



Principy distribuovaných systémů

NSWI035
ZS 2012/13

RNDr. Filip Zavoral, Ph.D.

Katedra softwarového inženýrství

`zavoral@ksi.mff.cuni.cz`

`http://ulita.mff.cuni.cz -> Výuka`



1. Úvod

- ♦ motivace, funkce, architektury

2. Meziprocesová komunikace

- ♦ zprávy, spolehlivost, RPC, skupinová komunikace

3. Synchronizační algoritmy

- ♦ fyzické a logické hodiny, vyloučení procesů, volba koordinátora
- ♦ kauzální závislost, doručovací protokoly, virtuální synchronie
- ♦ distribuovaný konsensus, detekce globálního stavu

4. Distribuovaná sdílená paměť (DSM)

- ♦ konzistenční modely, distribuované stránkování

5. Správa prostředků

- ♦ zablokování, distribuované algoritmy detekce
- ♦ správa prostoru jmen, kapability

6. Procesy

- ♦ vzdálené spouštění procesů, migrace, vyvažování zátěže

7. Replikace

- ♦ replikace, aktualizací protokoly
- ♦ klientocentrické konzistenční modely, epidemické protokoly



- Pokrývá přednášenou (a zkoušenou) látku
 - Tanenbaum, van Steen: Distributed Systems - Principles and Paradigms, 2nd ed
 - Chow, Johnson: Distributed Operating Systems & Algorithms
- Další zdroje informací o DS
 - Kshemkalyani, Singhal: Distributed Computing - Principles, Algorithms and Systems
 - Coulouris, Dollimore: Distributed Systems - Concepts and Design, 4th ed
 - Singhal, Shivaratri: Advanced Concepts in Operating Systems
 - Sinha: Distributed Operating Systems - Concepts and Design
- Formální metody a distribuované algoritmy
 - Santoro: Design and Analysis of Distributed Algorithms
 - Mullender: Distributed Systems, 2nd ed
- slajdy nejsou skripta
- tzv. 'učební texty' D.O.S. nepoužívejte
 - na různých fórech a skladištích vědomostí
 - **velmi** zastaralé, nepřesné, neúplné, chybové



"Definice"

**Distribuovaný systém
je systém propojení množiny nezávislých uzlů,
který poskytuje uživateli dojem jednotného systému**

Hardwarová nezávislost

- ♦ uzly jsou tvořeny nezávislými "počítači" s vlastním procesorem a pamětí
- ♦ jedinou možností komunikace přes komunikační (síťové) rozhraní

Dojem jednotného systému

- ♦ uživatel (člověk i software) komunikuje se systémem jako s celkem
- ♦ nemusí se starat o počet uzlů, topologii, komunikaci apod.


distribuovaný systém - celá škála různých řešení

- ♦ multiprocesory na jedné základové desce
- ♦ celosvětový systém pro miliony uživatelů
- ♦ moderní technologie: cluster, cloud, grid, ...


Zaměření přednášky: uzel = ('běžný') počítač, běžná síť, softwarový systém

- ♦ principy, algoritmy


- operační systém vyvinutý speciálně pro potřeby DS
- "zlatý věk": 90. léta - Amoeba, Sprite, V, Chorus, Mosix ... T4
- součástí jádra OS podpora distribuovanosti, komunikace, synchronizace
- aplikace: transparentní využití distribuovaných služeb
- neexistuje rozdíl mezi lokální a distribuovanou aplikací
- nesplněná očekávání, žádný systém nedotažen do masově použitelného stavu



- softwarový průmysl - jiný směr
- dominance MS Windows, UNIX / Linux
- použití některých principů a mechanismů distribuovaných systémů
- libovolný lokální OS, rozšiřující vrstva - distribuované prostředí + další služby
- prostředí pro distribuované aplikace – **middleware** (OSF DCE, CORBA, DCOM, Globe, ..)



- service-oriented computing
 - SaaS, PaaS, IaaS
- nutná podpora virtualizace
- kompletní infrastruktura připravená k použití
- Windows Azure, Amazon Elastic Compute Cloud, Google Cloud Platform, ...



Cloud Computing

Execution Models	Virtual Machines	Web Sites	Cloud Services		
Data Management	SQL Database	Tables	Blobs		
Networking	Virtual Network	Connect	Traffic Manager		
Business Analytics	SQL Reporting	Hadoop			
Messaging	Queues	Service Bus			
Caching	Caching	CDN			
Identity	Windows Azure Active Directory				
High-Performance Computing	HPC Scheduler				
Media	Media Services				
Commerce	Marketplace				
SDKs	.NET	Java	PHP	Python	Node.js



Distributed Computing

Obecné principy distribuovaných systémů aplikovatelné na různá prostředí

- mobilní systémy
 - bezdrátové sítě, routing, lokalizace, replikace
- ubiquitní a pervasivní systémy
 - mikrouzly, každodenní sci-fi, samoorganizace, kolektivní znalost a rozhodování
- peer-to-peer sítě
 - sdílení MM obsahu, P2P výpočty, distribuované ukládání, replikace, důvěryhodnost
- content management (*správa obsahu*)
 - publish-subscribe, media distribution, streaming
- distribuovaní agenti
 - mobilita, migrace, task-oriented entities, kooperace
- cluster / grid (*LHC-CERN*) / cloud / sky computing
- distribuované databáze, NoSQL databáze, Big Data
- distributed data mining (*dolování dat*)
- ...



Motivace a cíle návrhu distribuovaného systému

Motivace

- ♦ **Ekonomika**
 - síť běžných PC × supercomputer
- ♦ **Výkon**
 - technologické limity
- ♦ **Distribuovanost**
 - 'inherentní distribuovanost'
- ♦ **Spolehlivost**
 - výpadek jednoho uzlu × výpadek CPU
- ♦ **Rozšiřitelnost**
 - přidání uzlu × upgrade centrálního serveru

Cíle návrhu

- ♦ Transparentnost – přístupová, lokační, migrační, replikační, ...
- ♦ Přizpůsobivost – autonomie, decentralizované rozhodování, ...
- ♦ Spolehlivost
- ♦ Výkonnost
- ♦ Rozšiřitelnost – rozdílné metody pro 100 a 100.000.000 uzlů
- ♦ ...



Transparentnost

na úrovni komunikace s uživatelem, komunikace procesů s jádrem
stupeň transparentnosti × výkonnost systému

■ Přístupová

- ♦ proces má stejný přístup k lokálním i vzdáleným prostředkům
- ♦ jednotné služby, reprezentace dat, ...

■ Lokační

- ♦ uživatel (proces) nemůže říci, kde jsou prostředky umístěny
- ♦ *nevyhovuje: počítač:cesta/soubor*

■ Exekuční / Migrační

- ♦ procesy mohou běžet na libovolném uzlu / přemísťovat se mezi uzly

■ Replikační

- ♦ uživatel se nemusí starat počet a aktualizaci kopií objektů

■ Perzistentní

- ♦ uživatel se nemusí starat o stav objektů, ke kterým přistupuje

■ Konkurenční

- ♦ prostředky mohou být automaticky využívány více uživateli

■ Paralelismová 😊

- ♦ různé akce mohou být prováděny paralelně bez vědomí uživatele

Přizpůsobivost

- Autonomie
 - ◆ každý uzel je schopný samostatné funkčnosti
- Decentralizované rozhodování
 - ◆ každý uzel vykonává rozhodnutí nezávisle na ostatních
- Otevřenost
 - ◆ lze zapojit různé komponenty vyhovující rozhraní
 - ◆ oddělení interface × implementace
- Migrace procesů a prostředků
 - ◆ procesy i prostředky mohou být přemístěny na jiný uzel

Spolehlivost

- Teorie: nespolehlivost jednoho serveru 1%
 - ⇒ nespolehlivost čtyř serverů $0.01^4 = 0.00000001$
- Leslie Lamport: distribuovaný systém je ...
 - "systém, který pro mě odmítá cokoliv vykonat, protože počítač, o kterém jsem nikdy neslyšel, byl náhodně vypnut"*



Rozšiřitelnost - scalability

- Rozdílné metody pro 100 uzlů × 100 milionů uzlů
- Princip: vyhnout se čemukoliv **centralizovanému** 💣💀
 - ♦ žádný uzel nemá úplnou informaci o celkovém stavu systému
 - ♦ uzly se rozhodují pouze na základě lokálně dostupných informací
 - ♦ výpadek jednoho uzlu nesmí způsobit nefunkčnost algoritmu
 - ♦ nelze spoléhat na existenci přesných globálních hodin
 - *'každou celou hodinu si všechny uzly zaznamenají poslední zprávu'*
- Další problémy
 - ♦ koordinace a synchronizace
 - ♦ geografická odlehlost, administrace
- Techniky škálovatelnosti
 - ♦ asynchronní komunikace
 - ♦ distribuce
 - ♦ caching a replikace


serverům, službám,
tabulkám, algoritmům, ...



Výkonnost, chyby návrhu


Výkonnost


- Teorie: více uzlů vyšší výkon
- Praxe: výrazně nižší než lineární nárůst výkonu
- Příčiny: komunikace, synchronizace, komplikovaný software
- Granularita výpočetní jednotky



Chyby návrhu distribuovaných systémů



- Síť je spolehlivá
- Síť je zabezpečená
- Síť je homogenní
- Topologie se nemění
- Nulová latence
- Neomezená kapacita sítě
- Jeden administrátor






Sběrnicevá architektura

- ♦ sdílená sběrnice mezi procesory a paměť
- ♦ levná, běžně dostupná
- ♦ max. 32 (64) uzlů
- ♦ cache – synchronizace




Přepínačová (switched) architektura

- ♦ Možné zapojení i většího počtu uzlů
- ♦ Mřížka - crosspoint switch
 - sběrníková mřížka - procesory $\times$ paměťové bloky
 - nákladné – kvadratický počet přepínačů
- ♦ Omega network
 - postupně přepínaná cesta mezi procesorem a pamětí
 - při větším počtu úrovní pomalé
 - počet přepínačů $n * \log n$




Sběrníková architektura

- ♦ vlastní paměť každého uzlu → výrazně nižší komunikace
- ♦ možnost teoreticky neomezeného počtu uzlů
- ♦ levná, běžně dostupná
- ♦ '*normální*' počítače propojené '*normální*' sítí
- ♦ lze i jiné provedení: processor pool



(a)



(b)

Přepínačová (switched) architektura


♦ Mřížka

- relativně jednoduchá (dvourozměrná) implementace
- vhodné pro řešení 'dvourozměrných' problémů – grafy, analýza obrazu, ...

♦ Hyperkrychle

- n-rozměrná krychle, častý rozměr 4
- každý uzel přímo propojen se sousedy ve všech rozměrech
- supercomputers - tisíce až miliony uzlů
 - 2012 IBM Sequoia Blue Gene - 1.5 mil cores, 1.5 PB RAM, 8 MW Linux ☺

Non Uniform Memory Access




- S-COMA - Simple Cache-Only Memory Architecture
 - ◆ požadavek na nelokální data je propagován vyšší vrstvě
- ccNUMA - Cache Coherent NUMA
 - ◆ globální adresace, konzistence cache
- NUMA-faktor - rozdíl latence lokálních a vzdálených paměťových přístupů

General-purpose computing on graphics processing units

- Frameworks
 - OpenCL, CUDA, C++Amp
- Tesla GPU, Kepler, ...




CPU
MULTIPLE CORES



GPU
THOUSANDS OF CORES



Mechanismy sdílení paměti



BusMP - Firefly - DEC, 5xVAX on a bus, snoopy cache

SwMP - Dash - Stanford, Alewife - MIT

Cm* - hw přístup do paměti, sw caching

Distributed paging - Ivy, Li; Mirage - Bershad 1990

Munin Benett 1990





absence sdílené paměti → zasílání zpráv
RPC, doors, RMI, M-queues, ...

Jednotný komunikační mechanismus


- ♦ jednotný obecný mechanismus pro rozdílné podmínky
 - lokální komunikace, rychlá síť, vzdálené síť s pomalým přístupem
- ♦ nízká režie
 - lokální služby
- ♦ síla služeb
 - mapování, sdílení, ochrana, ...
- ♦ flexibilita
 - nespolehlivost dálkové komunikace, zpoždění, zabezpečení
- ♦ distribuované aplikace
 - typicky ignorují problém síťové režie

Klient – server model




- TCP - standard pro spolehlivý přenos vzdálených dat
 - ♦ ale: většina komunikace v rámci rychlé a relativně spolehlivé LAN
 - ♦ nevýhoda TCP - složitost protokolu, menší výtěžnost sítě

- specializované protokoly pro (spolehlivé) lokální sítě
 - ♦ optimistické
 - ♦ vysoký výkon za cenu složitějšího zotavení z chyb
 - ♦ T/TCP, FLIP, ...




(a)
TCP




(b)
T/TCP


- duplicita zpráv - číslování, zahození - poslední zpráva / okno
- předbíhání zpráv - číslování, zpráva o nedoručení - režie, okno
- ztráta zprávy - komplikovanější
 - ◆ klient vyslal žádost a neví
 - ◆ ztráta žádosti / ztráta odpovědi / příliš pomalá komunikace
 - ◆ typické řešení: potvrzování, timeout, opakování



- potvrzování → zvýšení režie → odpověď = potvrzení příjmu
- při delším zpracování - timeout serveru nebo klienta
- další služební zprávy - ACK, NAK, AYA, IAA, CON, ...



- jednotka přenosu = zpráva
 - ♦ příliš dlouhá → rozdělení na pakety
- co potvrzovat?
 - ♦ každý paket? režie při správném přenosu !
 - ♦ celá zpráva? režie při špatném přenosu !
- možné řešení - **buřty** (dávka, blast, burst)
 - ♦ potvrzování dávky (definovaný počet paketů)
 - ♦ v pořádku celá dávka → ACK
 - ♦ předbíhání, výpadek → NAK
 - přenos celé dávky / od místa výpadku
 - ♦ ztráta posledního (-ích) paketů → timeout






Pevné a dynamické dávky

- **pevné dávky** - jednodušší
 - ◆ při vyšší zátěži síť velká chybovost
 - ◆ při volné síti nízká výtěžnost


- **dynamické dávky** - úprava velikosti podle aktuální situace
 - ◆ n-krát správný přenos dávky → zvětšení
 - ◆ špatný přenos → zmenšení
 - ◆ vysoká výtěžnost aniž by jeden přenos omezoval ostatní
 - ◆ konsensus o velikosti dávky!

Nepřichází odpověď klientovi:


- ♦ ztratila se zpráva se žádostí
- ♦ ztratila se zpráva s odpovědí
- ♦ server je příliš pomalý nebo zahlcen
- ♦ server nefunguje



(a)



(b)



(c)

■ Havárie serveru

- ♦ obecně nelze zjistit, zda se operace provedla
- ♦ i když lze, pro některé služby náročné (transakce)



idempotentní služby

- ♦ nevádí opakované provedení služby
- ♦ 👍 sečti $1 + 1$
- ♦ 🙅 vyber 1000000 \$ z mého účtu 😊

▪ **exactly once** sémantika

- ♦ pro některé služby nelze (tisk na tiskárně)

▪ **at-least-once** sémantika

- ♦ služba se určitě alespoň jednou provede
- ♦ nelze zajistit, aby se neprovedla vícekrát

▪ **at-most-once** sémantika

- ♦ služba se určitě neprovede vícekrát
- ♦ nelze zajistit, že se provede



Havárie klienta

sirotci (orphans)

typicky se neřeší – specializované dlouhotrvající výpočty



sirotci (orphans)

typicky se neřeší – specializované dlouhotrvající výpočty

- exterminace

- ◆ klient po zrození sám zruší službu

- reinkarnace

- ◆ klient po zrození nastartuje novou epochu
- ◆ server zruší všechny úlohy patřící do prošlých epoch

- expirace

- ◆ úloha má přiděleno kvantum času
- ◆ při překročení si server vyžádá nové kvantum





Implementace vzdáleného volání

```
main()
{
    struct message m1, m2;
    for(;;)
    {
        receive( &m1);
        switch( m1.opcode)
        {
            case SERVICE1: fnc1( &m1, &m2); break;
            case SERVICE2: fnc2( &m1, &m2); break;
            case SERVICE3: fnc3( &m1, &m2); break;
            default:  m2.retval = ERR_BAD_OPCODE;
        }
        send( m1.client, &m2);
    }
}
```

server

klient


```
fnc()
{
    struct message m;
    m.opcode = SERVICE1;
    m.arg1 = ...;
    m.arg2 = ...;
    send( MY_SERVER, &m);
    receive( &m);
    if( m.retval != OK)
        error_handler( m.retval);
    process_data( &m.data);
}
```

RPC – vzdálené volání procedur

Meziprocesová komunikace většinou příliš nízkourovňová


Idea: přiblížit zažitým mechanismům volání procedur

RPC - Remote Procedure Call



RPC – mechanismus volání

1. Klientova funkce normálním způsobem zavolá klientský stub
2. Stub vytvoří zprávu a zavolá jádro
3. Jádro pošle zprávu jádru počítače, kde běží server
4. Vzdálené jádro předá zprávu stubu serveru / skeletonu
5. Stub rozbalí parametry a zavolá server
6. Server zpracuje požadavky a normálním způsobem se vrátí do stubu
7. Stub zabalí výstupní parametry do zprávy a zavolá jádro
8. Jádro pošle zprávu klientovu jádru
9. Klientovo jádro předá zprávu stubu
10. Stub rozbalí výstupní parametry a vrátí se ke klientovi





RPC - spojení

Kompilace


- ♦ Klient a server jsou programovány "lokálně"
- ♦ Vytvoří se stub (klient) a skeleton (server)

Spojení

- ♦ Server se "zviditelní" (exporting, registering) - *binder, trader, broker*
- ♦ Klient se "spojí" (binding) se serverem

Vyvolání

- ♦ Vytvoří (marshalling) a přenesse se zpráva
- ♦ Potvrzování, exception handling





Příklad IDL (DCE)

jednoznačný id rozhraní

```
[ uuid(a01d0280-2d27-11c9-9fd3-08002b0ecef1), version(1.0) ]
```

definice rozhraní

```
interface math{
```

```
    const long ARRAY_SIZE = 10;
```

```
    typedef long array_type[ARRAY_SIZE];
```

```
    long get_sum([in] long first, [in] long second);
```

```
    void get_sums([in] array_type a,
```


```
                  [in] array_type b,
```

```
                  [out] array_type c);
```

```
}
```


omezení velikosti polí

vstupní / výstupní parametry





RPC – kompilace modulů





RPC - problémy

Problémy

- reprezentace dat
 - ◆ endians, float, kódování řetězců
- přístup ke globálním proměnným
 - ◆ neexistence sdílené paměti
 - ◆ možné řešení DSM – příliš těžkopádné
- předávání ukazatelů, dynamické struktury
- předávání polí
 - ◆ copy/restore, aktuální velikost
- variabilní parametry - printf
- skupinová komunikace
- komunikační chyby - odlišná sémantika
- bezpečnost

RPC obecně


👍 užitečné, prakticky použitelné (a používané)

👎 není zcela transparentní, nutno dávat pozor na omezení

Další mechanismy:
SRPC
Asynchronous RPC
Doors, RMI
MPI, MQ, MOM, ...





Message passing interfaces







Message Queues



Jeden odesílatel – více příjemců

- Atomicita
 - ◆ doručení *všem* členům nebo nikomu
 - ◆ evidence a změna členství
- Synchronizace
 - ◆ doručování od různých odesílatelů
- Uzavřená skupina
 - ◆ pouze členové skupiny
 - ◆ vhodné pro kooperativní algoritmy
- Otevřená skupina
 - ◆ zasílat zprávy může kdokoliv
 - ◆ vhodné pro distribuované služby, replikované servery
- Vnitřní uspořádání skupin
 - ◆ všechny procesy rovnocenné
 - ◆ hierarchické uspořádání
 - ◆ koordinátor skupiny



Problém:

různé pořadí doručení zpráv

Uzel B:


A: $x += 1;$

E: $x *= 2;$

Uzel D:


E: $x *= 2;$

A: $x += 1;$



Doručovací protokoly

- příjem
 - ♦ kdy přišla síťová zpráva
- doručení
 - ♦ předání příjemci




Překrývající se skupiny



Synchronizace

- logické a fyzické hodiny a jejich synchronizace
- distribuované vyloučení procesů
- volba koordinátora
- doručovací protokoly, virtuální synchronie, změny členství ve skupinách
- detekce globálního stavu
- distribuovaný konsensus
- neexistence sdílené paměti - zprávy
- rozprostřená informace mezi několika uzly
- rozhodování na základě lokálních informací
- vyloučení havarijních komponent
- neexistence společných hodin



Synchronizace s fyzickým časem

- jak sesynchronizovat lokální hodiny jednotlivých komponent systému
- jak sesynchronizovat jednotlivé hodiny mezi sebou

Fyzický čas

- astronomické měření – solární sec. = $1/86400$ solárního dne
- 1948 - atomové hodiny - $1s \approx 9$ mld přechodů atomu cesia 133
- 1950 - TAI - Bureau International de l'Heure – průměr asi 50 laboratoří
- 1 TAI den je o 3 ms kratší než solární den
- rozdíl >800 ms – vložená sekunda – Universal Coordinated Time UTC
- vysílání UTC (krátké vlny, satelit) – nepřesnost cca 0.1 - 10 ms

milióny instrukcí

Synchronizace s fyzickým časem

- jak sesynchronizovat lokální hodiny jednotlivých komponent systému
- jak sesynchronizovat jednotlivé hodiny mezi sebou

Fyzický čas

- astronomické měření – solární sec. = $1/86400$ solárního dne
- 1948 - atomové hodiny - $1s \approx 9$ mld přechodů atomu cesia 133
- 1950 - TAI - Bureau International de l'Heure – průměr asi 50 laboratoří
- 1 TAI den je o 3 ms kratší než solární den
- rozdíl >800 ms – vložená sekunda – Universal Coordinated Time UTC
- vysílání UTC (krátké vlny, satelit) – nepřesnost cca 0.1 - 10 ms

Poslední změna UTC 30.6.2012 neproběhla zrovna podle představ MTU. Problémy hlásily hlavně servery s OS Debian Linux, některé z nich postihl krátký výpadek. Poruchy hlásil také Reddit, který měl potíže kvůli databázím Cassandra a programům napsaným v Javě. V jeho případě však určitou roli zřejmě hrály také bouřky v Severní Virginii.




Synchronizace fyzických hodin

vnitřní hw hodiny C , fyzický čas t

hodiny na počítači p v čase t je $C_p(t)$


přesné hodiny: $C_p(t) = t \quad \forall t$, tedy $dC/dt = 1$

míra přesnosti ρ : $1 - \rho \leq \frac{dC}{dt} \leq 1 + \rho$



maximální odchylka dvojice hodin $2\rho\Delta t$


požadovaná odchylka $\delta \Rightarrow$ intervaly max. $\delta/2\rho$



- jeden pasivní time server (UTC)
- periodické dotazy v intervalech $\delta/2\rho$
- $T = T_{UTC} + (T_1 - T_0 - I)/2$
- nikdy nepřerušovat najednou !
 - (dis)kontinuita
 - postupná změna
 - zrychlování nebo zpomalování



- aktivní time server
- periodicky se ptá ostatních na rozdíl času
- počítá průměr, vrátí rozdíl
- postupná synchronizace



Distribuovaný algoritmus

- žádný server ani koordinátor
- resynchronizační intervaly pevné délky
- i -tý interval: $T_0 + iR \dots T_0 + (i+1)R$
- broadcast (ve fyzicky nestejný čas), spočítání průměru
- případné zahození extrémů

Intervalový čas

- čas není okamžik ale interval
- porovnání časů - některé časové údaje jsou neporovnatelné
- time clerk (klient) – určování času, započítání odchylky
- např. DCE – 33 knihovných funkcí

Problém: fyzické hodiny nelze dostatečně přesně sesynchronizovat

Lamport:

- důležité pořadí, nikoliv přesný čas
- nekomunikující procesy nemusí být sesynchronizovány

$e1 \rightarrow^p e2$ uspořádání v rámci procesu p

$\text{send}(m)$ resp. $\text{rcv}(m)$ je odeslání resp. příjem zprávy m




Kauzální závislost

- jestliže $\exists p: e1 \rightarrow^p e2$ potom $e1 \rightarrow e2$
- $\forall m: \text{send}(m) \rightarrow \text{rcv}(m)$
- jestliže $e1 \rightarrow e2$ & $e2 \rightarrow e3$ potom $e1 \rightarrow e3$

Události konkurentní: $e1 \nrightarrow e2$ & $e2 \nrightarrow e1$


Logické hodiny

- událost a , čas $C(a)$
- jestliže $a \rightarrow b$ pak $C(a) < C(b)$




Synchronizace podle přijímání zpráv - časová značka zprávy T_m

- Proces i vysílá v čase $C_i(a)$ zprávu m ; $T_m = C_i(a)$
- Proces j přijme zprávu m v čase $C_j(b)$. Pak $C_j = \max(C_j(b), T_m + 1)$



(a)



(b)

oprava lokálních hodin

Zúplnění

- událost a v procesu i , událost b v procesu j
- $C(a) = C(b) \ \& \ P_i < P_j \Rightarrow C'(a) < C'(b)$
- 'byrokratické' uspořádání

Vektorové / maticové hodiny

- kauzalita
- doručovací protokoly
- virtuální synchronie

Kauzální závislost

- jestliže $\exists p: e1 \rightarrow^p e2$ potom $e1 \rightarrow e2$
- $\forall m: \text{send}(m) \rightarrow \text{rcv}(m)$
- jestliže $e1 \rightarrow e2$ & $e2 \rightarrow e3$ potom $e1 \rightarrow e3$

Platí 😊


- jestliže $a \rightarrow b$ pak $C(a) < C(b)$

Neplatí 😞

- jestliže $C(a) < C(b)$ pak by bylo hezké aby $a \rightarrow b$

Jak tedy zjistím kauzalitu událostí?

- později - vektorové hodiny



- neexistence společné paměti - semafor!
- pouze zprávy
- korektnost



■ Způsoby řešení

◆ centralizovaná ochrana přístupu

◆ permission-based

- časové značky
- volby

Lamport ($3n$), *Ricart-Agrawala* ($2n$)

Maekawa ($\sqrt{n}$), *Agrawal-ElAbadi* ($\log n$)

◆ token-based




- token-passing
- strom
- token ring

Suzuki-Kasami

Raymond

Centralizovaný algoritmus

- ♦ jeden server s frontou - sekvencér
- ♦ žádost / potvrzení / zamítnutí / uvolnění
- ♦ centralizovaná komponenta
 - ideově nevhodné
 - výpadek serveru - ztráta informace, nutnost volby
 - výpadek klienta - problém vyhladovění (starvace)





Lamportův algoritmus

Idea: Proces vyšle žádost a čeká až

- ♦ dorazí odpovědi od všech procesů a
- ♦ všechny žádosti v jeho frontě mají větší časovou značku

proces p , časová značka odeslání jeho zprávy Tp , fronta žádostí a potvrzení
zprávy typu *req*, *ack*, *rel*

akce se zprávami *send*, *add*, *del*

Událost	Akce procesu p
Žádost Mp	$\text{send } Mp = \{\text{req}, p, Tp\}$
Přijetí žádosti Mi	$\text{add } Mi; \text{ send } \{\text{ack}, p, Tp\}$
Přijetí potvrzení Ai	$\text{add } Ai$
Podmínka vstupu Mp	$\forall i \neq p \exists \{\text{ack}, i, Ti\} : Tp < Ti$ & $\forall \{\text{req}, i \neq p, Ti\} : Tp < Ti$
Uvolnění Rp	$\text{send } \{\text{rel}, p, Tp\}$
Přijetí uvolnění Ri	$\text{del } \{\text{req}, i, Tk\} : Tk < Ti$

uložení žádosti
a odpověď s vlastním časem


od všech přišlo novější potvrzení

neexistují starší žádost


po přijetí uvolnění smažu starší
žádosti tohoto procesu

Lamportův algoritmus


Vstup A
do kritické sekce




Žádost B o vstup



Uvolnění A
a vstup B



Uvolnění kritické
sekce



initially: $(\forall q :: \neg x_q)$

```

program  $p$ :  do forever  $\rightarrow$ 
                {  $\neg x_p$  }
                 $x_p, F_p := \text{true}, c_p$ 
            ; {  $x_p$  }
                ( ||  $q: p \neq q$ : send  $F_p$  to  $co\ p, q$ 
                  ; receive-acknowledgement from  $co\ p, q$ 
                    {  $\neg x_q \vee F_p < F_q$  } {  $F_p < c_q$  }
                )
            ; {  $x_p$  } {  $(\forall q: p \neq q: (\neg x_q \vee F_p < F_q) \wedge F_p < c_q)$  }
                Critical Section  $p$ 
            ;  $x_p := \text{false}$ 
        od
    
```


Proces chce vstoupit do kritické sekce:

- ♦ zašle žádost s TM ostatním procesům a čeká na všechny došlé odpovědi s potvrzením

Proces přijme zprávu se žádostí:

- ♦ Jestliže není v kritické sekci a ani do ní nechce vstoupit, pošle zprávu s potvrzením
- ♦ Jestliže je v kritické sekci, neodpovídá, požadavek si zařadí do fronty
- ♦ Jestliže není v kritické sekci, avšak chce do ní vstoupit, porovná TM žádosti s vlastní žádostí:
 - Pokud má vlastní žádost nižší časovou značku (byla vyslána dříve), neodpovídá a zařadí žádost odesílatele do fronty
 - V opačném případě (žádost odesílatele byla odeslána dříve) pošle zpět potvrzení

Po opuštění kritické sekce pošle proces potvrzení všem procesům, které má ve frontě



■ Základní princip

- ◆ procesy se snaží získat hlasy ostatních procesů
- ◆ každý proces má v jeden okamžik právě jeden hlas
 - může ho dát sobě nebo jinému procesu
- ◆ před vstupem do kritické sekce žádost o hlasy
 - pokud proces dostane víc hlasů než jakýkoliv jiný, může vstoupit
 - pokud dostane méně, čeká dokud nedostane dostatečný počet
- ◆ problém: jak hlasovat a počítat výsledky, kdy už proces ví že vyhrál



■ Naivní volby

- ◆ každý proces zná všechny ostatní
- ◆ ReceivedVotes / MyVote (*Available/Unavailable*)
- ◆ při žádosti jiného procesu dá proces hlas pokud je Available
- ◆ relativně odolný proti výpadkům
 - vydrží výpadek až poloviny procesů
- ◆ složitost $O(n)$
 - není lepší než TS
- ◆ deadlock!
 - více procesů může dostat stejný počet hlasů



Vyloučení procesů - pseudokód naivních voleb

```
Naive_Voting_Enter_CS()
  if (MyVote == Available)
  {
    for every( q != self)
      send(q, VoteRequest);
    ReceivedVotes = self;    // my vote
    wait while( ReceivedVotes < (M+1)/2);
    MyVote = Unavailable;
    enter_CS();
  }
```

čeká na nadpoloviční
většinu hlasů

```
Naive_Voting_Monitor_CS()
  wait for( msg from p);
  switch( msg.type)
  { case VoteRequest:
    if (MyVote == Available){
      Send(p, VoteOk);
      MyVote = Unavailable;
    }
    case VoteRelease:
      MyVote = Available;
    case VoteOk:
      VotesReceived.Add(p);
  }
```

```
Naive_Voting_Exit_CS()
  for every( p in VotesReceived)
    if( p != self)
      send(p, VoteRelease);
  MyVote = Available;
```

- Mamoru Maekawa (1985)
 - ♦ organizace procesů pro optimalizaci komunikační složitosti
 - ♦ každému procesu p je přiřazen **volební okrsek S_p** (voting district)
 - ♦ pro vstup do kritické sekce je nutné získat všechny hlasy z vlastního okrsku

- Podmínky pro volební okrsky
 - ♦ $\forall p, q: S_p \cap S_q \neq \emptyset$
 - každá dvojice kandidátů má alespoň jednoho společného voliče
 - každý proces může volit pouze jednou $\Rightarrow$ nemohou být současně zvoleny dva procesy
 - ♦ $\forall p, q: |S_p| = |S_q| = K$
 - velikost volebních okrsků je konstantní, procesy potřebují stejný počet hlasů
 - ♦ $\forall p, q: |S_i: p \in S_i| = |S_j: p \in S_j| = D$
 - p je obsažen ve stejném počtu D volebních okrsků
 - každý proces má stejnou zodpovědnost

- Důsledek - komunikační složitost $O(|S_p|)$
 - ♦ cíl: minimalizovat velikost volebních okrsků

korektnost

spravedlnost

- Rozdělení do okrsků
 - jak velké okrsky?
 - v kolika okrscích má být každý proces?
- počet okrsků: $N \times K = D \times M$
- proces $\approx$ okrsek
 - musí získat všechny hlasy svého okrsku
 - $D \times M / K = M \rightarrow K = D$
- každý $q \in S_p$ je obsažen v $D-1$ jiných okrscích
 - max. počet okrsků $(D-1)K+1$
- $M = K(K-1)+1 \rightarrow K = O(\sqrt{M})$

K - velikost okrsku


N - celkový počet okrsků


M - počet procesů

D - počet okrsků ve kterých je každý proces

K - velikost okrsku
M - počet procesů

- Algoritmus rozdělení procesů do okrsků
 - ♦ optimální pro $M=K(K-1)+1$ složitý
 - vyžaduje restrukturalizaci při změně členství
 - ♦ suboptimální pro $K = O(\sqrt{M})$ jednoduchý
 - prakticky použitelný
 - $M = n^2, P_{i,j}, S_{i,j}, 1 \leq i,j \leq n$
 - $S_{i,j} = \bigcup P_{i,x} \cup \bigcup P_{y,j} \text{ pro } 1 \leq x,y:$





Soutěží P3 a P23

Možnost deadlocku
P21 volí P23
P5 volí P3

novější

starší !


Race
Condition!!
Nevadí to ?

■ Prevence deadlocku - logické hodiny

♦ při příjmu žádosti procesu r s TS_r procesem p

- p má volný hlas: potvrzení ACK_r
- p dal již hlas jinému procesu q s $TS_q < TS_r$: zařadit do fronty
- p dal již hlas jinému procesu q s $TS_q > TS_r$: pošle zprávu REJECT procesu q
 - pokud již q je v kritické sekci (dostal všechny potřebné hlasy), odpoví až po opuštění kritické sekce
 - pokud q ještě nemá všechny hlasy, vrátí hlas procesu p a ten ho předá procesu r

Maekawa - deadlock a jeho řešení



Scénář 1

- ♦ yD, yE - ACK
- ♦ xA, xC - ACK
- ♦ **yB - ACK**
- ♦ y → CS
- ♦ **xB - enqueue x**
- ♦ y ← CS - REL
- ♦ xB - ACK
- ♦ x → CS

TS:
x>y

Scénář 2

- ♦ yD, yE - ACK
- ♦ xA, xC - ACK
- ♦ **xB - ACK**
- ♦ x → CS
- ♦ **yB - REJECT x - ignored**
- ♦ x ← CS - REL
- ♦ yB - ACK
- ♦ y → CS

x:CS

Scénář 3

- ♦ yD, yE - ACK
- ♦ xA - ACK
- ♦ **xB - ACK**
- ♦ **yB - REJECT x - revoked**
- ♦ yB - ACK
- ♦ y → CS
- ♦ y ← CS - REL
- ♦ xC, xB - ACK
- ♦ x → CS


TS:
x>y

Agrawal & El Abbadi (1991)

- ♦ Volby - složitost $O(\ln(n))$
 - quorum = cesta od kořene k listu
 - fault tolerance
 - náhrada havarovaného uzlu jeho podstromy

Raymond (1989)

- ♦ token-based
- ♦ kostra, nezakořeněný strom
- ♦ každý uzel udržuje referenci na souseda směrem k token holderu
- ♦ při přenosu tokenu přesměrování referencí - rekonfigurace




Suzuki & Kasami

- ♦ přenos zprávy obsahující povolení ke vstupu do kritické sekce
- ♦ žádost o vstup - broadcast
- ♦ zpráva obsahuje frontu požadavků
- ♦ lze prioritní řazení

Token ring

- ♦ logický kruh
- ♦ přenos zprávy obsahující povolení ke vstupu do kritické sekce
- ♦ výpadek - broadcast, centrální registr



Porovnání algoritmů vzájemného vyloučení

Algoritmus	Počet zpráv	Problémy
Centralizovaný	3	Havárie koordinátora
Lamport	$3(n-1)$	výpadek libovolného uzlu
Ricart & Agrawala	$2(n-1)$	výpadek libovolného uzlu
Maekawa	$2\sqrt{n}$	výpadek libovolného uzlu
Agrawal & El Abbadi	$2 \ln n$	výpadek uzlu zvětšuje kvórum a složitost
Raymond	$2 \ln n$	výpadek uzlu - rekonfigurace
Token ring	1 až ∞	ztráta peška, výpadek uzlu

Moudro:

Obvykle nemá smysl řešit centralizovaný problém distribuovaným algoritmem

Volba koordinátora - bully algoritmus

■ Předpoklady


- ♦ omezená doba přenosu zprávy (*message propagation time*)
- ♦ omezená doba zpracování zprávy a odpovědi (*message handling time*)
- ♦ synchronní systém - 'spolehlivý' detektor havárie: $2T_m + T_p$

Pozor !! Velmi silný požadavek

- Když se proces rozhodne volit, zašle zprávu všem procesům s vyšší identifikací (*číslo procesu*)
 - ♦ když přijde odpověď, proces končí
 - ♦ když nepřijde nic, proces vyhrál, je novým koordinátorem, pošle zprávu všem ostatním
- Když proces přijme zprávu o volbě, vrátí zpět odpověď a vyšle žádosti všem vyšším procesům
- Volba se provede ve dvou kolech

proč zrovna ve dvou?
čím se liší 2. kolo?

rozhodl se volit





Volba koordinátora - invitation algoritmus

- Asynchronní systém
 - nelze předpokládat nic o délce událostí
- Bully algoritmus
 - při překročení časových limitů možnost více koordinátorů
 - 💣💣💣💣💣

Invitation algoritmus (*Garcia-Molina 1982*)

Reálné prostředí

- ♦ Procesor: může havarovat (fail-stop), neomezená doba reakce
- ♦ Komunikace: rozpojení na segmenty, ztráta zpráv
- ♦ Nelze spolehlivě detekovat havárii: absence odpovědi neznamená havárii

Idea: koordinátor je vázán na skupinu, skupiny lze štěpit

- ♦ všichni členové stejné verze skupiny (*pohled, view*) vidí stejného koordinátora



Volba koordinátora - invitation algoritmus

Invitation algoritmus (*Garcia-Molina 1982*)

Reálné prostředí

- ♦ havárie, neomezená doba reakce, nespolehlivá detekce havárie

Idea: koordinátor je vázán na skupinu, skupiny lze štěpit

- ♦ všichni členové stejné verze skupiny (*pohled, view*) vidí stejného koordinátora

koordinátor: pravidelná výzva *AreYouCoordinator*

příjem AYC koordinátorem

- ♦ sjednocení do skupiny vyššího koordinátora


pokud člen skupiny neobdrží AYC svého koordinátora (*dostatečně dlouho*)

- ♦ prohlásí se za koordinátora vlastní nové skupiny
- ♦ pozvání ke sjednocení ostatním novým skupinám


konzistence relativní vzhledem ke skupině

- ♦ procesy se shodují na členství ve skupině a na nějaké hodnotě
- ♦ koordinátor vyzve ostatní k připojení
 - pokud se nepřipojí, jsou konzistentní samy se sebou


Invitation algorithmus - průběh




One partition. One group
Coordinator = Processor 4




The network is partitioned, but
no one notices




Processor 1 notices the partitioning.
and declares itself a coordinator.
It calls out and reaches processor 3.



Processor 3 realizes the partitioning
and becomes a coordinator.
Processor 1 retires from this role.




The network partition is repaired,.
but none of the processors notice




Either processor 3 or processor 4.
discover that the network has been
repaired. Processor 4 responds by
announcing that it is coordinator
and restoring global consistency.

Invitation algorithmus - vyzývací zprávy



Volba koordinátora - kruhový algoritmus


- proces se rozhodne volit, pošle zprávu následníkovi
- zpráva obsahuje čísla procesů (odesílatel a nejvyšší živý)
- po návratu obsahuje zpráva nového koordinátora
- následuje fáze oznámení
- stačí znát následníky a mít možnost zjistit následníka nedostupného uzlu
- složitost $O(n^2)$



optimalizace komunikační složitosti

- koordinátor okolí 2^k
- složitost $O(n \log n)$
- implementačně náročnější
- výhodné pouze při vysoké frekvenci konkurentních voleb a velkých skupinách

- Globální uspořádání
 - ♦ zprávy jsou doručovány v pořadí odeslání
 - ♦ nelze – neexistence globálních hodin
- Sekvenční uspořádání
 - ♦ všechny uzly doručí zprávu ve stejném pořadí
 - ♦ doručení nezávisí nutně na času odeslání
 - ♦ sekvencer, dvoufázový distribuovaný alg.
- Atomický multicast
 - ♦ spolehlivé sekvenční doručení
- Kauzální uspořádání
 - ♦ kauzálně vázané zprávy ve správném pořadí
 - ♦ konkurenční zprávy v libovolném pořadí
- Kauzálně vázané zprávy
 - ♦ obsah vázané zprávy **může být** ovlivněn
 - ♦ není podstatné, jestli obsah **byl** ovlivněn
- Konkurenční zprávy
 - ♦ ty, které nejsou kauzálně vázané



Kauzální závislost *(opakování je matkou ...)*

→ *(kauzálně předchází)* je relace definovaná:

- jestliže $\exists p: e1 \rightarrow^p e2$, potom $e1 \rightarrow e2$
- $\forall m: \text{send}(m) \rightarrow \text{rcv}(m)$
- jestliže $e1 \rightarrow e2$ & $e2 \rightarrow e3$ potom $e1 \rightarrow e3$

Kauzální uspořádání doručovaných zpráv

$\text{dest}(m)$ množina procesů, kterým je zaslána zpráva m

$\text{deliver}_p(m)$ je událost doručení zprávy m procesu p

- $m1 \rightarrow m2 \Rightarrow \forall p \in (\text{dest}(m1) \cap \text{dest}(m2)) : \text{deliver}_p(m1) \rightarrow^p \text{deliver}_p(m2)$

Význam: Jestliže $m2$ je zpráva kauzálně závislá na $m1$, potom ve všech procesech, kterým budou doručeny obě tyto zprávy bude zachováno pořadí tohoto doručení

časové značky, vector clock, vector time, timestamps

Časová značka je vektor délky n , kde n je počet procesů ve skupině
časová značka procesu p : $VT(p)$, časová značka zprávy: $VT(m)$

Obecná pravidla aktualizace časových značek

- při startu je $VT(p_i)$ nulový
- $\forall \text{ send } p_i(m): VT(m) = ++VT(p_i)[i]$
- p_j doručující m upraví $VT(p_j)$:

$$\forall k \in 1..n: VT(p_j)[k] = \max(VT(p_j)[k], VT(m)[k])$$
- $\forall m_i, m_j (i \neq j): VT(m_i) \neq VT(m_j)$

Pozor! Obecná pravidla neříkají
KDY k doručení dojde

po složkách maxima ze stávajícího a
přijátého vektoru

Porovnávání časových značek

- $VT1 \leq VT2 \Leftrightarrow \forall i: VT1[i] \leq VT2[i]$
- $VT1 < VT2 \Leftrightarrow VT1 \leq VT2 \ \& \ \exists i: VT1[i] < VT2[i]$

ne každá dvojice VT musí být
porovnatelná - konkurentní

odeslání zprávy m procesem p_i


- $VT(p_i)[i] ++$
- $VT(m) = VT(p_i)$


přijetí zprávy m procesem p_j

- proces $p_j \neq p_i$ pozdrží doručení m dokud:
 - ◆ $VT(m)[k] = VT(p_j)[k] + 1$ pro $k = i$
 - ◆ $VT(m)[k] \leq VT(p_j)[k]$ jinak

doručení

- po doručení si proces p_j upraví VT
 - ◆ $\forall k \in 1..n: VT(p_j)[k] = \max(VT(p_j)[k], VT(m)[k])$







Doručovací protokol pro překrývající se skupiny

Vektory vektorových hodin - maticové hodiny

Časovou značku spojenou se skupinou g_a značíme VT_a

$VT_a[i]$ vyjadřuje počet multicastů procesu p_i do skupiny g_a

S odesílanou zprávou posílá proces VT všech skupin, kterých je členem.

odeslání procesem p_i do skupiny g_a

- $VT_a(p_i)[i]++$
- $VT(m) = \cup VT_b(p_i) : p_i \in g_b$

VT všech skupin, kterých je odesílatel členem

Přijetí zprávy m procesem p_j (od p_i , $VT(m)$, do g_a)

- Proces $p_j \neq p_i$ pozdrží m dokud neplatí:
 - ♦ $VT_a(m)[i] = VT_a(p_j)[i] + 1$
 - ♦ $\forall k (p_k \in g_a \ \& \ k \neq i): VT_a(m)[k] \leq VT_a(p_j)[k]$
 - ♦ $\forall b (p_j \in g_b): VT_b(m) \leq VT_b(p_j)$


kauzalita vzhledem k skupině, do které byla zaslána zpráva

kauzalita vzhledem k ostatním skupinám příjemce

Doručení

- Po doručení si proces p_j upraví VT

Kauzální doručování pro překrývající se skupiny



Distribuovaný total-order protokol

Totální / sekvenční doručování, total-order protocol


všechny zprávy jsou všem členům doručeny ve stejném pořadí

stačí skalární vektorové hodiny

při příjmu zprávy potvrzení odesilatel TSA_i

odesílatel po příjmu všech potvrzení odešle finalizační zprávu s $TSF = \max(TSA_i)$

po příjmu finalizační zprávy doručí příjemce zprávy podle TSF



Komunikační složitost $3n$

V praxi častěji řešení pomocí sekvenceru

- ♦ komunikačně jednodušší, nutnost výběru koordinátora, zaslání zpráv / pořadí



Spolehlivé doručování

'Naivní definice' - *všem členům skupiny bude doručena zpráva*

- Naivní implementace - spolehlivým kanálem všem členům skupiny odeslat zprávu
 - ◆ problémy:
 - výpadek příjemce
 - výpadek odesílatele

- Transakce
 - ◆ doručení pouze po commitu
 - ◆ funguje, ale příliš striktní
 - ◆ nepříjemné důsledky:
 - odesílatel neobdrží potvrzení - abort
 - .. i když by stačilo něco méně drastického, např. redukce skupiny
 - havárie odesílatele po odeslání všech zpráv



Virtuální synchronie

Group **view** - množina uzlů ve skupině

Terminologie: delivery list, view, group membership, membership list ... **pohled**

Značení: L , L_i , L^x , L_i^x

globální pohled, lokální pohled procesu i , verze pohledu x

Algoritmus spolehlivého doručování je **virtuálně synchronní** když



- všechny uzly ve skupině udržují stejný L
- pokud zpráva m je odeslána skupině s L^x před změnou na L^{x+1}
 - ♦ buď m doručí všechny uzly z L^x před provedením změny na L^{x+1}
 - ♦ nebo žádný uzel z L^x který provede změnu na L^{x+1} zprávu m nedoručí



Pozorování:

- ♦ Nemusí platit, že přijetí zprávy členem L implikuje doručení všem členům L
- ♦ *Odesílatel může také havarovat*



Virtuální synchronie - přípustné doručování







Spolehlivé kauzální doručování

- Záplavový (flooding) algoritmus
 - ◆ Při příjmu každé doposud nepřijaté zprávy ji každý uzel přepośle všem ostatním
 - ◆ nakonec všichni zbývající členové zprávu přijmou
 - ◆ spolehlivý, neefektivní

- Idea algoritmu s potvrzováním
 - ◆ p_i odesílatel zprávy, $p_j \in L$ příjemce zprávy, p_x havarovaný uzel
 - ◆ p_i odešle zprávu $\forall p \in L$, zprávu si uchová až do obdržení $\text{Ack}(p) \forall p \in L$ nebo do zjištění že p_x havaroval
 - ◆ p_j po příjmu zprávy odešle $\text{Ack}(p_j)$ uzlu p_i , zprávu si uchová až do zjištění že zprávu přijaly $\forall p \in L$
 - ◆ jestliže p_j zjistí, že p_i havaroval, odešle zprávu $\forall p \in L$ o kterých neví, že zprávu přijaly

- 'Drobný' technický detail
 - ◆ jak p_j zjistí které uzly zprávu přijaly?



Trans algoritmus

Protokol pro spolehlivé kauzální doručování

Potvrzení - graf závislostí (DAG)

- Melliar-Smith & co '90

Invariant:

- p rozesílá $Ack(m)$ když přijal m a všechny kauzálně předcházející zprávy
- není nutné potvrzovat zprávy kauzálně předcházející m

transitive
acknowledgements

Stabilní zpráva - přijata všemi členy skupiny

DAG G - **graf kauzality** celé skupiny

G_p - všechny zprávy které p přijal a ještě nejsou stabilní

Jestliže m potvrzuje zprávu m' pak $(m, m') \in G$

orientace
ve směru potvrzení,
ne kauzality

Zdrojem informací pro negativní potvrzování je G (nepřijaté zprávy)


Implementace - 3 komponenty:

- ♦ příjem potvrzení a výpočet vlastních potvrzení
- ♦ detekce nepřijatých zpráv
- ♦ ukládání zpráv a detekce stabilních zpráv

■ Jak p_j zjistí které uzly zprávu přijaly?

- ♦ rozesílání $\text{Ack}(p)$ nejen odesílateli, ale $\forall p \in L$
 - neefektivní, mnoho potvrzení zbytečných - $n^2 + n$ zpráv pro jedno doručení
- ♦ využití kauzality zpráv a piggybacking potvrzení


A B C D



♦ D může po příjmu $a, b + \text{Ack}(a), c + \text{Ack}(b)$ odvodit:

- B přijal a
- C přijal a i b

A B C D



♦ D může po příjmu $b + \text{Ack}(a), c + \text{Ack}(b)$ odvodit:

- B přijal a
- C přijal a i b
- A odeslal a -> žádost o zaslání

Při korektním kauzálním doručování jsou potvrzení zpráv tranzitivní

Implementace

- přeposlání zprávy vždy včetně ACK
- ack_list, nack_list - seznam zpráv pro potvrzení / nepřijatých zpráv
- undelivered_list – seznam přijatých ale ještě nedoručených zpráv

Trans_send(m)

```

    m += nack_list
    m += ack_list
    ack_list = m
    G += m
    send m to every proc

```

nack_list zůstává až do příjmu zprávy

vyčištění ack_listu, přidat m

m do grafu kauzality

Trans_Receive(m)

```
foreach nak(n) ∈ m
```

```
    if n ∈ Gp
```

```
        multicast n
```

včetně ACK!

```
if m ∈ Gp
```

```
    exit
```

```
foreach ack(n) ∈ m && n ∉ Gp
```

zaznamenání nepřijaté zprávy

```
    nak_list += n
```

```
if m ∈ nak_list
```

```
    nak_list -= m
```

všechny kauzálně předcházející
byly doručeny

```
undelivered_list += m
```

```
G += m
```

```
foreach n ∈ undelivered_list && causal(n)
```

```
    undelivered_list -= n
```

```
    deliver n
```

```
foreach n ∈ Gp && causal(n)
```

všechny kauzální zprávy které
nemohly být tranzitivně potvrzeny

```
    && neex( n': causal(n') && (n', n) ∈ Gp)
```

```
    ack_list += n
```

```
foreach n ∈ Gp && stable(n)
```


n' -> n, n' potvrzuje zprávu n

```
    Gp -= n
```

vyčištění všech stabilních zpráv


Průběh Trans algoritmu

ACK: {}
NAK: {a}




Přijme b + Ack(a)
a do NAK listu

ACK: {}
NAK: {a,d}



Přijme c + Ack(b,d)
d do NAK listu
stále nelze doručovat


ACK: {b}
NAK: {d}



causal line

Přijme a
a, b kauzální – doručit
ACK list pouze b!

ACK: {e}
NAK: {d}



Odešle e + Ack(b)
e není kauzálně vázané na c



Trans protokol – pozorování

pohled na protokol - posun causal line a stable line

nově příchozí zpráva vně casual line

pokud všechny kauzálně předcházející zprávy jsou uvnitř,
pak i zprávu lze dát dovnitř causal line

Pozorování:

- je-li zpráva doručena spolehlivému procesu,
pak někdy každý nehavarující proces zprávu dostane
- zprávy jsou doručovány v kauzálním uspořádání
- G reprezentuje graf závislosti v kauzálním uspořádání
- všechny procesy vytvářejí stejný graf závislostí
 - ◆ pořadí přidávání uzlů však může být různé
- jestliže procesor havaruje, paměťová náročnost je neomezená ! 🙄👉
 - ◆ slabina - pro praktické použití musí být Trans protokol doplněn nějakým protokolem pro změnu členství ve skupinách

důležitá součást spolehlivých doručovacích protokolů

podmínka vzájemné konzistence: $p \in L_q \Rightarrow q \in L_p$

striktní chování - asynchronní shoda

♦ nelze *motivace a 'důkaz' později*

♦ slabší *podobně jako např. D2PC*

♦ typicky pesimistické modely

- považuje za havarovaný i ten uzel, který je detekován od jediného uzlu

■ Sekvence pohledů (group view sequence) $L^0, L^1, L^2, \dots$

♦ hodnota L^i je shodná pro všechny $p \in L^i$

♦ uzly instalují pohledy ve stejném pořadí

■ Virtuální synchronie

♦ $p, q \in L^x, L^{x+1}$

♦ $\text{install } L_p^x < \text{deliver}_p(m) < \text{install } L_p^{x+1} \Rightarrow \text{install } L_q^x < \text{deliver}_q(m) < \text{install } L_q^{x+1}$

doručení zprávy
respektuje pohledy

■ Přesná formální definice konzistentní změny pohledů

♦ konzistentní řezy, běhy, temporální logika, ...

♦ nejednotná



Členství ve skupinách - Transis algoritmus

Transis - spolehlivý kauzální multicast, členství ve skupinách


- ♦ vychází z Trans, založen na principech Trans a ISIS
- ♦ Technion, '92 - Amir, Dolev, Kramer, Malki <http://www.cs.huji.ac.il/labs/>

Monotónnost protokolu

- ♦ **paranoia** - jedno podezření stačí k vyloučení
 - k vyloučení stačí větší zpoždění - nerozeznatelné od havárie
- ♦ **jednosměrnost** - vyloučené procesy se již do algoritmu nevrací
 - lze se ale explicitně znovu připojit

Idea: konzistentní změny pohledů, doručování v rámci pohledů

- ♦ při detekci havárie zpráva FAULT(q), při přijetí její přeposlání
- ♦ kauzální hranice pohledu
 - doručení předcházejících zpráv
 - pozdržení zpráv kauzálně následujících
- ♦ konkurentní detekce různých havárií - společná hranice, doručení obou zpráv
 - doručení pozdržených zpráv
- ♦ kauzální doručení zpráv havarovaného procesu vzhledem ke změně pohledu





Transis algoritmus

G	graf kauzálních závislostí stejný jako u Trans: m potvrzuje $m' \Rightarrow (m, m') \in G$
L	aktuální pohled (množina procesů)
F	procesy označené za havarované (Fault)
Fault(q)	zpráva s detekcí havárie procesu q
blocked	zprávy blokováné pro doručení v následujícím pohledu
Last[i]	procesy označené procesem i za havarované
J	procesy přidávané do pohledu
JLast[i]	procesy naposledy označené procesem i za přidávané

přidávání uzlů do
pohledu symetrické

Trans_failure(q)

F += q

Last[self] = F

Trans_send(FAULT, F)

detekce havárie procesu q

Trans_deliver(m, sender)

doručení zprávy

Trans_new(q)

Trans_deliver_join(m, sender)

ekvivalent failure
F/J, Last/JLast



Transis algoritmus - odebrání uzlu, doručení

```
Trans_deliver(m, sender)
```

```
  if( sender  $\in$  F && (m, FAULT(F'))  $\in$  G && sender  $\in$  F')
```

zahození m v Lx+1
od havarovaného odesílatele

```
    discard m
```

pozdržení zprávy do Lx+1

```
  else if( F  $\neq$   $\emptyset$  && (m, FAULT(F'))  $\in$  G)
```

```
    blocked += m
```

doručení FAULT

```
  else if( m == FAULT(fset)) {
```

```
    Last[sender] = fset
```

nově havarované procesy

```
    if( fset - F  $\neq$   $\emptyset$ ) {
```

```
      deliver deliverable msgs from blocked
```

zprávy patřící do Lx

```
      F += fset
```

```
      Trans_send(FAULT, F)
```

potvrzení / propagace

```
    }
```

```
  if( Last[i] == Last[j]  $\forall$  i, j  $\in$  L - F) {
```

FAULT od všech žijících

```
    deliver msgs from blocked that precede every FAULT(F)
```

```
    install L -= F
```

doručení Lx

```
    deliver all from blocked
```

```
    F =  $\emptyset$ 
```

instalace nového pohledu

```
    foreach( i  $\in$  L)
```

```
      Last[i] =  $\emptyset$ 
```

doručení pozdržených, vyčištění

```
  }
```

```
} else
```

```
  deliver(m, sender)
```

normální doručení



ISIS protokol - spolehlivé kauzální doručování

Základem doručovacích protokolů je způsob přenosu informace o doručení

- ♦ Trans - kauzální potvrzení
- ♦ ISIS - maticové hodiny

vektorové hodiny:

- ♦ $VT_{p_i}[i]$ vlastní odeslané zprávy procesu p_i
- ♦ $VT_{p_i}[k]$ pro $k \neq i$ zprávy přijaté od ostatních procesů

idea - každý proces zná $VT[]$ všech procesů - udržuje matici

- ♦ $VT_{p_i}[j][k]$ co proces p_i ví o doručení zpráv procesu p_j od p_k

při příjmu zprávy od p_i k p_j se aktualizuje $VT_{p_j}[i]$ a $VT_{p_j}[j]$ co ví příjemce o sobě

$VT_{p_j}[j][i] = VT_m[i]$, $VT_{p_j}[i][*] = VT_m[*]$

co ví příjemce o odesílateli

stabilní zprávy (přijaté všemi členy skupiny) - doručeny VT od všech členů skupiny

■ porovnání s Trans

- ♦ Trans potřebuje potvrdit max. M jiných zpráv - lze nahradit VT

Trans lze považovat
za formu
komprimace VT

■ optimistický algoritmus

- ♦ relativně nízká režie při správném přenosu, vysoká režie při chybách



ISIS protokol - členství ve skupinách

Cíl: všechny zprávy zaslané do pohledu L jsou doručeny všem žijícím procesům v L před instalací nového pohledu

Každý proces v L udržuje zprávu dokud není stabilní

Po příjmu zprávy o instalaci nového pohledu proces přepoše všechny nestabilní zprávy a potom potvrzení instalace (flush message), zatím pohled neinstaluje


Po příjmu flush od každého procesu může instalovat nový pohled

Zprávy od havarovaných procesů

- ♦ každý proces udržuje seznam 'havarovaných' procesů aktuálního pohledu
- ♦ s každou zprávou se rozesílá seznam, při příjmu se sjednotí s vlastním
- ♦ zprávy od havarovaných procesů se zahazují

Reálné nasazení

- ♦ New York Stock Exchange
- ♦ Swiss Stock Exchange
- ♦ French Air Traffic Control System




Průběh instalace nového pohledu v ISIS


- a) proces 4 zjistil havárii procesu 7, rozesílá instalaci nového pohledu
- b) proces 6 rozesílá nestabilní zprávy a potvrzení instalace
- c) proces 6 po přijetí všech flush instaluje nový pohled



Průběh virtuální synchronie



Fyzický průběh



Virtuálně synchronní doručování




Doručovací protokoly - shrnutí

Shrnutí problémů doručovacích protokolů
principy a protokoly, které je řeší

problém	protokol
sekvenční doručování	skalární hodiny sekvencer
kauzální doručování	vektorové hodiny
překrývající se skupiny	maticové hodiny
nespolehlivá komunikace, stabilní zprávy	Trans
měnící se skupiny virtuální synchronie	Transis a Isis

Ukončení distribuovaných procesů

orientovaný graf uzlů, vstupní / výstupní kanály
signální kanály - signalizace ukončení



- Iniciační proces začíná výpočet, vyšle podél svých výstupních hran zprávu
- Proces se při příjmu zprávy dostane do stavu *výpočet*
 - ♦ může dále posílat zprávy podél výstupních hran
 - ♦ může přijímat zprávy ze vstupních hran
 - ♦ když proces skončí výpočet, dostane se do stavu *ukončen*, zprávy neposílá, může přijímat
 - ♦ při přijetí zprávy se proces zrestartuje do stavu *výpočet*

Algoritmus ukončení:

- ♦ všechny procesy jsou ve stavu *ukončen*, pak se v konečném čase toto všechny procesy dozví
- ♦ stačí, když se to dozví iniciační uzel (může ostatním uzlům poslat zprávu)



Dijkstra-Scholten (DS) algoritmus

Strom

- ♦ každý listový proces při přechodu do stavu *ukončen* pošle signál svému otci
- ♦ proces dostane signály od všech svých synů, pošle signál svému otci
- ♦ iniciační proces dostane všechny signály - konec výpočtu

Acyklický orientovaný graf (DAG)

- ♦ s každou hranou je asociován čítač - tzv. *deficit*
 - rozdíl mezi počtem zpráv došlých tímto datovým kanálem a počtem signálů poslaných signálním kanálem zpět
- ♦ končící proces vyšle každým signálním kanálem tolik signálů, aby deficit = 0

Obecný (orientovaný) graf

- ♦ problém: neexistují listy, které by mohly rozhodnout o ukončení výpočtu
- ♦ řešení: výpočet vytvoří dynamicky kostru grafu
 - otec = uzel, od kterého přišla první zpráva
- ♦ algoritmus ukončení pro jeden proces:
 1. Poslat signál podél všech vstupních hran kromě hrany k otci
 2. Čekat na signál od všech výstupních hran
 3. Poslat signál otci
- ♦ iniciační proces dostane všechny signály - konec výpočtu



Značkový (TM) algoritmus


Značka - speciální zpráva odlišitelná od všech ostatních

Iniciační uzel vyšle žádost o ukončení (značku, že je kanál prázdný) všem výstupním hranám

- Příjem první značky:
 - ◆ připraven - propagace značky výstupním hranám
 - ◆ nepřipraven - negativní signál (zamítnutí)
- Příjem další značky: signál / zamítnutí
- Příjem zamítnutí: zamítnutí první žádosti
- Příjem všech potvrzení: signál první žádosti


Speciální případ obecnějšího algoritmu - detekce globálního stavu

Detekce falešného deadlocku



Inference from

- o_1 : p_1 waits for r_2
- o_2 : r_1 waits for p_1
- o_3 : r_2 waits for p_2
- o_4 : p_2 waits for r_1



From $O=\{o_1, o_2, o_3, o_4\}$
the deadlock detector
concludes there is a
deadlock!

Množina událostí v systému $E = \{e\}$

Řez c je disjunkttní rozdělení E na P_c a F_c : $P_c \cup F_c = E$ & $P_c \cap F_c = \emptyset$

Konzistentní řez c : $a \rightarrow b$ & $a \in F_c \Rightarrow b \in F_c$



Stav (distribuovaného) procesu je množina událostí, které se v procesu udály

Konzistentní stav $S = P_c$, kde c je konzistentní řez

S konzistentní stav, e : $S' = S \cup e$ je konzistentní stav:

$S \rightarrow^e S'$ (S' je **dosažitelný** z S)

Posloupnost událostí $s = (e_1, e_2, \dots, e_n)$ se nazývá **rozvrh** (schedule), jestliže

$S \rightarrow^{e_1} S_1 \rightarrow^{e_2} S_2 \dots S_{n-1} \rightarrow^{e_n} S_n$ Značíme $S \rightarrow^s S_n$

Zřejmě platí $S \rightarrow^s S_n \Rightarrow S \subseteq S_n$


Využití:

- ♦ d. detekce deadlocků
- ♦ d. garbage collection
- ♦ detekce ukončení d. výpočtů
- ♦ obecně detekce globálních vlastností



Konzistentní a nekonzistentní řez


c – konzistentní řez



stav, který 'fyzicky' nikdy nenastal

Konzistentní a nekonzistentní řez

c – konzistentní řez



c' – nekonzistentní řez



Algoritmus detekce globálního stavu

stav uzlu: množina přijatých a odeslaných zpráv

stav kanálu: množina zpráv, které byly kanálem odeslány, ale ještě nebyly doručeny

Algoritmus:



- Iniciátor vyšle všem výstupním uzlům značku
- Příjem první značky:
 - ◆ Uzel si zapamatuje poslední přijaté a odeslané zprávy = stav uzlu
 - ◆ Stav všech příchozích kanálů označí za prázdný
 - ◆ Vyšle všem výstupním uzlům značku
- Příjem zpráv od uzlů, od kterých ještě nepřišla značka:
 - ◆ Zapamatuje si čísla zpráv
- Příjem značek od dalšího uzlu:
 - ◆ Stav kanálu = zaznamenané zprávy došlé od uzlu první a touto značkou
- Konec algoritmu:
 - ◆ po přijmutí všech značek

Zaznamenané stavy uzlů a kanálů definují konzistentní stav systému



Chandy, Lamport (1985)



Průběh detekce GS 1





A	$A \rightarrow B$	1
	$A \rightarrow C$	0
B	$A \rightarrow B$	
	$C \rightarrow B$	
	$B \rightarrow C$	
	$B \rightarrow D$	
C	$A \rightarrow C$	
	$B \rightarrow C$	
	$C \rightarrow B$	
	$C \rightarrow D$	
D	$B \rightarrow D$	
	$C \rightarrow D$	





A	$A \rightarrow B$	1
	$A \rightarrow C$	0
B	$A \rightarrow B$	◇
	$C \rightarrow B$	
	$B \rightarrow C$	1
	$B \rightarrow D$	0
C	$A \rightarrow C$	
	$B \rightarrow C$	
	$C \rightarrow B$	
	$C \rightarrow D$	
D	$B \rightarrow D$	
	$C \rightarrow D$	





Průběh detekce GS 3



A	$A \rightarrow B$	1
	$A \rightarrow C$	0
B	$A \rightarrow B$	◇
	$C \rightarrow B$	1
	$B \rightarrow C$	1
	$B \rightarrow D$	0
C	$A \rightarrow C$	
	$B \rightarrow C$	◇
	$C \rightarrow B$	1
	$C \rightarrow D$	1
D	$B \rightarrow D$	◇
	$C \rightarrow D$	




A	$A \rightarrow B$	1
	$A \rightarrow C$	0
B	$A \rightarrow B$	◇
	$C \rightarrow B$	◇1
	$B \rightarrow C$	1
	$B \rightarrow D$	0
C	$A \rightarrow C$	
	$B \rightarrow C$	◇
	$C \rightarrow B$	1
	$C \rightarrow D$	1
D	$B \rightarrow D$	◇
	$C \rightarrow D$	◇





A	$A \rightarrow B$	1
	$A \rightarrow C$	0
B	$A \rightarrow B$	◇
	$C \rightarrow B$	◇1
	$B \rightarrow C$	1
	$B \rightarrow D$	0
C	$A \rightarrow C$	◇
	$B \rightarrow C$	◇
	$C \rightarrow B$	1
	$C \rightarrow D$	1
D	$B \rightarrow D$	◇
	$C \rightarrow D$	◇

Průběh detekce GS - výsledek



A	$A \rightarrow B$	1
	$A \rightarrow C$	0
B	$A \rightarrow B$	◇
	$C \rightarrow B$	◇1
	$B \rightarrow C$	1
	$B \rightarrow D$	0
C	$A \rightarrow C$	◇
	$B \rightarrow C$	◇
	$C \rightarrow B$	1
	$C \rightarrow D$	1
D	$B \rightarrow D$	◇
	$C \rightarrow D$	◇



globální stavy, globální predikáty
stabilní vlastnosti, důkazy korektnosti



Problém dvou armád

- ♦ Početnější armáda B je rozdělena
- ♦ Úspěch pouze při synchronizovaném útoku, jinak drtivá porážka
- ♦ Obě části musí mít jistotu, že druhá část začne útok také
- ♦ Komunikace pouze nespolehlivým kurýrem - zajetí

Striktní řešení NEEXISTUJE !!!

A1->A2: Attack!

A2->A1: ACK

A1->A2: ACK

A2->A1: ACK

A1->A2: ACK

A2->A1: ACK

A1->A2: ACK

.....

...

.....

...

(A1 neví, jestli zprávu A2 dostal)

(A2 neví, jestli A1 dostal potvrzení)

(A1 neví, jestli A2 dostal potvrzení)

(A2 neví, jestli A1 dostal potvrzení)

(A1 neví, jestli A2 dostal potvrzení)

(A2 neví, jestli A1 dostal potvrzení)

(A1 neví, jestli A2 dostal potvrzení)

.....

.....




Praktická řešení



- Agresivní strategie
 - první generál vyšle větší množství zpráv oznamující čas útoku
 - a zaútočí tak jako tak
 - předpokládá se, že při vysokém počtu poslaných zpráv alespoň jedna projde
 - druhý generál zde ani nemusí odpovídat.
- Pravděpodobnostní strategie
 - první generál vyšle větší množství (N_0) zpráv
 - kromě času útoku přidá i to, kolik jich poslal
 - druhý generál odpoví na každou, kterou obdržel (N_1)
 - počet odpovědí vrácených prvnímu generálovi je N_2
 - oba generálové znají přibližnou míru úspěšnosti, že posel zprávu pronese

Problém Byzantských generálů

- Předpoklady:
 - ◆ uzly mohou libovolně havarovat
 - ◆ havarovaný uzel se může chovat zákeřně!
 - ◆ spolehlivá komunikace (časově neohraničená)
- Úkol:
 - ◆ někteří generálové jsou zrádci
 - ◆ všichni loajální generálové se musejí rozhodnout shodně
 - ◆ každý generál se rozhoduje na základě informací obdržených od ostatních generálů
- BÚNO: 1 generál, ostatní důstojníci
 - ◆ jak generál tak důstojníci mohou být zrádci
 - ◆ generál vydá rozkaz, důstojníci ho předají ostatním
 - ◆ rozkaz bude vydán na základě většiny
- Cíl:
 - ◆ C1: všichni loajální důstojníci vydají stejný rozkaz
 - ◆ C2: Je-li generál loajální, pak každý loajální důstojník vydá rozkaz generála



Problém Byzantských generálů - 3 uzly





- Zrádce generál
 - ♦ různé rozkazy důstojníkům
 - ♦ důstojník 1 dostane 2 různé rozkazy
- Zrádce důstojník
 - ♦ falešné předání rozkazu
 - ♦ důstojník 1 dostane 2 různé rozkazy

🧠 Řešení pro 3 uzly s 1 zrádcem neexistuje

Obecně: Pro m zrádců, pak neexistuje řešení pro $n \leq 3m$ uzlů

Problém Byzantských generálů - 4 uzly



- Zrádce generál
 - ◆ alespoň 2 stejné rozkazy
 - důstojníci si vzájemně přepošlou většinový rozkaz (C2)
 - ◆ 3 různé rozkazy
 - důstojníci se shodnou na tom, že generál je zrádce (C1)
- Zrádce důstojník
 - ◆ nejhorší případ: falešné předání rozkazu všem ostatním
 - ◆ loajální důstojníci dostanou většinu správných rozkazů (C2)

👍 Řešení pro 4 uzly s 1 zrádcem existuje

Obecně: Pro m zrádců existuje řešení pro $n \geq 3m+1$ uzlů

Lamport, Shostak, Paese: The Byzantine Generals Problem, ACM '82



Klasifikace problémů distribuovaného konsensu

■ Byzantský konsensus (*Byzantine agreement*)

1 → 1

- ♦ iniciátor zvolí hodnotu, rozešle ji všem uzlům
- ♦ všechny loajální uzly se musí shodnout na stejné hodnotě
- ♦ pokud je iniciátor loajální, hodnota se musí shodovat s iniciální

■ Konsensus

n → 1

- ♦ každý uzel má iniciální hodnotu
- ♦ všechny loajální uzly se musí shodnout na společné hodnotě
- ♦ pokud je iniciální hodnota všech loajálních uzlů stejná, musí se shodnout na této hodnotě

■ Interaktivní konzistence

n → n

- ♦ každý uzel má iniciální hodnotu
- ♦ všechny loajální uzly se musí shodnout na společném vektoru
- ♦ hodnota položek vektoru odpovídajících loajálním uzlům se musí shodovat s jejich iniciální hodnotou

$$BK \cong K \cong IK$$



Synchronizace v DS - shrnutí

- fyzické hodiny
 - ◆ synchronizace vůči přesnému zdroji nebo navzájem, úprava rychlosti tiků
- logické hodiny
 - ◆ kauzalita událostí, neexistence globálního času, relace 'předchází'
- distribuované vyloučení procesů
 - ◆ absence sdílené paměti
 - ◆ centralizované, časové značky, voting, token passing
- volba koordinátora
- doručovací protokoly
 - ◆ sekvenční/kauzální doručování, spolehlivé doručování
 - ◆ virtuální synchronie, změny členství
- detekce globálního stavu
 - ◆ konzistentní řez, značkový algoritmus
- konsensus
 - ◆ dvě armády, problém byzantských generálů




Distribuovaná sdílená paměť

- Paralelní výpočty
 - ◆ multiprocesory
 - malý počet procesorů
 - příliš komplikované a drahé
 - ◆ multicomputery
 - snadno dostupné
 - programování a synchronizace není prakticky (inženýrsky) dobře zvládnutá
 - RPC – problémy
 - Pokus o řešení – distribuovaná sdílená paměť
 - 1986 Li & Hudak – DSM - množina uzlů sdílející adresový prostor
- Distribuovaná sdílená paměť (DSM)
 - ◆ Konzistenční modely
 - ◆ Distribuované stránkování
 - ◆ Distribuované sdílené proměnné a objekty



Mechanismy sdílení paměti



BusMP - Firefly - DEC, 5xVAX on a bus, snoopy cache

SwMP - Dash - Stanford, Alewife - MIT

Cm - hw přístup do paměti, sw caching*

Distributed paging - Ivy, Li ... T4

Mirage - Bershad 1990

Munin - Benett 1990



Konzistenční modely DSM

- Konzistenční model

- ◆ Specifikace co implementace musí splňovat vzhledem k operacím čtení a zápis

Značení:

W(x)a	zápis hodnoty a do proměnné x
R(x)a	při čtení z proměnné x je vrácena hodnota a
S	synchronizace
Acq	vstup do kritické sekce (Acquire)
Rel	výstup z kritické sekce (Release)
Pi	proces i



Striktní konzistence

Strict consistency, atomic consistency

Jakékoliv čtení z paměti z adresy x vrátí hodnotu uloženou při posledním zápisu na adresu x.

- ♦ zajišťuje absolutní časové uspořádání
- ♦ nejsilnější, na jednoprosesorových systémech je tradičně zajištěna
- ♦ všechny zápisy **okamžitě** všude viditelné
- ♦ podmínka: musí existovat přesný globální čas
- ♦ ideální pro programování 😊, v distribuovaném systému nedosažitelné ☹️

```
a=1; a=2; print(a);
```

vytiskne vždy 2

P1: W(x)1

P2: R(x)1

striktní konzistence

P1: W(x)1

P2: R(x)0 R(x)1

paměť, která není striktně konzistentní



Sekvenční konzistence

Sequential consistency

Výsledek výpočtu je stejný, jako kdyby všechny operace všech procesorů byly vykonávány v nějakém sekvenčním uspořádání a operace každého procesoru jsou vykonávány v pořadí specifikovaném programem.

■ o něco slabší model

- ♦ snadno implementovatelná
- ♦ příjemná pro programování
- ♦ povoleno libovolné prokládání instrukcí na různých procesorech
- ♦ **všechny** procesy vidí **stejně** pořadí změn paměti
- ♦ změny nejsou propagovány okamžitě, není zaručena velikost zpoždění (sec, min)

P1: W(x)1

P2: R(x)1 R(x)1

P1: W(x)1

P2: R(x)0 R(x)1

dvakrát spuštěný tentýž program – může dát různé výsledky



Sekvenční konzistence

P1:

a=1;

print(b,c) ;

P2:

b=1;

print(a,c) ;

P3:

c=1;

print(a,b) ;

šest instrukcí - $6!=720$ možných uspořádání
pouze $3*(5!/4)=90$ nenarušuje konzistenci

a=1;

print(b,c) ;

b=1;

print(a,c) ;

c=1;

print(a,b) ;

a=1;

b=1;

print(a,c) ;

print(b,c) ;

c=1;

print(a,b) ;

b=1;

c=1;

print(a,b) ;

print(a,c) ;

a=1;

print(b,c) ;

b=1;

a=1;

c=1;

print(a,c) ;

print(b,c) ;

print(a,b) ;

Výstup: (skutečný výstup, např. na obrazovce)

001011

101011

010111

111111

Signatura: (výstupy jednotlivých procesů v pevném pořadí)

001011

101011

110101

111111



Sekvenční konzistence

```
a=1;
```

```
print(b,c);
```

```
b=1;
```

```
print(a,c);
```

```
c=1;
```

```
print(a,b);
```

■ signatura

- ♦ spojení výstupů procesů v pevném (předem daném) pořadí
- ♦ konkrétní proložení instrukcí procesů, a tím i pořadí paměťových referencí
- ♦ celkem $2^6=64$ možných signatur
- ♦ ne všechny odpovídají sekvenční konzistenci
 - např. 000000, 001001 neodpovídají žádnému sekvenčnímu proložení instrukcí

P1: W(a)1 R(b)0 R(c)0

P2: W(b)1 R(a)1 R(c)0

P3: W(c)1 **R(a)0** R(b)1

signatura 001001 je nedosažitelná v sekvenčně konzistentním modelu


■ Sekvenční konzistence

- ♦ příjemný model pro programování
- ♦ výkonnost není příliš velká, dokázáno (Lipton & Sandberg, 1988):
 - čas čtení r , čas zápisu w a čas přenosu zprávy (paketu) t : **$r + w \geq t$**
 - optimalizace protokolu pro čtení znamená delší čas pro zápis a naopak

Causal consistency

Kauzálně vázané zápisy musí být viděny všemi procesy ve stejném pořadí.
Konkurenční zápisy mohou být viděny v různém pořadí.

- ♦ rozlišuje události, které jsou potenciálně závislé a které ne
- ♦ kauzálně závislé zápisy
 - pokud $W(x)_a$ a (druhý proces) $R(x) W(y)_b$, pak $W(y)_b$ je kauzálně závislý na $W(x)_a$
- ♦ analogie k zasílání zpráv: zápis $\approx$ odeslání, čtení $\approx$ přijetí



splňuje podmínku kauzální konzistence, nesplňuje sekvenční



Kauzální konzistence

P1: $W(x)1$
P2: $W(x)2$
P3: $R(x)2$ $R(x)1$
P4: $R(x)1$ $R(x)2$

kauzálně konzistentní rozvrh

P1: $W(x)1$
P2: $R(x)1$ $W(x)2$
P3: $R(x)2$ $R(x)1$
P4: $R(x)1$ $R(x)2$

porušení kauzální konzistence
(přidaná operace čtení)

není kauzálně konzistentní

- ♦ implementace složitější
 - vyžaduje vyžaduje udržování grafu závislostí zápisů na čtení



PRAM (Pipelined RAM) consistency

Zápisy prováděné jedním procesem jsou viděny ostatními procesy v tom pořadí, ve kterém byly prováděny.

Zápisy různých procesů mohou být viděny různými procesy různě.

♦ srovnání se sekvenční konzistencí:

- v PRAM neexistuje jednotný pohled na rozvrh

♦ snadná na implementaci

- nezáleží na pořadí, v němž různé procesy vidí přístupy k paměti
- je nutné dodržet pořadí zápisů z jednoho zdroje

P1 přečte b dříve než uvidí jeho zápis
P2 přečte a dříve než uvidí jeho zápis

není možné při libovolném
globálním uspořádání instrukcí

P1 :

a=1;

if (b==0) kill(P2);

P2 :

b=1;

if (a==0) kill(P1);

možný výsledek: oba procesy budou zabity



PRAM konzistence

P1:

```
a=1;  
print(b,c);
```

P2:

```
b=1;  
print(a,c);
```

P3:

```
c=1;  
print(a,b);
```

```
a = 1;  
print(b,c);  
b = 1;  
print(a,c);  
c = 1;  
print(z,b);
```

```
a = 1;  
b = 1;  
print(a,c);  
print(b,c);  
c = 1;  
print(a,b);
```

```
b = 1;  
print(a,c);  
c = 1;  
print(a,b);  
a = 1;  
print(b,c);
```

Výstup:

00

10

01

PRAM-konzistentní lokální rozvrhy



Slow memory

Zápisy jedním procesem do jednoho místa musí být viděny ve stejném pořadí

Nejslabší model - lokální zápis, pomalá nesynchronizovaná propagace
Neposkytuje žádnou synchronizaci

P1:	W(x)1	W(x)2	W(y)3		W(x)4		
P2:			R(y)3	R(x)1		R(x)2	R(x)4

zápis do x před zápisem do y ještě není propagován

Ještě slabší modely?

Casual Consistency (Bednárek 2009)

Příležitostná konzistence - když je příležitost, tak to je konzistentní 😊

- Dopusud uvedené konzistenční modely velmi restriktivní
 - ♦ vyžadují propagaci všech zápisů všem procesům
 - ♦ málo efektivní
 - ♦ ne všechny aplikace vyžadují sledování všech zápisů, natož pak jejich pořadí
 - ♦ typická situace:
 - proces v kritické sekci ve smyčce čte a zapisuje data
 - ostatní procesy nemusí jednotlivé zápisy vidět, není nutné, aby byly propagovány
 - ♦ paměť ale neví, že proces je v kritické sekci, musí propagovat všechny zápisy
- Řešení: nechat proces ukončit kritickou sekci a poté rozeslat změny ostatním
- Speciální druh proměnné - **synchronizační proměnná**
 - ♦ použití pouze pro synchronizační účely

S	synchronizace
Acq	vstup do kritické sekce (Acquire)
Rel	výstup z kritické sekce (Release)



Slabá konzistence

Weak consistency

1. Přístup k synchronizačním proměnným je sekvenčně konzistentní.
2. Přístup k SP není povolen, dokud neskončí všechny předchozí zápisy.
3. Přístup k datům není povolen, dokud nebyly dokončeny všechny předchozí přístupy k SP.

- ♦ zavedení synchronizační proměnné (synchronizační operace)
- ♦ bod 1: všechny procesy vidí všechny přístupy k SP ve stejném pořadí
- ♦ bod 2: před přístupem k SP budou dokončeny všechny předchozí zápisy
- ♦ bod 3: při přístupu k obyčejným proměnným jsou dokončeny všechny předchozí přístupy k SP
- ♦ provedením synchronizace před čtením se zajistí aktuální verze dat

P1: W(x)1 W(x)2 **S**

P2: R(x)2 R(x)1 **S**

P3: R(x)1 R(x)2 **S**

slabě konzistentní rozvrh

P1: W(x)1 W(x)2 **S**

P2: **S R(x)1**

po synchronizaci musí
být data aktuální

porušení slabé konzistence

- ♦ 😊 odpadá nutnost propagací všech zápisů
- ♦ 😞 paměť při přístupu k SP nerozezná vstup a výstup z kritické sekce
 - pokaždé musí vykonat akce potřebné pro oba případy
- ♦ řešení: rozlišení vstupu (Acq) a výstupu (Rel) z kritické sekce

Release consistency

1. Před přístupem ke sdílené proměnné musí být úspěšně ukončeny předchozí Acq() procesu.
2. Před provedením Rel() musí být ukončeny všechny předchozí zápisy i čtení prováděné procesem.
3. Acq() a Rel() musí být PRAM konzistentní.

- ♦ po Acq() jsou všechny lokální kopie aktuální
- ♦ po Rel() jsou propagovány změny ostatním procesům
- ♦ při správném párování Acq() a Rel() je výsledek jakéhokoliv výpočtu ekvivalentní sekvenčně konzistentní paměti

P1: **Acq** W(x)1 W(x)2 **Rel**

P2:

Acq R(x)2 **Rel**

P3:

R(x)1

release consistency

bez přístupu k SP
libovolně stará hodnota

■ Možnosti implementace

♦ Eager release consistency (*horlivá, dychtivá*)

- po Rel() se propagují změny všem procesům
- optimalizace přístupové doby

♦ Lazy release consistency (*líná*)

- po Rel() se nic nepropaguje, až při Acq() jiného procesu
- optimalizace síťového provozu

Entry consistency

1. Acq() k SP není povolen, dokud nebyly provedeny všechny aktualizace chráněných sdílených dat procesu.
2. Exkluzivní přístup procesu k SP (= zápis) je povolen pouze v případě, že žádný jiný proces nepřistupuje k SP, a to ani neexkluzivně (= čtení).
3. Po exkluzivním přístupu k SP si příští neexkluzivní přístup libovolného procesu k SP musí vyžádat aktuální kopii dat od vlastníka SP.

- ♦ sdílená data jsou vázána na SP, při přístupu se synchronizují pouze tato data
- ♦ přístup k datům a SP může být exkluzivní (RW) nebo neexkluzivní (RO)
- ♦ každá SP má vlastníka - proces, který k ní naposledy přistupoval
- ♦ vlastník může opakovaně vystupovat do a vystupovat z kritické sekce bez nutnosti komunikace
- ♦ proces, který není vlastníkem, musí požádat o vlastnictví

Nezávislá data x a y

P1: **Acq(Lx)** W(x)1 **Acq(Ly)** W(y)2 **Rel(Lx)** **Rel(Ly)**

P2: **Acq(Lx)** R(x)1 R(y)0

P3: **Acq(Ly)** R(y)2

	<i>Konzistence</i>	<i>Vlastnosti</i>
bez SP	Striktní	Absolutní časové uspořádání
	Sekvenční	Všechny události jsou vidět ve stejném pořadí
	Kauzální	Kauzálně vázané události jsou vidět ve stejném pořadí
	PRAM	Události jednoho procesu jsou vidět ve stejném pořadí
	Slow mem	Zápisy jednoho procesu na jedno místo jsou vidět ve stejném pořadí
s SP	Slabá	Sdílená data jsou konzistentní po synchronizaci
	Výstupní	Sdílená data jsou konzistentní po opuštění kritické sekce
	Vstupní	Sdílená data vázaná na kritickou sekci jsou konzistentní při vstupu do kritické sekce

- Konzistenční modely bez použití synchronizačních proměnných
 - ♦ implementace možná na úrovni virtuální paměti
 - ♦ procesy nemusí o DSM vůbec vědět
 - ♦ standardní programovací jazyky / knihovny
- Konzistenční modely s použitím synchronizačních proměnných
 - ♦ speciální jazyky nebo knihovny
 - ♦ procesy musí být korektně naprogramovány
 - ♦ vyšší výkonnost




Distribuované stránkování

- Obdoba virtuální paměti
 - ◆ přístup k nenamapované stránce - přerušení, obsluha, načtení
- Problémy
 - ◆ replikace → konzistence *jak udržovat data konzistentní*
 - namapování read-only, při zápisu synchronizační akce
 - invalidace vs. aktualizace
 - ◆ nalezení stránky *jak nalézt distribuovaná data*
 - broadcast
 - centralizovaný manager
 - replikovaný manager - indexace spodními n bity / hash
 - ◆ správa kopií *co dělat s kopiemi při čtení / zápisu*
 - broadcast
 - copyset - vlastník stránky udržuje množinu lokací kopií
 - ◆ uvolňování stránek *kterou stránku uvolnit*
 - nevlastněná read-only kopie
 - vlastněná replikovaná kopie - přenos vlastnictví
 - lokální heuristika (LRU, ...)
 - ◆ falešné sdílení *nezávislá data na stejné stránce*

■ Problémy

◆ falešné sdílení





nezávislá data na stejné stránce







Sekvenčně konzistentní distribuované stránkování



čtení




Povýšení




Invalidace,
povýšení




Invalidace,
změna vlastníka,
povýšení




Kopie



Invalidace, kopie,
změna vlastníka,
povýšení



Degradace,
kopie



Invalidace, kopie,
změna vlastníka,
povýšení

kradení - viskozita



Kauzálně konzistentní distribuované stránkování

- základní idea – graf závislostí

- vektorové hodiny:

- ♦ VT_S jednotka granularity (stránky)

na kterých stránkách
závisí obsah

- ♦ VT_P procesy

z kterých stránek
znám data

- $VT[i] \approx$ stránka i

- výpadek stránky – přenos dat, $VT_P = \max(VT_S, VT_P)$

jak OS pozná zápis?
změna mapování

- zápis do stránky – $VT_S = \text{inc}(VT_P)$

- aktualizace VT_P – zneplatnění stránek i : $VT_{Si}[i] < VT_P[i]$

- Problémy:


- ♦ velká prostorová režie (1 MB = 256 stránek = 512 B / stránku)

- ♦ propagace konkurentních zápisů

- zámký, bariéry, timeouty



Kauzálně konzistentní distribuované stránkování





Kauzálně konzistentní distribuované stránkování

- základní idea – graf závislostí
- vektorové hodiny:
 - ◆ VT_S jednotka granularity (stránky)
 - ◆ VT_P procesy
- $VT[i] \approx$ stránka i
- výpadek stránky – přenos dat, $VT_P = \max(VT_S, VT_P)$
- zápis do stránky – $VT_S = \text{inc}(VT_P)$
- aktualizace VT_P – zneplatnění stránek i : $VT_{Si}[i] < VT_P[i]$
- Problémy:
 - ◆ velká prostorová režie (1 MB = 256 stránek = 512 B / stránku)
 - ◆ propagace konkurentních zápisů
 - zámký, bariéry, timeouty

na kterých stránkách
závisí obsah

z kterých stránek
znám data



Distribuované sdílené proměnné

- Implementace na úrovni knihoven
 - ◆ potenciálně replikovaná distribuovaná databáze
 - ◆ typicky konzistenční model se synchronizačními proměnnými
- Výhody
 - ◆ potenciálně lepší výkonnost
 - ◆ eliminace falešného sdílení
- Nevýhody
 - ◆ nepodporováno přímo operačním systémem
 - ◆ nutnost implementace pro různé jazyky
 - ◆ nutnost rekompile
- Příklad implementace: Munin 1990 Benett & spol.
- Distribuované objekty
 - ◆ díky zapouzdření flexibilnější - komunikace a synchronizace v metodách
 - ◆ distribuovaná data potomkem základní distribuované třídy
 - ◆ Class Definition Language - automatické generování hlaviček a kódu
 - ◆ základní "distribuovaná" třída, dědění vlastností, CORBA, Java RMI, ...

Middleware



Implementace sdílených dat - Munin

- ordinary / shared / synchronization variables
- sdílené proměnné - *read-only, migratory, write-shared, conventional*
- read-only
 - ◆ při výpadku je v adresáři nalezen vlastník, žádost o read-only kopii dat
- migratory
 - ◆ acquire/release protokol implementující eager release consistency
 - ◆ při opuštění kritické sekce se propagují změny
 - ◆ data chráněná SP migrují na uzel v kritické sekci
- write-shared
 - ◆ stránky iniciálně r/o, při zápisu kopie s původním obsahem r/w, označí se dirty
 - ◆ po release se porovná stránka s původní, změny se propagují
 - ◆ propagace na ne-dirty stránku akceptace, jinak word-po-wordu porovnání
 - ◆ sjednocení dat / konflikt - runtime-error
- konvenční sdílená data (*nepatřící do žádné z výše uvedených kategorií*)
 - ◆ jako distribuované stránkování - single writer/many readers
 - ◆ sekvenční konzistence



Identifikace a správa prostředků

- Identifikace a přístup k objektům
 - ◆ který objekt má být použit (identifikace)
 - ◆ kde je tento objekt umístěn (adresa)
 - ◆ jak je možné se k němu dostat (cesta)

- Druhy a struktura identifikací
- Kapability, distribuovaná správa jmen, přístup k objektům
- Uváznutí (deadlocks)
- Distribuované hashovací tabulky




Trvanlivost identifikací, prostory jmen

- Dynamická jména (*dočasná, tranzientní*)
 - ◆ typicky vázána na životnost procesu
 - ◆ deskriptory otevřených objektů, porty, adresy DSM
- Statická jména (*trvalá, perzistentní*)
 - ◆ nezávislá na procesech
 - ◆ jména souborů, kapability
- Převod dočasných a trvalých jmen
 - ◆ freeze / melt
 - ◆ *port / kapabilita*
- Prostor jmen
 - ◆ separátní prostory - file system, registry, URL, identifikace procesů, ...
 - ◆ jednotný - distribuovaný name server
 - ◆ lokační a replikační transparentnost

■ Systémová jména

- ♦ interní identifikace objektů, optimalizace pro strojové zpracování
- ♦ typicky binární řetězce pevné délky i struktury
- ♦ chráněné objekty jádra - porty



■ Access Control Matrix - user $\times$ resource $\rightarrow$ effective right

- ♦ Capabilities uživatel drží oprávnění k prostředkům
- ♦ Access Control List prostředek má seznam oprávněných uživatelů



■ Kapability (capabilities)

- ◆ datová struktura umožňující jednoznačnou identifikaci objektu
- ◆ obsahuje navíc přístupová práva pro držitele kapability
- ◆ ochrana objektů, šifrování, redundance
- ◆ k jednomu objektu typicky několik různých kapabilit
 - vlastník, písař, čtenář, ... další druhy služeb
- ◆ uživatelským procesům znemožněno vlastní generování kapabilit i změny práv

■ Výhody

- ◆ snadný test oprávněnosti přístupu
- ◆ flexibilita - každý správce prostředků může nadefinovat vlastní druhy práv

■ Nevýhody


- ◆ kontrola propagace
 - copy bit, čítač - chráněný způsob přenosu
- ◆ review - seznam oprávněných uživatelů
- ◆ revocation - odejmutí práva
 - zrušení objektu a vytvoření nového, notifikace ostatních uživatelů
- ◆ garbage collection



Implementace kapabilit

■ Kapabilita s podpisem


- ♦ hlavní část - identifikace objektu a přístupových práv
- ♦ platná kapabilita je rozšířena o podpis, který je vypočítán z obsahu hlavní části
- ♦ celá kapabilita zašifrována tajným klíčem
 - ochrana proti odvození podpisové funkce uživatelskými procesy
- ♦ řídkost: ze všech binárních čísel velikosti kapability jsou platné jen ty, jejichž podpis odpovídá zbytku kapability





Implementace kapabilit

- Kapabilita s redundantní kontrolou
 - ◆ port serveru a identifikátor objektu jsou volně přístupné
 - ◆ přístupová práva a náhodně vygenerované binární číslo pevné délky - zakódováno
 - ◆ ochrana serveru
 - port, dostatečně velké náhodně generované číslo
 - ◆ ochrana přístupových práv
 - zašifrování pole s přístupovými právy spolu s redundantní kontrolou
 - ◆ uživatelskému procesu znemožněna změna přístupových práv
 - proces nemůže svá práva změnit, nezná dešifrovací funkci, ani ji nemůže odvodit
 - náhodně generovaná redundance
 - ◆ služba serveru - vygenerování kapability s menšími právy



- Name servers, directory services, lookup servers
- Adresáře – množina položek <jméno, hodnota>
- Hodnoty:


- ◆ primitivní
 - čísla, řetězce, binární data, ...
- ◆ perzistentní reference
 - trvalé odkazy na objekty, kapability
- ◆ tranzientní reference
 - odkazy na živé objekty, porty, kanály
- ◆ odkazy na jiné adresáře – lokální / vzdálené

- Základní operace:


- ◆ adresář -> `set( jmeno, hodnota );`
- ◆ adresář -> `lookup( slozene_jmeno );`
 - `adresář -> lookup("A") -> lookup("B") -> lookup("C");`

- Klientský proces – několik základních 'adresářů'

- ◆ filesystem, objekty, služby a servery, registry, ...



- Server spravuje objekty (*identifikace, operace nad nimi*)
 - ◆ každý objekt má lokální identifikátor spravovaný serverem
 - ◆ na něm definovány operace / služby
 - ◆ server publikuje řídicí port a porty pro otevřené objekty





Služby pro přístup k objektům

- vytvoření objektu, tranzientní reference

```
obj_port = service_port -> create_object(...);
```

porty $\approx$ objekty
služby $\approx$ metody

- operace nad objektem

```
obj_port -> op(...);
```

- freeze – vytvoření kapability (perzistentního odkazu)

```
cap = obj_port -> freeze();
```

- zrušení tranzientní reference (ne objektu)

```
obj_port -> drop();
```

- uložení kapability s plnými právy

```
ns -> add( "mydata/cap/this_obj", cap );
```

- vytvoření kapability s restringovanými právy

```
cap2 = service_port -> cap_restrict( cap, 0101 );
```

- zveřejnění restringované kapability

```
ns -> add( "public/published_obj", cap2 );
```

- vyzvednutí kapability


```
cap = ns -> resolve( "public/published_obj" );
```

- otevření objektu - vytvoření tranzientní reference (portu)



```
obj_port = service_port -> melt( cap );
```



Spolupráce name serveru a souborového serveru




oddělené adresářové a
souborové (objektové) služby



- Centralizované řešení - resource manager
- Pokusy o distribuovanou správu
 - ♦ prakticky nepoužitelné - *distribuované vyloučení procesů*
- Migrace - identifikace, komunikace
- Replikované servery – aktualizací protokol

- Uvážnutí (deadlock)
 - ♦ typické řešení - pštroší algoritmus
 - ♦ detekce - větší problém než u centralizovaných systémů
 - ♦ WFG – Wait-For-Graph
 - orientovaný graf (procesů, transakcí)
 - $P1 \rightarrow P2$ proces P1 je blokován procesem P2
 - orientovaná kružnice – uvážnutí





- Korektnost algoritmu detekce deadlocku
 1. Každý existující deadlock je v konečném čase detekován
 2. Detekovaný deadlock musí existovat
 - Pozor na vnořené deadlocky - phantom deadlock

- Modely deadlocků
 - ◆ single model
 - ◆ AND model
 - ◆ *OR model*
 - ◆ *m-out-of-n model*
 - ◆ *AND-OR model*

- Metody konstrukce WFG
 - ◆ centralizované řešení, hierarchické
 - ◆ path-pushing - kontrakce a distribuovaná kolekce WFG
 - ◆ probe based: edge-chasing, diffusing computation
 - ◆ detekce globálního stavu

- *Ho-Ramamoorthy, Bernstein*
- Přenos informací:
 - ◆ po každé změně lokálního stavu
 - ◆ v pravidelných intervalech
 - ◆ na požádání
- Problém - falešné uvážnutí kvůli zpoždění zpráv
- Řešení – logické hodiny, kauzální doručování
- Rozšíření - hierarchický algoritmus
 - ◆ uzel řeší deadlocky lokálně
 - ◆ koordinátor řeší deadlocky podřízených uzlů






Inference from

o_1 : p_1 waits for r_2

o_2 : r_1 waits for p_1


o_3 : r_2 waits for p_2

o_4 : p_2 waits for r_1




From $O=\{o_1, o_2, o_3, o_4\}$
the deadlock detector
concludes there is a
deadlock!

- *Obermanck, Menasce-Muntz, Gligor-Shattuck*
- WFG distribuovaný, uzly spravují lokální části WFG
- Sousedním uzlům jsou zasílány externí závislosti
- Mnoho publikovaných algoritmů/protokolů nekorektních
 - ◆ phantom deadlock



- *Chandy-Misra-Haas, Stankovic, Singhal-Kshemkalyani, Roesler*
- Speciální zprávy (probes) jsou zasílány podél WFG
 - ◆ proces rozešle zprávu všem procesům, kterými je blokován
 - ◆ pokud se zpráva vrátí odesílateli – deadlock (orientovaná kružnice)
- Paralelní spuštění - overkill
 - ◆ zpráva zároveň hledá vhodného kandidáta





Edge-chasing Chandy-Misra-Haas

Sending the probe:

```
if  $P_i$  is locally dependent on itself then deadlock.  
else for( all  $P_j$  and  $P_k$  such that  $P_i$  is locally dependent upon  $P_j$   
        &  $P_j$  is waiting on  $P_k$  &  $P_j$  and  $P_k$  are on different sites)  
    send probe( $i, j, k$ ) to the home site of  $P_k$ 
```

Receiving the probe(i, j, k):

```
if  $P_k$  is blocked &  $\text{dependent}_k(i)$  is false &  $P_k$  has not replied to all requests of  $P_j$   
{  
     $\text{dependent}_k(i) := \text{true};$   
    if  $k = i$  then  $P_i$  is deadlocked  
    else ... (send)  
}
```

P_k ví o tom, že
 P_i čeká na P_k

■ Diffusing computation


- ◆ *Chandy-Misra-Haas, Chandy-Herrmann*
- ◆ 'distribuovaný výpočet' končí v okamžiku nalezení cyklu
- ◆ pokud se zpráva dostane k iniciátorovi, vracejí se signály
- ◆ iniciátor po obdržení signálu může rozhodnout
- ◆ vhodné pro složitější modely (*OR, n-nad-m*)

■ Detekce globálního stavu

- ◆ *Bracha-Toueg, Kshemkalyani-Singhal*
- ◆ jestliže $WFG \rightarrow WFG'$ a proces je v deadlocku v WFG , pak je v deadlocku i v WFG'
 - existuje-li deadlock, pak existuje i v konzistentním řezu
- ◆ při příjmu značky (okamžik řezu) uzel zaznamená lokální WFG
- ◆ lokální kontrakce WFG, externí závislosti zaslány iniciátorovi
- ◆ distribuovanější varianta - redukovaný edge-chasing na WFG

- Správa procesů v distribuovaných systémech
 - ◆ sdílet výpočetní sílu systému
 - ◆ rozdělovat zátěž na jednotlivé procesory
 - ◆ provádět operace na vzdálených procesech
 - ◆ synchronizovat procesy a vést evidenci stavu


- Vzdálené spouštění procesů
- Alokace procesorů
- Migrace procesů
- Vyvažování zátěže





Vzdálené spouštění procesů

- Nalezení volného počítače
 - alokační algoritmy
- Znalost vlastní zátěže
 - ◆ procento využití procesoru
 - periodické měření - vyhlazení (nějaký klouzavý průměr)
- Spuštění vzdáleného procesu
 - ◆ transparentnost
 - ◆ přenesení kódu a dat – nezajímavé
 - heterogenní prostředí
 - ◆ vytvoření prostředí odpovídající domovskému počítači
 - kontexty (fs, naming, environment)
 - systémová volání – vzdálená / přesměrování
- Hostitelský počítač přestane být volný (*uživatel se vrátil z oběda, potřeba restartu*)
 - ◆ doběhnutí
 - ◆ zabití
 - ◆ čas na uložení / uzavření
 - ◆ *migrace*





Klasifikace alokačních algoritmů

- zda jsou předem známy údaje o procesech, podle kterých se algoritmus rozhoduje
 - ♦ deterministické / heuristické
- do jaké míry se provádí optimalizace
 - ♦ optimální / suboptimální
- co se snaží optimalizovat
 - ♦ využití CPU / čas odpovědi / přidělování prostředků / komunikační složitost, ...
- zda umožňují přemístění již rozběhnutého procesu
 - ♦ migrační / nemigrační
- rozdíl mezi procesory a speciální požadavky procesů na vlastnosti procesorů
 - ♦ homogenní / heterogenní
- podle charakteru algoritmu
 - ♦ centralizované / distribuované
- podle jakých informací se provádí rozhodnutí o vzdáleném spuštění procesu
 - ♦ lokální / globální
- kdo iniciuje vzdálené spuštění procesu
 - ♦ odesílatel / příjemce / symetrický

- Implementace alokačních algoritmů
 - ◆ deterministický grafový algoritmus
 - minimalizace komunikace
 - nutnost znalosti komunikační složitosti
 - optimální deterministický algoritmus – tok v sítích
 - ◆ hierarchický algoritmus
 - manažeři skupin, při neúspěchu žádost vyšším místům
 - ◆ distribuovaný heuristický algoritmus
 - k náhodných výběrů cíle
 - server / receiver initiated
 - ◆ bidding (obchodní, nabídkový) algoritmus
 - procesy kupují výpočetní sílu, procesory ji nabízejí
 - ◆ up-down algoritmus




Up-down algoritmus

- Mutka-Livny 1987
- Optimalizace na stejnoměrné sdílení výkonu
- Koordinátor
 - ◆ tabulka se záznamem pro každý procesor obsahující “trestné body”
- Při každé významné akci (*vytvoření procesu, ukončení procesu, tik hodin*) zpráva koordinátoru, který provede změny:
 - ◆ každý proces běžící na jiném počítači - **plus** trestné body
 - ◆ každý neuspokojený požadavek - **mínus** trestné body
 - ◆ jestliže nic z tohoto - směrem **k nule**
- V okamžiku uvolnění procesoru se vezme ten proces z fronty (*neuspokojených požadavků*), jehož vysílající procesor má nejméně trestných bodů



Up-down algoritmus

Homogenní
Nemigrační
Spravedlivý
Heuristický
Centralizovaný
Suboptimální
Globální
Symetrický





Migrace procesů

korektní a transparentní přenesení procesu během výpočtu

- Motivace:
 - ◆ vyvažování zátěže; optimalizace - I/O, komunikační; přemístění; shutdown
- Korektnost
 - ◆ ostatní procesy nejsou migrací podstatně ovlivněny
 - ◆ po ukončení stav odpovídá stavu bez migrace
- Transparentnost
 - ◆ proces o migraci neví a nemusí spolupracovat
 - ◆ zůstanou zachovány vazby na komunikující procesy
 - ◆ není narušena komunikace
 - ... v konečném důsledku
- Problémy k řešení
 - ◆ přenesení rozpracovaného stavu ...
 - ◆ přenesení adresového prostoru ...
 - ◆ reinicializace vazeb na ostatní procesy
 - ◆ komunikace s ostatními procesy
 - ◆ reziduální dependence - žádná, domácí, průběžná, dočasná
 - ◆ vícenásobná migrace - viskozita



Implementace migrace - přenos procesu


- Přenos procesu
 - ◆ vyjmutí ze stavu, zmražení, speciální stav
 - ◆ oznámení příjemci o migraci, alokace procesu
 - ◆ přenos stavu - registry, zásobník, stav procesu
 - ◆ přenos kódu / adresového prostoru
 - ◆ přesměrování / doručení zpráv
 - ◆ dealokace procesu, vyčištění
 - ◆ vazby na nové jádro, nastartování procesu
 - přesunutí části stavu spolu s procesem (obsah VM)
 - forwardování (některých) požadavků (komunikace s konzolí)
 - použití odpovídajícího prostředku na cílové stanici (fyzická paměť)
 - ◆ dokončení přenosu vazeb, dočištění
 - dočasná reziduální dependence, přesměrování zpráv




Implementace migrace - virtuální paměť

- Virtuální paměť
 - ◆ přenesení celé VM při migraci
 - výhody - eliminace reziduálních dependencí
 - nevýhody - prodloužení doby zmražení procesu, mnohdy zbytečné přesouvat celý obsah virtuálního adresového prostoru
 - ◆ Pre-copying
 - výhoda - proces je zmražen pouze po dobu přesunu malého množství dat
 - nevýhoda - některé části se kopírují vícekrát - prodloužení celkové doby migrace
 - ◆ Copy-on-reference
 - nejprve se přenesou stav procesu potřebný pro běh (registry, kanály, ...)
 - přesun adresového prostoru odložen
 - stránky na cílové stanici označeny jako neprezentní (jako by byly odloženy na disk)
 - při přístupu na stránku se obsah přenesou
 - nutnost evidence různých zdrojů dat pro každou stránku
 - swap, vícenásobná migrace, DSM, ...


Migrace v heterogenních systémech




- Zprávy
 - ♦ přesměrování - dočasné / trvalé
 - ♦ oznámení předem - problém: komu všemu
 - ♦ opakování zpráv - no ACK, NAK
 - ♦ migrace kanálů, spojení front




Migrace serveru vzhledem k lokálnímu klientu



Migrace serveru vzhledem k vzdálenému klientu







Přehled některých migračních systémů

- DEMOS/MP
- Charlotte
- V
- MOSIX
- Sprite
- další ...

Amoeba, Emerald, Spice, Accent, T4, ...

Berkeley v r. 1983

IPC pomocí linků spojených s procesy, migrace v jádře
plná transparentnost, jednotné komunikační rozhraní nezávislé na poloze procesů

Migrace

- ♦ Vyjmutí procesu (*Zdroj*) - stav „v migraci“, vyjmutí z fronty
- ♦ Podrobnější informace pro cíl (*Zdroj*) - velikost procesu, alokované prostředky
- ♦ Alokace stavu na cíli (*Cíl*) - datové struktury pro proces, alokace
- ♦ Přesun stavu (*Cíl*) - zajímavé - **cílová stanice** si proces „tahá“ k sobě
- ♦ Přesun adresového prostoru a paměti (*Cíl*)
- ♦ Forward čekajících zpráv na cílovou stanici (*Zdroj*)
- ♦ Vyčištění stavu na zdroji (*Zdroj*) - veškerá data kromě adresy (pro forwarding)
- ♦ Restart procesu (*Cíl*)

Forwardování zpráv - 3 druhy zpráv podle toho jak přicházely

- ♦ Odeslané ale nepřijaté před migrací - přeneseny při migraci
- ♦ Odeslané po migraci za použití staré adresy - průběžný forward
- ♦ Odeslané po migraci s využitím nové adresy - není problém



Uni Wisconsin (Bryant, ..) 1985-87

IPC pomocí linků nezávislých na umístění procesů, možnost přesouvat linky
migrační politika v uživatelském procesu, migrace v jádru
nezůstávají reziduální dependence, snaha o maximální fault-toleranci
migrační strategie - **sběr statistiky** - sběr 50-80 ms, rozesílání 5-8 s

o počítači: počet procesů, komunikační linky, využití CPU, síťová komunikace
o procesu: doba běhu, stav procesu, využití CPU, síťová komunikace

Průběh migrace

- Negotiation
 - ♦ výměna informací mezi procesy, proces na zdrojové stanici zavolá „Migrate Out“
 - ♦ podrobnější informace o procesu na cílovou stanici, cílová stanice zavolá „Migrate In“
- Vlastní přesun procesu
 - ♦ přesun obrazu procesu
 - ♦ **nastavení komunikačních linků** - jádra na počátcích linků obdrží novou pozici konce,
 - ♦ přesun stavu - deskriptory procesu, komunikačních linků, událostí a zpráv
- Clean-up - vyčištění zdrojové stanice

Stanford (Cheriton) 1984-86

síťově transparentní prostředí a meziprocesová komunikace, [zotavení ze ztráty](#) zprávy

Návrh migrace

předmětem migrace „[logical host](#)“ - adresový prostor, možnost několika procesů

minimalizace doby zamražení - na úkor celkové doby migrace - [precopying](#)

Mechanika migrace

Inicializace cíle

- ♦ vytvoří se nový logical host

Precopying stavu

- ♦ proces na zdrojové stanici provádí kopírování stavu (adresový prostor); proces stále běží
- ♦ migrovaný logický host je zamražen, dokončí se kopírování modifikované paměti
- ♦ kopírování stavu z jádra zdrojové stanice

Odmražení, přesměrování odkazů

- ♦ smaže se stará kopie logical hostu, nová se odmrazí
- ♦ PID se naváže na novou kopii logical hostu, navázání na nový počítač (cache)
- ♦ broadcast nové adresy logical hostu

Technion (Barak, Shiloh, ...) (1977-) 1988-2004(!)

UNIX adaptovaný na distribuované prostředí, rozsáhlé vyvažování zátěže

Jeden z mála prakticky používaných distribuovaných systémů

Rozšíření struktury procesu:

čas od poslední migrace, čas na procesoru, příčina migrace, statistika IPC

Vlastní migrace

Příprava

- ♦ Cílová stanice zjistí, jestli si může dovolit příjem procesu
- ♦ Zajistí opravu komunikačních kanálů
- ♦ Nastaví se paměťové oblasti
- ♦ Čeká na doručení procesu - až bude proces doručen, rutina jej probudí a vrátí se

Přesun dat - adresový prostor

Rozběhnutí odmigrovaného procesu

Na zdrojové stanici se smažou lokální data procesu

Berkley (Douglas, Ousterhout, Welch) 1992

- Předpoklady:
 - mnoho nevyužitých stanic
 - po návratu vlastníka potřeba uvolnit (odmigrovat)
- Cíle
 - rychlost, maximální transparence
- Návrh migrace
 - vlastní migrace jádro / sběr statistiky a rozhodování provádí uživatelský proces
 - původní **idea**: všechna **volání** jádra **forwardovat** na domácí stanici
 - transparence vs. reziduálních dependence
 - později ústup - kombinace s voláním na cílové stanici
 - ze 106 volání Sprite: 91 lokálně, 11 forwardováno, 4 se řeší kooperací
- Virtuální paměť
 - kombinace přesunu veškeré paměti najednou a „**copy-on-reference**“
 - nevýhoda: paměť se přesouvá po síti dvakrát
- **Jednotný mechanismus** migrace různých entit
 - každá součást stavu má definovány **4 rutiny**
 - pre-migration, encapsulation, de-encapsulation, post-migration routine

Systém, který by

- byl dostatečně efektivní a použitelný jako konvenční operační systém
- poskytoval dostatečně silné prostředí pro použití jako distribuovaný systém

Hlavní části

- meziprocesová komunikace
- vzdálená komunikace
- přenosové protokoly
- name services
- podpora pro "vyšší" distribuované služby
 - distribuovaná sdílená paměť
 - migrace procesů, load balancing


Zkušenosti s T4

- základ pro výuku a platforma pro studentské projekty a experimenty
 - ++ diplomové práce, PGDS
- základ dalšího výzkumu v oblasti distribuovaných systémů
 - + - články, konference (málo), výzkum jiným směrem
- pro běžné každodenní použití
 - aplikace !!!

- Rozhodnutí o okamžiku migrace
 - ◆ jak porovnávat zatížení uzlů
 - ◆ udržování konzistence údajů
 - ◆ volba migrujícího procesu
 - ◆ volba příjemce
 - ◆ přenos a běh procesu

- **Párový algoritmus** (Bryant & Finkel, Charlotte)
 - ◆ vytvářejí se páry, které se vzájemně vyvažují
 - ◆ A pošle B žádost o vytvoření páru se seznamem procesů
 - ◆ B odmítne / vytvoří pár / migruje
 - ◆ zatíženější uzel vybere proces podle míry vylepšení
 - $k_i = A_i / (B_i + AB_i)$
 - ◆ významné zlepšení stavu – migrace a další proces, jinak konec

- Barak & Shiloh - Mosix
 - ◆ pevný vektor zátěže L , $L(0) = \text{vlastní zátěž}$
 - ◆ periodicky každý uzel provádí:
 - zjistí vlastní zátěž
 - náhodně pošle polovinu vektoru
 - ◆ při příjmu L' : $L(2i) = L(i)$, $L(2i+1) = L'(i)$
 - ◆ k zátěži se přičte komunikační režie



- **Bidding algoritmus** (Stankovic & Sidhu)
 - ◆ McCulloch-Pittsova vyhodnocovací procedura
 - ◆ vyhodnocovací buňka - excitátory, inhibitory, výstup
 - ◆ výstup vyšší - OK, nižší - migrace, nula - nelze migrovat (inhibitor)
 - ◆ migrace:
 - 'žádost o nabídku' (RFB) až do vzdálenosti d
 - odpovědi s nabídkou se zkorigují o režii
 - nejlepší nabídka / žádná nabídka: d++
 - ◆ problém: obtížná kvantifikace vlastností procesů
- SLA algoritmus (Stankovic)
 - ◆ stochastic learning automata - zpětné učení
- BDT algoritmus
 - ◆ bayesian decision theory - posílání globálních stavů

neprosadily se
příliš komplikované

■ Centralizovaný / hierarchický algoritmus

- ♦ centralizovaný manažer, zná zátěž všech počítačů, velí
- ♦ hierarchicky organizované skupiny, nadřazení manažeri

myšlenka:
vyvažující se skupiny
nebývají příliš velké

■ Lokální algoritmus

- ♦ známa pouze lokální zátěž, prahová hodnota
- ♦ žádost n počítačům, podprahová / nejlepší odpověď OK

velmi jednoduchý
velmi suboptimální
velmi použitelný 😊

■ hlediska srovnání vyvažovacích algoritmů:

- ♦ efektivita a režie vlastního algoritmu
- ♦ komunikační složitost:
 - přenos detailních popisů procesů
 - přenos globálního stavu (zátěž, . . .)
- ♦ aktualizace údajů



Distribuovaná správa souborů

Identifikační a adresářové služby

Adresářový modul, Kontrola přístupu, Umisťovací modul, Lokační

Middleware

Replikační služby

Konzistence dat, Multiple copy update

Transakční služby

Transakční operace, Modul zotavení, Kontrola konkurence

Transakce

Souborové služby

Přístup k souborům, Přístup k atributům




Operační systémy

Blokové a diskové služby

Modul správy bloků, Ovladače zařízení, Caching

- replikace souborů - udržování více kopií na více fileserverech
 - ◆ spolehlivost (*reliability*) - při havárii serveru nejsou ztracena data
 - ◆ dostupnost (*availability*) - k souborům lze přistupovat i při výpadku serveru
 - ◆ výkon (*performance*) - lze přistupovat k nejbližším datům, rozdělení výkonu
- explicitní replikace
 - ◆ 'uživatel' se sám stará o udržování konzistence
- odložená replikace
 - ◆ zápis do primární repliky, aktualizace sekundárních
- skupinová komunikace
 - ◆ zápisy simultánně zasílány všem dostupným replikám

typicky knihovny






Aktualizační protokoly

- Problém aktualizací kopií

- ◆ primární kopie
- ◆ většinové hlasování (*majority voting*)
 - $N_r > N/2$
 - $N_w > N/2$


speciální případ váženého hlasování

- Problém aktualizací kopií
 - ♦ primární kopie
 - ♦ většinové hlasování (*majority voting*)
 - ♦ vážené hlasování (*weighted voting*)
 - read / write quorum: $N_r + N_w > N$, $2 * N_w > N$
 - většinové hlasování $\approx$ vážené při $N_r = N_w$
 - optimalizace čtení zápis
 - problém při 'totální optimalizaci' ($N_r=1$) - potenciální nemožnost zápisu
 - ♦ hlasování s duchy (*voting with ghosts*)
 - bezdatový (dummy, ghost) server, obsahuje pouze verze, žádná data
 - neúčastní se hlasování o čtení, pouze o zápisu
 - ♦ dynamická kvóra



Klientocentrické konzistenční modely

- Konzistenční modely DSM - pohled na sdílená data různými procesy
- Replikovaná databáze
 - ◆ zápisy málo časté, masivně paralelní čtení
 - ◆ není potřeba vzájemná synchronizace klientů
 - ◆ WWW + cache, mobile computing, News, ...
- Klientocentrický model - pohled na replikovaná data jedním procesem



■ Eventual consistency

Po ukončení všech zápisů budou všechny repliky v konečném čase aktualizovány

■ Problém: pohled jednoho procesu na data různých replik

Značení:

$x_i, x_i[t]$	hodnota proměnné x na replice L_i (v čase t)
$W(x_i)$	prvotní zápis hodnoty x_i
$S(x_i), S(x_i[t])$	posloupnost operací na L_i vedoucí k hodnotě x_i
$S(x_i; x_j)$	posloupnost x_i předchází x_j , $S(x_i) \subset S(x_j)$

A, B - připojení jednoho klienta k různým replikám

A:	$S(x_1)$	$R(x_1)$	
B:		$S(x_2)$	$R(x_2)$ $S(x_1; x_2)$

Příklad: při připojení k jedné replice uživatel vidí zprávy, po připojení k jiné replice některé zprávy (které již viděl) 'ještě' nevidí



Monotonní čtení

■ Monotonic read consistency

Po přečtení hodnoty x všechna další čtení vrátí stejnou nebo novější hodnotu

A: $S(x_1)$ $R(x_1)$
B: $S(x_1;x_2)$ $R(x_2)$

Vyhovuje monotónnímu čtení

A: $S(x_1)$ $R(x_1)$
B: $S(x_2)$ $R(x_2)$ $S(x_1;x_2)$

Nevyhovuje monotónnímu čtení

Příklad: při připojení k jiné replice uživatel vidí všechny dosud přečtené zprávy



Monotonní zápis

■ Monotonic write consistency

Zápis proměnné je proveden před jakýmkoliv následným zápisem této proměnné

A: W(x1)
B: S(x1) W(x2)

Vyhovuje monotónnímu zápisu

A: W(x1)
B:  W(x2)

Nevyhovuje monotónnímu zápisu

Příklad: CVS commit na různých replikách



Čtení vlastních zápisů

- Read your writes consistency

Zápis proměnné je proveden před jakýmkoliv následným čtením této proměnné

A: W(x1)
B: S(x1;x2) R(x2)

Vyhovuje č.v.z.

A: W(x1)
B: S(x2) R(x2)

Nevyhovuje č.v.z.

Příklad: po aktualizaci webové stránky si neprohlížím kopie z cache



Zápisy následují čtení

- Writes follow reads consistency

Zápis proměnné po předchozím čtení této proměnné je proveden na stejné nebo novější hodnotě

A: S(x1) R(x1)
B: S(x1;x2) W(x2)

Vyhovuje z.n.č.

A: S(x1) R(x1)
B: S(x2) W(x2)

Nevyhovuje z.n.č.

Příklad: zápis odpovědi do newsgroups se provede tam, kde je i přečtená hodnota



Naïvní implementace

- každému **zápisu** je přiřazen globálně jednoznačný identifikátor **WID**
 - ♦ přiřazuje replika kde byl zápis proveden klientem: $WID = repl_id + loc_id$
- každý **klient** udržuje dvě množiny identifikátorů: **read-set**, **write-set**
- Monotónní čtení
 - ♦ při **čtení** replika serveru ověří podle **read-set** aktuálnost svých zápisů
 - při chybějících zápisech provede synchronizaci nebo forwarduje čtení
 - ♦ po **čtení** si klient aktualizuje **read-set** podle repliky ze které četl
- Monotónní zápis
 - ♦ při **zápisu** replika ověří podle **write-set** aktuálnost svých zápisů
 - chybějí-li nějaké, zapíše je
 - ♦ po **zápisu** si klient aktualizuje **write-set**
- Čtení vlastních zápisů
 - ♦ při **čtení** replika ověří podle **write-set** aktuálnost svých zápisů
 - jiné možné řešení - forward čtení na aktuální repliku
- Zápisy následují čtení
 - ♦ aktualizace repliky podle **read-set**
 - ♦ aktualizace read-set i write-set klienta

Problém:
neomezený růst
read/write set



Efektivnější implementace

- Problém: read-set i write-set neomezeně rostou
- Možné řešení: seskupení do relací (session)
 - ◆ typicky vázané na aplikaci nebo modul
 - ◆ při ukončení / restartu smazání množin
 - ◆ neřeší problém trvale běžících aplikací
- Jiné řešení: reprezentace množin - vektorové hodiny (Bayou)
 - ◆ replika serveru při zápisu přiřadí WID a lokální TS(WID)
 - ◆ každá replika S_i udržuje $RCV(i)[j]$ - TS poslední operace zápisu přijatá S_i od S_j
 - ◆ při přijetí žádosti o čtení nebo zápis replika vrátí aktuální $RCV(i)$
 - ◆ read-set i write-set jsou reprezentovány vektorovými hodinami
 - ◆ obecná pravidla:
 - $VT(A)[i] = \max \text{ TS operací z } A \text{ iniciovaných na replice } S_i$
 - sjednocení: $VT(A+B)[i] = \max(VT(A)[i], VT(B)[i])$
 - test podmnožiny: $A \subseteq B \Leftrightarrow VT(A) \leq VT(B)$
 - ◆ po přijetí TS si klient aktualizuje read-set nebo write-set
 - čtení: $VT(RS)[j] = \max(VT(RS)[j], RCV(i)[j]) \forall j$
 - zápis: $VT(WS)[j] = \max(VT(WS)[j], RCV(i)[j]) \forall j$
 - ◆ read/write-set reprezentuje poslední operace zápisu, které klient viděl/zapisoval



Optimalizace komunikace ve **VELMI** rozsáhlých systémech, neřeší konflikty

- rozšíření infekce co nejrychleji na co největší počet uzlů

- možné výměny:

$$P \rightarrow Q$$

při velkém počtu infikovaných uzlů malá pravděpodobnost rozšíření

$$P \leftarrow Q$$

zpočátku pomalé rozšiřování, nakonec infekce celé množiny

$$P \leftrightarrow Q$$

Lze spojit výhody předchozích postupů



Epidemické protokoly

Implementace eventuální konzistence

Optimalizace komunikace ve VELMI rozsáhlých systémech, neřeší konflikty

Teorie epidemií - infekční nákaza

- rozšíření infekce co nejrychleji na co největší počet uzlů

Antientropie - server P náhodně vybere server Q k výměně dat

■ možné výměny:

- ♦ push - při velkém počtu infikovaných uzlů malá pravděpodobnost rozšíření
- ♦ pull - zpočátku pomalé rozšiřování, nakonec infekce celé množiny
- ♦ push/pull - lze spojit výhody předchozích postupů

■ push problém: kdy má uzel přestat infikovat

Gossiping

- při nákaze infikovaného uzlu se s pravd. $1/k$ uzel uvede do klidového stavu
- oblíbená kombinace: Gossiping + periodický Pull
- výhoda epidemických protokolů: rozšiřitelnost
- složitější topologie - hierarchie, rychlejší infekce

Problém mazání dat

- ♦ naivní implementace: smazání dat → smazání všech informací o datech
 - důsledek: entropie jiným kanálem data zase obnoví
- ♦ vylepšení: certifikát smrti (death certificate) - záznam o smazání
 - problém: neomezený nárůst certifikátů o historických datech
- ♦ řešení: v konečném čase certifikát zanikne
 - podmínka: konečná doba rozšiřování infekce

Aplikace - agregace dat

- ♦ *uzly, spočítejte se!*
- ♦ podproblém: spočítejte průměr
 - uzel i : x_i = iniciální (libovolná) hodnota
 - epidemicky: $(x_i, x_k) = (x_i + x_k) / 2$
 - $x_i \rightarrow \text{avg}_{\forall n} (x_n)$
- ♦ iniciátor $x_i = 1$, ostatní $x_i = 0$
 - $x_i \rightarrow 1 / N$



Další zajímavé protokoly

- Distribuční protokoly
 - ◆ kolik a kde umístit repliky
 - ◆ permanent, server-initiated, client-initiated

- Další konzistenční protokoly
 - ◆ primary-based - remote-write, local-write
 - ◆ replicated-write - active replication
 - ◆ cache coherence
 - ◆ lazy replication, causal consistency, ...

- Živý výzkum v oblasti velmi rozsáhlých systémů

■ Nový hardware

- 😊 síť $\approx$ rychlá sběrnice, multicomputery $\approx$ multiprocesory
- 😊 rychlé optické kabely - přenos po síti rychlejší než na disk
- 😊 velké disky - WORM, zapisovatelné, ...
- 😞 velká paměť - mapované soubory, nestránkování
- 😞 neblokové soubory - append v paměti rychlejší

Mooreův zákon:

$$1.8^{18} \approx 40\,000$$

■ Globální systémy

- 😞 algoritmy - centralizované / hierarchické / distribuované, masivní škálovatelnost
- 😊 lokalizace - znaková sada, ikony, národní prostředí
- 😊 potřeba datových dálnic
- 😊 problémy s prostorem jmen - strom příliš košatý
- 😞 globální IS - VLDB

■ Mobilní uživatelé

- 😞 konektivita v letadle
- 😊 ochrana dat a osobních údajů

■ ...





to be continued ...

- NSWI080 Middleware
 - Petr Tůma
 - CORBA, DCE, DCOM, EJB, JMS, RMI, JavaSpaces, MQ, ..., ..., ...
- NPRG042 Programování v paralelním prostředí
 - Jakub Yaghob
 - OpenMP, Cluster Open MP, Threading Building Blocks, MPI
- NSWI152 Vývoj cloudových aplikací
 - Filip Zavoral, Jaroslav Kezníkl, Tomáš Pop
 - Goggle App Engine, Amazon Elastic Cloud, Windows Azure