PB165 Grafy a sítě: Plánování s komunikací

Plánování s komunikací

Plánování s precedencemi: přehled

Příklady aplikací

- **plánování komunikujících úloh s precedencemi**
  - acyklický graf precedenčních závislostí mezi úlohami
  - přenos dat po skončení úlohy následující úlohám
- **plánování acyklických workflows**

Algorimy

- optimální (polynomiální složitost)
  - použitelné pouze pro velmi specializované problémy
  - obtížná rozšiřitelnost na obecné problémy
  - př. plánování na dvou procesorech, plánování stromů
- heuristické
  - **plánování seznamem (list scheduling)**
  - **heuristiky mapování (mapping heuristics)**
  - **shlukovací heuristiky (clustering heuristics)**

Úlohy a komunikace

Referenční doba trvání p_j úlohy j

Precedenční omezení $j1 \rightarrow j2$

Komunikace: $size_{j1,j2}$

- $size_{j1,j2}$: velikost přenesených dat mezi úlohami $j1$ a $j2$
- pokud existuje $j1 \rightarrow j2$, pak $size_{j1,j2} \geq 0$, jinak $size_{j1,j2} = 0$
- pokud jsou $j1$ a $j2$ zpracovány na stejném stroji, tak lze čas na komunikaci (a tedy i velikost přenášených dat) zanedbat

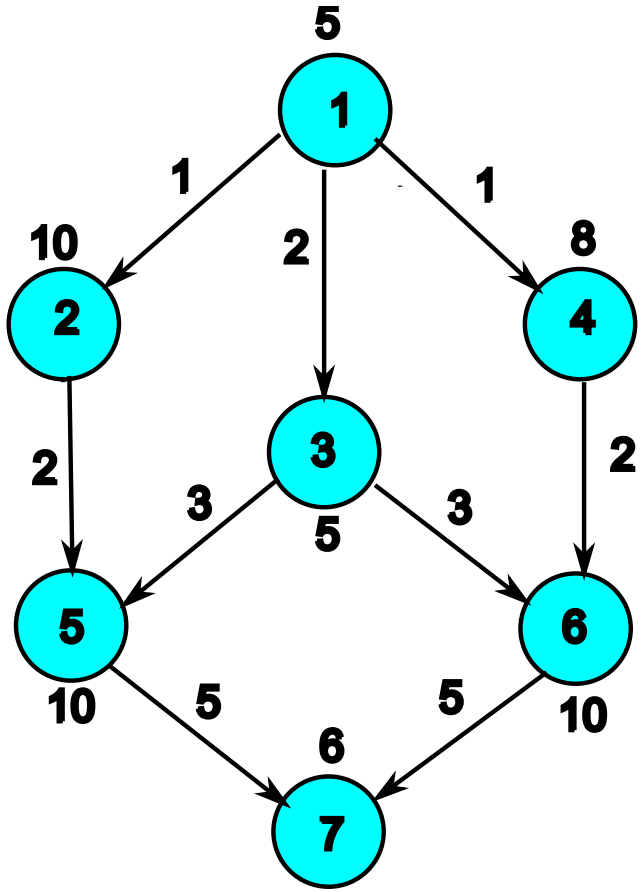

Hranově a vrcholově ohodnocený acyklický orientovaný graf

- vrcholy: úlohy
- orientované hrany: precedenční vztahy mezi úlohami
- ohodnocení hrany: velikost dat na komunikaci
- ohodnocení vrcholu: referenční doba trvání

Síť a komunikační zpoždění

- Topologie sítě: příklady

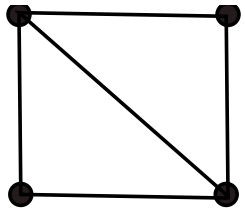

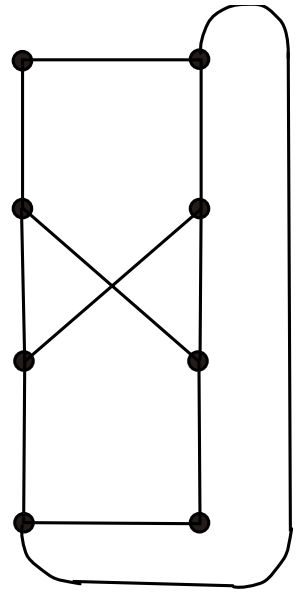

každý uzel grafu reprezentuje dual-core procesor

- $transrate_{i1,i2}$: přenosová rychlost mezi sousedními stroji $i1, i2$
- $setupmesg_i$: (inicializační) doba na poslání zprávy strojem i
- **Komunikační zpoždění** $c(j1, j2, i1, i2)$ pro poslání dat z úlohy $j1$ úloze $j2$ ze stroje $i1$ na sousední stroj $i2$

$$c(j1, j2, i1, i2) = \frac{size_{j1,j2}}{transrate_{i1,i2}} + setupmesg_{i1}$$

Doba provádění, optimalizace

- $speed_i$: rychlost zpracování strojem i
- $setuptask_i$: (inicializační) doba na nastartování úlohy na stroji i
- **Doba provádění** p_{ij} úlohy j na stroji i:

$$p_{ij} = \frac{p_j}{speed_i} + setuptask_i$$

- **Objektivní funkce (performance measure)**
  - minimalizace makespan (čas dokončení poslední úlohy)
  - do makespan se započítává:
    doba provádění + komunikační zpoždění

Plánování seznamem (list scheduling)

Plánování seznamem = jednoduchý efektivní algoritmus

- založeno na seřazení úloh v **prioritní frontě**
- složitost algoritmu závisí na výpočtu
  - priority určující pořadí spuštění úloh
  - metody výběru stroje (pro danou úlohu)

Používán i při plánování úloh bez precedencí, kde priorita dána

- pořadím přicházejích úloh
- úrovní paralelismu
- délkou trvání
- vlastníkem úlohy
- ...

Základní algoritmus plánování seznamem

Algoritmus parametrizován funkcemi

- výpočet priority P
- výběr stroje M

Plánování seznamem(P, M)

1. každé úloze j přiřazena priorita pomocí $P(j)$

   prioritní fronta inicializována úlohami bez předchůdců

   úlohy ve frontě řazeny v klesajícím pořadí dle priority
2. pokud existuje volný stroj a fronta je neprázdná, prováděj:
   1. jakmile provedeni všichni přímí předchůdci nějaké úlohy, tak je úloha přidána dle priority do fronty
   2. odebrána první úloha z fronty
   3. volný procesor je vybrán pro spuštění úlohy j pomocí $M(j)$

Algoritmus plánování seznamem a aktuální čas t

Při plánování seznamem je nutné pracovat s **aktuálním časem** t

- rozšíříme základní algoritmus tak, aby byla práce s časem zřejmá

Plánování seznamem včetně času(P, M)

1. **inicializace aktuálního času** $t = 0$
2. každé úloze j přiřazena priorita pomocí $P(j)$

   prioritní fronta inicializována úlohami bez předchůdců

   úlohy ve frontě řazeny v klesajícím pořadí dle priority
3. pokud existuje volný stroj a fronta je neprázdná, prováděj:
   1. $t =$ **nejdřívější čas, kdy je nějaký stroj volný**
   2. jakmile provedeni všichni přímí předchůdci $j_1, \ldots, j_k$ nějaké úlohy j_0, **tj.** $\forall l = 1..k : C_l \leq t$
      tak je úloha j_0 přidána dle priority $P(j_0)$ do fronty
   3. odebrána první úloha (j) z fronty
   4. volný procesor je vybrán pro spuštění úlohy j pomocí $M(j)$
      startovní čas S_j **úlohy** j **je** t

Priority pro plánování seznamem

Délka cesty přes uzly $j_1, j_2 \ldots j_n$:

$$w1 \sum_{j=1}^{n} p_j + w2 \sum_{j=1}^{n-1} size_{j,j+1}$$

$w1, w2$: koeficienty určující poměr mezi dobou trvání a velikostí přenesených dat

Počáteční uzly *Begin*: uzly bez předchůdců
Koncové uzly *End*: uzly bez následníků

Možnosti pro **výpočet priority** $P(j_0)$ **uzlu** j_0

- **úroveň (level)** bude dále používána pro výpočet priority

  délka nejdelší cesty z uzlu j_0 do koncového uzlu

$$P(j_0) = \max_{\forall \text{cesty } (j_0, j_1, \ldots, j_k): j_k \in End} w1 \sum_{j=0}^{k} p_j + w2 \sum_{j=0}^{k-1} size_{j,j+1}$$

- **ko-úroveň (co-level)**

  délka nejdelší cesty z počátečního uzlu do uzlu j_0

Zanedbání komunikace, výběr stroje M

Zanedbání doby na komunikaci:

- pokud máme $j1 \rightarrow j2$ a úlohy $j1$ a $j2$ jsou prováděny na stejném stroji, tak dobu na komunikaci zanedbáme

Značení: **koncový čas C_{ij} úlohy j při zpracování na stroji i**

Výběr stroje $M(j)$ pro úlohu j:

- pro provádění úlohy jsou vybírány pouze volné stroje
- pro provádění úlohy j je vybrán volný stroj i, na kterém bude úloha j dokončena nejdříve

$$C_j = \min_{\forall i : volny(i)} C_{ij}$$

- v případě více možností je vybrán stroj s nejmenším indexem
- pozor: při výpočtu koncového času úloh, je třeba brát v úvahu, zda na některém stroji nedojde k zanedbání komunikace

Zjednodušení modelu plánování

Předpokládejme, že

- doba na poslání dat z úlohy $j1$ na úlohu $j2$ nezávisí na tom, mezi kterými stroji budeme data posílat a odpovídá přímo $size_{j1,j2}$

$$c(j1, j2, i1, i2) = c(j1, j2) = size_{j1,j2}$$

- $w1 = w2 = 1$
- všechny stroje i mají stejnou jednotkovou rychlost

$$speed_i = 1$$

- doba na nastartování úlohy $setuptask_i$ na stroji i je zanedbatelná

$\Rightarrow$ Doba provádění úlohy j není závislá na stroji, tj.

$$p_{ij} = \frac{p_j}{speed_i} + setuptask_i = p_j$$

budeme tedy pro značení doby trvání úlohy j používat pouze p_j

$\Rightarrow$ Úlohy lze plánovat přímo podle dle zadané p_j a $size_{j1,j2}$

Koncový čas C_{ij} úlohy j při zpracování na volném stroji i

C_{ij} spočítán na základě

- aktuálního času t (čas, ve kterém úlohu j odebíráme z fronty)
- doby provádění p_j
- komunikace s předchůdci $j1$ ($j1 \rightarrow j$), kteří nebyli prováděni na stroji i

$$\text{pro } volny(i) : C_{ij} = t + p_j + \sum_{\substack{\forall j1 : j1 \rightarrow j, \\ j1 \text{ prováděna na stroji i1}, i1 \neq i}} size_{j,j1}$$

Tj. uvažujeme možné zanedbání komunikace

- úloha je ve frontě až v okamžiku, když jsou všichni předchůdci dopočítáni tj. známe jejich stroj a víme, zda dojde k zanedbání komunikace

Příklad: $t = 1$

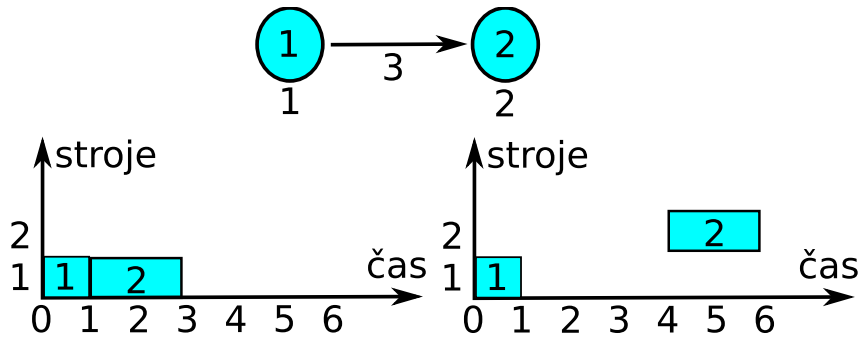

se zanedbáním komunikace bez zanedbání komunikace

Výběr stroje: algoritmus (shrnutí)

Výběr stroje $M(j)$ pro úlohu j v čase t

1. $C_j = MaxNumber$
2. REPEAT
   1. i = nejmenší index dosud neprozkoumaného volného stroje
   2. spočítáme koncový čas C_{ij} úlohy j na stroji i
      $$C_{ij} = t + p_j + \sum_{\substack{\forall j1 : j1 \to j, \\ j1 \text{ prováděna na stroji i1}, i1 \neq i}} size_{j,j1}$$
   3. pokud je koncový čas na stroji i lepší,
      tak je i novým kandidátem na zpracování úlohy j
      IF $C_{ij} < C_j$ THEN $M(j) = i$

   UNTIL jsme neprošli všechny volné stroje

Plánování seznamem: příklad

Plánování 6 úloh zadaných grafem na 2 stroje se stejnou rychlostí

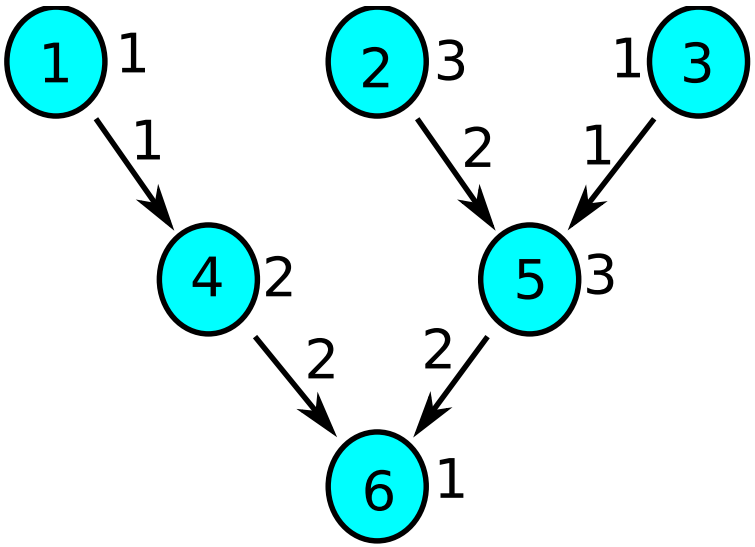

komunikace zanedbána:

1->4

2->5

5->6

Fronta: ~~2~~ ~~3~~ ~~1~~ ~~4~~ ~~5~~ ~~6~~

Úroveň: ~~11~~ ~~8~~ ~~7~~ ~~5~~ ~~6~~ ~~1~~

Akt.čas: 0 0 1 2 3 7

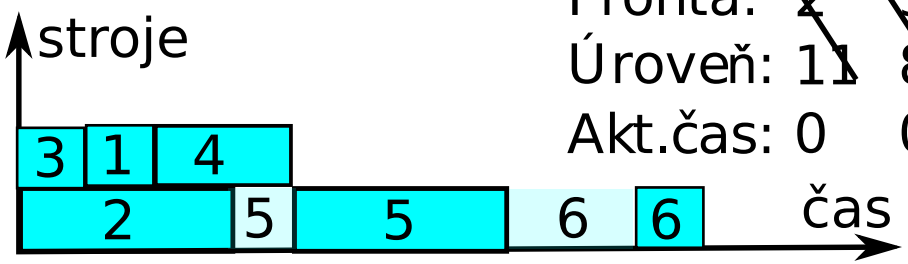

- tmavší obdélníky v rozvrhu znázorňují dobu, kdy úloha běží
- světlejší obdélníky odpovídají době na komunikaci pro danou úlohu
  - pro 5: komunikace $3 \rightarrow 5$, pro 6: komunikace $4 \rightarrow 6$

Plánování seznamem: cvičení

Vyřešte následující problém plánování s komunikací a s precedencemi pomocí plánování seznamem:

- jsou dány 2 stroje se stejnou rychlostí
- je dáno 6 úloh s dobou trvání
  $p_1 = 1, p_2 = 1, p_3 = 2, p_4 = 1, p_5 = 2, p_6 = 1$
- jsou dány precedence: $1 \rightarrow 2, 2 \rightarrow 4, 4 \rightarrow 6, 1 \rightarrow 3, 3 \rightarrow 5, 5 \rightarrow 6$
- $size_{i1,i2}$ reprezentuje dobu na přenos dat a je zadán takto:
  $size_{1,2} = 1, size_{2,4} = 3, size_{4,6} = 1,$
  $size_{1,3} = 2, size_{3,5} = 4, size_{5,6} = 2$

Plánování seznamem: diskuse

Výběr úlohy s nejvyšší úrovní = **výběr úlohy na kritické cestě**

Problémy při použití heuristiky

- snadno může dojít ke **změně kritické cesty**: důsledkem toho, že
  - $\Leftarrow$ komunikační zpoždění závisí na alokaci úlohy na stroj
  - $\Leftarrow$ např. při alokaci na stejné stroje se zanedbatelným zpožděním nebo při nestejnoměrné vzdálenosti strojů (a počtu hopů)

Řada heuristik založena na principu (několika) prioritních front

- rozsáhlé modifikace priorit a metod výběru stroje

  umožňují zachytit různé charakteristiky systému
- např. **produkční plánovací systémy** pro plánování úloh na počítačích PBSPro, SGE

Heuristiky mapování (mapping heuristics)

- **Modifikace plánování seznamem**
- Více uvažovány reálné parametry:
  - topologie sítě, rychlost procesoru, přenosová rychlost, ...
- Doba provádění úlohy i na stroji j

$$p_{ij} = \frac{p_i}{speed_j} + setuptask_j$$

- Komunikační zpoždění

$$c(j1, j2, i1, i2) = \left(\frac{size_{j1,j2}}{transrate} + setupmesg \right) \times hops_{i1,i2} + contdelay_{i1,i2}$$

  - předpokládán konstantní *transrate* a *setupmesg*
  - $hops_{i1,i2}$: počet hopů mezi stroji $i1$ a $i2$, (délka nejkratší cesty mezi stroji při jednotkovém ohodnocení hran)
  - $contdelay_{i1,i2}$: zpoždění dané zatížením linky mezi $i1$ a $i2$ (*contention delay*)

Heuristiky mapování (mapping heuristics)

- Konstruována a udržována **směrovací tabulka** obsahující
  - odhadované hodnoty p_{ij} a $c(j1, j2, i1, i2)$
  - pro každý procesor
    - počet hopů, preferovaná linka pro daný cíl, zpoždění dané zatížením
- **Úlohy plánovány podle nejvyšší úrovně**, v případě nejednoznačnosti vybrána úloha s větším množstvím přímých následníků
- Jakmile jsou dokončeni všichni předchůdci úlohy, tak je **úloha naplánována na stroj, kde nejdříve skončí**
- Koncový čas úlohy na stroji spočítán z
  - rychlost procesoru, přenosová rychlost, vybraná linka, počet hopů, zpoždění dané zatížením linky

Plánování se shlukovacími heuristikami (clustering heuristics)

- Plánování řeší
  1. umístění úloh na stroje
  2. seřazení úloh na stroji / umístění úloh v čase

- **Shlukovací heuristiky**: primárně řeší umístění (alokaci) úloh na stroje
- Následné naplánování úloh v čase na vybraný stroj je realizováno **jednoduchou aplikací plánování seznamem**

- **Shluk**: množina úloh, která bude prováděna na stejném stroji

Princip plánování založeného na shlukování

1. **Shlukování úloh** na nelimitovaný počet plně propojených procesorů
2. Namapování shluků a jejich úloh na daný počet procesorů (m) provedením následujících operací
   1. **spojování shluků**: pokud je počet shluků vyšší než m
   2. **fyzické mapování shluků**: přiřazení shluků na procesory tak, aby byla minimalizována komunikace
      (na této úrovni uvažována reálná konektivita mezi stroji)
   3. **uspořádání úloh**: úlohy jsou na stroji prováděny tak, by byly splněny závislosti mezi úlohami,
      např. pomocí zjednodušeného plánování seznamem na jeden stroj

Shlukování

- Shlukování
  - bez backtrackingu (abychom se vyhnuly vysoké složitosti), tj. jakmile jsou jednou shluky spojeny nelze je zpětně rozpojit
- Iniciálně: jedna úloha = jeden shluk
- Typický krok heuristiky shlukování
  - spojení shluků + **vynulování hrany**, která je spojuje
  - vynulování hrany: úlohy prováděny na stejném procesoru, kde je čas na komunikaci zanedbatelný
- Kritérium pro výběr hrany na nulování

  redukce tzv. **paralelního času rozvrhu**

Naplánovaný graf úloh

Naplánovaný graf úloh

- graf úloh **zahrnující** aktuální vynulování hran ve shluku
- úlohy v jednom shluku jsou seřazeny (jako na procesoru) dle nejvyšší úrovně

původní graf úloh se 3 shluky

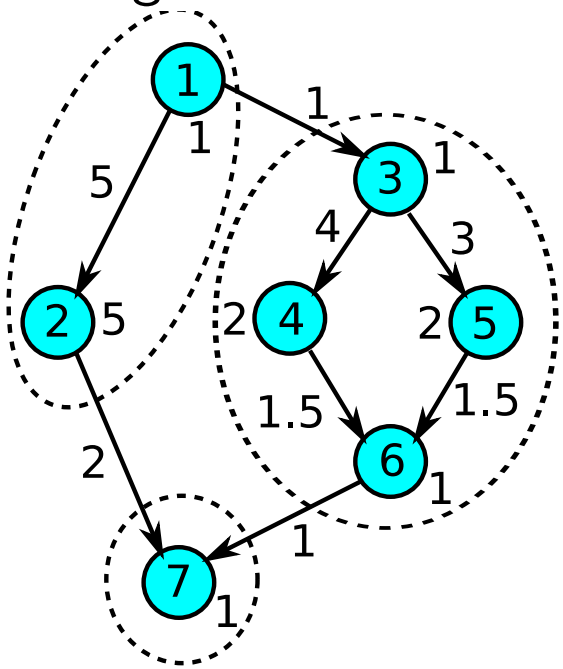

naplánovaný graf úloh

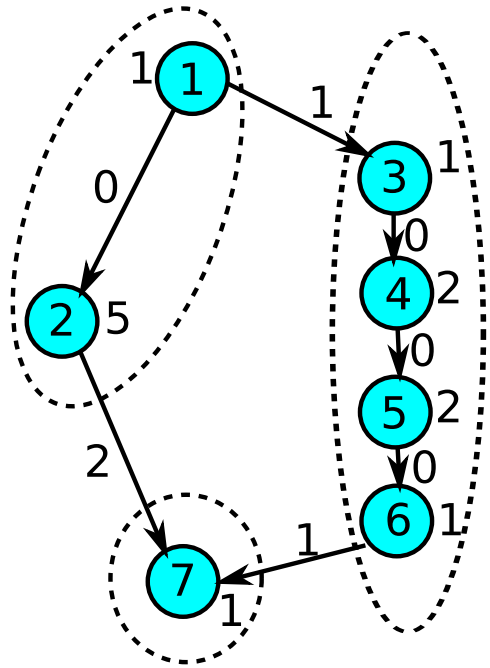

Paralelní čas a dominantní posloupnost

- Připomenutí: délka cesty přes uzly $j_1, j_2 \ldots j_n$:

$$w1 \sum_{j=1}^{n} j_i + w2 \sum_{j=1}^{n-1} size_{j,j+1}$$

- **Dominantní posloupnost**:
  nejdelší cesta v naplánovaném grafu úloh
- **Paralelní čas rozvrhu**:
  doba nutná na provedení dominantní posloupnosti
- Pokud $w1 = w2 = 1$ a $size_{j1,j2}$ reprezentuje dobu na přenos mezi $j1, j2$
  $\Rightarrow$ délka cesty odpovídá době na provedení úloh na cestě
  $\Rightarrow$ paralelní čas rozvrhu = délka cesty dominantní posloupnosti

Dominantní posloupnost: příklad

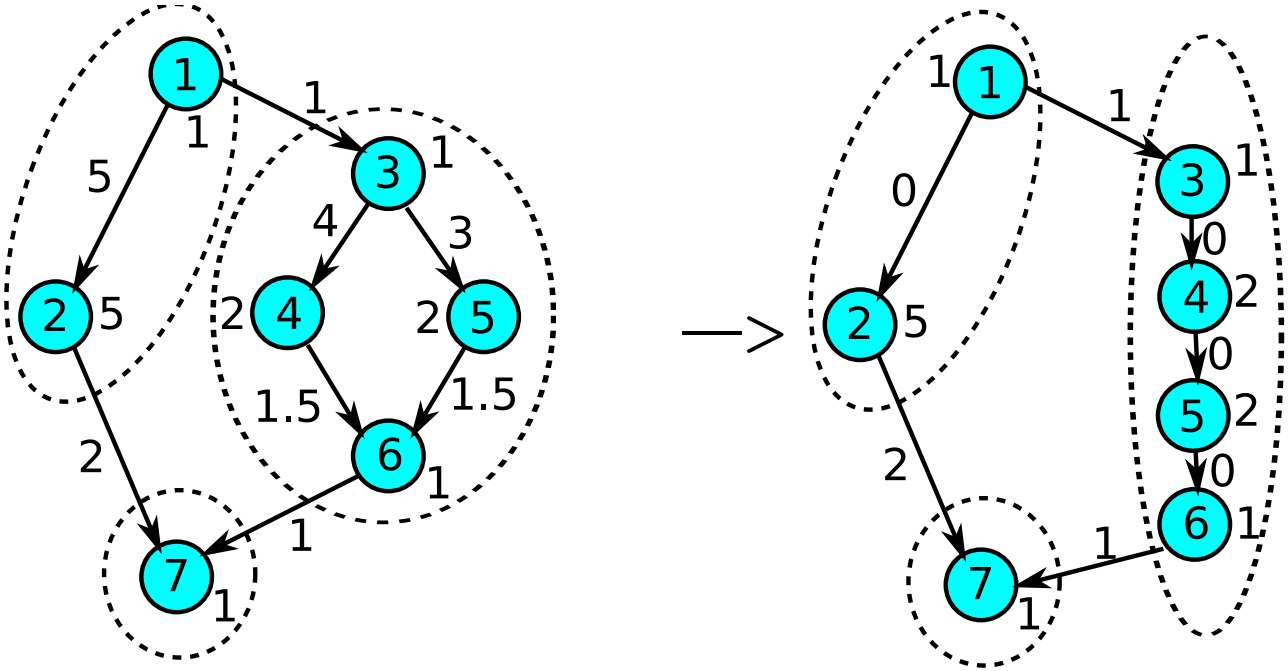

Dominantní posloupnost 1,3,4,5,6,7 s délkou 10, tj. paralelní čas rozvrhu je 10

Odpovídající rozvrh na 3 strojích:

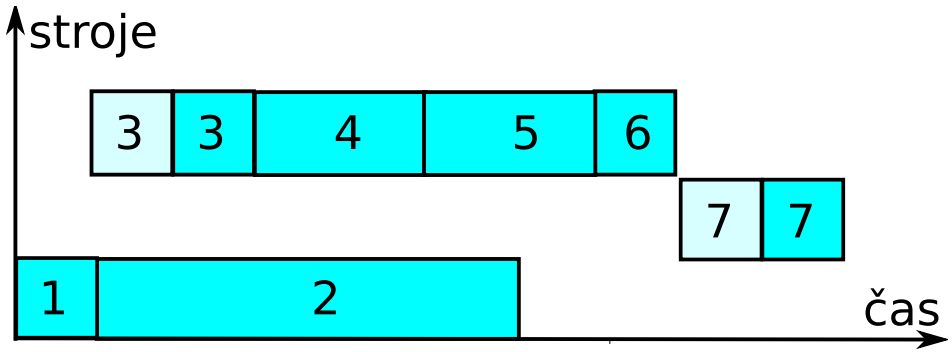

Algoritmus shlukování

Shlukování

1. Inicializace: všechny hrany označeny jako nevyzkoušené
   každá úloha tvoří jeden shluk
2. Seřazení všech hran $(j1, j2)$ v grafu úloh v klesajícím pořadí dle komunikační ceny ($size_{j1,j2}$)
3. REPEAT
   1. vynulování největší nevyzkoušené hrany v seřazeném seznamu, **pokud nevzroste paralelní čas**
   2. hrana je označena jako vyzkoušená
   3. když jsou spojeny dva shluky, úlohy jsou uspořádány dle nejvyšší úrovně

   UNTIL všechny hrany jsou vyzkoušené

Komentář: *podobně jako existují různé metody plánování seznamem, tak existují různé varianty shlukování*

Shlukování: příklad

Problém:

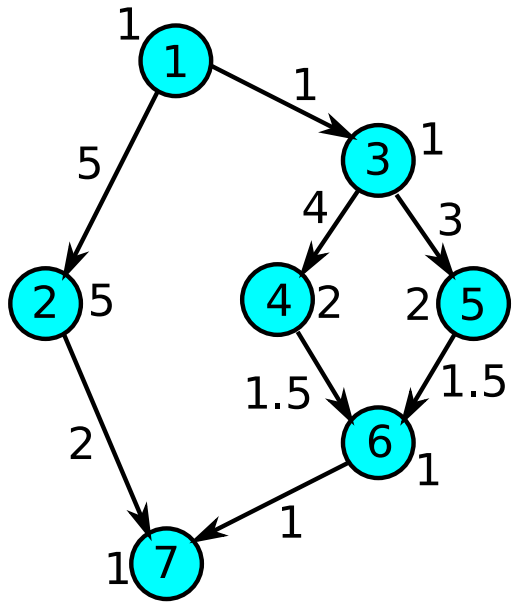

Řešení pomocí algoritmu:

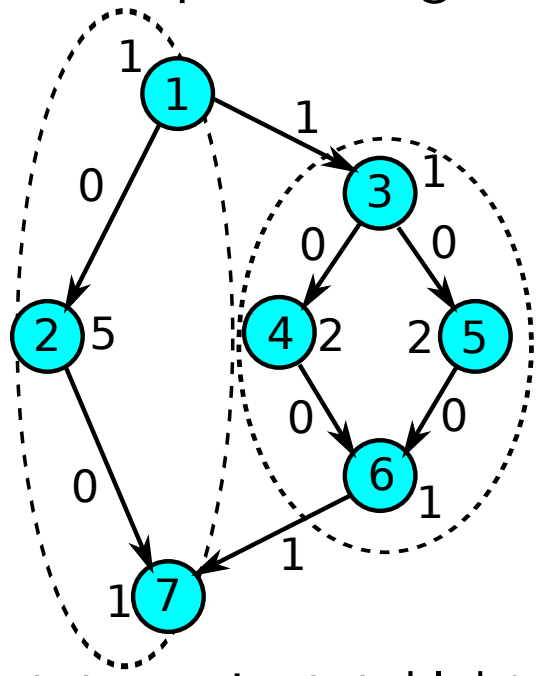

Postup:

seřazení hran, postupné zkoušení na vynulování a spojování shluků:

12 (vynulována, shluk 12), 34 (vynulována, shluk 34), 35 (vynulována, shluk 345), 27 (vynulována, shluk 127), 46 (vynulována, shluk 3456), 56 (vynulována), 13 (nevynulována, paralelní čas by z 10 pro dominantní cestu 1,3,4,5,6,7 vzrostl na 13 s dominantní cestou 1,2,3,4,5,6,7), 67 (nevynulována stejně jako 13)

Spojování shluků

Pokud je shluků méně než strojů

- každý shluk přiřadíme na jeden stroj
  (zbývající stroje zůstanou volné)

Pokud je shluků stejně jako strojů

- shluk = stroj

Pokud máme shluků více je nutné aplikovat **spojování shluků**

- lze využít **problému plnění košů (bin packing problem)**
  - plnění předmětů do košů tak, aby byly všechny koše rovnoměrně naplněny
  - 1 stroj = 1 koš
  - 1 shluk = 1 předmět dané velikosti
  - velikost shluku $S = \sum_{j \in S} p_j$
  - cíl: součet velikostí předmětů ve všech koších je přibližně stejný

Shlukovací heuristiky: shrnutí

Plánování pomocí shlukovací heuristiky:

1. **shlukování**
2. **spojování shluků**, pokud je shluků více než strojů
3. **fyzické mapování** spojených shluků na stroje
   - obecně: přiřazení shluků na procesory tak, aby byla minimalizována komunikace
4. **uspořádání úloh na každém stroji**

   např. pomocí jednoduchého plánování seznamem
   - není nutno brát v úvahu $M(j)$, stroj už je předem vybrán
   - stačí uvažovat prioritu $P(j)$/úroveň a seřadit úlohy dle jejich úrovně
   - úlohy pak mohou být spuštěny na stroji, jakmile jsou dokončeni všichni jejich předchůdci

Uspořádání úloh na stroji: příklad

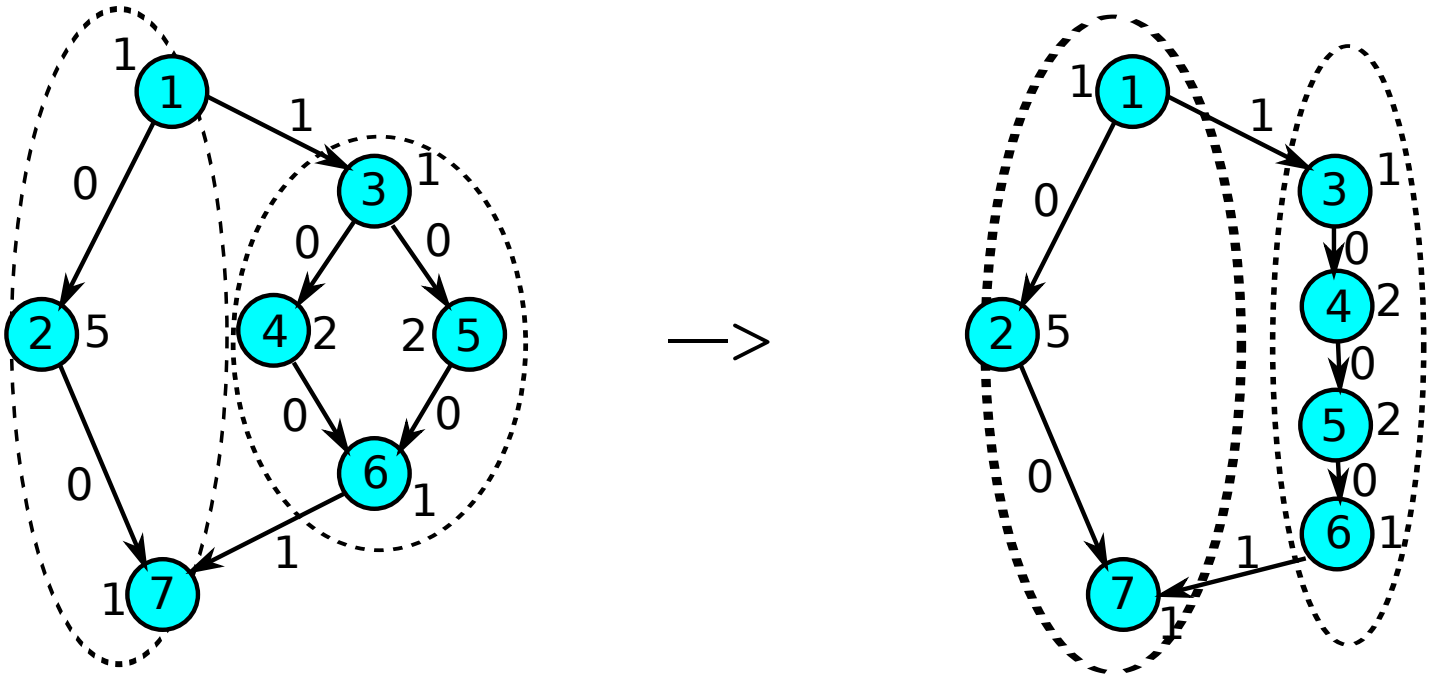

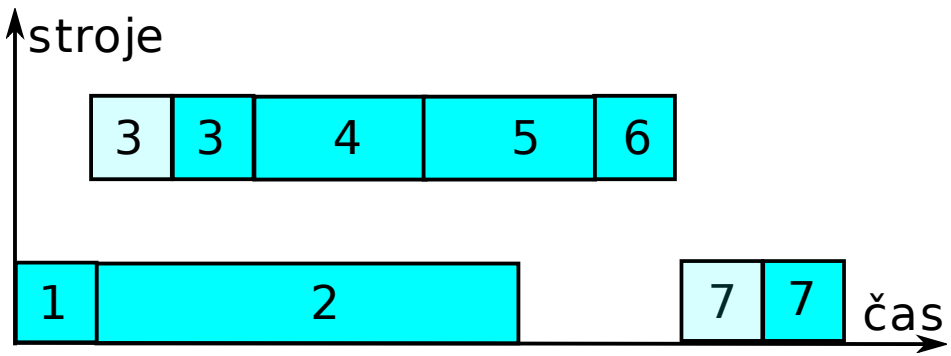

Shlukování: cvičení

Vyřešte cvičení z kapitoly plánování seznamem pomocí algoritmu shlukování. Následně uspořádejte úlohy na stroji (použijte stejný počet strojů jako máte shluků) a zkonstruujte výsledný rozvrh.

Je v řešení nějaký rozdíl?
(nápověda: *ano, u shlukovacích heuristik víme, na kterém stroji bude úloha zpracovávána předem, a proto je možné zahájit některé komunikace dříve, a tedy rozvrh skončí dříve*)