Distribuovaný deadlock

Distribuované systémy
Lekce 6
Ing. Jiří Ledvina, CSc.

Předpoklady

- Systém má pouze znovupoužitelné zdroje
- Existuje pouze výlučný přístup ke zdrojům
- Každý zdroj existuje pouze v jedné kopii
- Proces je ve stavu běžící nebo blokován
- Běžící – proces má všechny zdroje
- Blokovaný – čeká na jeden nebo více zdrojů

Grafické znázornění - RAG

- Modelem je graf
- Uzly grafu jsou procesy
- Hrany grafu jsou nevyřízené požadavky procesů nebo přiřazené zdroje
- Graf je proto označován RAG (Resource Allocation Graph)
- P1 → R1 znamená, že P1 čeká na R1
- Nebo R2 → P1 znamená, že R2 je přidělen P1
- P2 → R2 → P1 → R1 → P2
- Deadlock je orientovaný cyklus v tomto grafu

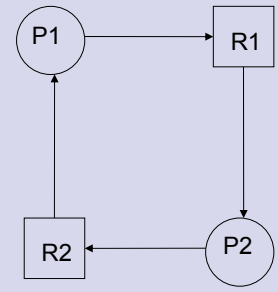

Grafické znázornění - WFG

- Modelem může být i WFG (Wait-For-Graph)
- Uzly grafu jsou procesy
- Hrany grafu jsou vazby mezi procesy
- Vyjadřují vzájemné čekání
- P1 → P2 znamená, že P1 čeká na P2
- P1 → P2 → P1
- Deadlock je orientovaný cyklus v tomto grafu

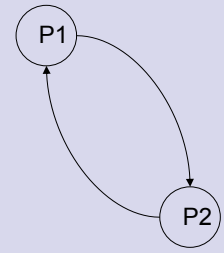

Modely deadlocku

- Jednoduchý model
  - Uzel může být pouze v jednom cyklu
  - Přidělení jednoho zdroje
  - Cyklus WFG je postačující podmínkou pro detekci deadlocku
- AND model
  - Tentýž jako předchozí případ
  - proces může současně požadovat více zdrojů
  - zůstává blokován dokud neobdrží všechny požadované zdroje
  - Cyklus WFG je postačující podmínkou pro detekci deadlocku
- OR model
  - proces může najednou požadovat více zdrojů
  - zůstává blokován dokud neobdrží alespoň jeden z požadovaných zdrojů
  - Nalezení smyčky v grafu (knot) je postačující podmínkou pro detekci deadlocku

Modely deadlocku

- AND – OR model
  - Kombinace požadavků na AND model a OR model
- P-out-of-Q model
  - Získání P z Q zdrojů
  - Např. přístup k replikám (stačí přístup k P replikám z Q replik)
  - Speciální případy
    - P = 1 … OR model
    - P = Q … AND model
  - Nalezení smyčky v grafu (knot) je postačující podmínkou pro detekci deadlocku

Příklad AND modelu

- Přítomnost smyčky

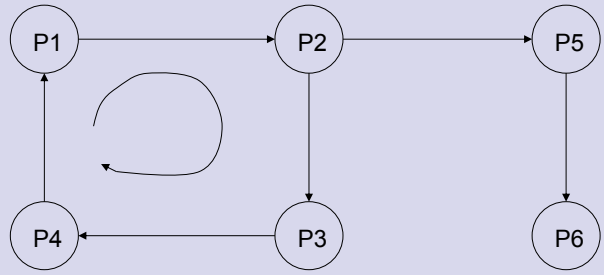

OR model

- Přítomnost smyčky
- Knot (smyčka): podmnožina orientovaného grafu taková, že počínajíc z libovolného uzlu podmnožiny je nemožné opustit smyčku po hranách grafu.

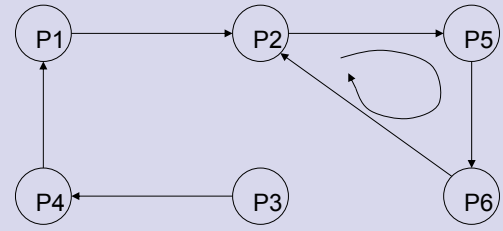

Strategie zpracování deadlocku

- Akceptování deadlocku
  - ignorování problému a víra, že deadlock nenastane (UNIX)
- Prevence deadlocku – obtížné
  - zabránění vzniku podmínek vedoucích k deadlocku
  - vždy drahé
- Předcházení deadlocku – před alokací zdroje kontrola možného deadlocku
  - obtížné protože bych potřeboval mít informaci o globálním stavu každého uzlu který ovládá zdroje
  - cílem je udržení bezpečných stavů
- Detekce a odstranění deadlocku

Strategie zpracování deadlocku prevence

- Prevence může být dosaženo zrušením jedné ze čtyř následujících podmínek
  - 1. výlučný přístup ke zdrojům
    - většina prostředků vyžaduje výlučný přístup
    - jedná se např. o paměť, periferie
    - lze obejít virtualizací (virtuální tiskárna, virtuální paměť)
  - 2. postupné přidělování
    - zdroje jsou přidělovány postupně, ne najednou
    - lze řešit ohodnocením zdrojů a zachováním pořadí při jejich přidělování i uvolňování

Strategie zpracování deadlocku prevence

- Prevence může být dosaženo zrušením jedné ze čtyř následujících podmínek
  - 3. nepreemtivní plánování
    - prostředek může uvolnit pouze proces, který jej vlastní
    - řešení opět ve virtualizaci
  - 4. neomezené čekání
    - předchozí podmínky vedou k neomezenému čekání na přidělení zdrojů
    - odstranění některé z předchozích podmínek vede k prevenci deadlocku

Prevence deadlocku uspořádání podle časových značek

- Uspořádání požadavků – prevence proti vzniku cyklů
  - Požadavky
    - Globální čas (Lamportův logický čas)
    - Atomické transakce
  - Transakcím jsou přiřazeny časové značky
    - Schéma wait-die (zemřít)
      - Starší čeká na uvolnění zdroje, který vlastní mladší
      - Mladší končí (roll-back) pokud žádá o zdroj, který vlastní starší
    - Schéma wound-wait (postřelit)
      - Starší požaduje zdroj držený mladším, mladší končí (roll-back)
      - Mladší požaduje zdroj držený starším - čeká

Strategie zpracování deadlocku - předcházení deadlocku

- **Zavádíme jisté a nejisté stavy**
  - **ze stavu jistý nemůžeme dosáhnout deadlocku vézt přímo přidělením jednoho zdroje**
  - **předpokládejme tři procesy a 10 stejných zdrojů**
  - **A žádá o jeden zdroj, může být přidělen?**
  - **B žádá o jeden zdroj, může být přidělen?**

Thread	Current	Max	Balance
A	2	4	2
B	3	6	3
C	3	8	5

Strategie zpracování deadlocku detekce a odstranění

- Detekce deadlocku hledání cyklů
  - Vytváří se a následně redukuje **Resource Allocation Graph**
  - RAG je bipartitní graf s dvojími uzly
    - Procesy (vlákna) - kroužky
    - Zdroje – obdelníčky
    - Orientované hrany
  - WFG (Wait-for-Graph) – redukovaný RAG
    - Procesy (vlákna)
    - Orientované hrany
  - Obnova po deadlocku představuje ukončení běhu některého z procesů (vláken) a je založena na ad-hoc technikách

Strategie zpracování deadlocku detekce a odstranění

- Algoritmy detekce deadlocku musí zajistit
  - Nesmí nedetekovat žádný deadlock
  - Musí detekovat všechny deadlocky v konečném čase
  - Nesmí detekovat falešné deadlocky (phantom, false)
    - jsou způsobeny dobou zpoždění (latencí) sítě
    - představují principiální problém při budování korektního distribuovaného detekčního algoritmu

Falešný deadlock

- Phantom (false) deadlock
- Předpokládejme, že procesy manipulují se zdroji pomocí
  - Request – žádost o zdroj
  - Acquire – získat, přidělit zdroj
  - Release – uvolnění zdroje
- Zprávy nemusí přicházet ve správném pořadí
- Př.
  - Zpráva A: Release (P2, R2)
  - Zpráva B: Request (P1, R2)

Falešný deadlock

- Správné pořadí doručení
  - Zpráva A: Release (P2, R2)
  - Zpráva B: Request (P1, R2)

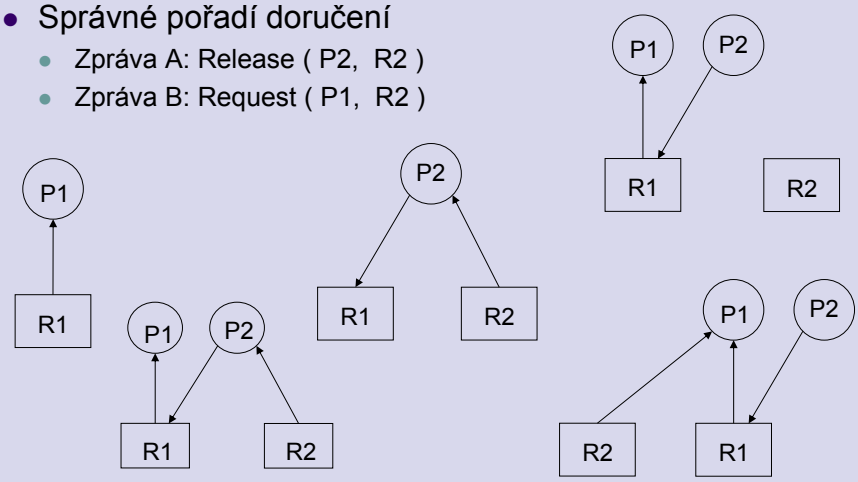

Falešný deadlock

- Chybné pořadí doručení
  - Zpráva B: Request (P1, R2)
  - Zpráva A: Release (P2, R2)

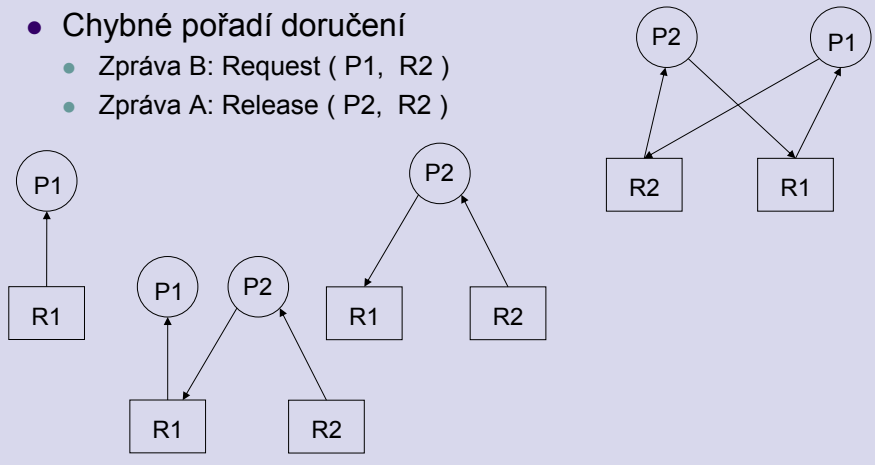

Detekce deadlocku, cyklus a uzel

- AND modelu požadavků požaduje aby všechny právě požadované zdroje byly přiděleny jako podmínka pro odblokování výpočtu
  - v tomto modelu je detekce cyklu postačující podmínkou pro detekci deadlocku
- OR model požadavků dovoluje vytvářet při výpočtu požadavky na více různých zdrojů a odblokování výpočtu je možné pokud je alespoň jeden uspokojen
  - v tomto modelu je cyklus podmínkou nutnou
  - smyčka je podmínkou postačující

Příklad

- v AND modelu je to deadlock
- v OR modelu není, protože chybí smyčka

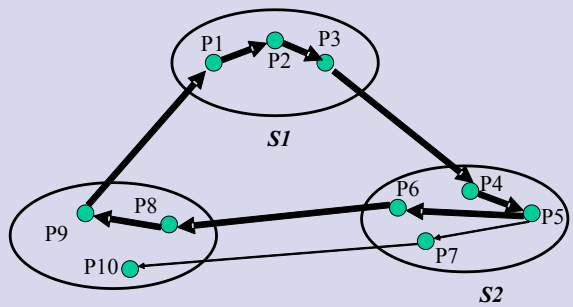

Příklad

- v AND modelu je to deadlock
- v OR modelu také

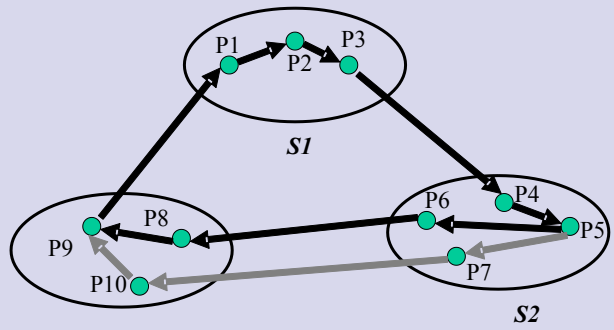

Možnosti řešení deadlocku v distribuovaných systémech

- Centralizované řízení
  - řídicí uzel vytváří WFG a kontroluje orientované cykly
  - WFG může být udržován průběžně nebo budován na přání při požadavku FWG jednotlivými stranami
- Distribuované řízení
  - WFG je rozprostřen na různých uzlech. Kterýkoliv uzel může iniciovat proces detekce deadlocku
- Hierarchické řízení
  - uzly jsou uspořádány do hierarchie
  - uzel kontroluje cykly pouze u podřízených

Centralizované algoritmy

- Centralizované algoritmy
- Jednoduchá koncepce
  - každý uzel posílá zprávu do hlavního detekčního uzlu
  - hlavní detekční uzel vytváří a analyzuje WFG
  - pokud je deadlock detekován, hlavní detekční uzel řídí odstraňování deadlocku
- Závažné problémy
  - výskyt chyby
  - zahlcení sítě
  - detekce falešného deadlocku

Centralizované algoritmy

- Ho-Ramamoorthy 2-fázový algoritmus (AND i OR)
  - každý uzel si udržuje stavovou tabulku o přidělených (uzamčených) zdrojích a čekajících procesech
  - řídicí uzel se periodicky dotazuje na obsah těchto tabulek ve všech uzlech. Tabulky jednoho uzlu stahuje najednou (atomická operace)
  - řídicí uzel vytváří WFG, analyzuje jej, hledá smyčky a pokud je najde, pak hledá řešení
  - nutnou podmínkou pro detekci deadlocku je nalezení smyčky, pokud najde smyčku, požádá znovu o zaslání tabulek z ostatních uzlů
  - pokud je opět detekován cyklus, může se jednat o deadlock
  - může se jednat i o falešný (false) nebo zdánlivý (phantom) deadlock

Centralizované algoritmy

- Ho-Ramamoorthy 1-fázový algoritmus
  - každý uzel udržuje dvě tabulky
    - stavovou tabulku zdrojů
    - stavovou tabulku procesů
  - tabulka zdrojů
    - transakce mohou být uzamčeny nebo čekají na zdroje
  - tabulka procesů
    - zdroje uzamčené transakcemi nebo čekající v transakcích
  - řídicí uzel periodicky soustřeďuje tyto tabulky ze všech uzlů
  - z transakcí vytváří WFG společný pro obě tabulky
  - nalezení cyklu znamená deadlock

Distribuované algoritmy

- Každý uzel má stejné možnosti detekovat deadlock
  - WFG se stává abstrakcí, kde každý uzel obsahuje svou část WFG
  - v zásadě detekce je vyvolána stranou, kde nějaké vlákno čeká příliš dlouho ve frontě na zdroj
- Existují 4 modely které mohou být použity k realizaci algoritmu pro detekci deadlocku
  - **Path-pushing**: informace o cestě v grafu (vztah čekajícího procesu a přiděleného zdroje) je posílána z čekajícího uzlu do blokujícího uzlu (Obermarck)
  - **Edge-chasing**: hranami WFG jsou posílány speciální zprávy (probe – sondy). Jestliže je sondovací zpráva přijata iniciátorem, je detekován deadlock (Chandy-Misra-Haas).
  - **Global state detection**: získává snímek (snapshot) o distribuovaném systému, konstruuje a redukuje WFG (zametá hrany)
  - **Diffusion computation**: WFG jsou posílány echo zprávy, obsahující dotaz na stav jednotlivých uzlů

Path-pushing (propagace nalezených cest)

- Obermarckův algoritmus (AND model)
  - založen na databázovém modelu, který používá transakční zpracování
  - strana, která detekuje ve svém částečném WFG cyklus, přenesou objevenou cestu členům úplně uspořádané transakce.
  - Transakce s nejvyšší prioritou detekuje deadlock (Ex => T1 => T2 => Ex")
  - algoritmus může detekovat i falešné deadlocky protože snímek zjišťuje asynchronně

Edge-chasing algorithm (odstranění hran)

- Chandy-Misra-Haas algoritmus (AND model)
  - proces Pi detekuje deadlock posláním zprávy (probe) P(i, j, k). Tato zpráva je posílána procesem Pj procesu Pk.
  - Tato zpráva putuje po hranách grafu mezi stranami tak dlouho, pokud se nezruší, nebo dokud nedoputuje do Pi . V tom případě implikuje detekci deadlocku.
  - Tedy:
    - Pj závisí na Pk, jestliže existuje posloupnost Pj, Pi1,.., Pim, Pk
    - Pj je lokálně závislé na Pk, jestliže předchozí podmínka a Pj, Pk jsou na téže straně.
    - Každý proces si udržuje vektor závislostí: Di(j) je true Pi ví, že Pj je na něm závislé. (inicializováno na false pro i a j).

Edge-chasing algorithm
Algoritmus Chandy-Misra-Hass

- Odeslání požadavku (testovací zprávy)
  - jestliže Pi je lokálně závislý na sobě, pak nastal deadlock.
  - Jestliže pro všechna Pj a Pk taková že
    - Pi je lokálně závislé na Pj
    - Pj čeká na Pk a
    - Pj a Pk jsou na různých uzlech, pak pošli P(i,j,k) do uzlu s Pk.

Edge-chasing algorithm
Algoritmus Chandy-Misra-Hass

- Příjem požadavku (testovací zprávy)
  - jestliže je
    - Pk blokováno a
    - Dk(i) je false a
    - Pk neodpověděl na všechny požadavky Pj,
  - pak
    - Dk(i) := true;
    - jestliže (k == i) pak Pi je uvíznuté
    - jinak pro všechna Pm a Pn taková že
      - Pk je lokálně závislé na Pm, a
      - Pm čeká na Pn, a
      - Pm a Pn jsou na různých uzlech, pošli P(i,m,n) do uzlu s Pn

Edge-chasing algorithm
Algoritmus Chandy-Misra-Hass

- Výkonnost
  - pro detekci deadlocku, který zahrnuje m procesů nad n stranami (uzly) je třeba m(n-1)/2 zpráv P
  - délka zprávy je 3 slova (id)
  - zpoždění při detekci deadlocku je O(n).

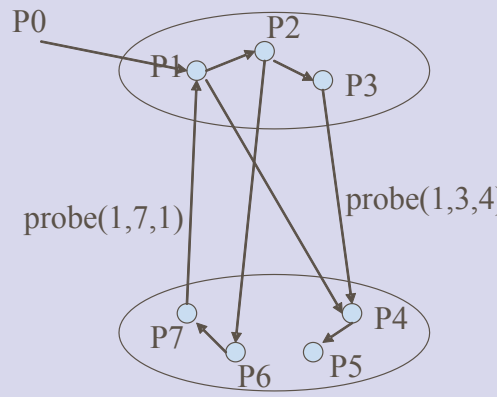

Algoritmy založené na difuzním zpracování

- Výpočet detekce deadlocku difunduje skrz systémový WFG
  - zprávy jsou posílány z výpočetního procesu uzlu a difundují hranami WFG do ostatních uzlů
  - jestliže dotaz dosáhne aktivní neblokovaný výpočet, je zahozena
  - jestliže dotaz dosáhne blokovaný výpočet, pošle se echo zpět iniciátorovi
  - pokud všichni pošlou zpět echo, nastal deadlock

Difuzní zpracování Chandy-Misra-Hass

- Čekající výpočet na uzlu x posílá periodicky všem výpočtům, které také čekají (závislá množina), zprávu s označením ID iniciátoru a ID cíle
- Každý z těchto výpočtů se opakovaně dotazuje závislé podmnožiny členů (pouze pokud jsou také sami blokovány) označujíc každý dotaz ID iniciátoru, vlastním ID a a novým cílovým ID na který čeká.
- Výpočet neposílá echo dokud nedostane odpovědi od všech členů závislé podmnožiny, kterým poslal výzvu (požadavek)
- Jestliže dostane odpověď ode všech, pošle předchůdci odpověď s ID iniciátoru, vlastním ID a ID nejvzdálenějšího závislého uzlu.
- Jestliže iniciátor obdrží odpovědi na echo ode všech členů závislé podmnožiny, rozpozná deadlock pokud ID iniciátoru a ID nejvzdálenějšího uzlu jsou stejná.

Difuzní zpracování Chandy-Misra-Hass

- Inicializace blokovaným procesem Pi:
  - pošle query(i,i,j) všem procesům Pj v závislé množině DSi z Pi;
  - num(i) := |DSi|; waiti(i) := true;
- Blokovaný proces Pk přijme query(i,j,k):
  - jestliže jde o prvotní dotaz od Pk
    - posílá query(i,k,m) všem Pm v DSk;
    - numk(i) := |DSk|; waitk(i) := true;
  - jinak jestliže waitk(i) == true pak pošli reply(i,k,j) do Pj.
- Proces Pk přijme reply(i,j,k)
  - jestliže waitk(i) pak
    - numk(i) := numk(i) - 1;
  - jestliže numk(i) = 0 pak
    - jestliže i = k pak nastal deadlock
  - jinak pošli reply(i, k, m) do Pm, který poslal prvotní dotaz.

Detekce globálního stavu

- Založena na dvou skutečnostech z distribuovaných systémů
- Konzistentní snímek můžeme dostat bez umrtvení probíhajícího výpočtu
- Konzistentní snímek nemusí reprezentovat stav systému v libovolném čase, ale jestliže zastavíme systém před inicializací shromáždění snímku, bude stav zahrnut do snímku.

Hierarchická detekce deadlocku

- Tyto algoritmy reprezentují kompromis mezi zcela centralizovaným řešením a decentralizovaným řešením
- Řídicí uzel je informován z podřízených uzlů periodicky (centralizovaný algoritmus), řídicí uzly jsou uspořádány do hierarchie
- Nadřazený řídicí uzel (kořen stromu), vnitřní uzly slouží pro řízení větví.

Hierarchická detekce deadlocku

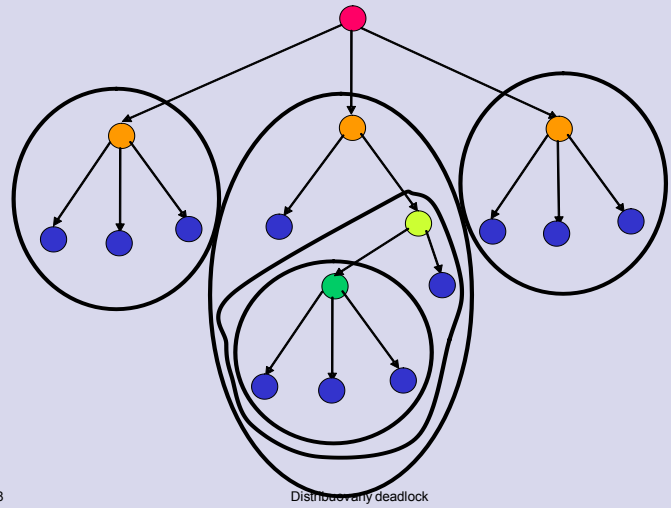

Hierarchická detekce deadlocku Menasce-Muntz Algorithm

- Listové kontrolery přidělují zdroje
- Hranové kontrolery jsou schopné k hledání deadlocku ve zdrojích rozprostřených v podstromu
- Může být ovládáno zahlcení sítě
- Chyby uzlů jsou méně kritické než u centralizovaného řešení
- Detekce může být prováděna několika cestami
  - Kontinuální informování o alokacích
  - Periodické informování o alokacích

Hierarchická detekce deadlocku Menasce-Muntz Algorithm

- Používá pouze 2 úrovně
  - hlavní řídicí uzel
  - řídicí uzly clusteru
- Řídicí uzly clusteru jsou schopné detekovat deadlock svých členů a oznamují závislosti mimo cluster hlavnímu řídicímu uzlu.
- Používá jednofázový Ho-Ramamoorthy algoritmus pro centralizovanou detekci
- Hlavní řídicí uzel je schopen detekovat deadlock uvnitř clusteru
- Přiřazování uzlů do clusteru je dynamické

Hierarchická detekce deadlocku Menasce-Muntz Algorithm