výchozí hodnoty

```
dijkstra_t *dij = (dijkstra_t*)malloc(sizeof(dijkstra_t));
dij->nodes = NULL;
dij->num_nodes = 0;
dij->start_node = -1;
dij->graph = allocate_graph();
```

Načtení grafu a inicializace uzlů 1/2

- Hrany načteme např. funkcí `load_graph_simple()`

Pro jednoduchost také předpokládáme bezchybné načtení

- Dále potřebujeme zjistit počet vrcholů

Lze implementovat přímo do načítání

- Alokujeme paměť pro uzly a nastavíme (bezpečné) výchozí hodnoty

```
load_graph_simple(filename, dij->graph);
int m = -1;
for (int i = 0; i < dij->graph->num_edges; ++i) {
    const edge_t *const e = &(dij->graph->edges[i]);
    m = m < e->from ? e->from : m;
    m = m < e->to ? e->to : m;
} // smyčka pro určení maximálního počtu vrcholů

dij->num_nodes = m + 1; //m je index a začína od 0 proto +1
dij->nodes = (node_t*)malloc(sizeof(node_t) * dij->num_nodes);
for (int i = 0; i < dij->num_nodes; ++i) {
    dij->nodes[i].edge_start = -1;
    dij->nodes[i].num_edges = 0;
    dij->nodes[i].parent = -1; // pokud neexistuje indikujeme -1
    // pro cenu volíme -1 ve výpisu bude kratší než MAX_INT
    dij->nodes[i].cost = -1;
} // nastavení výchozích hodnot uzlů
```

Inicializace uzlů 2/2

- Nastavíme indexy hran jednotlivým uzlům

```
for (int i = 0; i < dij->graph->num_edges; ++i) {  
    int cur = dij->graph->edges[i].from;  
    if (dij->nodes[cur].edge_start == -1) { // first edge  
        // mark the first edge in the array of edges  
        dij->nodes[cur].edge_start = i;  
    }  
    dij->nodes[cur].num_edges += 1; // increase no. of edges  
}
```

Hledání nejkratších cest

- Využijeme implementaci prioritní fronty s `push()` a `update()`

```

dij->nodes[dij->start_node].cost = 0; // inicializace
void *pq = pq_alloc(dij->num_nodes); // prioritní fronta
int cur_label;
pq_push(pq, dij->start_node, 0);
while ( !pq_is_empty(pq) && pq_pop(pq, &cur_label)) {
    node_t *cur = &(dij->nodes[cur_label]); // pro snazší použití
    for (int i = 0; i < cur->num_edges; ++i) { // všechny hrany z uzlu
        edge_t *edge = &(dij->graph->edges[cur->edge_start + i]);
        node_t *child = &(dij->nodes[edge->to]);
        const int cost = cur->cost + edge->cost;
        if (child->parent == -1) {
            child->cost = cost;
            child->parent = cur_label;
            pq_push(pq, edge->to, cost);
        } else if (cost <= child->cost) { // uzel již v pq, proto
            child->cost = cost; // testujeme cost
            child->parent = cur_label; // a případně aktualizujeme
            pq_update(pq, edge->to, cost); // odkaz (parent) a pq
        }
    } // smyčka přes všechny hrany z uzlu cur_label
} // prioritní fronta je prázdná
pq_free(pq); // uvolníme paměť

```

lec11/dijkstra.c

Zápis řešení

- Zápis řešení do souboru můžeme implementovat jednoduchým výpisem do souboru

```
_Bool dijkstra_save_path(void *dijkstra, const char *
    filename)
{
    _Bool ret = false;
    const dijkstra_t *const dij = (dijkstra_t*)dijkstra;
    if (dij) {
        FILE *f = fopen(filename, "w");
        if (f) {
            for (int i = 0; i < dij->num_nodes; ++i) {
                const node_t *const node = &(dij->nodes[i]);
                fprintf(f, "%i %i %i\n",
                        i, node->cost, node->parent);
            } // end all nodes
            ret = fclose(f) == 0;
        }
    }
    return ret;
}
```

lec11/dijkstra.c

Příklad použití

- Základní implementace uvedeného hledání cest je dostupná v `lec11/graph_search`
- Vytvoříme graf `g` programem `tdijkstra` např. o max 1000 vrcholech,

```
./tdijkstra -c 1000 g
```

- Program zkompilujeme a spustíme např.

```
./tgraph_search g s
```

- Programem `tdijkstra` můžeme vygenerovat referenční řešení např.

```
./tdijkstra g s.ref
```

- a naše řešení pak můžeme porovnat např.

```
diff s s.ref
```

Prioritní fronta s push() a update()

- Při expanzi uzlu, můžeme do prioritní fronty vkládat uzly s cenou pro každou hranu vycházející z uzlu
- Obecně může být hran výrazně více než počet uzlů

Pro plný graf o n uzlech až n^2 hran

- Proto pro prioritní frontu (haldu) implementujeme funkci `update()` a tím zaručíme, že ve frontě bude nejvýše tolik prvků, kolik je vrcholů
- Můžeme tak snadno implementovat prioritní frontu haldou reprezentovanou v poli
Získáme tak složitost operací $O(\log n)$
- Pro efektivní implementaci funkce `update()` však potřebujeme získat pozici daného uzlu v haldě
 - V případě hledání nejkratších cest, se délka cestu do uzlu může pouze snižovat
 - Proto se aktualizovaných „uzel“ může v haldě pohybovat pouze směrem nahoru

Jedná se tak o identický postup jako při přidání nového prvku funkcí `push()`. V tomto případě však prvek může startovat z prostředka stromu.

Příklad reprezentace haldy v poli a aktualizace ceny cesty

V haldě jsou uloženy délky dosud známých nejkratších cest pro vrcholy označené: 3, 4, 5, 7, 9, a 11.

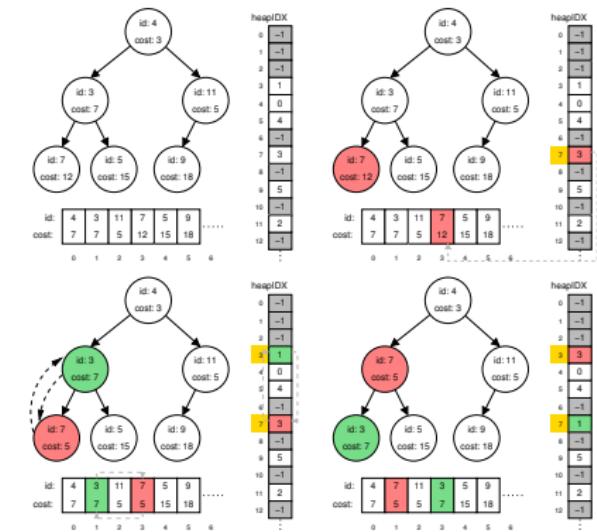
- Při expanzi dalšího uzlu jsme našli kratší cestu do uzlu 7 s délkou 5.

Zavoláme `update(id=7, cost=5)`

- Abychom mohli aktualizovat cenu v haldě, potřebujeme znát pozici uzlu v poli haldy.

- Proto vedle samotné haldy udržujeme pole, které je indexované číslem uzlu.
- Po aktualizaci ceny, není splněna vlastnost haldy. Provedeme záměnu.
- Při záměně udržujeme nejen prvky v samotné haldě, ale také pole `heapIDX` s pozicemi vrcholů v poli haldy.

Princip totožný, jen kromě samotné haldy ještě manipulujeme s další strukturou—polem s indexy `heapIDX`



Prioritní fronta pro Dijkstrův algoritmus

- Součástí balíku `lec11/graph_search` je rozhraní `pq_heap.h` pro implementaci prioritní fronty haldou s funkcí `update()`

```
void *pq_alloc(int size);
```

```
void pq_free(void *heap);
```

```
_Bool pq_is_empty(const void *heap);
```

```
_Bool pq_push(void *heap, int label, int cost);
```

```
_Bool pq_update(void *heap, int label, int cost);
```

```
_Bool pq_pop(void *heap, int *oLabel);
```

```
_Bool pq_is_heap(void *heap, int n);
```

`lec11/pq_heap.h`

- Jedná o relativně obecný předpis, který neklade zvláštní požadavky na vnitřní strukturu

V balíku je rozhraní implementované v modulu `pq_array-linear`, který obsahuje implementaci prioritní fronty s lineární složitostí

- Poslední domácí úkol HW10 je zaměřen na implementaci rozhraní `pq_heap.h` haldou, která bude mít složitost odpovídající $O(\log n)$.

Lineární prioritní fronta vs efektivní implementace

- Ukázková implemetace v `lec11/graph_search`, je sice funkční, pro velké grafy je však výpočet pomalý

- Například pro graf s 1 mil. vrcholů trvá načtení, nalezení všech nejkratší cest a uložení výsledku přibližně 120 sekund

```
./tdijkstra -c 1000000 g                               Intel Skylake@3.3GHz
/usr/bin/time ./tgraph_search g s
Load graph from g
Find all shortest paths from the node 0
Save solution to s
Free allocated memory
    120.53 real        115.92 user        0.07 sys
```

- Referenčnímu programu `tdijkstra` pouze cca 1 sekundu

Též k dispozici jako `tdijkstra.Linux` a `tdijkstra.exe`

```
/usr/bin/time ./tdijkstra g s.ref
    1.03 real        0.94 user        0.07 sys
```

- Oba programy vracejí identické výsledky

```
md5sum s s.ref
MD5 (s) = 8cc5ec1c65c92ca38a8dadf83f56e08b
MD5 (s.ref) = 8cc5ec1c65c92ca38a8dadf83f56e08b
```

Základní verze řešení HW10 nesmí být více než 10× pomalejší než referenční program.

Další možnosti urychljení programu

- Kromě efektivní implementace prioritní fronty haldou, která je zásadní, lze běh programu dále urychlit efektivnějším načítáním grafu a ukládáním řešení do souboru.

```
./tgraph_search-time g s 2>/  
    dev/null  
Load time ....1008ms  
Solve time ...118808ms  
Save time ....311ms  
Total time ...120127ms
```

```
./tdijkstra -v g s.ref  
Dijkstra version 2.3.4  
Load time ....223ms  
Solve time ...715ms  
Save time ....106ms  
Total time ...1044ms
```

lec11/graph_search-time.c

- Soutěž v rychlosti programu – prvních 20 nejrychlejších programů si rozdělí v součtu 50 extra bodů

Část III

Část 3 – Zadání 10. domácího úkolu
(HW10)

Zadání 10. domácího úkolu HW10



- Termín odevzdání: 07.01.2017, 23:59:59 PST

PST – Pacific Standard Time

Shrnutí přednášky

Diskutovaná téma

- Prioritní fronta
 - Příklad implementace spojovým seznamem
`lec11/priority_queue-linked_list`
 - Příklad implementace polem
`lec11/priority_queue-array`
- Halda - definice, vlastnosti a základní operace
- Reprezentace binárního plného stromu polem
- Prioritní fronta s haldou
- Hledání nejkratší cesty v grafu – využití prioritní fronty (resp. haldy)
- Příště: Systémy pro správu verzí.