Principy distribuovaných systémů

NSWI035 ZS 2015/16

RNDr. Filip Zavoral, Ph.D.
Katedra softwarového inženýrství

http://ulita.mff.cuni.cz -> Výuka

13.12.2015 12:19

Obsah přednášky

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
4. **Konsensus**
   - detekce globálního stavu, armády a generálové, Paxos
5. **Distribuovaná sdílená paměť**
   - konzistenční modely, distribuované stránkování
6. **Správa prostředků a procesů**
   - zablokování, distribuované algoritmy detekce
   - vzdálené spouštění procesů, migrace, vyvažování zátěže
7. **Replikace a konzistence**
   - replikace, aktualizační protokoly
   - klientocentrické konzistenční modely, epidemické protokoly

Literatura

- **Pokrývá většinu přednášené** (a zkoušené) **látky**
  - Tanenbaum, van Steen: Distributed Systems - Principles and Paradigms, *2nd ed*
  - Chow, Johnson: Distributed Operating Systems & Algorithms

- **Další zdoje 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: Distributred Systems, *2nd ed*

- slajdy ani velmi historické *'učební texty'* nejsou skripta!

Související předměty

- Tůma: *NSWI080* **Middleware** [LS]
  - RMI, Sun RPC, .NET Remoting, CORBA, DCE, DCOM, SOAP, WSDL, UDDI, MQSeries, JMS, DDS, MPI, CAN, Chord, Pastry, JavaSpaces, EJB, OSGi, ...
- Bednárek, Yaghob, Zavoral: *NSWI150* **Virtualizace a Cloud Computing** [ZS]
  - moderní aplikace principů distribuovaných systémů
- Yaghob, Kruliš: *NPRG042* **Programování v paralelním prostředí** [LS]
  - jiný způsob řešení 'výkonného počítání'
- Kruliš: *NPRG058* **Pokročilé programování v paralelním prostředí** [ZS]
  - nové architektury, GPGPU

"Definice"

Distribuovaný systém
je systém propojení množiny <u>nezávislých</u> uzlů,
který poskytuje uživateli dojem <u>jednotného</u> 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

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

- principy, algoritmy

“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.

"Definice"

Distribuovaný systém
je systém propojení množiny <u>nezávislých</u> uzlů,
který poskytuje uživateli dojem <u>jednotného</u> 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, grid cloud

Zaměření přednášky

- principy, algoritmy
- uzel = *běžný* počítač, *běžná* síť, softwarový systém

199x - Distribuované operační systémy

- 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

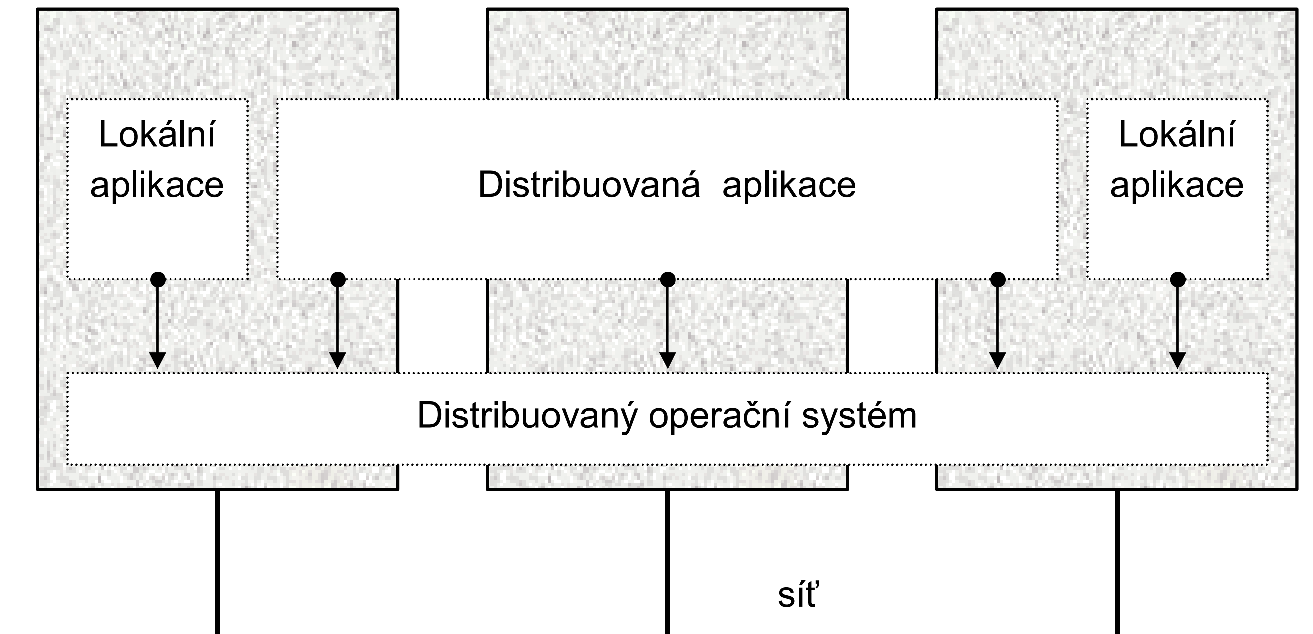

200x - Distribuované frameworky a aplikace

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

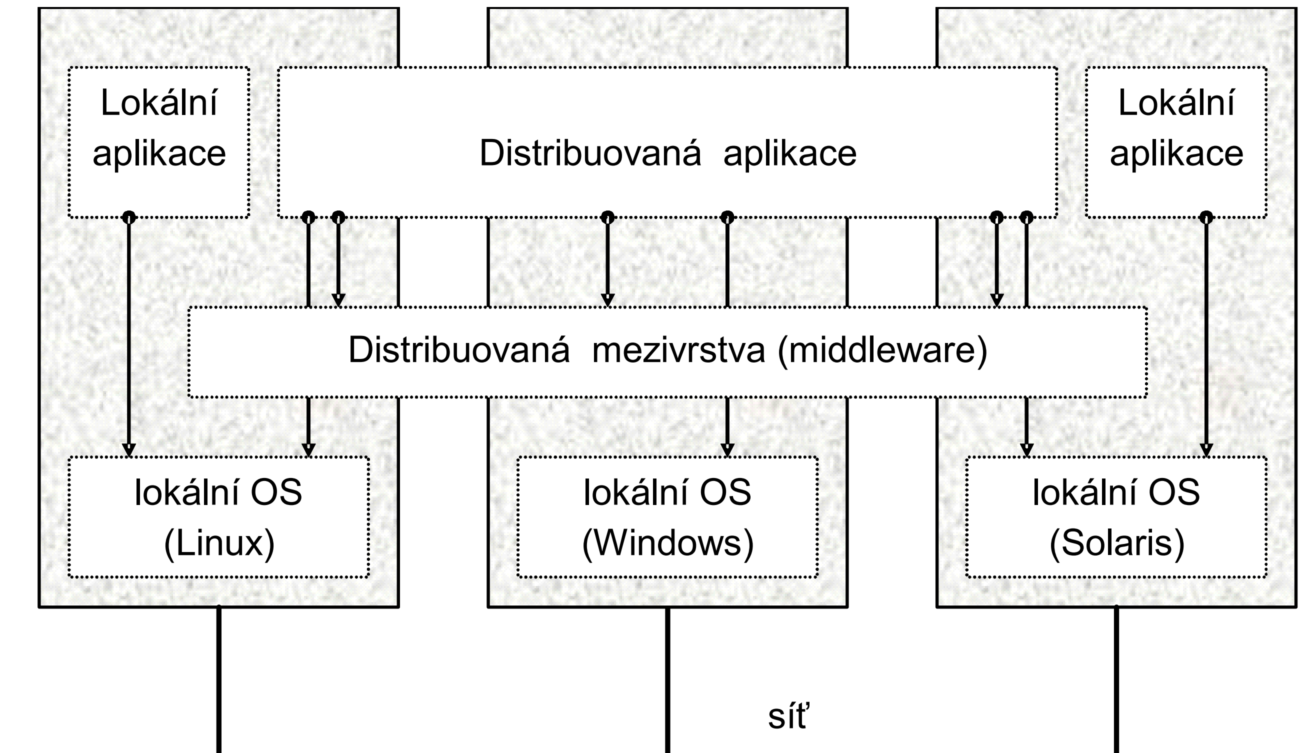

201x - Cloud computing, XaaS

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

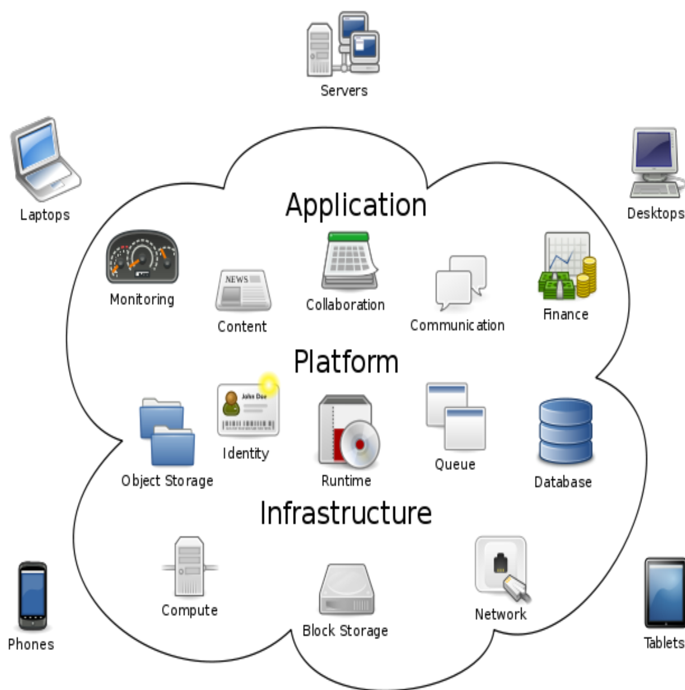

Execution Models	Virtual Machines	Web Sites	Cloud Services		
Data Management	SQL Database	Tables	Blobs		
Networking	Virtual Network	Connect	Traffic Manager		
Business Analytics	SQL Reporting	Hadoop			
Messaging	Queues	Service Bus			
Caching	Caching	CDN			
Identity	Windows Azure Active Directory				
High-Performance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

NSWI150

Distributed Computing

Obecné principy distribuovaných systémů aplikovatelné na různá prostředí

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

Motivace a cíle návrhu distribuovaného systému

Motivace

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

Cíle návrhu

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

Motivace a cíle návrhu distribuovaného systému

Motivace

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

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
    - *uzel:cesta/soubor* *vs* *služba:namespace/soubor*
- **Exekuční / Migrační**
  - procesy mohou běžet na libovolném uzlu / přemisťovat 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
  - využití moderního hw

Přizpůsobivost, spolehlivost

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%

  $\Rightarrow$ nespolehlivost čtyř serverů $0.01^4 = 0.00000001$
- Leslie Lamport: distribuovaný systém je ...

  "systém, který pro mě odmítá cokoliv vykonávat, protože počítač, o kterém jsem nikdy neslyšel, byl náhodně vypnut"

Přizpůsobivost, spolehlivost

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%

  $\Rightarrow$ 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

Rozšiřitelnost - škálovatelnost, scalability

- Rozdílné metody pro 100 uzlů × 100 milionů uzlů
- Principip: 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'*

serverům, službám, tabulkám, algoritmům, ...

- Další problémy
  - koordinace a synchronizace
  - geografická odlehlost, administrace
- Techniky škálovatelnosti
  - asynchronní komunikace
  - distribuce
  - caching a replikace

Výkonnost, chyby návrhu

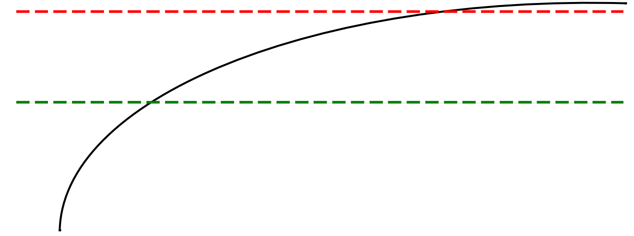

Výkonnost

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

Chyby návrhu distribuovanách systémů

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

Výkonnost, chyby návrhu

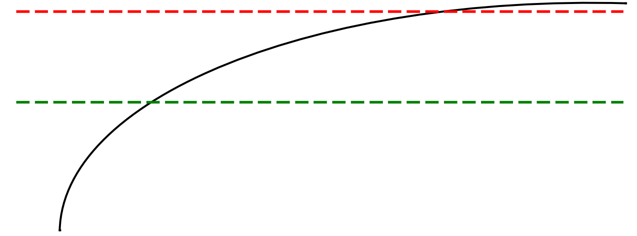

Výkonnost

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

Chyby návrhu distribuovanách systémů

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

Paralelní architektury

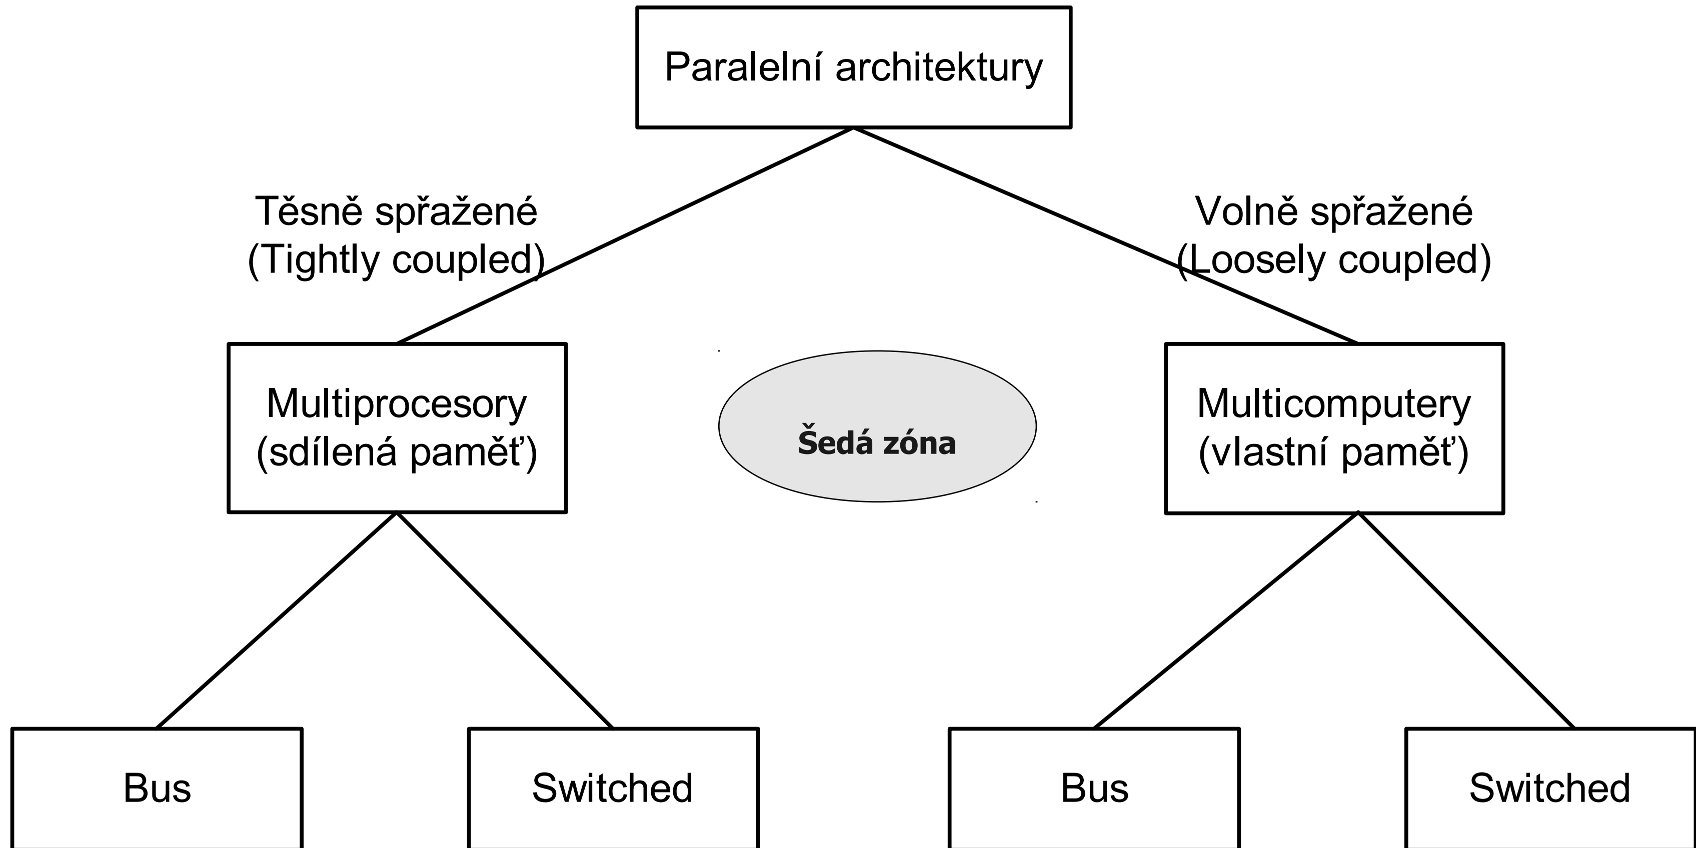

Multiprocesory – sběrnicová architektura

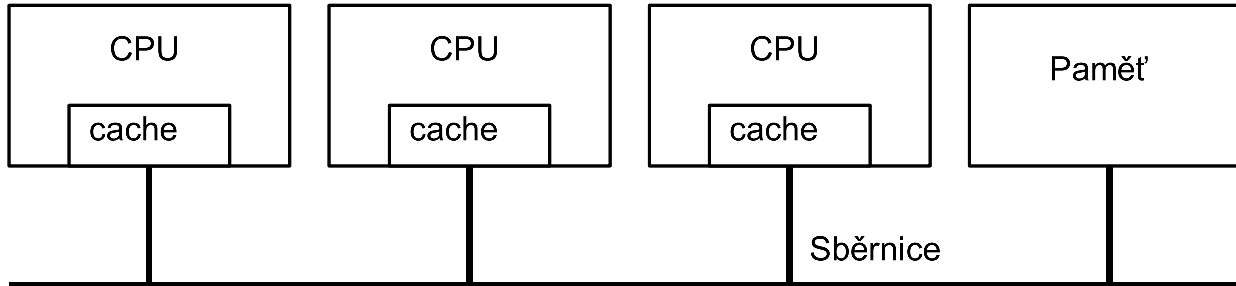

Sběrnicová architektura

- sdílená sběrnice mezi procesory a pamětí
- levná, běžně dostupná
- max. desítky uzlů
- cache – synchronizace

Multiprocesory – přepínačová architektura

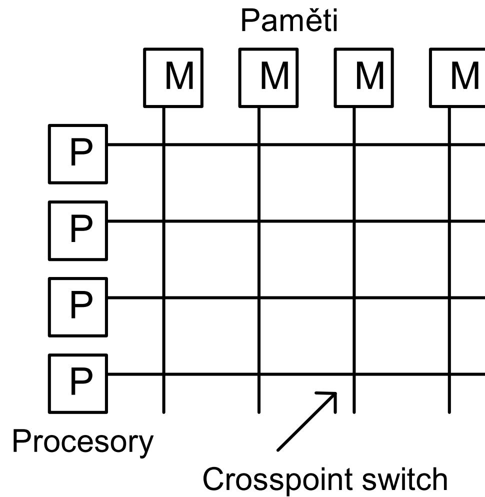

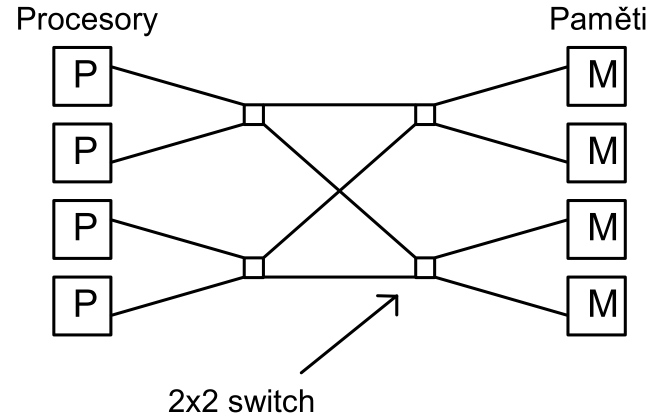

Přepínačová (switched) architektura

- Možné zapojení i většího počtu uzlů
- Mřízka - crosspoint switch
  - sběrnicová mřížka - procesory × 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

Multicomputery – sběrnicová architektura

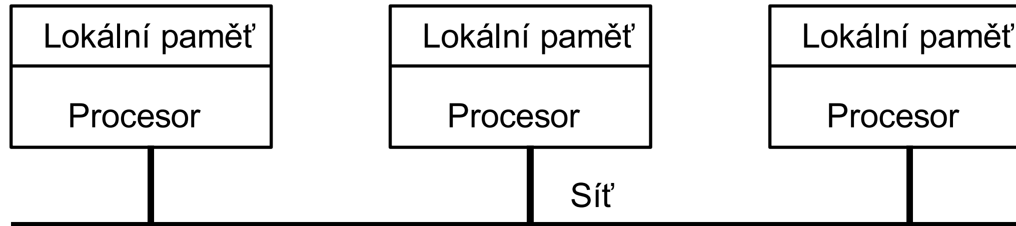

Sběrnicová architektura

- 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

Multicomputery – přepínačová architektura

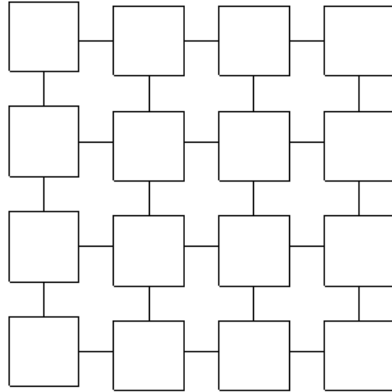

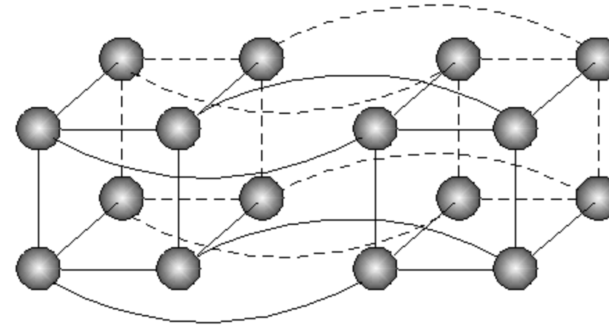

Přepínačová (switched) architektura

- 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
    - 2015 TianHe 2 (Milky Way) - 3.1 mil cores, 1 PB RAM, 18 MW (Xeon E5-2692 2.2GHz)

NUMA

Non Uniform Memory Access

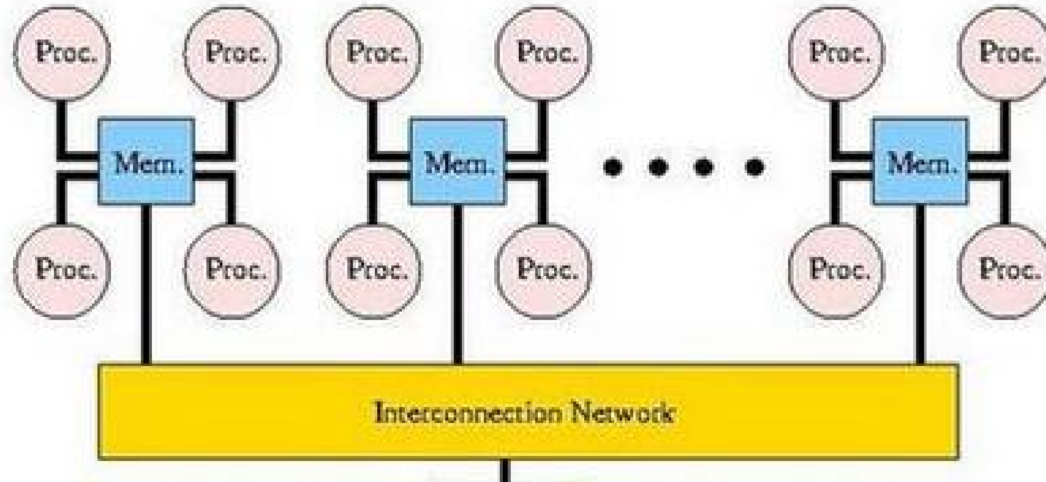

- S-COMA - Simple Cache-Only Memory Architecture
  - požadavek na nelokální data je propagován vyšší vrstvě
- ccNUMA - Cache Coherent NUMA
  - globální adresace, konzistence cache
- NUMA-faktor - rozdíl latence lokálních a vzdálených paměťových přístupů
  - NUMA-aware processing / scheduling

GPGPU

General-purpose computing on graphics processing units

- Moderní dostupný HW
  - NVidia Tesla, Kepler, Xeon Phi, ...
- Frameworks
  - CUDA, OpenCL, C++Amp

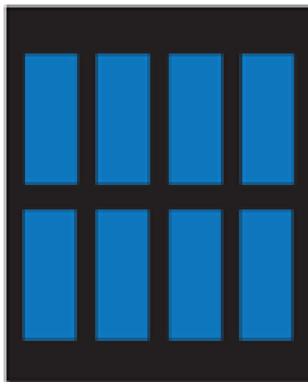

CPU
MULTIPLE CORES

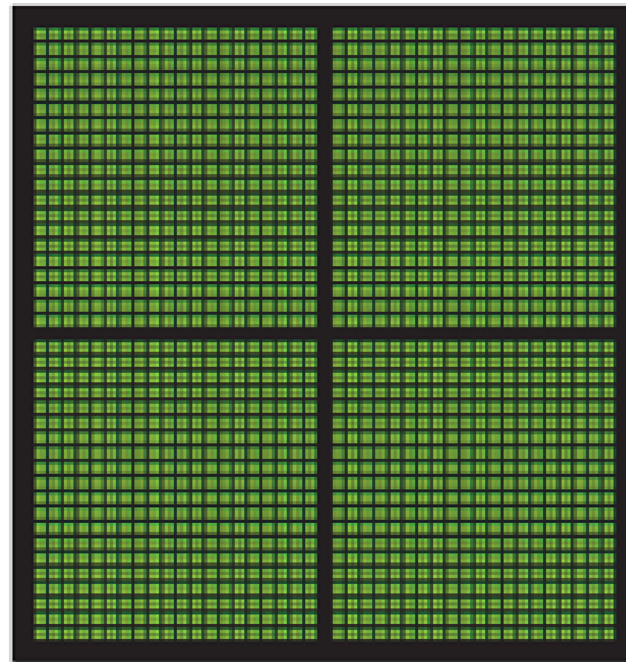

GPU
THOUSANDS OF CORES

Mechanismy sdílení paměti

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

SwMP - Dash - Stanford, Alewife - MIT

Cm* - hw přístup do maměti, sw caching

Distributed paging - Ivy, Li; Mirage - Bershad 1990

Munin Benett 1990

Komunikace

Komunikace

absence sdílené paměti → zasílání zpráv

vyšší komunikační mechanismy

- RPC, doors, RMI, M-queues, ...

Jednotný komunikační mechanismus

klient-server model

efektivita - lokální / vzdálený přístup

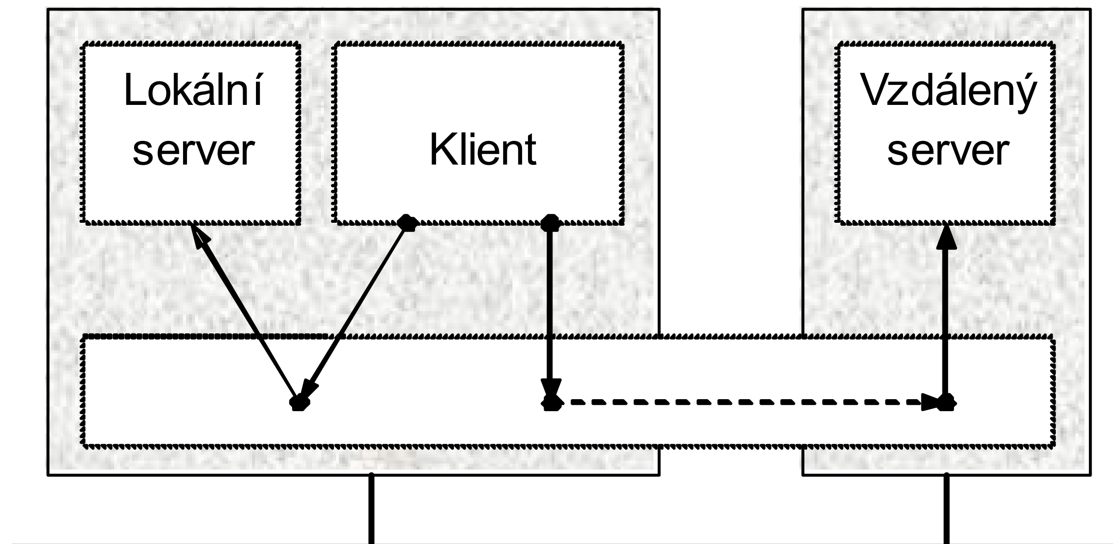

Síťová komunikace - optimalizované protokoly

- TCP - standard pro spolehlivý vzdálený přenos
  - ale: většina komunikace v rychlé a spolehlivé LAN
  - nevýhody:
    - složitost protokolu
    - vyšší latence
    - nižší propustnost
- specializované protokoly pro (spolehlivé) lokální sítě
  - optimistické
  - vysoký výkon
  - složitější zotavení z chyb
  - T/TCP, FLIP, VMTP

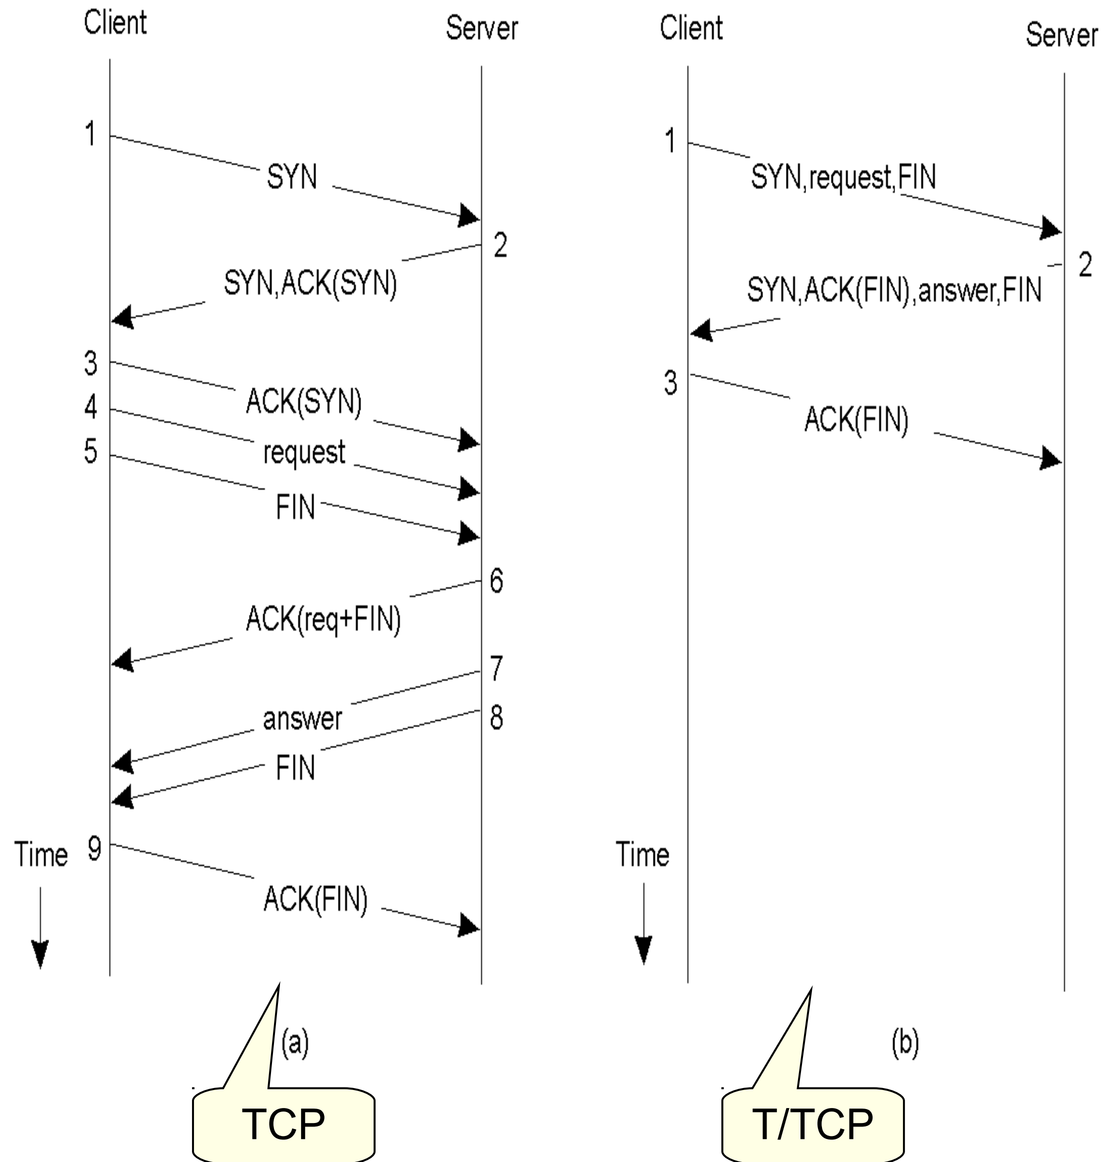

Zajištění spolehlivosti komunikace

- duplicita zpráv - číslování, zahození - poslední zpráva / okno
- předbíhání zpráv - číslování, zpráva o nedoručení - režie, okno
- ztráta zprávy - 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
- služební zprávy - ACK, NAK, AYA, IAA, CON, ...

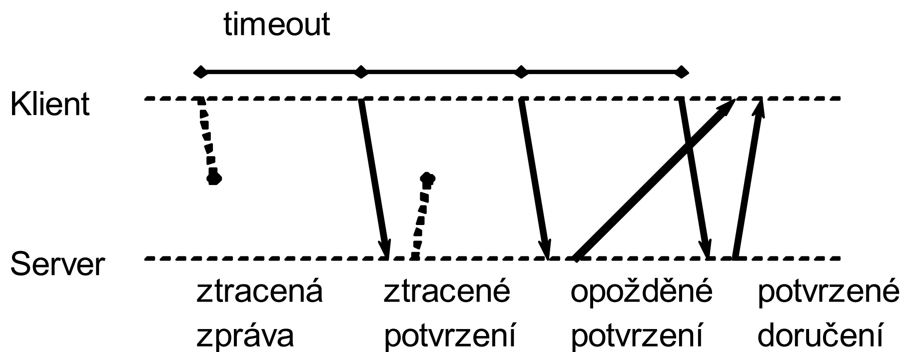

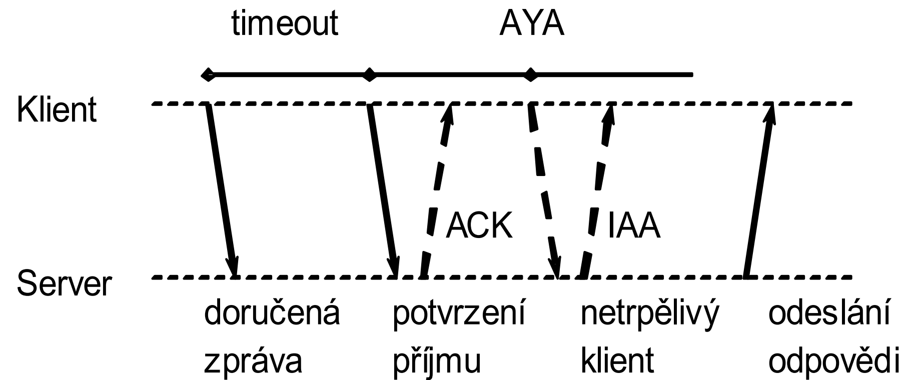

Přenos dlouhých zpráv

- jednotka přenosu = zpráva
  - příliš dlouhá → rozdělení na pakety
- co potvrzovat?
  - každý paket?
  - celá zpráva?

režie při správném přenosu !

režie při špatném přenosu !

Přenos dlouhých zpráv

- jednotka přenosu = zpráva
  - příliš dlouhá → rozdělení na pakety
- co potvrzovat?
  - každý paket?
  - celá zpráva?

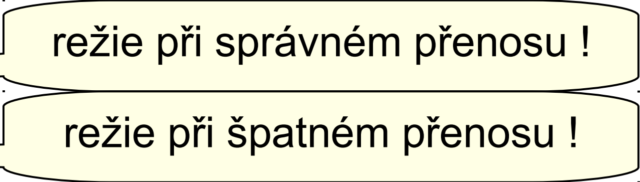

- možné řešení - dávky (*buřty*, blast, burst)
  - potvrzování dávky (definovaný počet paketů)
  - v pořádku celá dávka → ACK
  - předbíhání, výpadek → NAK
    - přenos celé dávky / od místa výpadku
  - ztráta posledního (-ích) paketů → timeout

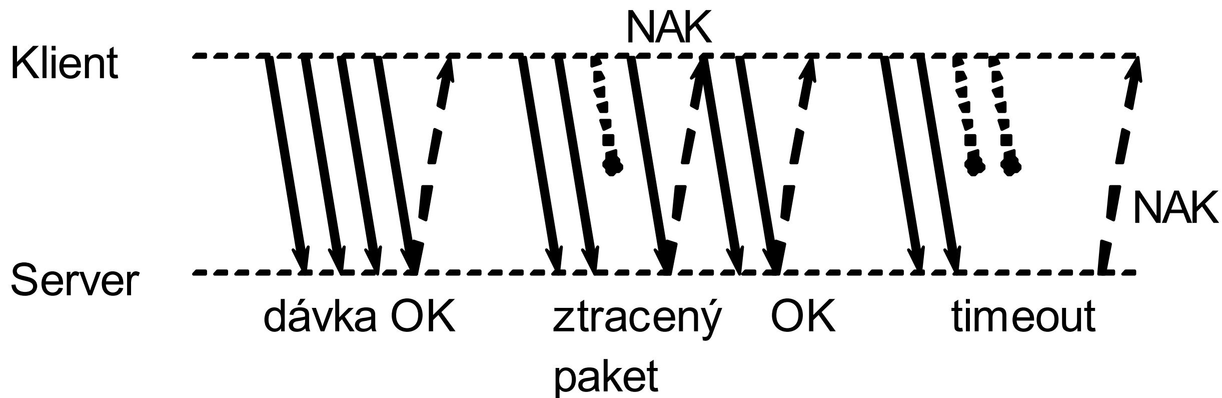

Pevné a dynamické dávky

- **pevné dávky** - jednodušší
  - při vyšší zátěži sítě velká chybovost
  - při volné/spolehlivé síti zbytečná režie
- **dynamické dávky** - úprava velikosti podle aktuální situace

Pevné a dynamické dávky

- **pevné dávky** - jednodušší
  - při vyšší zátěži sítě velká chybovost
  - při volné/spolehlivé síti zbytečná režie

- **dynamické dávky** - úprava velikosti podle aktuální situace
  - n-krát správný přenos dávky → zvětšení
  - špatný přenos → zmenšení
  - vysoká využitelnost kapacity aniž by jeden přenos omezoval ostatní
  - korektnost implementace, konsensus o velikosti dávky!

(Ne)spolehlivost serveru

Nepřichází odpověď klientovi:

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

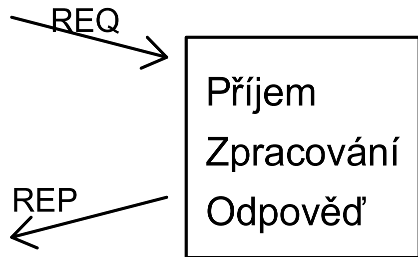

(a)

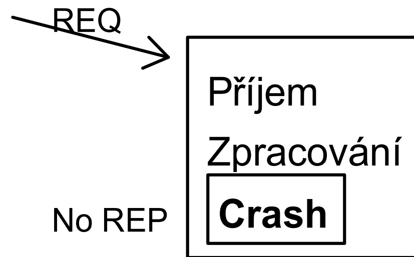

(b)

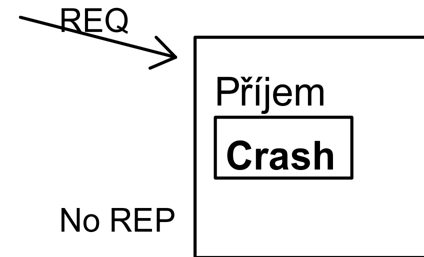

(c)

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

Sémanitka zpracování

idempotentní služby

- nevadí 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

Sémanitka zpracování

idempotentní služby

- nevadí 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
  - idempotentní!
- **at-most-once** sémantika
  - služba se určitě neprovede vícekrát
  - nelze zajistit, že se provede

Havárie klienta

sirotci (orphans)

typicky se neřeší

specializované dlouhotrvající výpočty

- exterminace

- reinkarnace

- expirace

Havárie klienta

sirotci (orphans)

typicky se neřeší

specializované dlouhotrvající výpočty

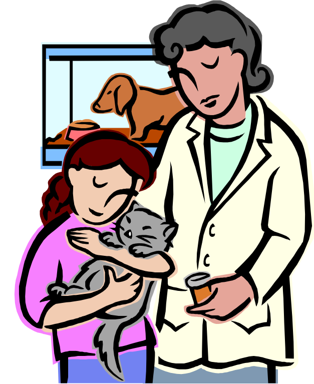

- exterminace
  - klient po zrození sám zruší službu
  - zodpovědnost klienta
- reinkarnace
- expirace

Havárie klienta

sirotci (orphans)

typicky se neřeší

specializované dlouhotrvající výpočty

- exterminace
  - klient po zrození sám zruší službu
  - zodpovědnost klienta
- reinkarnace
  - klient po zrození nastartuje novou epochu
  - server zruší všechny úlohy patřící do prošlých epoch
  - evedence na serveru, zodpovědnost klienta i serveru
- expirace

Havárie klienta

sirotci (orphans)

typicky se neřeší

specializované dlouhotrvající výpočty

- exterminace
  - klient po zrození sám zruší službu
  - zodpovědnost klienta
- reinkarnace
  - klient po zrození nastartuje novou epochu
  - server zruší všechny úlohy patřící do prošlých epoch
  - evedence na serveru, zodpovědnost klienta i serveru
- expirace
  - úloha má přiděleno kvantum času
  - při překročení si server vyžádá nové kvantum
  - zodpovědnost serveru, spolupráce klienta

Vzdálené volání pomocí zpráv

```
main()
{
   struct message m1, m2;
   for(;;)
   {
      receive( &m1);
      check( &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 příliš nízkoúrovňová

Idea: přiblížit zažitým mechanismům volání 'procedur'

RPC - **Remote Procedure Call**

Zabalení
Rozbalení
Klient
Server
Rozbalení
Zabalení
Jádro
Jádro

RPC – mechanismus volání

1. Klientova funkce normálním způsobem zavolá klientský stub
2. Stub vytvoří zprávu a zavolá jádro
3. Jádro pošle zprávu uzlu, kde běží server
4. Vzdálené jádro předá zprávu skeletonu *(server-side stub)*
5. Skeleton rozbalí parametry a zavolá výkonnou funkci / službu
6. Server zpracuje požadavky a normálním způsobem se vrátí do skeletonu
7. Skeleton zabalí výstupní parametry do zprávy a zavolá jádro
8. Jádro pošle zprávu zpět klientu
9. Klientovo jádro předá zprávu stubu
10. Stub rozbalí výstupní parametry a vrátí se ke klientovi

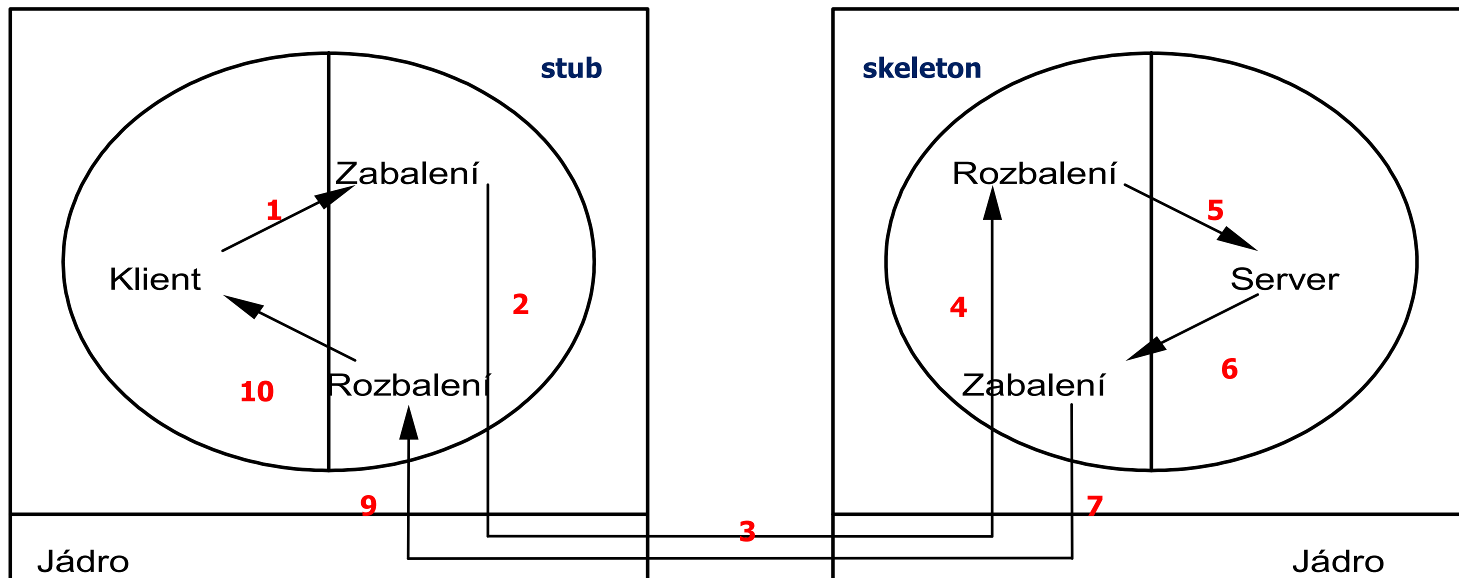

RPC - spojení

Kompilace

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

Spojení - odlišná životnost

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

Vyvolání

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

Directory machine
Directory server
3. Look up server
2. Register service
Client machine
Client
Server machine
Server
5. Do RPC
1. Register endpoint
4. Ask for endpoint
DCE daemon
Endpoint table

Příklad IDL (DCE)

jednoznačný id rozhraní

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

definice rozhraní

omezení velikosti polí

vstupní / výstupní parametry

```
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);
        }
```

RPC – kompilace modulů

Uuidgen

Interface definition file

IDL compiler

Client code

Client stub

Header

Server stub

Server code

#include

#include

C compiler

C compiler

C compiler

C compiler

Client object file

Client stub object file

Server stub object file

Server object file

Linker

Runtime library

Runtime library

Linker

Client binary

Server binary

RPC – kompilace modulů

klient

server

```
modul.idl
int funkce(in int limit, inout char pole[limit]);
```

```
klient.c

#include "modul.h"

char* buf;
rc = funkce(10,buf);
```

```
modul.h
int funkce( int limit, char* pole);
```

```
server.c

#include "modul.h"

int funkce(int limit,
           char* pole)
{
     ...
}
```

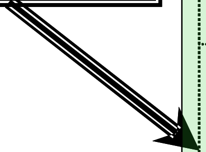

```
modul_cli.c
#include "modul.h"

int funkce(int limit,
           char* pole)
{
     ...
     send();
     receive();
}
```

```
modul_srv.c
#include "modul.h"

for(;;) {
receive();
     ...
rc = funkce(mp1, mp2);
     ...
send();
}
```

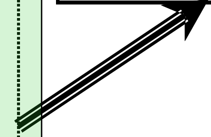

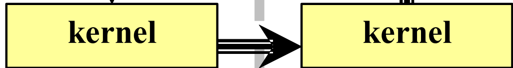

RPC - problémy

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
- skupinová komunikace
- komunikační chyby - odlišná sémantika
- bezpečnost

RPC obecně

- užitečné, prakticky použitelné (a používané)
- není zcela transparentní, nutno dávat pozor na omezení

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
- 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

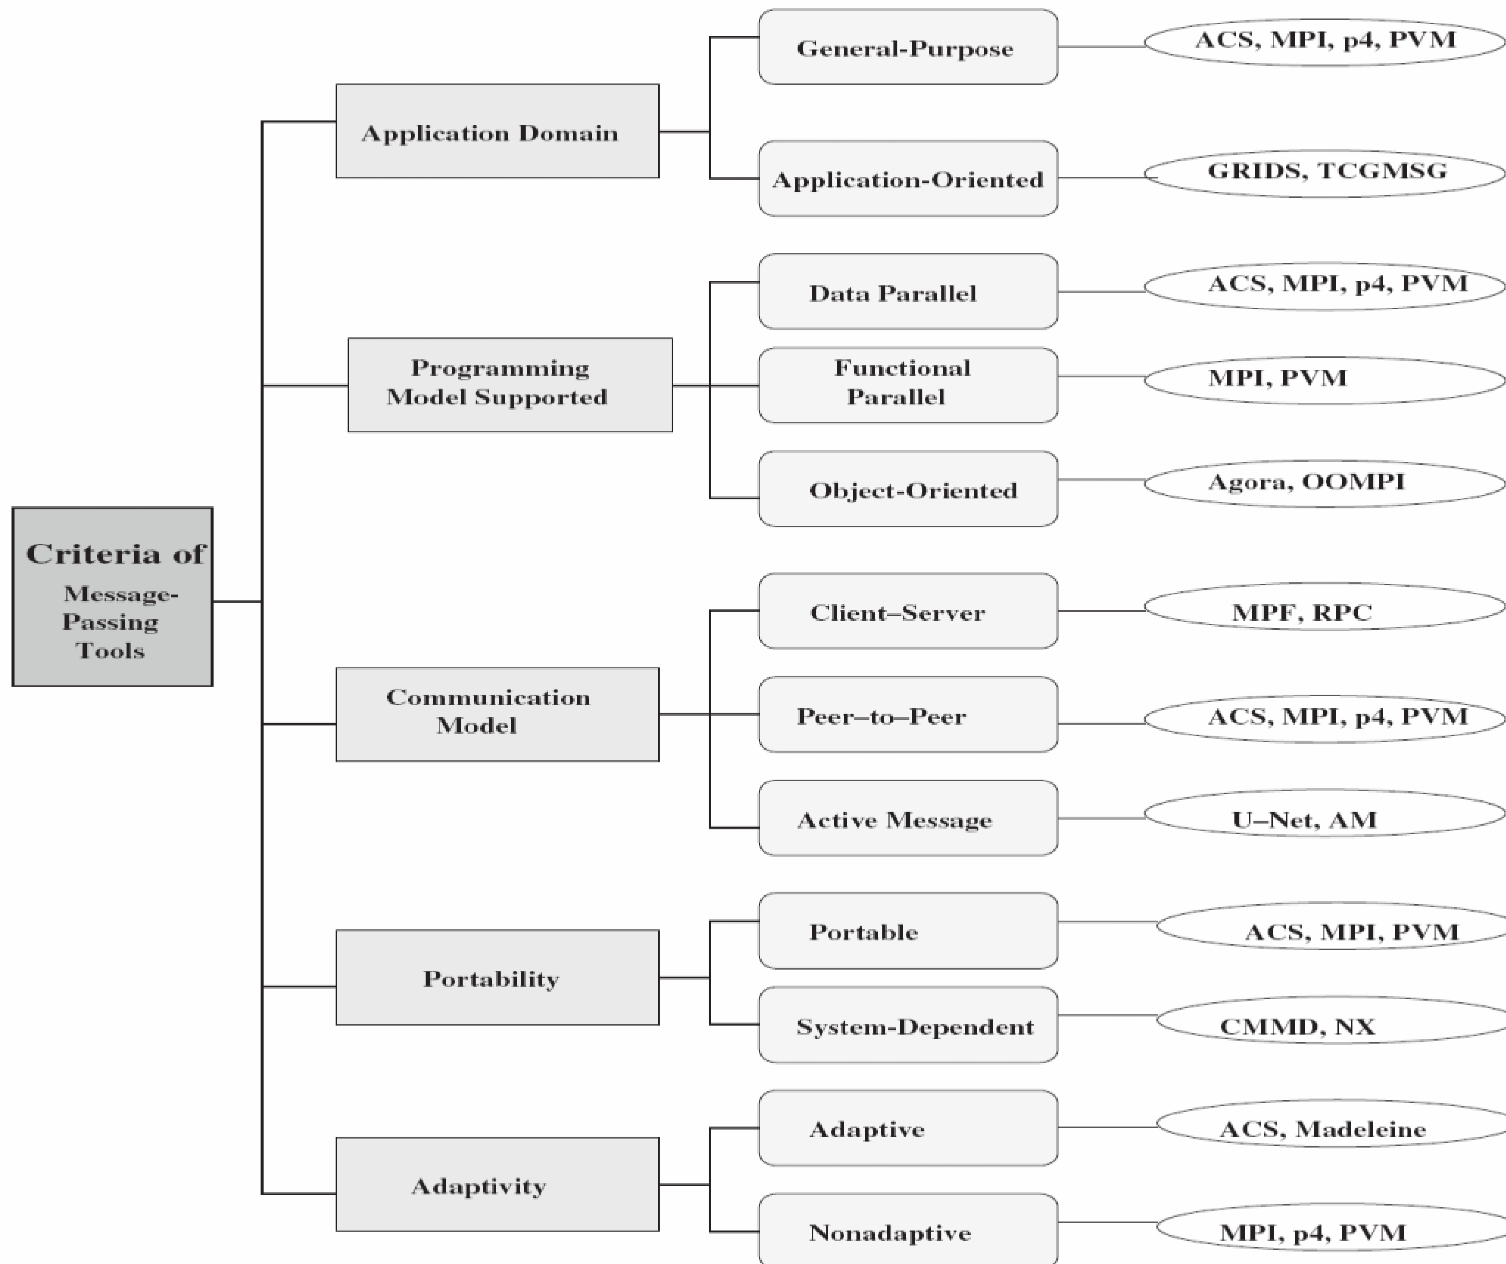

Message Queues

Sending client
Routing table
Send queue
Client's receive queue
Receiving client

Program
MQ Interface
Stub
Queue manager
Server stub
MCA
MCA
Queue manager
MCA
MCA
Server stub
Program
Stub

RPC (synchronous)
Local network
Enterprise network
Message passing (asynchronous)
To other remote queue managers

QMA

Alias table

LA1	QMC
LA2	QMD

Routing table

QMB	SQ1
QMC	SQ1
QMD	SQ2

SQ2
SQ1

QMB

Alias table

LA1	QMA
LA2	QMD

Routing table

QMA	SQ1
QMC	SQ1
QMD	SQ1

SQ1

QMD

Routing table

QMA	SQ1
QMC	SQ2
QMB	SQ1

SQ1
SQ2

Alias table

LA1	QMA
LA2	QMC

QMC

Routing table

QMA	SQ1
QMB	SQ1
QMD	SQ1

SQ1

Skupinová komunikace

Jeden odesílatel – více příjemců

- Atomicita
  - doručení ***všem*** členům nebo nikomu
  - evidence a změna členství
- Synchronizace
  - doručování od různých odesílatelů
  - příjem vs. doručení zprávy
  - doručovací protokol - sémantika

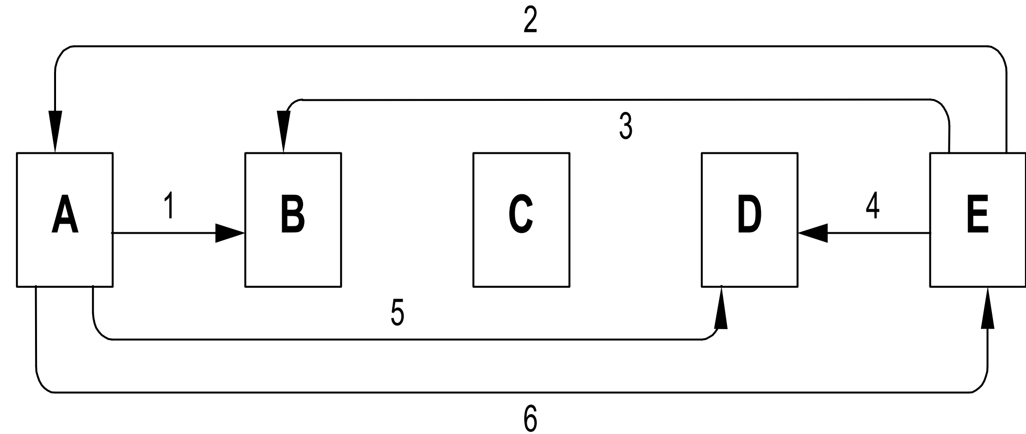

Uzel B:
A: **x += 1;**
E: **x *= 2;**
Uzel D:
E: **x *= 2;**
A: **x += 1;**

- Uzavřená skupina
  - pouze členové skupiny
  - vhodné pro kooperativní algoritmy
- Otevřená skupina
  - zasílat zprávy může kdokoliv
  - distribuované služby, replikované servery

- Překrývající se skupiny

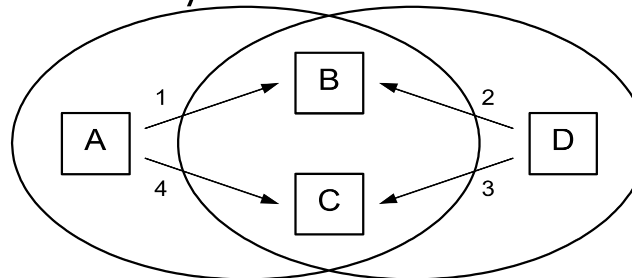

doručovací protokoly, virtuální synchronie

Synchronizační algoritmy

Synchronizace

- logické a fyzické hodiny a jejich synchronizace
- distribuované vyloučení procesů
- volba koordinátora
- doručovací protokoly, virtuální synchronie, změny členství ve skupinách
- ... → konsensus

- neexistence sdílené paměti - zprávy
- rozprostřená informace mezi několika uzly
- rozhodování na základě lokálních informací
- vyloučení havarijních komponent
- neexistence společných hodin

Synchronizace

- logické a fyzické hodiny a jejich synchronizace
- distribuované vyloučení procesů
- volba koordinátora
- doručovací protokoly, virtuální synchronie, změny členství ve skupinách
- ... → konsensus

- neexistence sdílené paměti - zprávy
- rozprostřená informace mezi uzly
- rozhodování na základě lokálních informací
- vyloučení havarijních komponent
- neexistence společných hodin

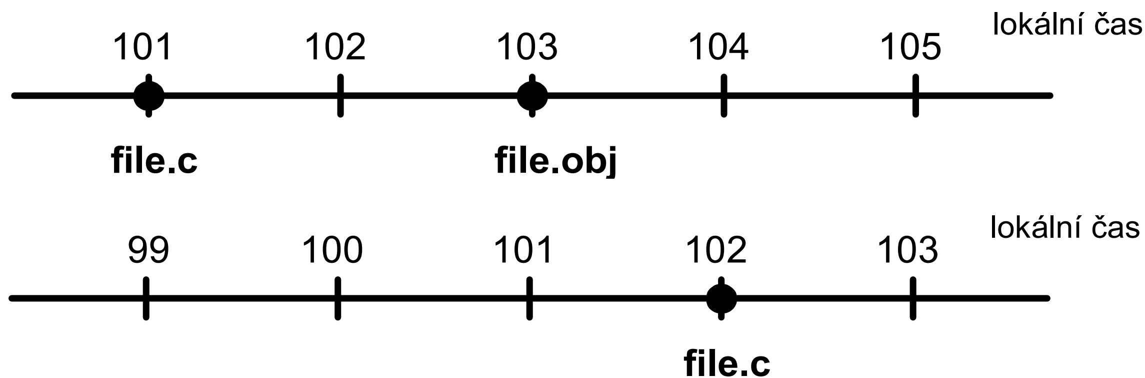

Fyzické hodiny

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 ≈ 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 – 1972 Universal Coordinated Time UTC
- vysílání UTC (krátké vlny, satelit) – nepřesnost cca 0.1 - 10 ms

Fyzické hodiny

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 ≈ 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 – 1972 Universal Coordinated Time UTC
- vysílání UTC (krátké vlny, satelit) – nepřesnost cca 0.1 - 10 ms

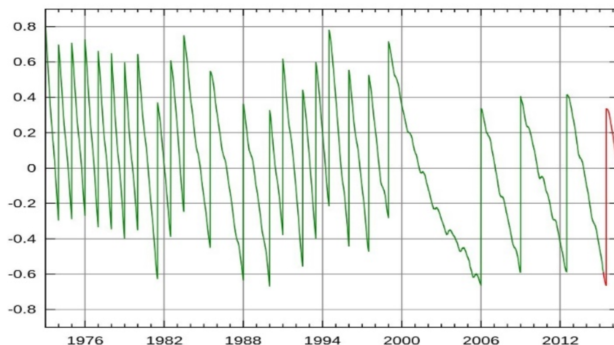

Změna UTC 30.6.2012 neproběhla zrovna podle představ MTU. Problémy hlásily servery s OS Debian Linux, které postihl krátký výpadek. Poruchy hlásil také Reddit, databáze Cassandra a programy napsané v Javě. V jeho případě však určitou roli zřejmě hrály také

Synchronizace fyzických hodin

vnitřní hw hodiny C,   fyzický čas t

hodiny na počítači p v čase t je Cp(t)

přesné hodiny: Cp(t) = t ∀t, tedy dC/dt = 1

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

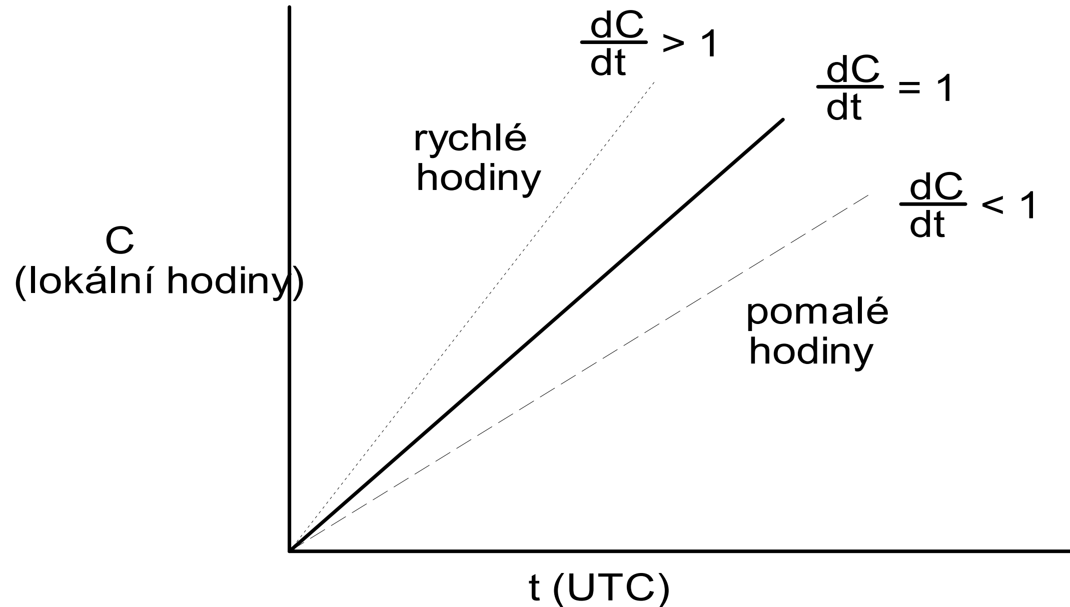

maximální odchylka dvojice hodin 2ρΔt

požadovaná odchylka δ ⇒ intervaly max. δ/2ρ

Cristianův algoritmus

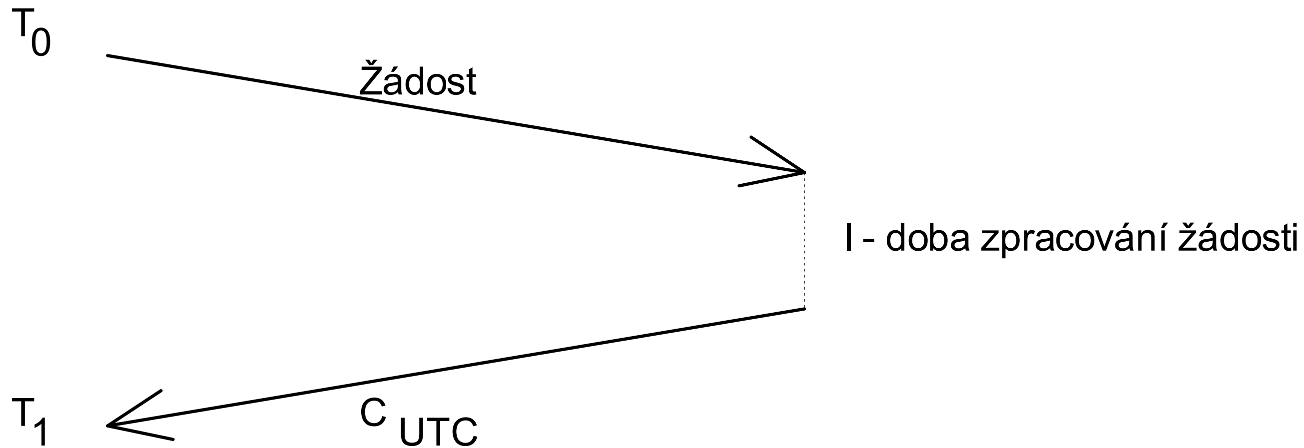

- jeden pasivní time server (UTC)
- periodické dotazy v intervalech < δ/2ρ
- T = T_UTC + (T1 - T0 - I)/2
- nikdy nepřeřizovat najednou !
  - (dis)kontinuita
  - postupná změna
  - zrychlování nebo zpomalování
- *Flaviu Cristian 1989*

Berkeley algoritmus

- aktivní time server
- periodicky se ptá ostatních na rozdíl času
- počítá průměr, vrátí rozdíl
- postupná synchronizace
- *Gusella and Zatti, Berkeley 1989*

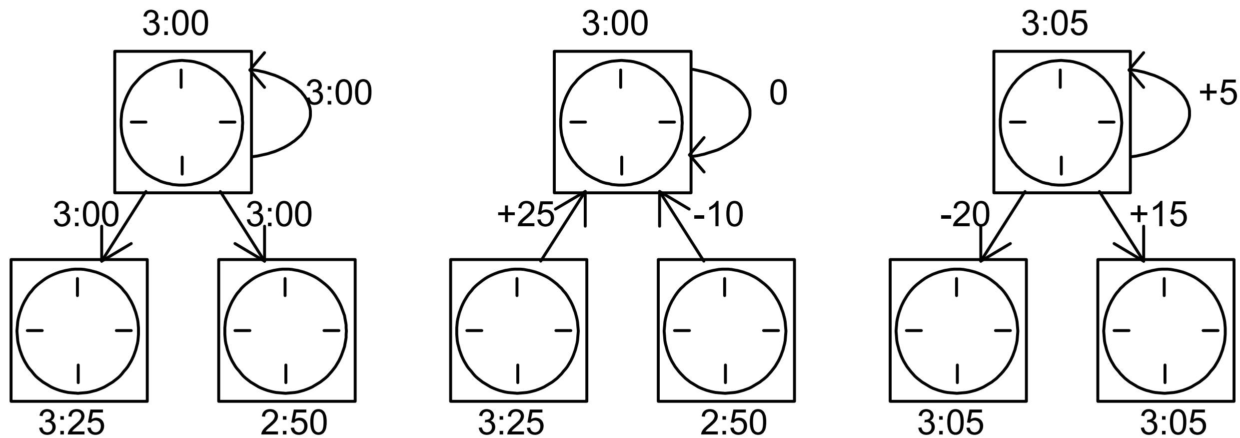

Další algoritmy

Distribuovaný algoritmus

- žádný server ani koordinátor
- resynchronizační intervaly pevné délky
  - i-tý interval: T0+iR .. T0+(i+1)R
- broadcast (ve fyzicky nestejný čas), spočítání průměru
- případné zahození extrémů
- *Marzullo 1984*
  - modifikovaná verze použitá pro NTP

Intervalový čas

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

Další algoritmy

Distribuovaný algoritmus

- žádný server ani koordinátor
- resynchronizační intervaly pevné délky
  - i-tý interval: T0+iR .. T0+(i+1)R
- broadcast (ve fyzicky nestejný čas), spočítání průměru
- případné zahození extrémů
- *Marzullo 1984*
  - modifikovaná verze použitá pro NTP

Intervalový čas

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

Logické hodiny

Problém: fyzické hodiny nelze dostatečně přesně sesynchronizovat ☹
Lamport:

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

$e1 \rightarrow_p e2$ uspořádání v rámci procesu p
send(m) resp. rcv(m) je odeslání resp. příjem zprávy m

Kauzální závislost

- jestliže $\exists p$: $e1 \rightarrow_p e2$ potom $e1 \rightarrow e2$
- $\forall$ m: send(m) $\rightarrow$ rcv(m)
- jestliže $e1 \rightarrow e2$ & $e2 \rightarrow e3$ potom $e1 \rightarrow e3$

Události konkurentní: $e1 \not\rightarrow e2$ & $e2 \not\rightarrow e1$

Logické hodiny

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

Logické hodiny

Problém: fyzické hodiny nelze dostatečně přesně sesynchronizovat

Lamport:

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

$e1 \rightarrow_p e2$ uspořádání v rámci procesu/uzlu p

send(m) resp. rcv(m) je odeslání resp. příjem zprávy m

Kauzální závislost

- jestliže $\exists p$: $e1 \rightarrow_p e2$ potom $e1 \rightarrow e2$
- $\forall$ m: send(m) $\rightarrow$ rcv(m)
- jestliže $e1 \rightarrow e2$ & $e2 \rightarrow e3$ potom $e1 \rightarrow e3$

Kauzálně předchází, kauzálně vázané/závislé

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

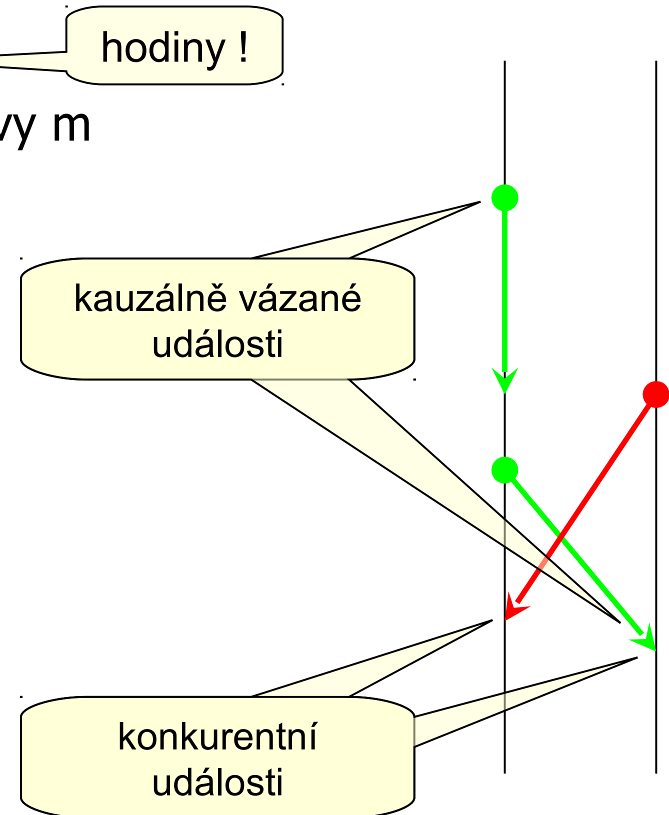

Logické hodiny

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

PDS

Synchronizace logických hodin

Synchronizace podle přijímání zpráv - časová značka zprávy Tm

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

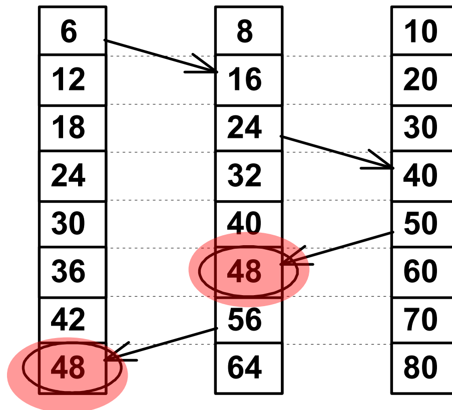

(a)

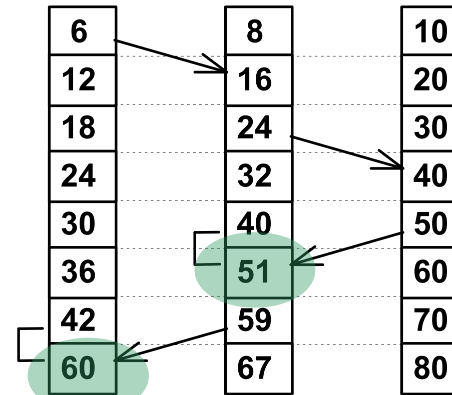

(b)

oprava lokálních hodin

Leslie Lamport

Synchronizace logických hodin

Synchronizace podle přijímání zpráv - časová značka zprávy Tm

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

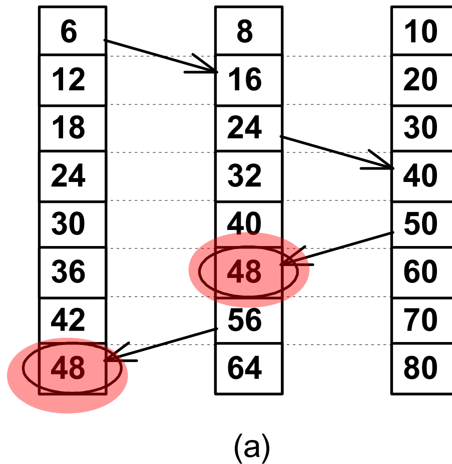

(a)

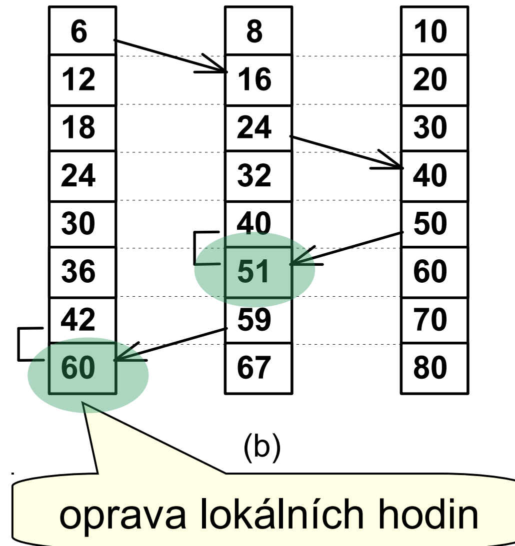

(b)

oprava lokálních hodin

Zúplnění

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

Logické hodiny a kauzalita

Kauzální závislost

- jestliže $\exists p: e1 \rightarrow_p e2$ potom $e1 \rightarrow e2$
- $\forall$ m: send(m) $\rightarrow$ 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

Vektorové / maticové hodiny
- kauzalita
- doručovací protokoly
- virtuální synchronie

$A1 \nrightarrow C3$

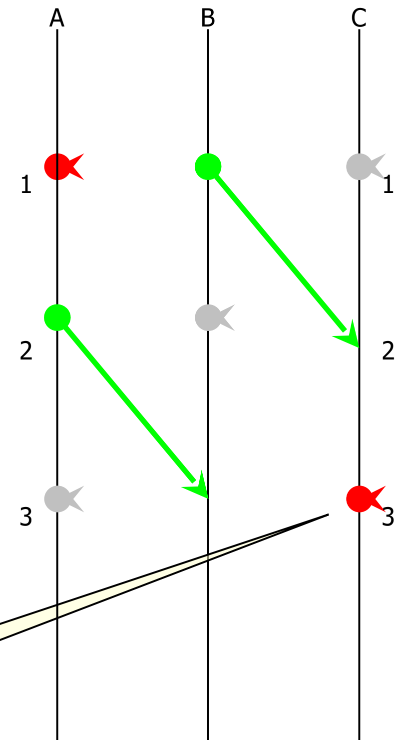

Vzájemné vyloučení procesů

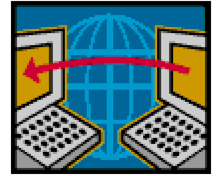

- neexistence společné paměti - semafor!
- pouze zprávy
- korektnost

- Způsoby řešení
  - centralizovaná ochrana přístupu
  - permission-based
    - časové značky — *Lamport* (3n), *Ricart-Agrawala* (2n)
    - volby — *Maekawa* (sqrt n), *Agrawal-ElAbadi* (log n)
  - token-based
    - token-passing — *Suzuki-Kasami*
    - strom — *Raymond*
    - token ring

Centralizovaný algoritmus

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)

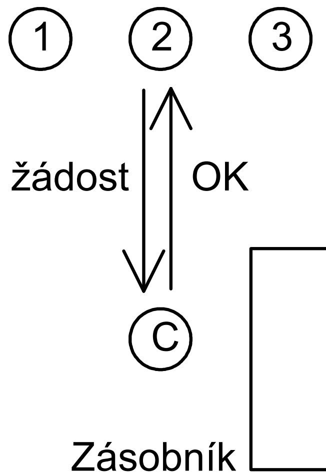

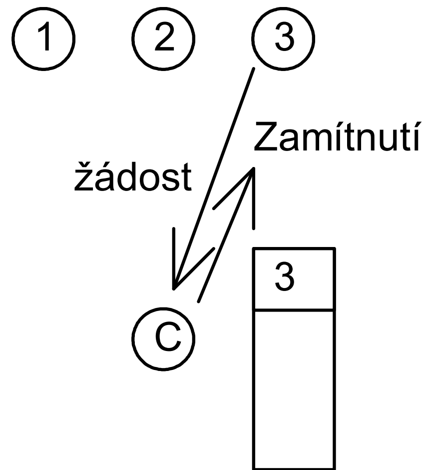

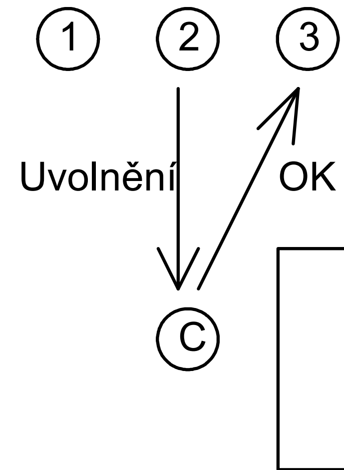

Lamportův algoritmus

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	`send` Mp={req,p,Tp}
Přijetí žádosti Mi	`add` Mi; `send` {ack,p,Tp}
Přijetí potvrzení Ai	`add` Ai
Podmínka vstupu Mp	**∀ i≠p ∃ {ack,i,Ti} : Tp<Ti** **& ∀ {req,i≠p,Ti } : Tp<Ti**
Uvolnění Rp	`send` {rel,p,Tp}
Přijetí uvolnění Ri	`del` {req,i,Tk } : Tk < Ti

uložení žádosti a odpověď s **vlastním** časem

od všech přišlo novější potvrzení

neeviduju starší žádost

po přijetí uvolnění smažu starší žádosti tohoto procesu

Komunikační složitost: 3(n-1)

Lamportův algoritmus

Vstup A
do kritické sekce

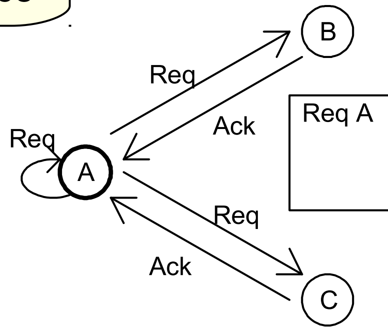

Žádost B o vstup

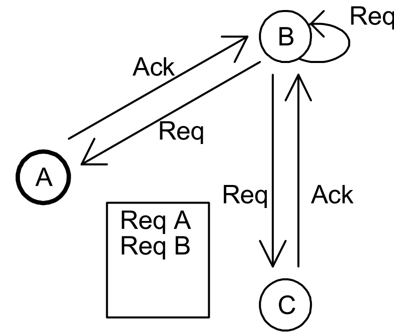

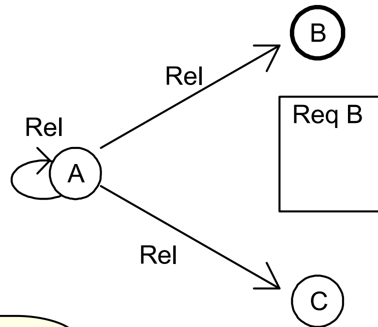

Uvolnění A
a vstup B

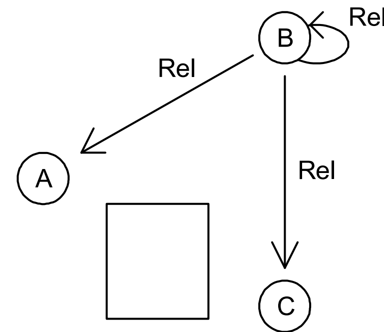

Uvolnění kritické
sekce

Lamportův algoritmus

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

program p: do forever $\rightarrow$

$\{\ \neg x_p\ \}$

$x_p, F_p :=$ 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

$;\ x_p :=$ false

od

Vyloučení procesů - Ricart & Agrawala

Proces chce vstoupit do kritické sekce:

- zašle žádost s TM a čeká na odpovědi s potvrzením

Proces přijme zprávu se žádostí:

- Jestliže **není** v kritické sekci a ani do ní **nechce** vstoupit, pošle potvrzení
- 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:
  - žádost má **nižší** časovou značku (= starší), neodpovídá a zařadí žádost odesilatele do fronty
  - v opačném případě (žádost odesilatele je starší) pošle zpět potvrzení

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

Komunikační složitost: 2(n-1)

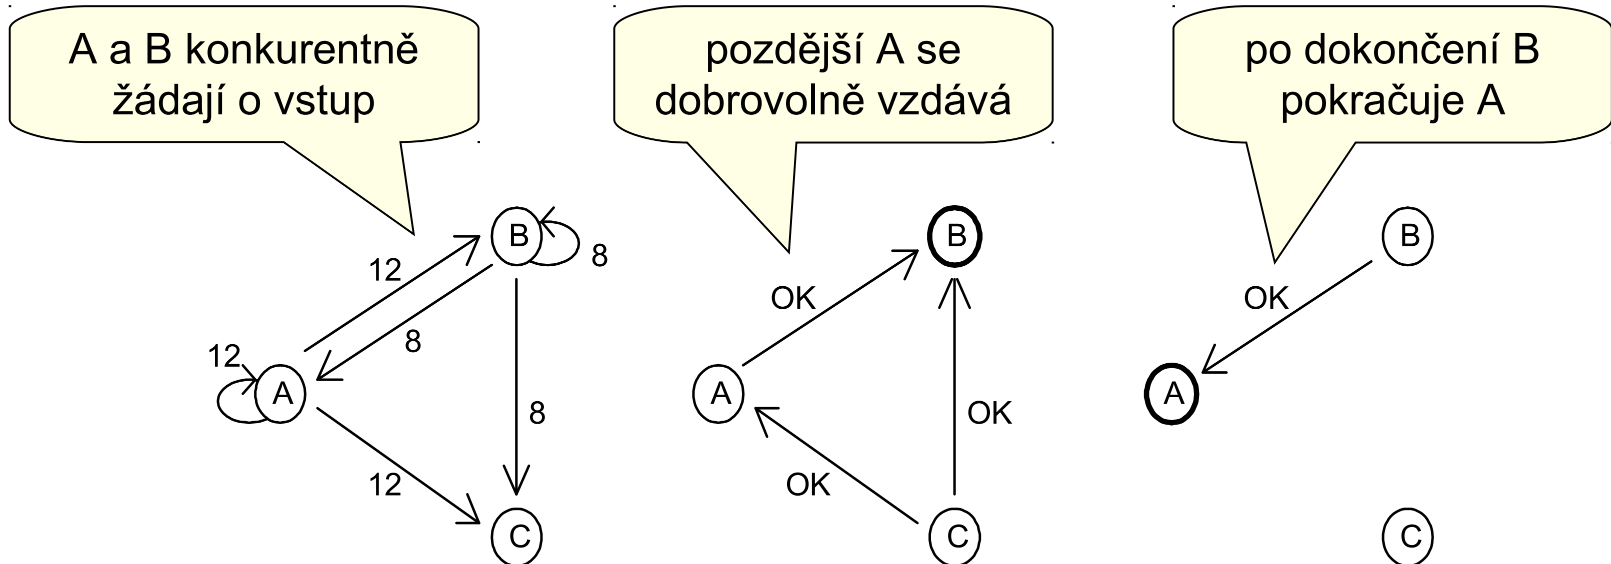

Vyloučení procesů - princip voleb

- 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

jak se to pozná?

- Naivní volby
  - každý proces zná všechny ostatní
  - při žádosti jiného procesu dá proces hlas
  - 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 - princip voleb

- 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
  - při žádosti jiného procesu dá proces hlas (pokud ještě nehlasoval)
  - ☺ 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;
```

Vyloučení procesů - Maekawa

- 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
  - $\forall p, q: |S_i: p \in S_i| = |S_j: q \in S_j| = D$
    - 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

Maekawa - volební okrsky

- Rozdělení do okrsků
  - jak velké okrsky?
  - v kolika okrscích má být každý proces?
- počet okrsků: $N \times K = D \times M$
- proces ≈ okrsek
  - musí získat všechny hlasy svého okrsku
  - $D \times M / K = M \rightarrow K = D$
  - → velikost okrsku ≈ počet okrsků, ve kterých je každý proces
- 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

Maekawa - volební okrsky

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
    - $M = n^2$, $P_{i,j}$, $S_{i,j}$, $1 \leq i,j \leq n$
    - $S_{i,j} = \bigcup P_{i,x} \cup \bigcup P_{y,j}$ *pro* $1 \leq x,y \leq n$

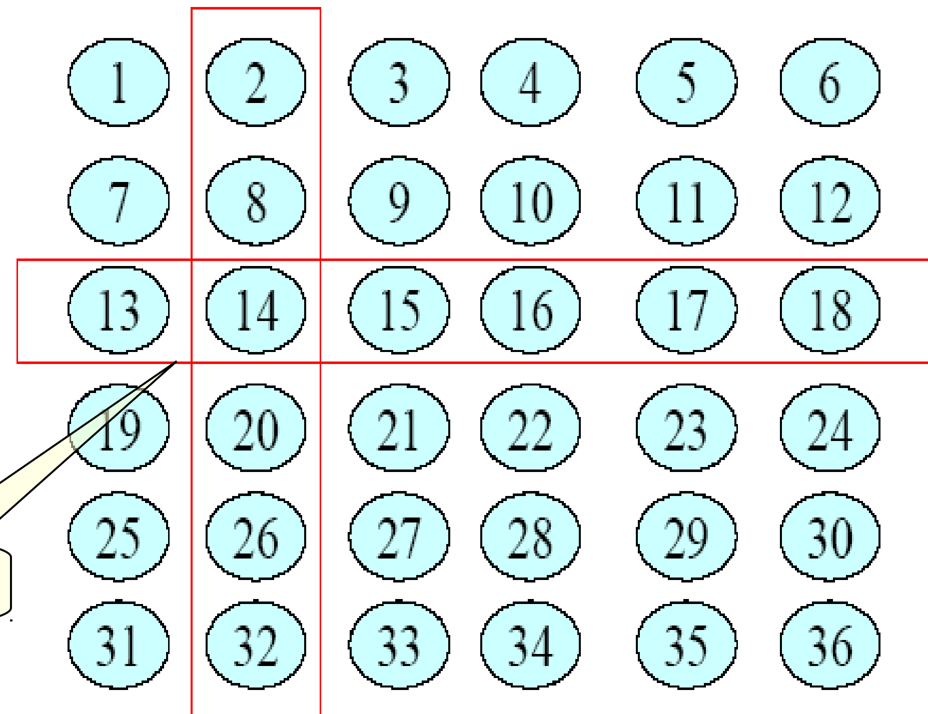

Maekawa - deadlock a jeho řešení

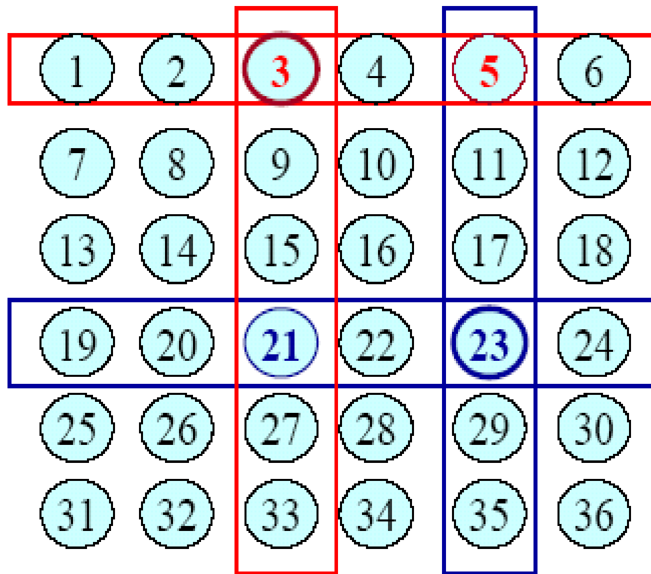

Soutěží P_3 a P_{23}

Možnost deadlocku
P_{21} volí P_{23}
P_5 volí P_3

Maekawa - deadlock a jeho řešení

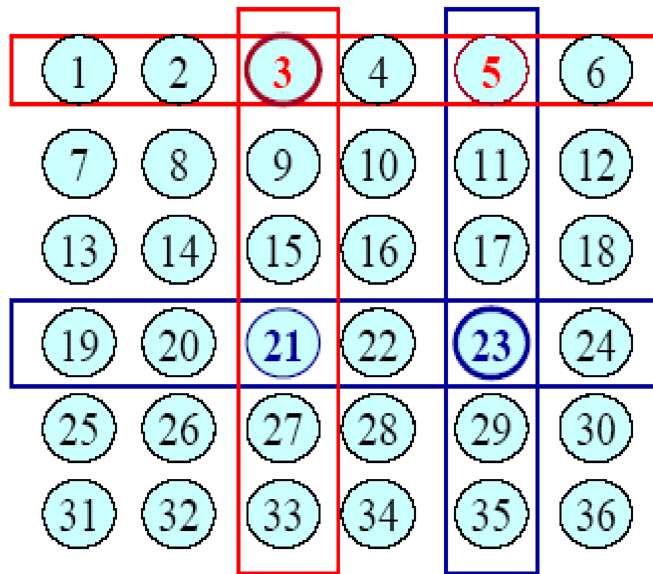

Soutěží P_3 a P_{23}

Možnost deadlocku
P_{21} volí P_{23}
P_5 volí P_3

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

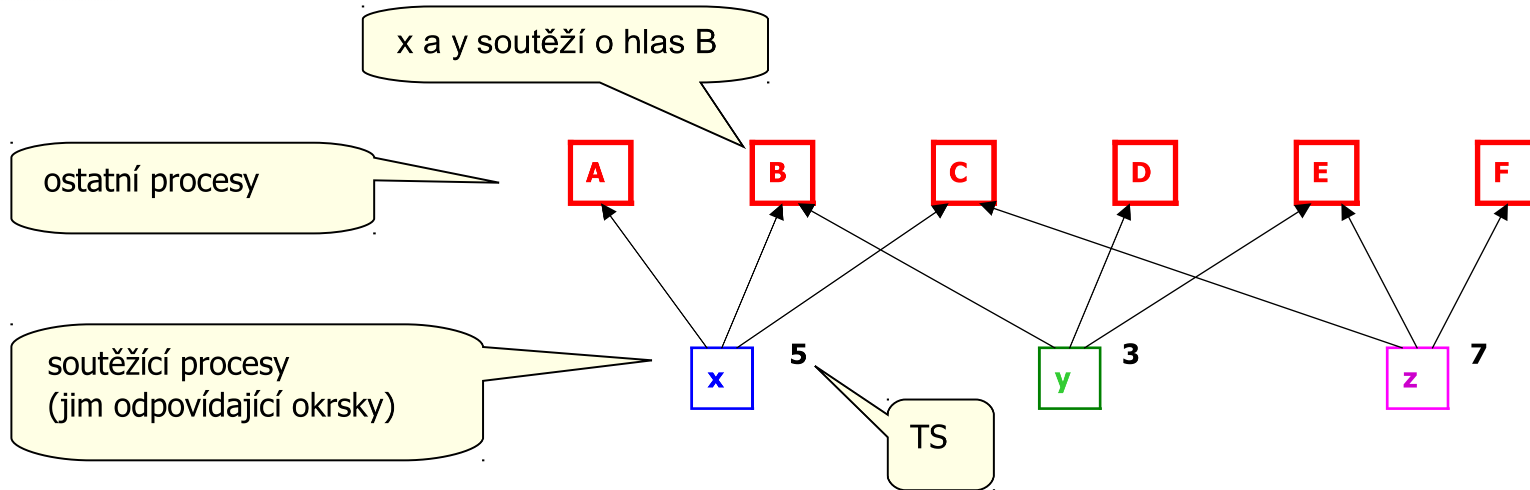

- Scénář 1
  - yD, yE - ACK
  - xA, xC - ACK
  - **yB - ACK**
  - y → CS
  - **xB - enqueue x**
  - y ← CS - REL
  - xB - ACK
  - x → CS

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

Vyloučení procesů - stromové algoritmy

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 - kořen
- kostra, neorientovaný strom → orientovaný strom
- každý uzel udržuje
  - referenci na souseda směrem k token holderu
  - frontu žádostí
- forward žádosti otci
- vstup do kritické sekce
  - přenos tokenu
  - změna kořenu
  - přesměrování referencí - rekonfigurace

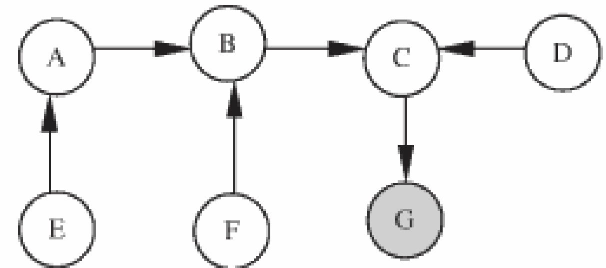

Vyloučení procesů - další algoritmy

Suzuki & Kasami (1985)

- 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

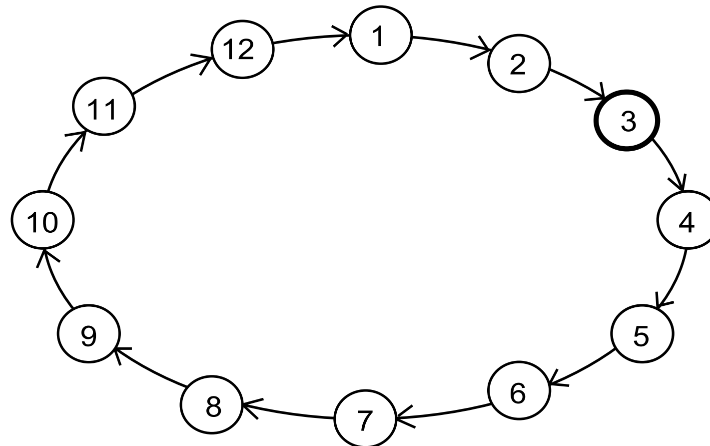

Porovnání algoritmů vzájemného vyloučení

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

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: 2Tm+Tp

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?

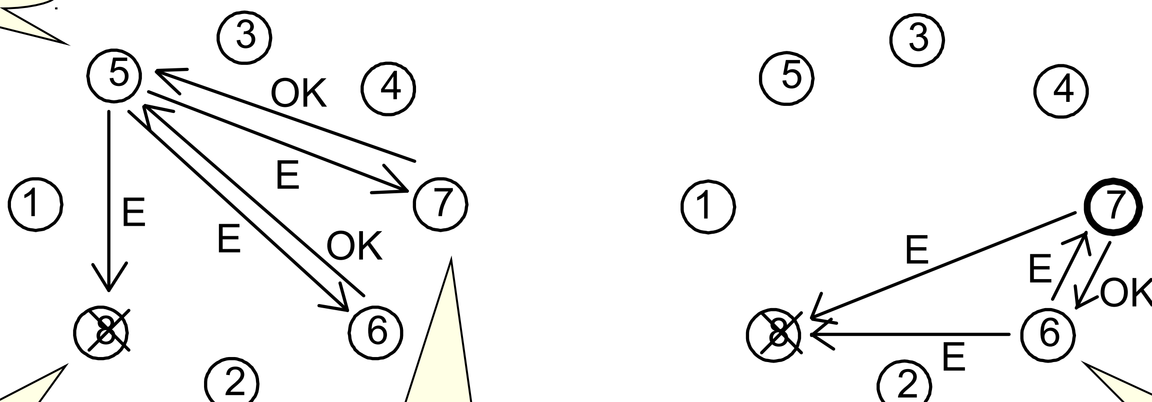

Volba koordinátora - invitation algoritmus

- 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

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

---

silnější sémantiky - distribuovaný konsensus, později

Invitation algoritmus - průběh

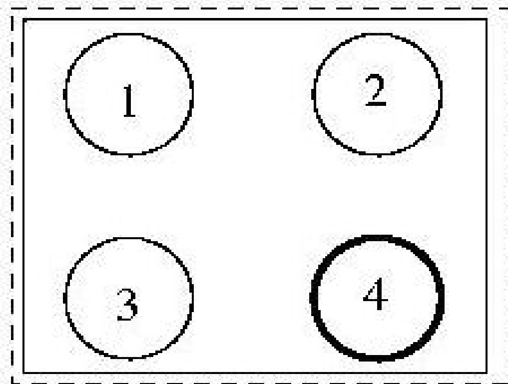

One partition. One group
Coordinator = Processor 4

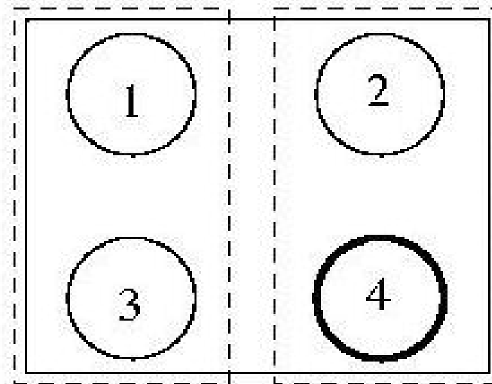

The network is partitioned, but
no one notices

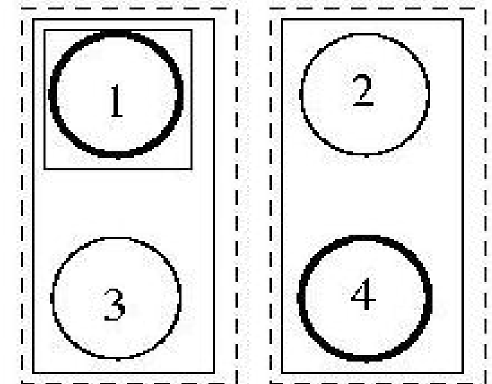

Processor 1 notices the partitioning.
and declares itself a coordinator.
It calls out and reaches processor 3.

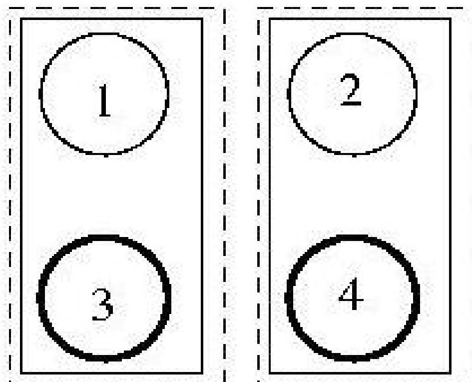

Processor 3 realizes the partitioning
and becomes a coodinator.
Processor 1 retires from this role.

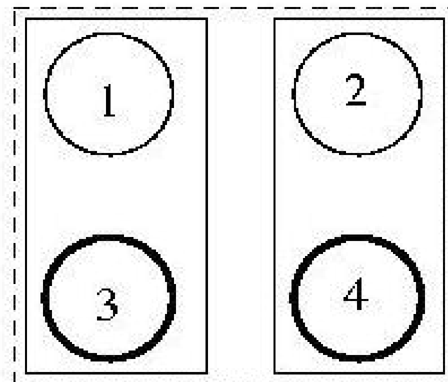

The network partition is repaired,.
but none of the processors notice

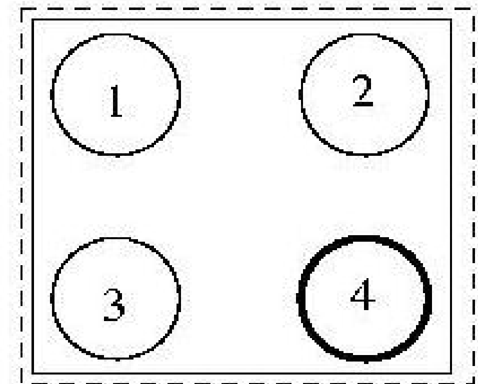

Either processor 3 or processor 4.
discover that the network has been
repaired. Processor 4 responds by
announcing that it is coordinator
and restoring global consistency.

Invitation algoritmus - vyzývací zprávy

P1 P3 P2 P4

Initial state
P4.1

Network is partitioned
P4.1

P1 notices and forms a new group and looks for other coordinators (this tips off P3)
P1.1
Are you a coordinator?
Not me!
P4.1

P3 notices and forms a new group and looks for other coordinators
P1.1
Are you a coordinator?
Yes!
P3.1
P4.1

P3 merges P1 into a new group.
New group! Join P3.2
P3.2
P4.1

The partition is repaired
P3.2
P4.1

P4 queries the other hosts and discovers P3's group.
Are you a coordinator?
P3.2
P4.1
Not me!
Yes!

P4 merges P3 into a new group. P3 in turn tells P1 to merge
New group! Join P4.2
New group! Join P4.2
New group! Join P4.2
P4.2

Volba koordinátora - kruhový algoritmus

Le Lann, Chang & Roberts (1979)

- 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 $O(n^2)$

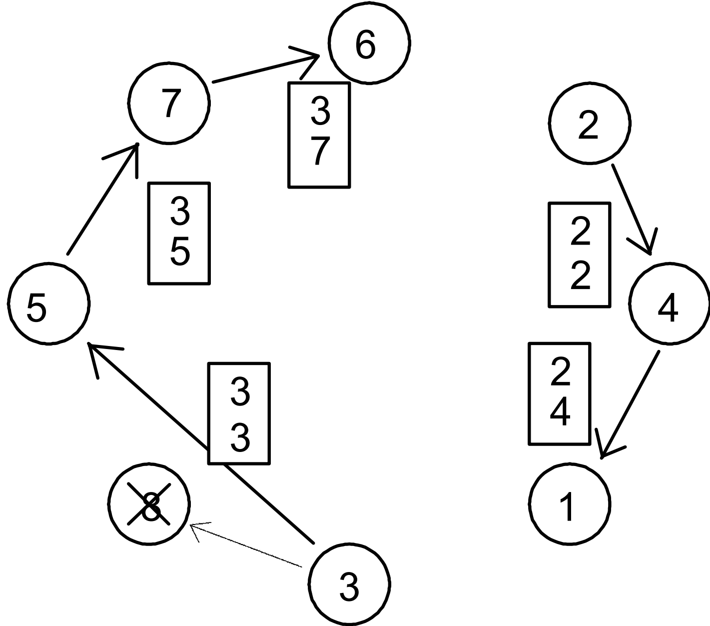

HS algoritmus

Hirschback & Sinclair (1980)

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

Chang & Roberts - pseudokód

$\texttt{boolean}\ \mathit{participant}{=}\texttt{false;}$

$\texttt{int}\ \mathit{leader_id}{=}\texttt{null;}$

To initiate an election:

$\quad\texttt{send(}\mathsf{ELECTION}\langle \mathit{my_id}\rangle\texttt{);}$

$\quad\mathit{participant}\texttt{:=true;}$

Upon receiving a message $\mathsf{ELECTION}\langle j\rangle$:

$\quad\texttt{if}\ (j > \mathit{my_id})\ \texttt{then}\ \ \texttt{send(}\mathsf{ELECTION}\langle j\rangle\texttt{);}$

$\quad\texttt{if}\ (\mathit{my_id} = j)\ \texttt{then}\ \ \texttt{send(}\mathsf{LEADER}\langle \mathit{my_id}\rangle\texttt{);}$

$\quad\texttt{if}\ ((\mathit{my_id} > j) \wedge (\neg \mathit{participant}))\ \ \texttt{then}$

$\qquad\texttt{send(}\mathsf{ELECTION}\langle \mathit{my_id}\rangle\texttt{);}$

$\mathit{participant}\texttt{:=true;}$

Upon receiving a message $\mathsf{LEADER}\langle j\rangle$:

$\quad\mathit{leader_id}\texttt{:=}j\texttt{;}$

$\quad\texttt{if}\ (\mathit{my_id} \neq j)\ \ \texttt{then}\ \ \texttt{send(}\mathsf{LEADER}\langle j\rangle\texttt{);}$

Hirschback & Sinclair - pseudokód

To initiate an election (phase 0):

send(ELECTION$\langle my_id, 0, 0\rangle$) to left and right;

Upon receiving a message ELECTION$\langle j, k, d\rangle$ from left (right):

if $((j > my_id) \wedge (d \leq 2^k))$ then
  send(ELECTION$\langle j, k, d+1\rangle$) to right (left);
if $((j > my_id) \wedge (d = 2^k))$ then
  send(REPLY$\langle j, k\rangle$) to left (right);
if $(my_id = j)$ then announce itself as leader;

Upon receiving a message REPLY$\langle j, k\rangle$ from left (right):

if $(my_id \neq j)$ then
  send(REPLY$\langle j, k\rangle$) to right (left);
else
  if (already received REPLY$\langle j, k\rangle$)
    send(ELECTION$\langle j, k+1, 1\rangle$) to left and right;

Doručovací protokoly

Doručovací protokoly skupinové komunikace

- 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
  - konkuretní zprávy v libovolném pořadí

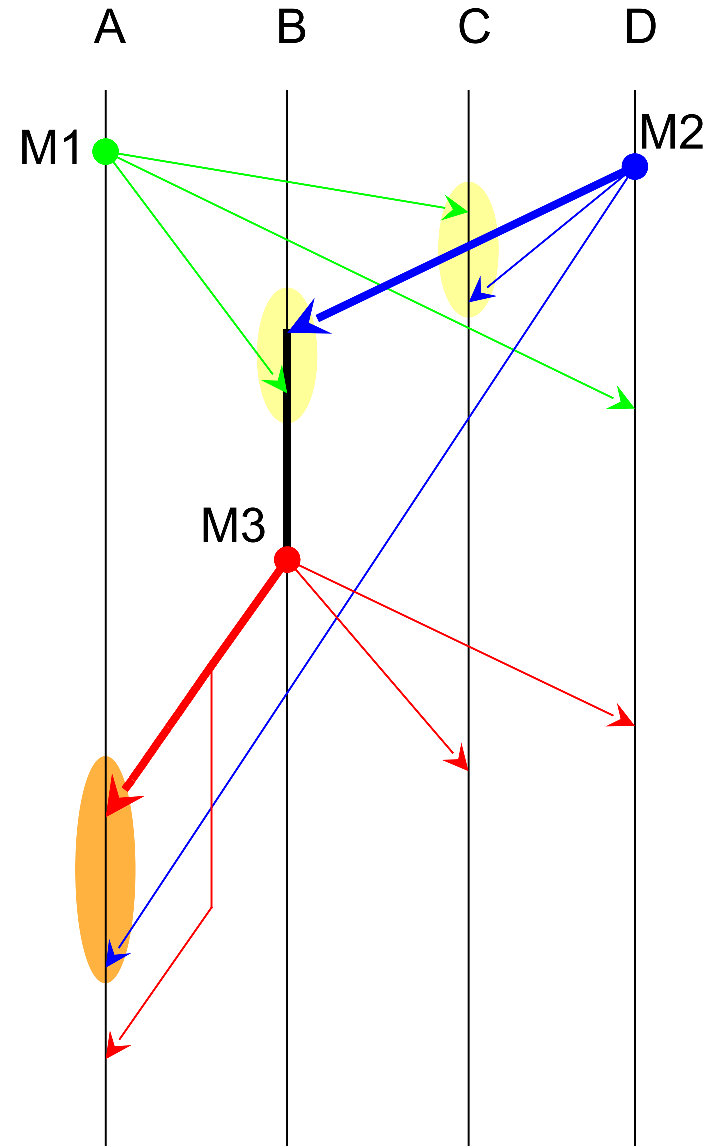

- Kauzálně vázané zprávy
  - obsah vázané zprávy **může být** ovlivněn
  - není podstatné, jestli obsah **byl** ovlivněn
- Konkurentní zprávy
  - ty, které nejsou kauzálně vázané

Kauzální doručování

Kauzální závislost *(opakování je matkou …)*

$\rightarrow$ *(kauzálně předchází)* je relace definovaná:

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

Kauzální uspořádání doručovaných zpráv

dest(m) množina uzlů, kterým je zaslána zpráva m

$deliver_p(m)$ je událost doručení zprávy m uzlu p

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

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

Vektorové hodiny

vektorové hodiny (*vektorová* časová značka, vector time, VT)

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
- $\forall$ send $p_i(m)$: $VT(m) = {+}{+}VT(p_i)[i]$
- p_j při doručení m upraví $VT(p_j)$:

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

Inkrementace položky ≈ odesílající uzel

Pozor! Obecná pravidla neříkají KDY k doručení dojde

po složkách maxima ze stávajícího a přijatého 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

Kauzální doručovací protokol

odeslání zprávy m uzlem p_i

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

podmínky doručení

přijetí uzlem p_j

- proces pj ≠ pi 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 uzel p_j upraví VT
  - $\forall k \in 1..n$: $VT(p_j)[k] =$
    $\max(VT(p_j)[k], VT(m)[k])$

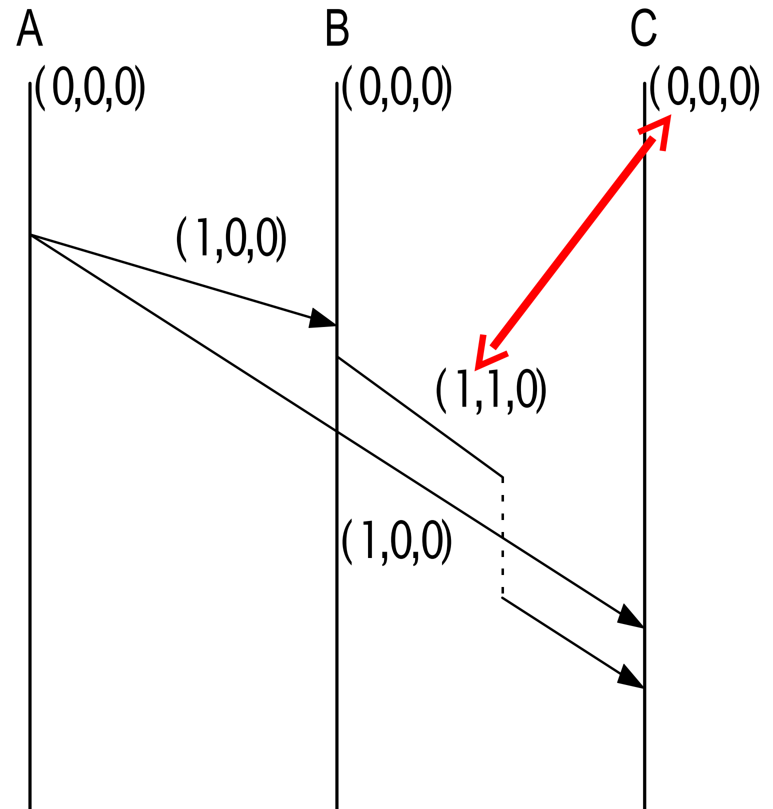

Kauzální doručování a překrývající se skupiny

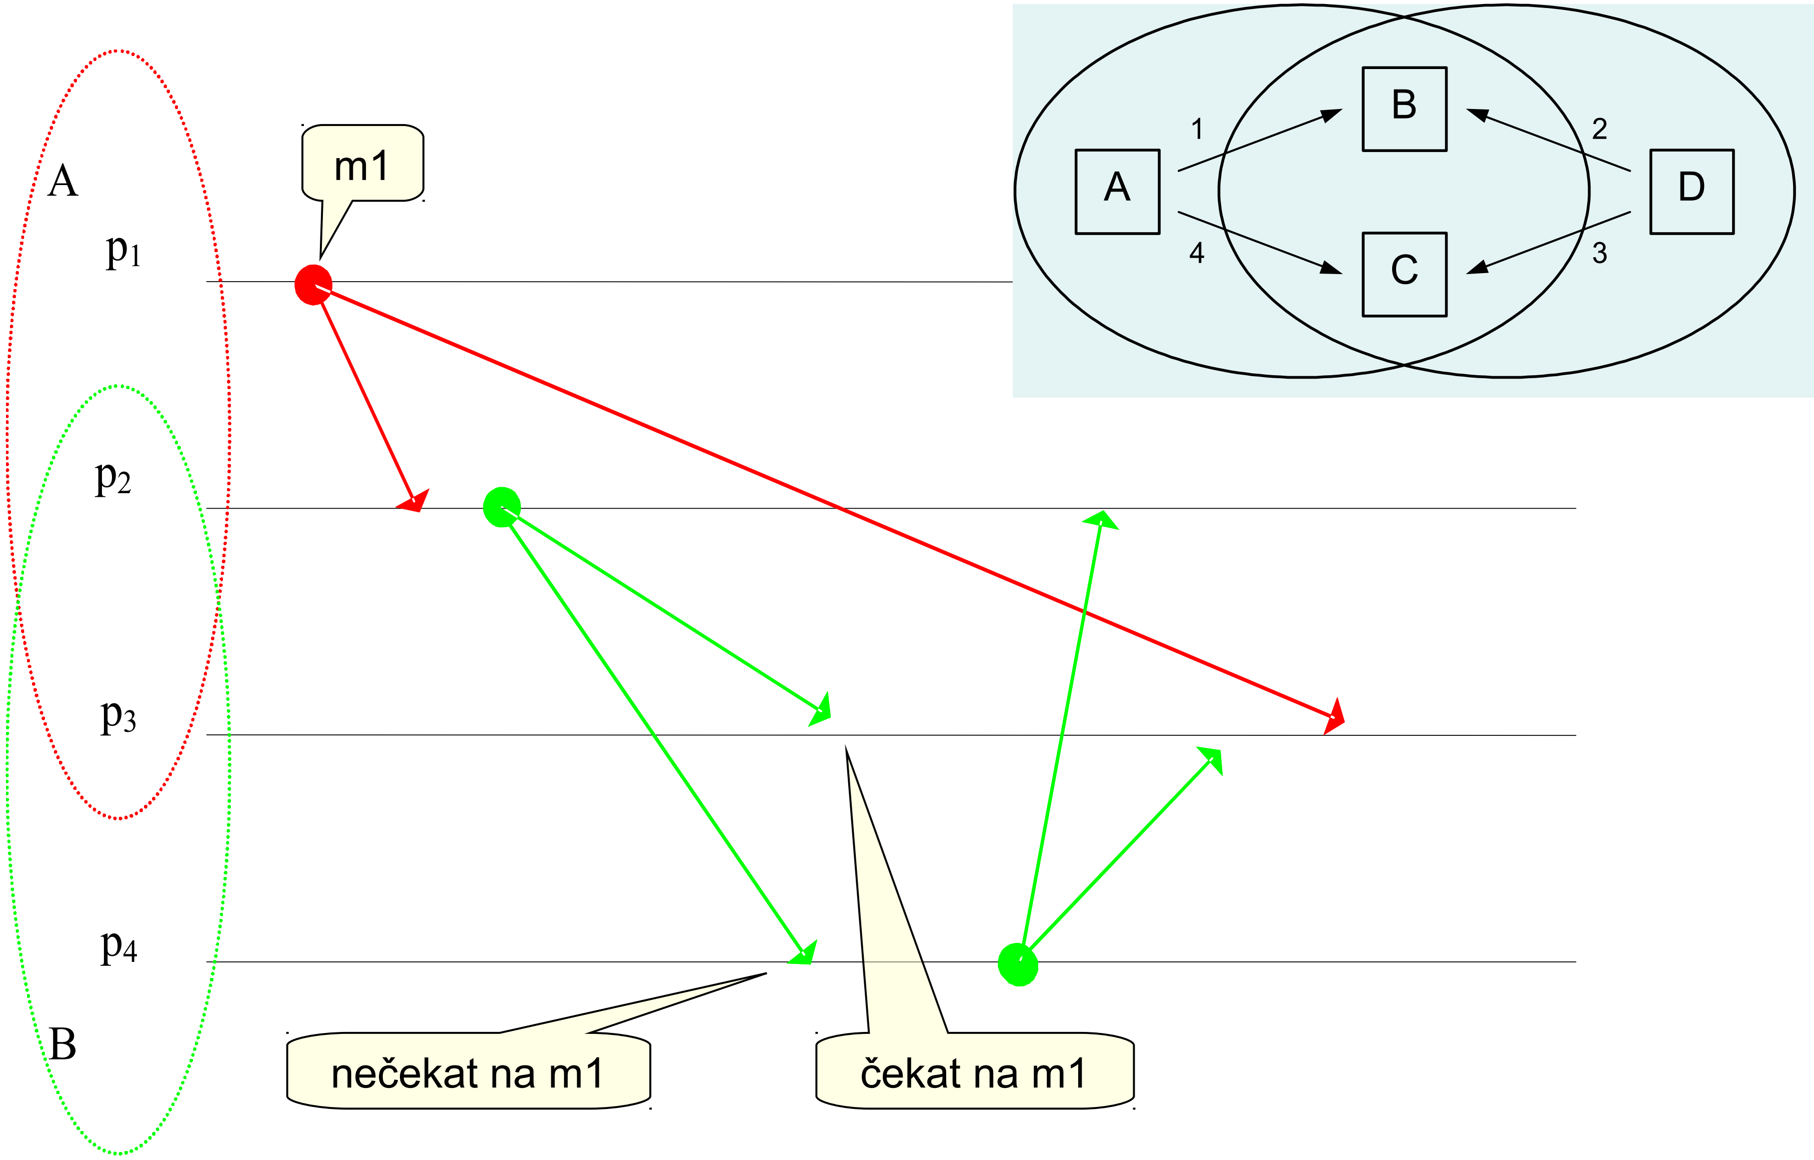

Doručovací protokol pro překrývající se skupiny

Vektory vektorových hodin - **maticové hodiny**

VTa - časová značka skupiny g_a

VTa[i] - počet multicastů uzlu p_i do g_a

S odesílanou zprávou posílá uzel časovou značku všech skupin, kterých je členem

odeslání uzlem p_i do skupiny g_a

- $VTa(p_i)[i]{+}{+}$
- $VT(m) = \cup\, VTb(p_i) \;:\; p_i \in g_b$

VT všech skupin, kterých je odesílatel členem

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

- uzel $p_j \neq p_i$ pozdrží m dokud neplatí:
  - $VTa(m)[i] = VTa\,(p_j)[i] + 1$
  - $\forall k\; (p_k \in g_a \;\&\; k \neq i)\colon VTa\,(m)[k] \leq VTa\,(p_j)[k]$
  - $\forall b\; (p_j \in g_b)\colon VTb\,(m) \leq VTb\,(p_j)$

kauzalita vzhledem k skupině, do které byla zaslána zpráva

kauzalita vzhledem k ostatním skupinám příjemce

Doručení

- Po doručení si uzel 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 hodiny (časové značky)
při příjmu zprávy potvrzení odesilateli TS(Ri)
odesilatel po příjmu všech potvrzení odešle finalizační zprávu s TSF = max(TS(Ri))
po příjmu finalizační zprávy doručí příjemce zprávy podle TSF

jedno pořadí → jeden čítač

podle TS příjemců

pořadí zprávy / časová značka

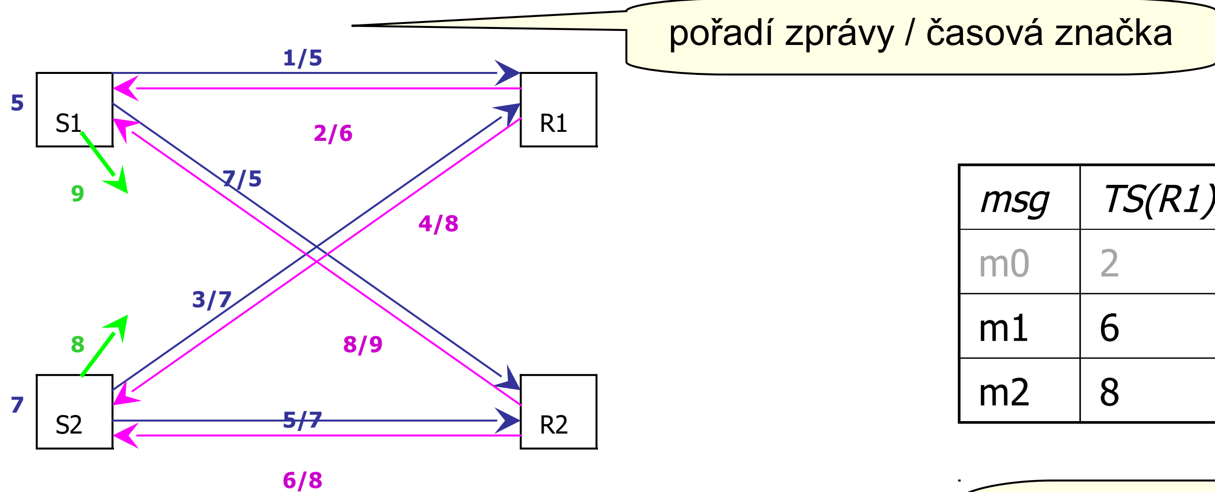

msg	*TS(R1)*	*TS(R2)*	*TSF*
m0	2	2	2
m1	6	9	9
m2	8	8	8

zjednoznačnění lokálních TS: TS.node_id

Komunikační složitost: 3n

Distribuovaný total-order protokol

Totální / sekvenční doručování, total-order protocol
všechny zprávy jsou všem členům doručeny ve stejném pořadí

stačí skalární hodiny (časové značky)
při příjmu zprávy potvrzení odesilateli TS(Ri)
odesilatel po příjmu všech potvrzení odešle finalizační zprávu s TSF = max(TS(Ri))
po příjmu finalizační zprávy doručí příjemce zprávy podle TSF

Sekvenční doručování - forma centralizované komponenty
Centralizované řešení efektivnější
Sekvencer

- komunikačně jednodušší
- nutnost výběru koordinátora
- serializace/uspořádání dle příjmu sekvencera
- možnost prioritního doručování

nemá smysl řešit centralizovaný problém ...

Spolehlivé doručování

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

- Naivní implementace - spolehlivým kanálem včem 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

Spolehlivé kauzální doručování

- Záplavový (flooding) algoritmus
  - Při příjmu každé doposud nepřijaté zprávy ji každý uzel přepošle 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 Ack(p) $\forall p \in L$ nebo do zjištění že p_x havaroval
  - p_j po příjmu zprávy odešle 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?

Spolehlivé kauzální doručování

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

základní myšlenka: přeposílat jen potřebným

- 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 Ack(p) $\forall p \in L$ nebo do zjištění že p_x havaroval
  - p_j po příjmu zprávy odešle 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?

Spolehlivé kauzální doručování

- Záplavový (flooding) algoritmus
  - Při příjmu každé doposud nepřijaté zprávy ji každý uzel přepošle 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 Ack(p) $\forall p \in L$ nebo do zjištění že p_x havaroval
  - p_j po příjmu zprávy odešle 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

Trans - protokol pro spolehlivé kauzální doručování *Melliar-Smith & co '90*

Potvrzení - graf závislostí (DAG)

transitive acknowledgements

Invariant:

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

Stabilní zpráva - přijata všemi členy skupiny

DAG G - **graf kauzality** celé skupiny

Gp - 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

Potvrzovací mechanismy

- Jak p_j zjistí které uzly zprávu přijaly?
  - rozesílání 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

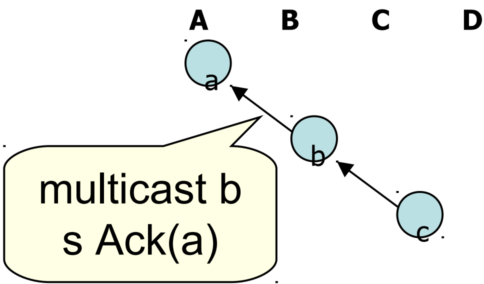

- D může po příjmu a, b+Ack(a), c+Ack(b) odvodit:
  - B přijal a
  - C přijal a i b

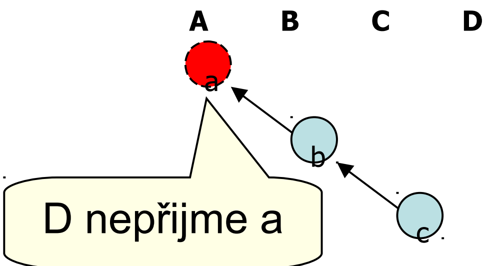

- D může po příjmu b+Ack(a), c+Ack(b) odvodit:
  - B přijal a
  - C přijal a i b
  - A odeslal a -> žádost o zaslání

Při korektním kauzálním doručování jsou potvrzení zpráv tranzitivní

Trans algoritmus - odesílání

Implementace

- ack_list, nak_list - seznam zpráv pro potvrzení / nepřijatých zpráv
- undelivered_list – seznam přijatých ale ještě nedoručených zpráv
- přeposlání zprávy včetně ack/nak-listu

```
Trans_send(m)
       m += nack_list
       m += ack_list
       ack_list = m
       G += m
       send m to every node
```

nak_list zůstává až do příjmu zprávy

vyčištění ack_listu, přidat m

m do grafu kauzality

Trans algoritmus - příjem

```
Trans_Receive(m)

      foreach nak(n) ∈ m
            if n ∈ Gp
                  multicast n
      if m ∈ Gp
            exit
      foreach ack(n) ∈ m && n ∉ Gp
            nak_list += n
      if m ∈ nak_list
            nak_list -= m
      undelivered_list += m
      G += m
      foreach n ∈ undelivered_list && causal(n)
            undelivered_list -= n
            deliver n
      foreach n ∈ Gp && causal(n)
               && neex( n': causal(n') && (n',n) ∈ Gp)
            ack_list += n
      foreach n ∈ Gp && stable(n)
            Gp -= n
```

přeposlání vyžádaných zpráv

včetně ACK!

zaznamenání nepřijaté zprávy

všechny kauzálně předcházející byly doručeny

všechny kauzální zprávy které nebyly tranzitivně potvrzeny

n' -> n,   n' potvrzuje zprávu n

vyčištění všech stabilních zpráv

Průběh Trans algoritmu

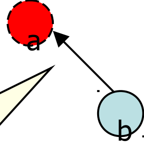

ACK: {}

NAK: {**a**}

Přijme b + Ack(a)
a do NAK listu

Průběh Trans algoritmu

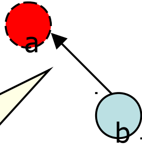

ACK: {}

NAK: {**a**}

Přijme b + Ack(a)
a do NAK listu

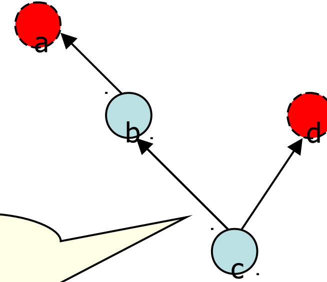

ACK: {}

NAK: {a,**d**}

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

Průběh Trans algoritmu

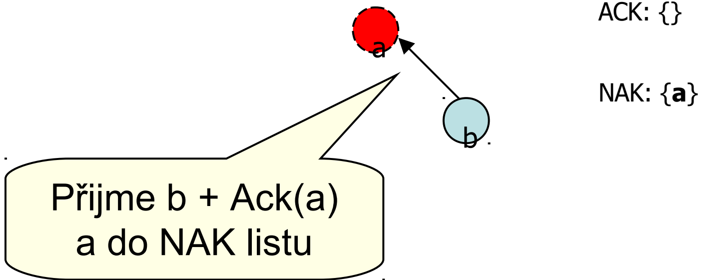

ACK: {}

NAK: {**a**}

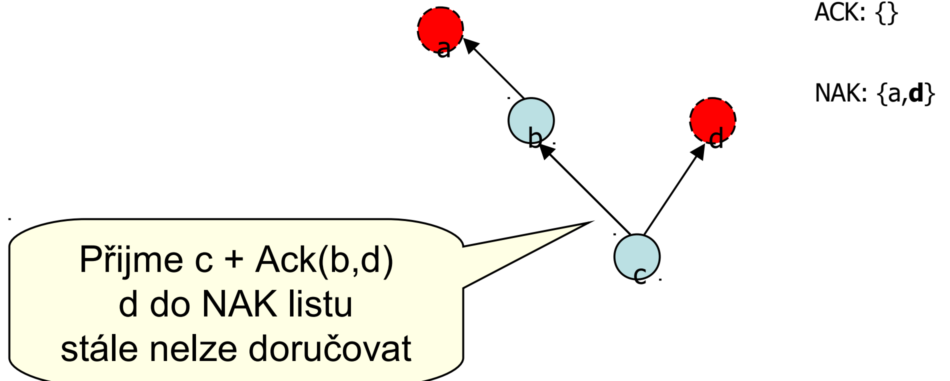

ACK: {}

NAK: {a,**d**}

ACK: {**b**}

NAK: {d}

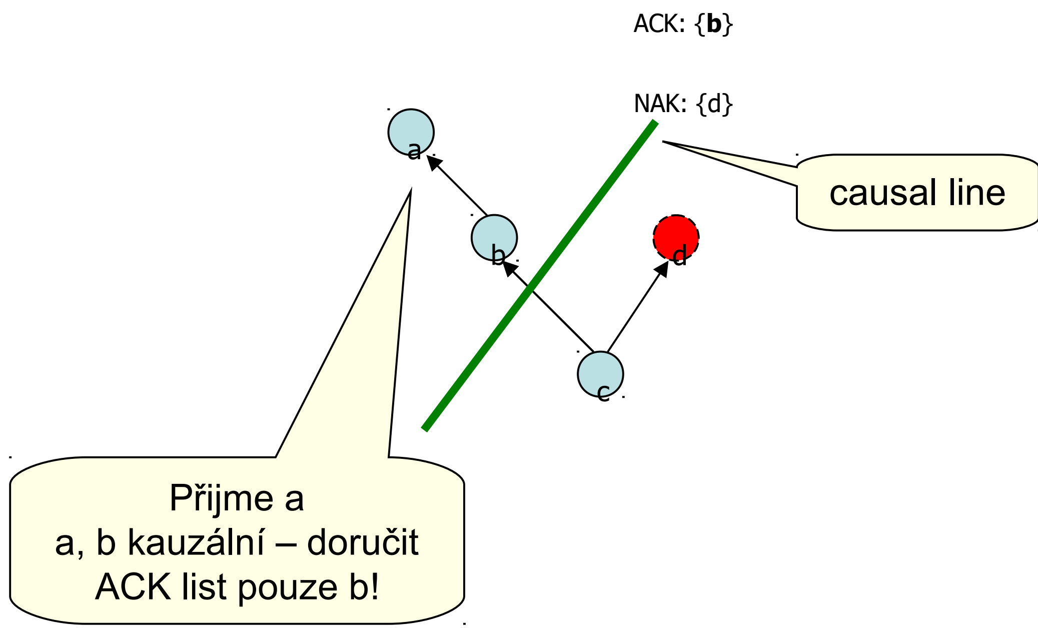

Průběh Trans algoritmu

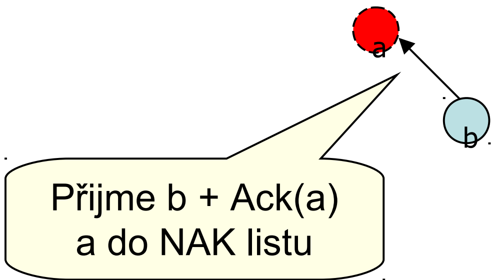

ACK: {}

NAK: {**a**}

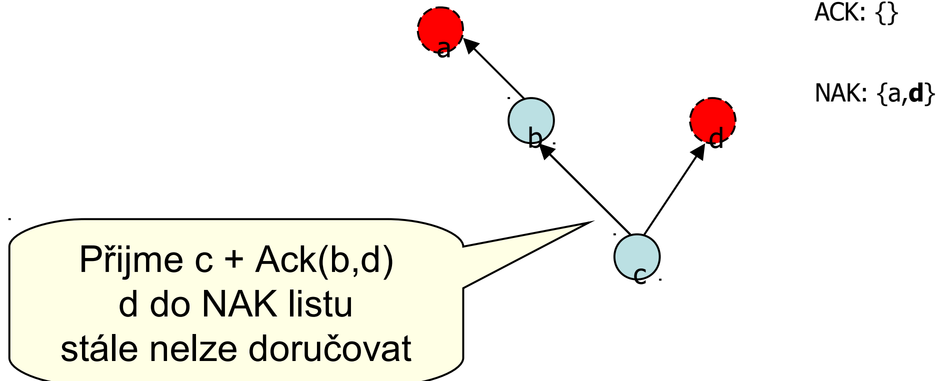

ACK: {}

NAK: {a,**d**}

ACK: {**b**}

NAK: {d}

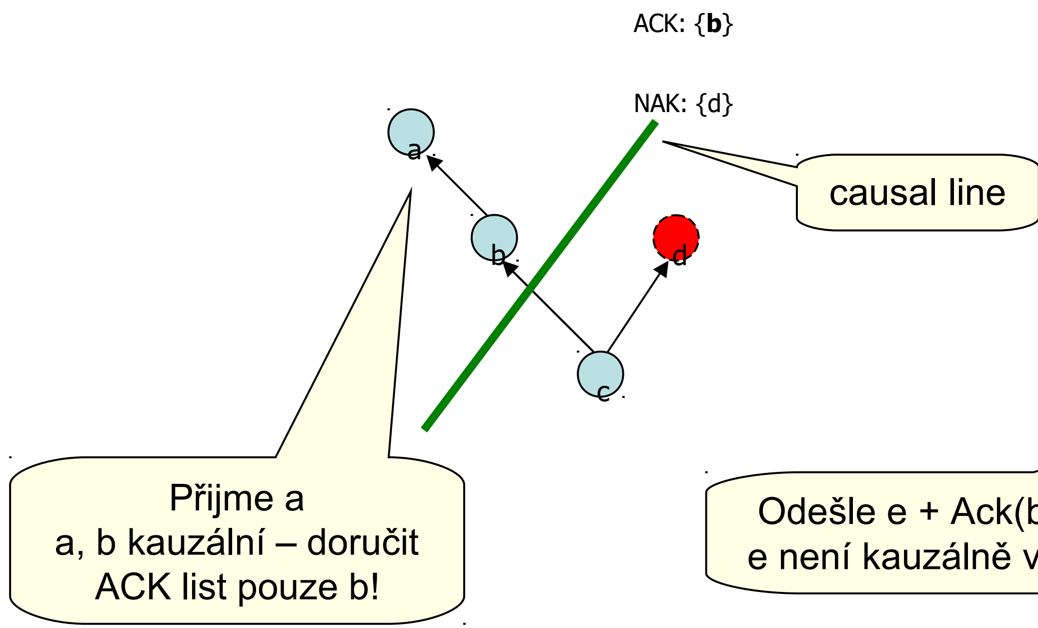

ACK: {**e**}

NAK: {d}

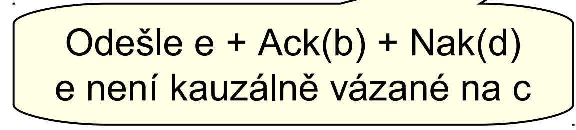

Trans protokol – pozorování

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 uzlu,
  pak někdy každý nehavarující uzel zprávu dostane
- zprávy jsou doručovány v kauzálním uspořádání
- G reprezentuje graf závislosti v kauzálním uspořádání
- všechny uzly vytvářejí stejný graf závislostí
  - pořadí přidávání zpráv do grafu však může být různé

- jestliže uzel havaruje, paměťová náročnost je **neomezená !** ☹👎☠💣
  - slabina - pro praktické použití musí být Trans protokol doplněn protokolem pro **změnu členství** ve skupinách

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

Virtuální synchronie

- $p, q \in L^x, L^{x+1}$
- install L_p^x < $deliver_p(m)$ < install $L_p^{x+1} \Rightarrow$ install L_q^x < $deliver_q(m)$ < install L_q^{x+1}

- pokud je zpráva *m* 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
- přesná formální definice konzistentní změny pohledů nejednotná
  - konzistentní řezy, běhy, temporální logika, ...

- podmínka vzájemné konzistence: $p \in Lq \Rightarrow q \in Lp$
  - všechny uzly ve skupině udržují stejný L
  - instalují nové pohledy ve stejném pořadí

Virtuální synchronie - přípustné doručování

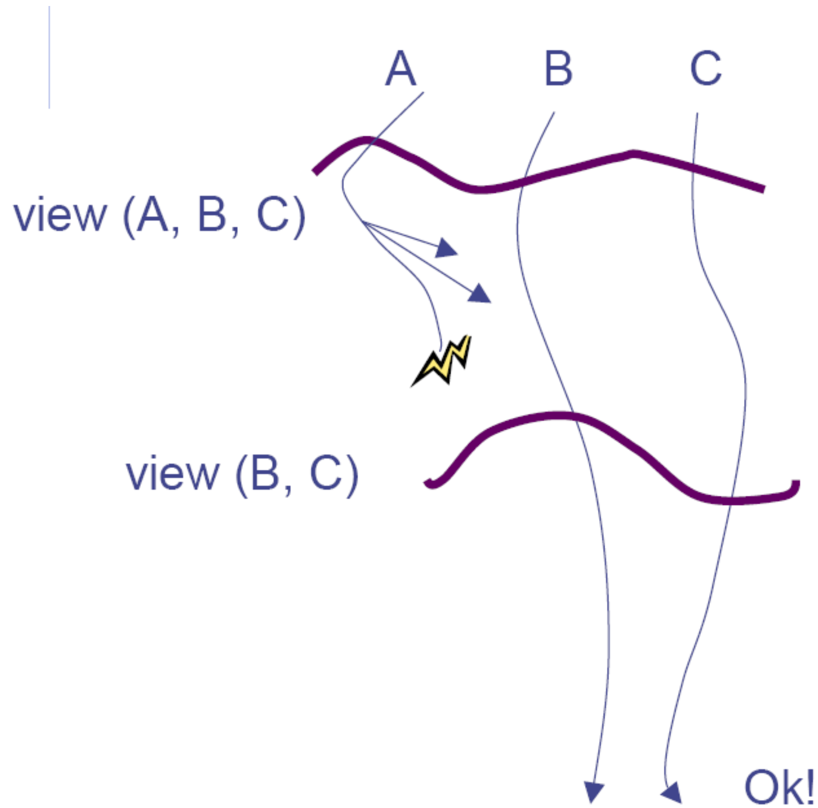

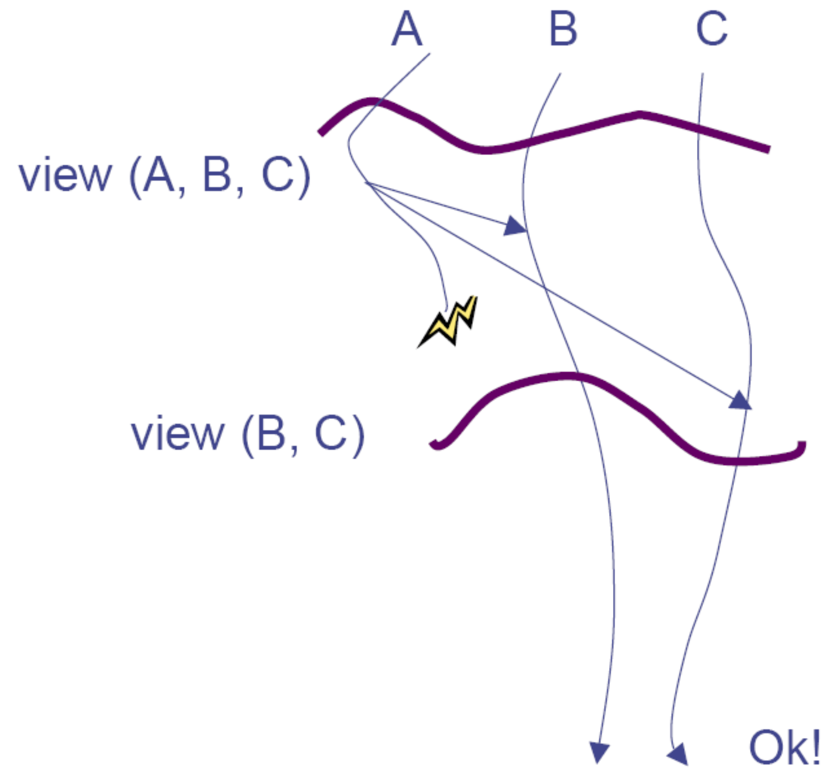

Virtuální synchronie - nepřípustné doručování

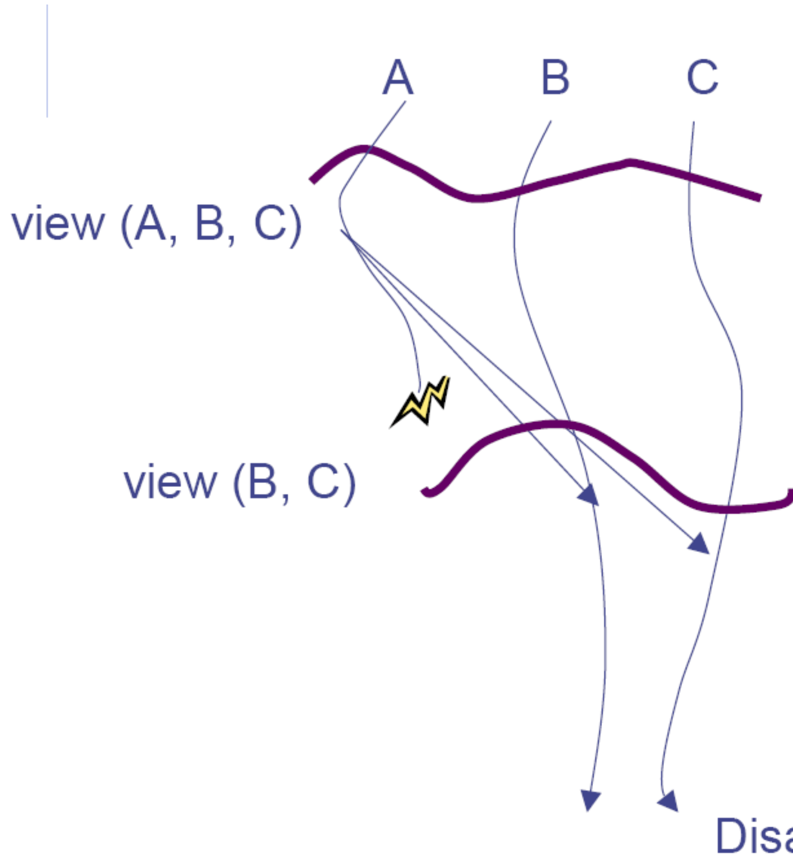

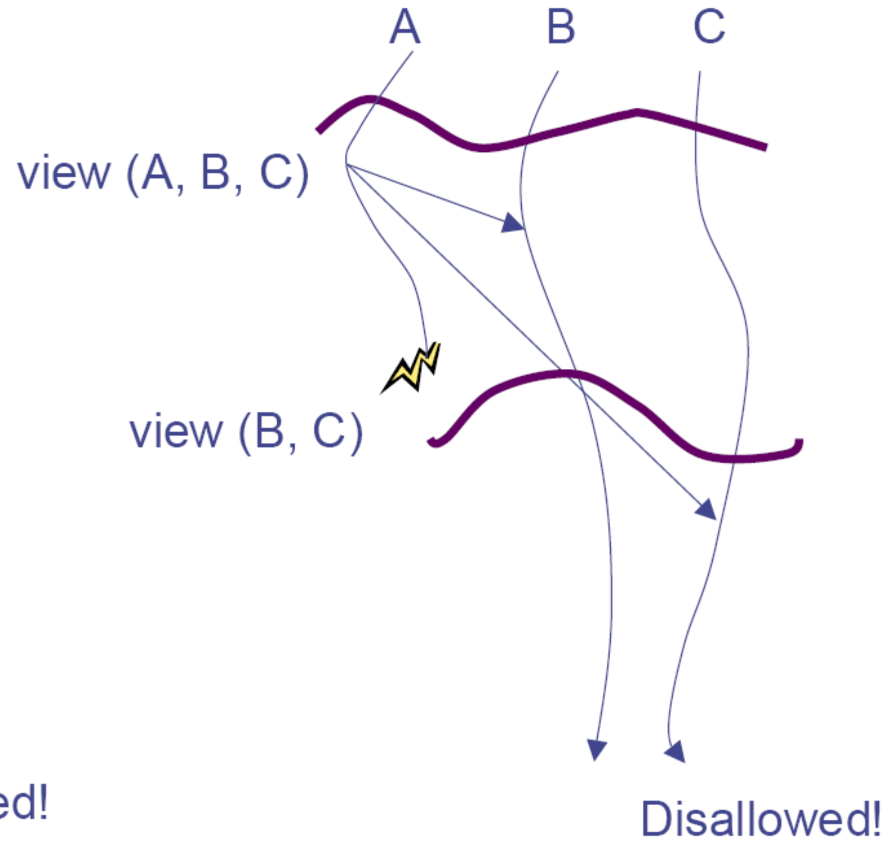

Transis algoritmus

Transis - spolehlivý kauzální multicast, členství ve skupinách

- vychází z Trans, založen na principech Trans a ISIS
- Technion, '92 - Amir, Dolev, Kramer, Malki

www.cs.huji.ac.il/labs/transis

Monotónnost protokolu

- nemožnost dosažení spolehlivého distribovaného konsensu *(později)*
- **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

Průběh Transis algoritmus

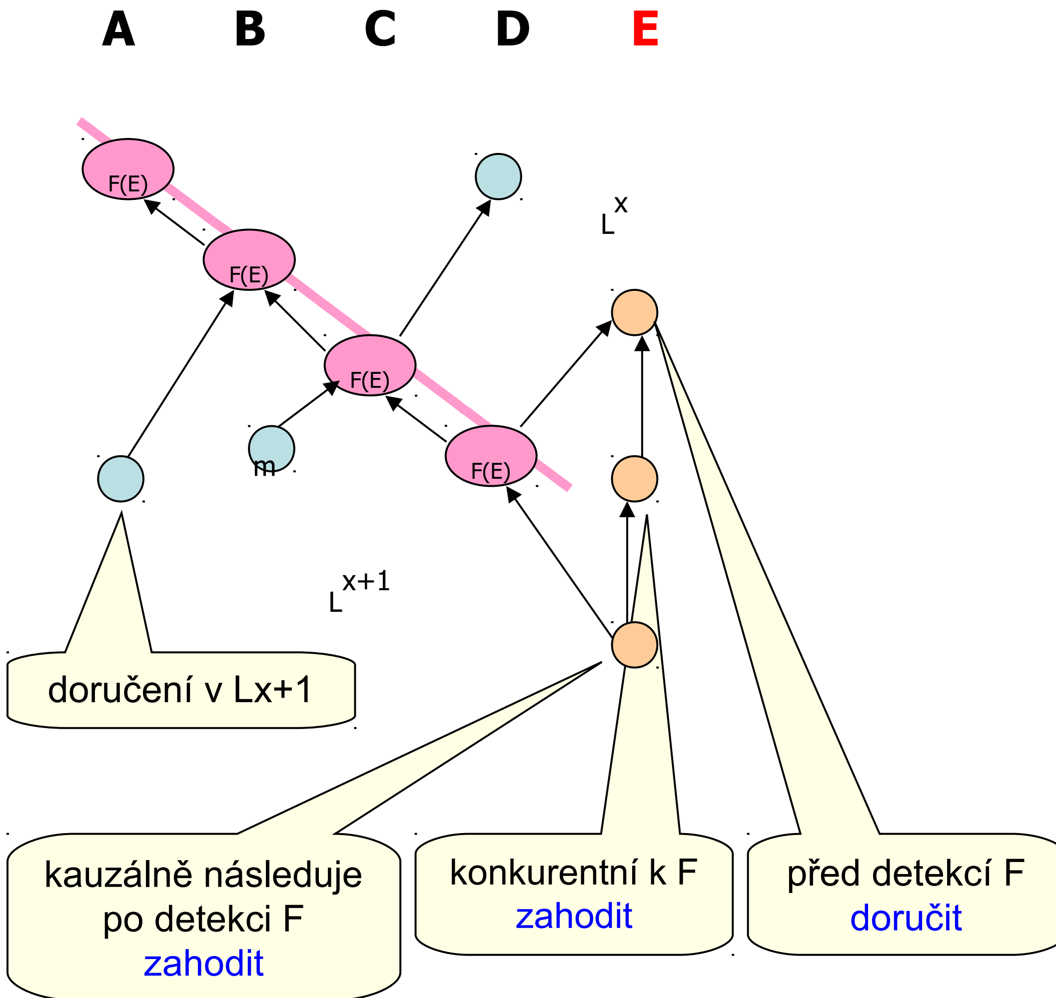

Průběh Transis algoritmus

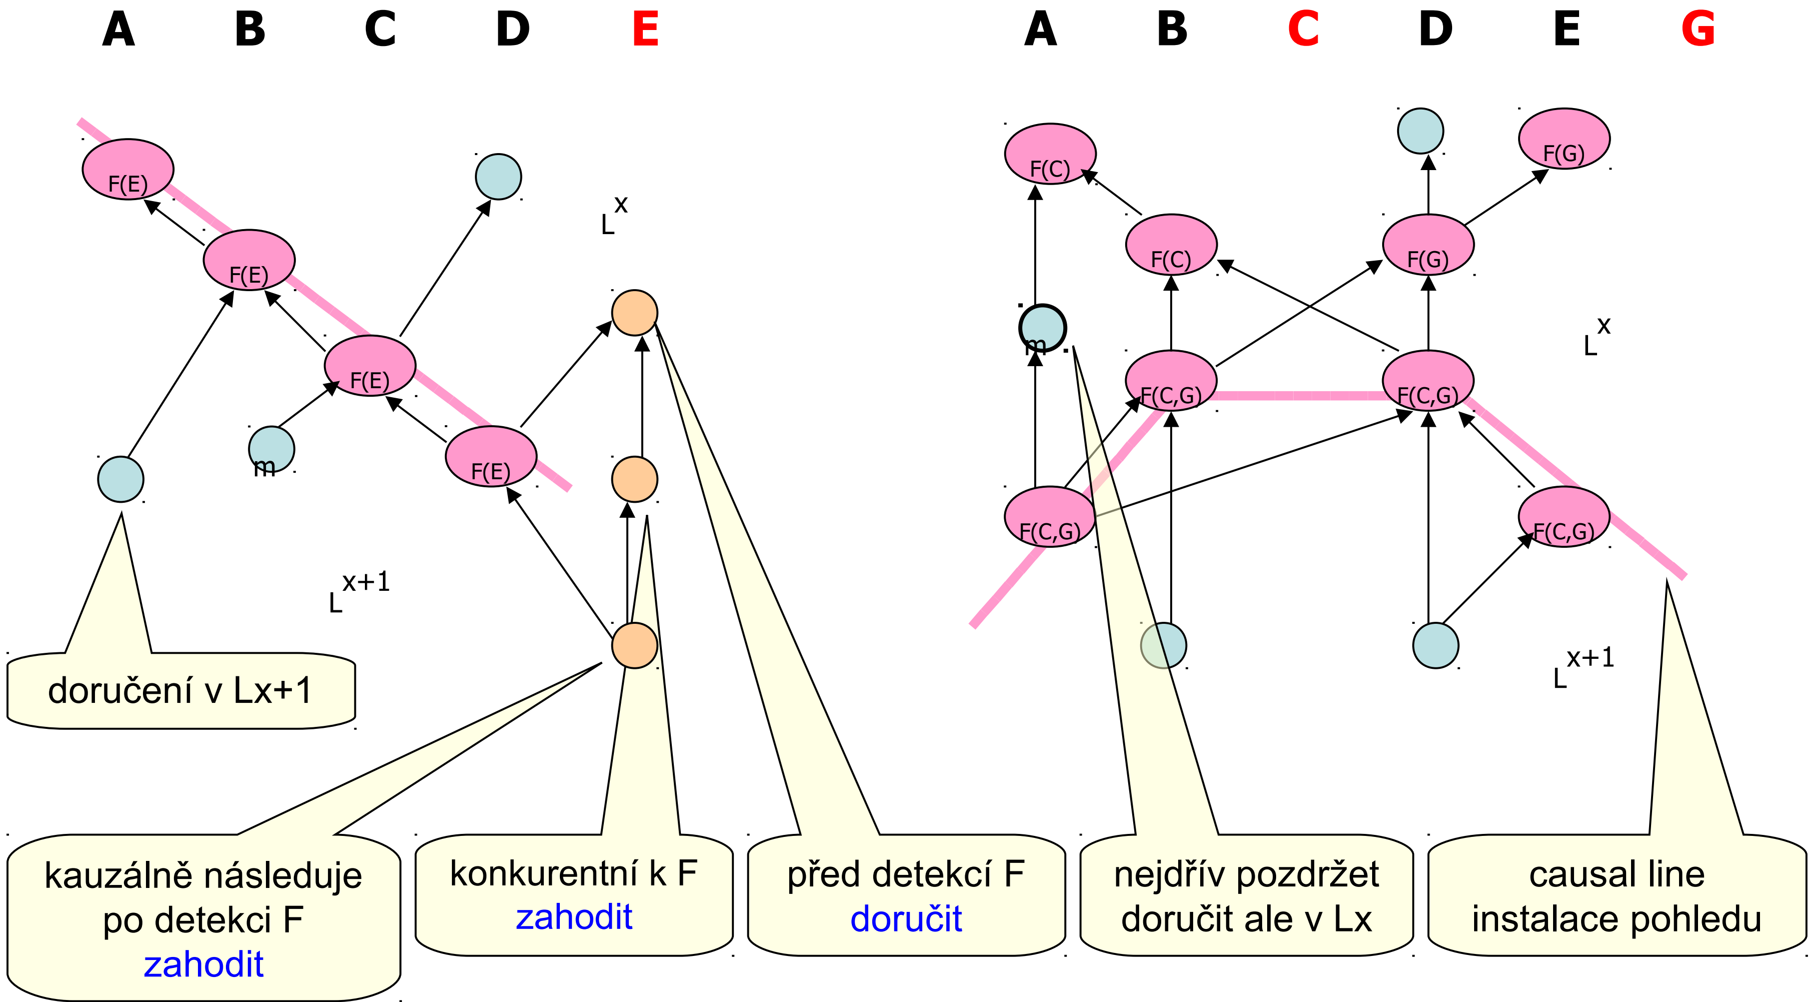

Transis algoritmus

G graf kauzálních závislostí

stejný jako u Trans: m potvrzuje zprávu m' ⇒ (m,m') ∈G

L aktuální pohled (množina procesů)

F množina procesů označených za havarované

FAULT(q) zpráva s detekcí havárie procesu q

blocked zprávy blokované 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∈F && (m,FAULT(F'))∈G && sender∈F')
        discard m
    else if( F≠∅ && (m,FAULT(F'))∈G)
        blocked += m
    else if( m == FAULT(fset)) {
        Last[sender] = fset
        if( fset-F ≠ ∅) {
            deliver deliverable msgs from blocked
            F += fset
            Trans_send(FAULT,F)
        }
        if( Last[i] == Last[j] ∀i,j∈L-F) {
            deliver msgs from blocked that precede every FAULT(F)
            install L -= F
            deliver all from blocked
            F = ∅
            foreach( i∈L)
                Last[i] = ∅
        }
    } else
        deliver(m,sender)
```

- zahození m v Lx+1 od havarovaného odesílatele
- pozdržení zprávy do Lx+1
- doručení FAULT
- nově havarované procesy
- zprávy patřící do Lx
- potvrzení / propagace
- FAULT od všech žijících
- doručení Lx
- instalace nového pohledu
- doručení pozdržených,vyčištění
- normální doručení

ISIS protokol - spolehlivé kauzální doručování

Základem doručovacích protokolů je způsob přenosu informace o doručení

- Trans - kauzální potvrzení
- ISIS - **maticové hodiny**

[opakování] vektorové hodiny:

- VTp_i [i] vlastní odeslané zprávy uzlu p_i
- VTp_i [k] pro $k \neq i$ zprávy přijaté od ostatních uzlů

idea: každý uzel zná VT[] všech uzlů - udržuje matici

- MTp_i [j][k] co uzel p_i ví o doručení zpráv uzlu p_j od p_k

p_j při příjmu zprávy od p_i aktualizuje MTp_j [j] a MTp_j [i]

MTpj [j][i]=MTm[i], MTpj [i][*]=MTm[*]

co ví příjemce o odesílateli

co ví příjemce o sobě

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

Trans lze považovat za formu komprimace MT

- srovnání s Trans
  - Trans potřebuje potvrdit max. M jiných zpráv - lze nahradit MT

ISIS protokol - členství ve skupinách

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

Každý uzel v L udržuje zprávu dokud není stabilní

detekce pomocí MT

Po příjmu zprávy o instalaci nového pohledu uzel:

- přepošle všechny nestabilní zprávy
- **flush** message - potvrzení instalace
- zatím pohled **ne**instaluje

Po příjmu flush od každého uzlu může instalovat nový pohled

Zprávy od havarovaných uzlů

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

Reálné nasazení

- New York Stock Exchange, Swiss Stock Exchange
- French Air Traffic Control System
- Reuters, Bloomberg

Instalace nového pohledu

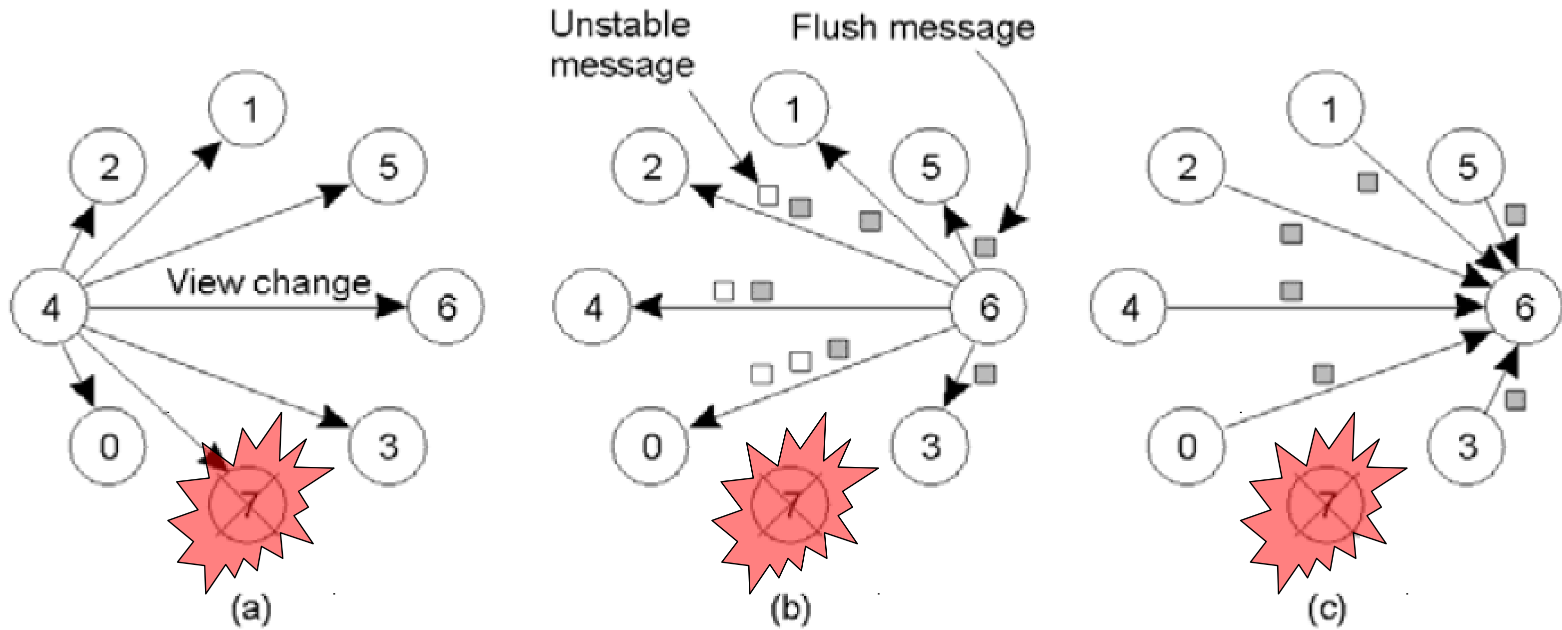

Průběh instalace nového pohledu v ISIS

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

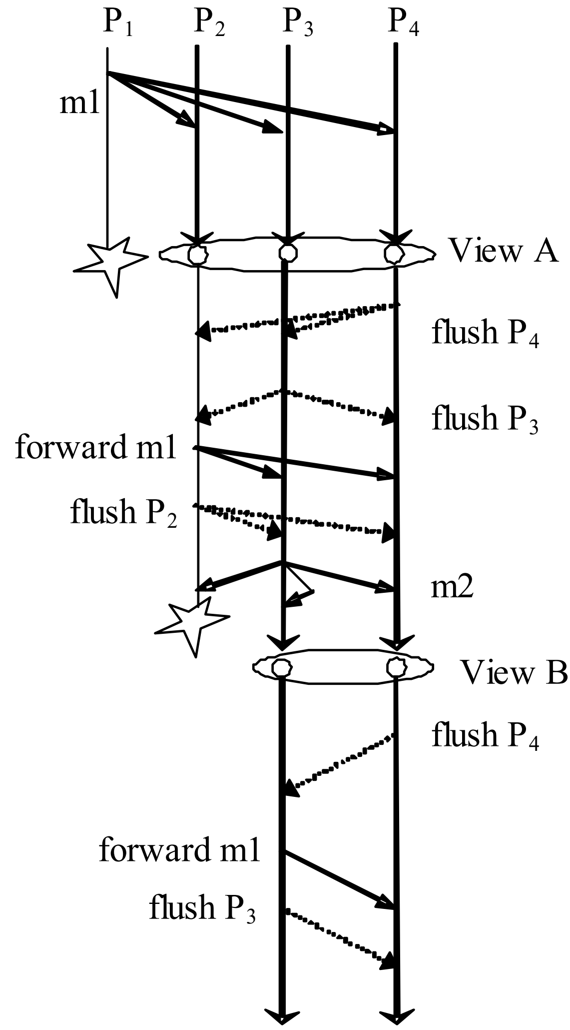

Fyzický průběh

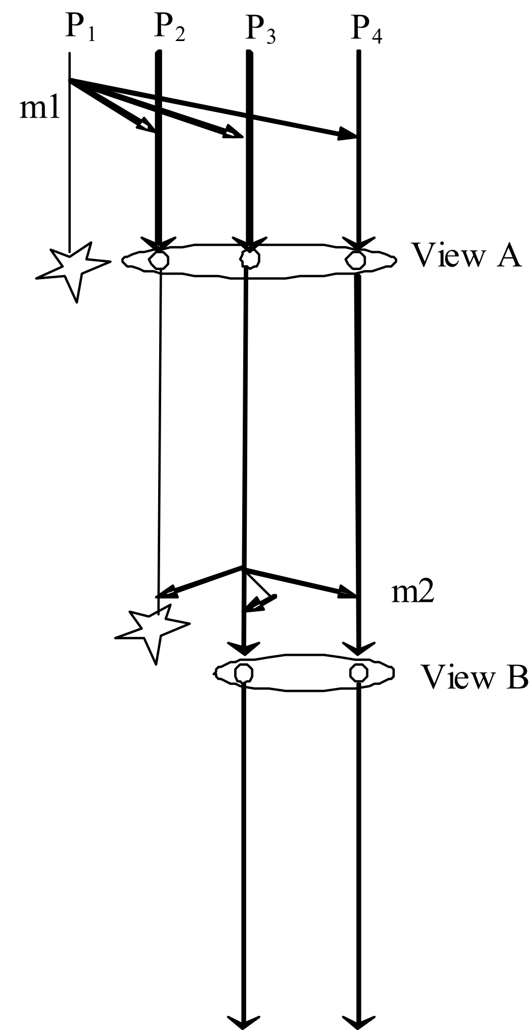

Virtuálně synchronní duručování

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
virtuální synchronie, změna pohledu	Transis - tranzitivní ack Isis - maticové hodiny

Real-World Group Communication Systems

- ISIS, Horus, Ensemble, QuickSilver - Cornell University
- Spread – John Hopkins University
- JGroups
- DCS in WebSphere and AS/400 - IBM
- iBus - SoftWire Inc.
- Transis, Xpand - Hebrew University
- Cactus – Arizona State University
- Phoenix - EPFL
- Relacs - University of Bologna
- Totem - UCSB
- Amoeba - Vrije University, Amsterdam
- Appia – University of Lisboa
- NewTOP - New Castle
- HP
- Lucent Bell-Labs
- Stratus

...

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

Konsensus

Konsensus

- Ukončení distribuovaných výpočtů
- Kauzálně konzistentní globální stav
- Detekce globálního stavu, značkový algoritmus
- Problém dvou armád
- Problém Byzantských generálů
- Paxos family

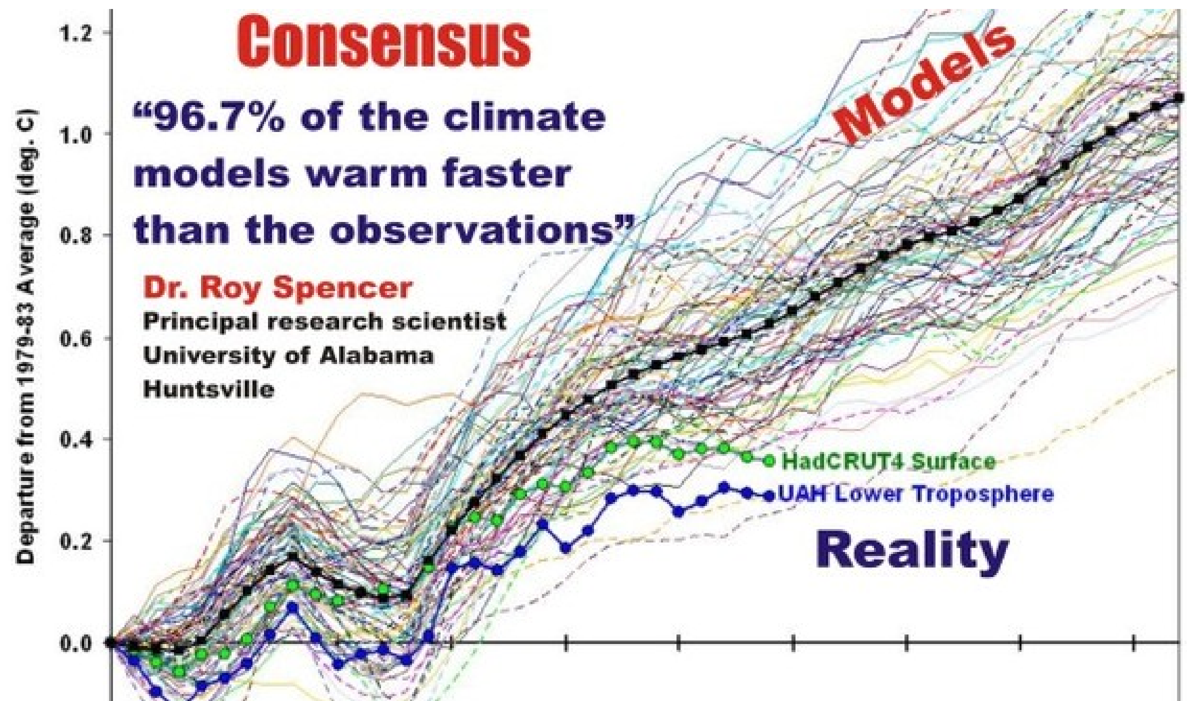

Ukončení distribuovaných procesů

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

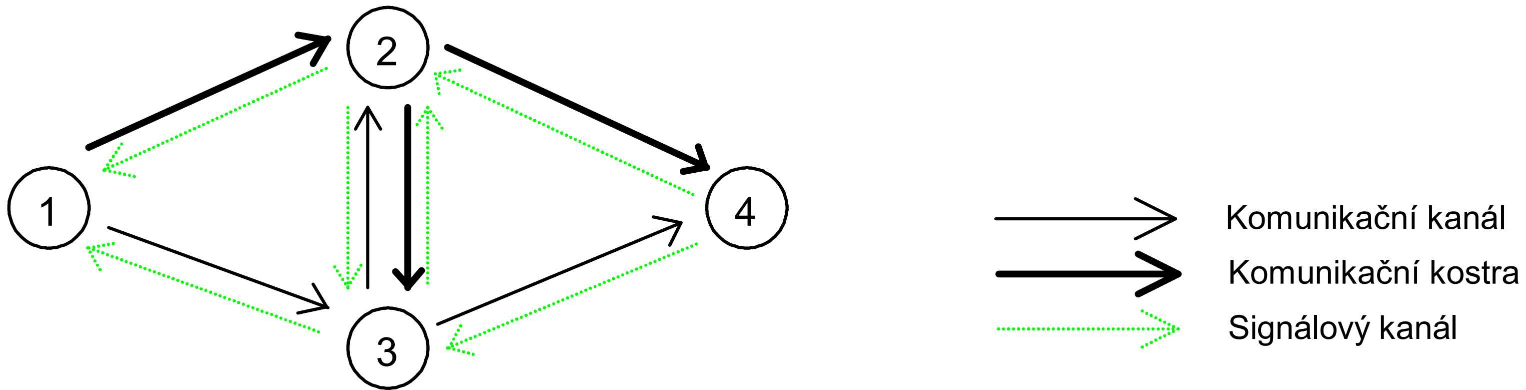

- Iniciační proces začíná výpočet, vyšle podél svých výstupních hran zprávu
- Proces se při příjmu zprávy dostane do stavu *výpočet*
    - může dále posílat zprávy podél výstupních hran
    - může přijímat zprávy ze vstupních hran
    - když proces skončí výpočet, dostane se do stavu *ukončen*, zprávy neposílá, může přijímat
    - při přijetí zprávy se proces vrátí 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
- iniciátor 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 **dynamicky** vytváří **orientovanou 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 signály od všech výstupních hran
  3. Poslat signál otci
- iniciátor dostane všechny signály - konec výpočtu

Huangův algoritmus

- Idea: dělení vah zpráv
  - každý proces má váhu, každá zpráva má váhu
  - váha iniciátora = W
  - váha ostatních procesů = 0

- Odeslání zprávy: předání části váhy zprávě
- Příjem zprávy: přičtení váhy zprávy k vlastní váze
- Proces ukončen: pošle zprávu s celou vahou procesu iniciátoru
- Konec výpočtu: váha iniciátora = W

- Problémy:
  - dělitelnost vah
  - havárie procesu / ztráta váhy

Značkový (TM) algoritmus

Značka - speciální zpráva odlišitelná od běžných zpráv

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 příchozímu kanálu / zamítnutí
- Příjem zamítnutí: zamítnutí první žádosti
- Příjem všech potvrzení: signál první žádosti

Aplikace obecnějšího algoritmu - detekce globálního stavu

Detekce globálního stavu - motivace

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

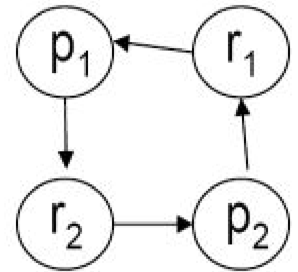

From $O=\{o_1,o_2,o_3,o_4\}$ the deadlock detector concludes there is a deadlock!

Konzistentní stav

Množina událostí v systému E = {e}

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

Past / Future

(Kauzálně) **Konzistentní řez** $c : a \to b$ & $a \in Fc \Rightarrow b \in Fc$

Intuitivní význam: minulost nelze ovlivnit událostí v budoucnosti

Stav distribuovaného výpočtu je množina událostí, které se během výpočtu udály

(Kauzálně) **Konzistentní stav** $S = P_c$, kde c je konzistentní řez

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

$S \to_e S'$ (S' je **dosažitelný** z S)

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

$S \to_{e1} S_1 \to_{e2} S_2 \ . \ . \ . \ S_{n-1} \to_{en} S_n$ Značíme $S \to_s S_n$

Zřejmě platí $S \to_s S_n \Rightarrow S \subseteq S_n$

Využití:

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

Konzistentní a nekonzistentní řez

c – konzistentní řez

Konzistentní a nekonzistentní řez

c – konzistentní řez

Pc c Fc

Proces A
Proces B
Proces C
Proces D

A1 A2
B1 B2 B3 B4
C1 C2 C3 C4
D1 D2

Pc' *c'* *Fc'*

c' – nekonzistentní řez

Důsledky nekonzistentního řezu

Detekce falešného deadlocku

p_1 r_1 r_2 p_2

Req, Ok, Req, Ok, Rel, Req, Ok, Req

o_1, o_2, o_3, o_4

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

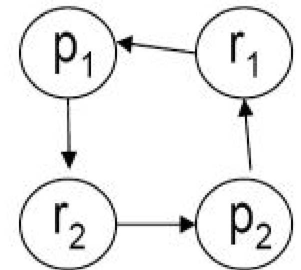

From $O=\{o_1,o_2,o_3,o_4\}$ the deadlock detector concludes there is a deadlock!

Značkový 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 = zprávy došlé kanálem mezi příjmem první a této značky
- Konec algoritmu:
  - po přijmutí všech značek

Zaznamenané stavy uzlů a kanálů definují (kauzálně) konzistentní stav systému

Chandy, Lamport (1985)

Průběh detekce GS 1

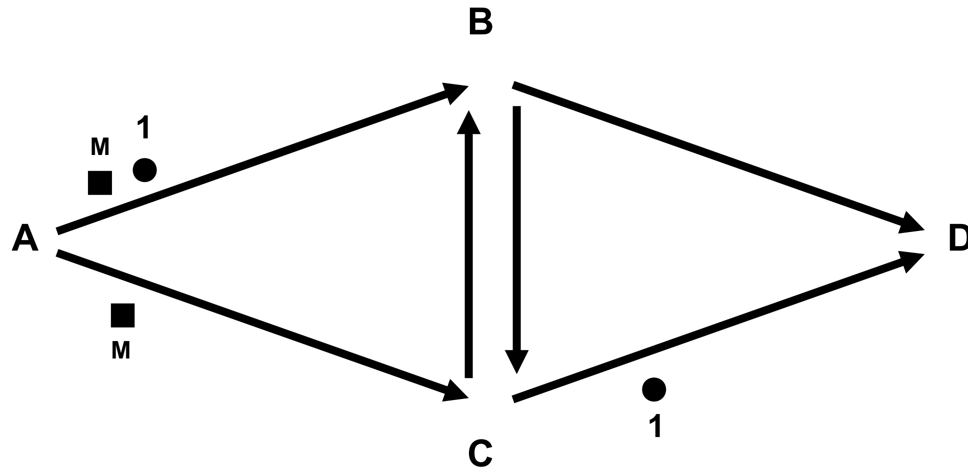

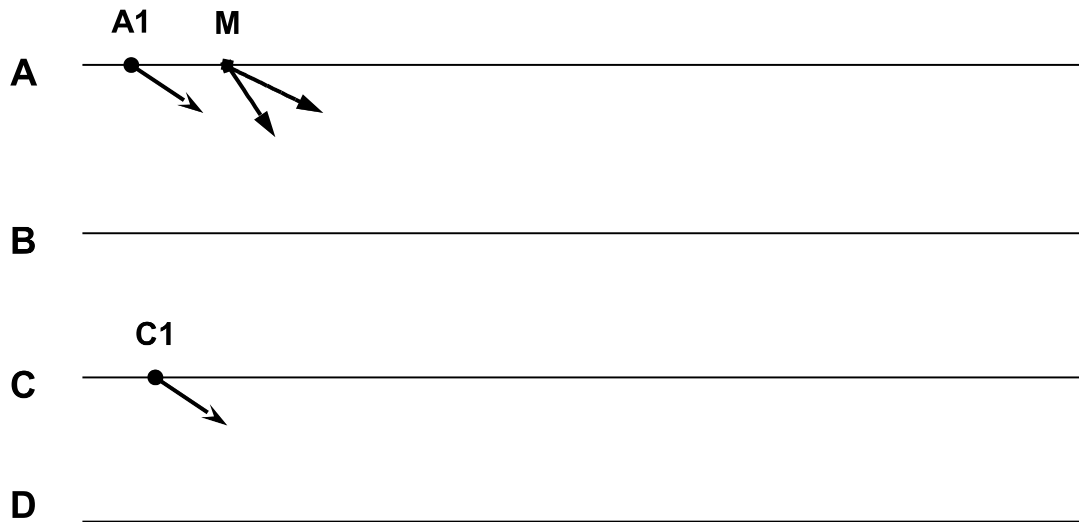

A	A→B	1
	A→C	0
B	A→B	
	C→B	
	B→C	
	B→D	
C	A→C	
	B→C	
	C→B	
	C→D	
D	B→D	
	C→D	

Průběh detekce GS 2

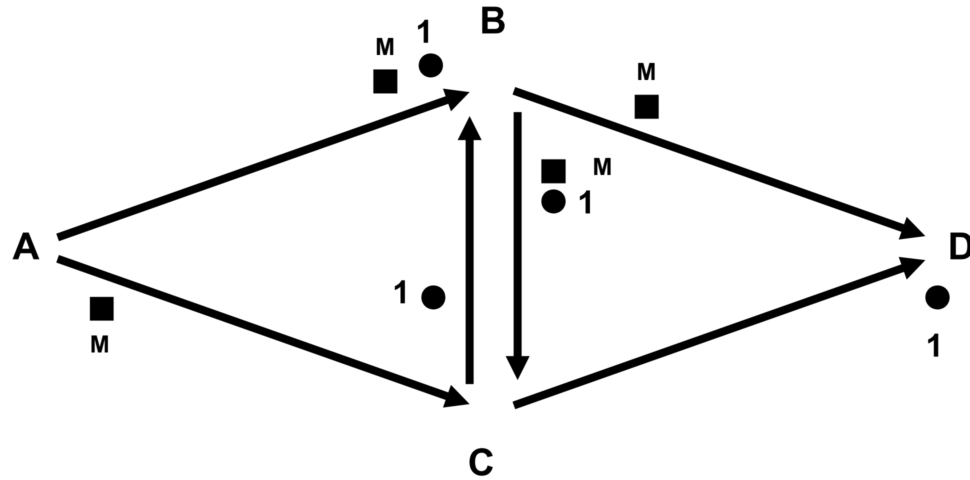

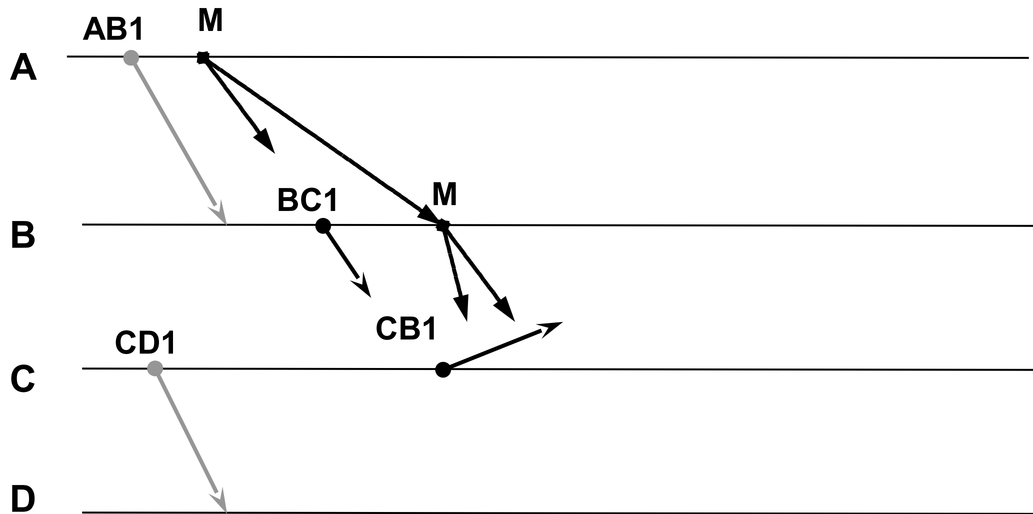

A	A→B	1
	A→C	0
B	A→B	◇
	C→B	
	B→C	1
	B→D	0
C	A→C	
	B→C	
	C→B	
	C→D	
D	B→D	
	C→D	

Průběh detekce GS 3

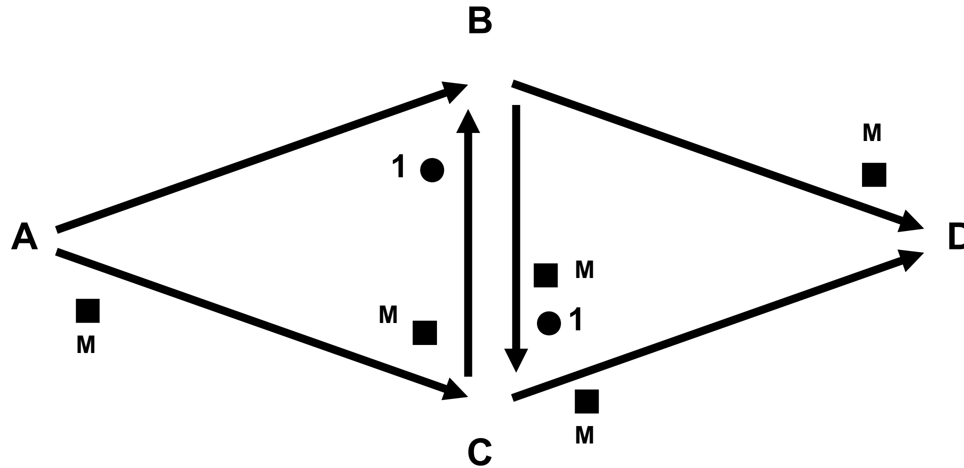

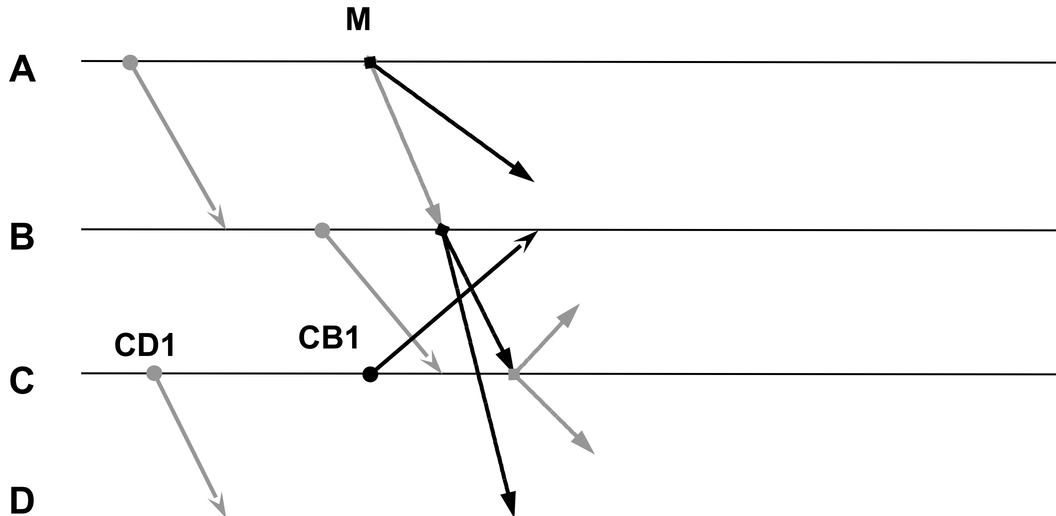

A	A→B	1
	A→C	0
B	A→B	◇
	C→B	1
	B→C	1
	B→D	0
C	A→C	
	B→C	◇
	C→B	1
	C→D	1
D	B→D	◇
	C→D	

Průběh detekce GS 4

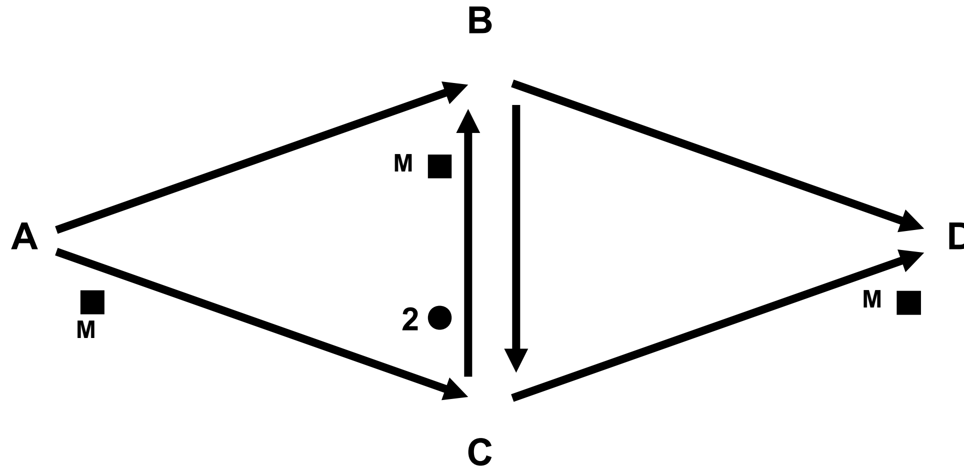

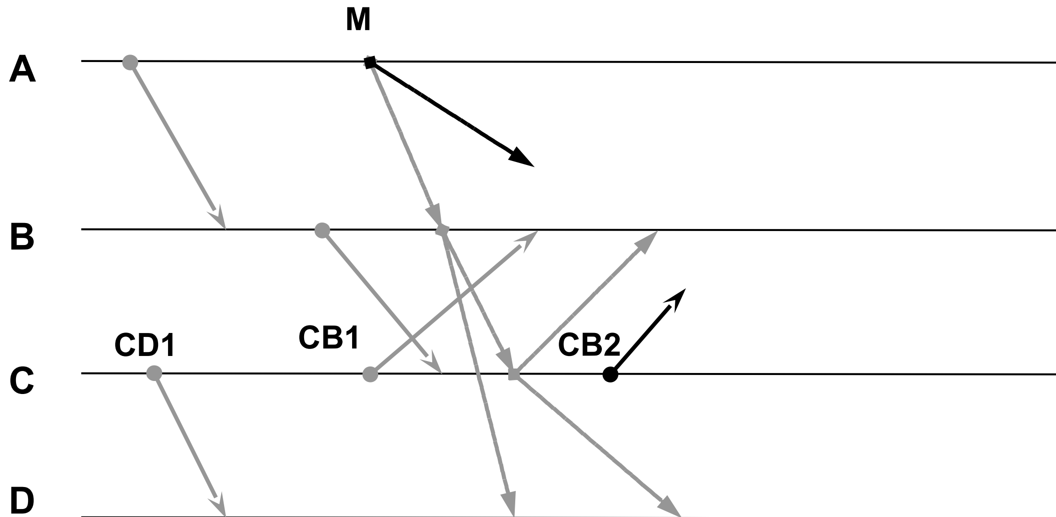

A	A→B	1
	A→C	0
B	A→B	◇
	C→B	◇1
	B→C	1
	B→D	0
C	A→C	
	B→C	◇
	C→B	1
	C→D	1
D	B→D	◇
	C→D	◇

Průběh detekce GS 5

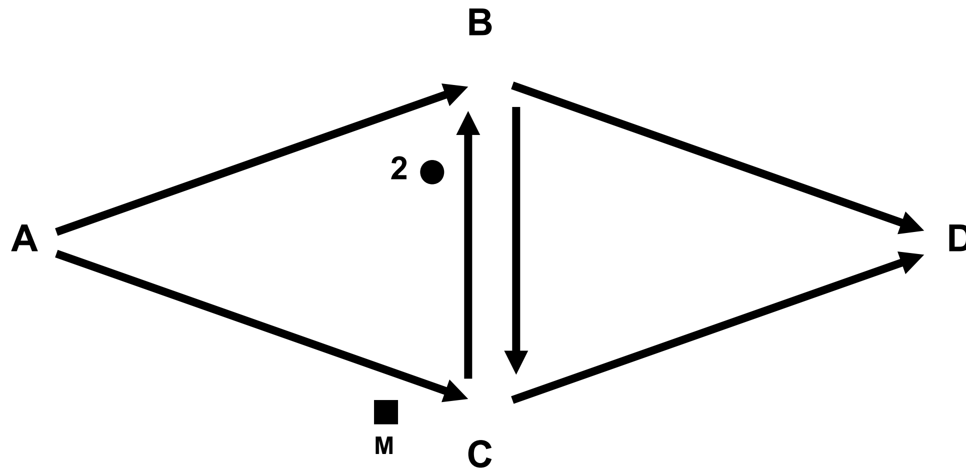

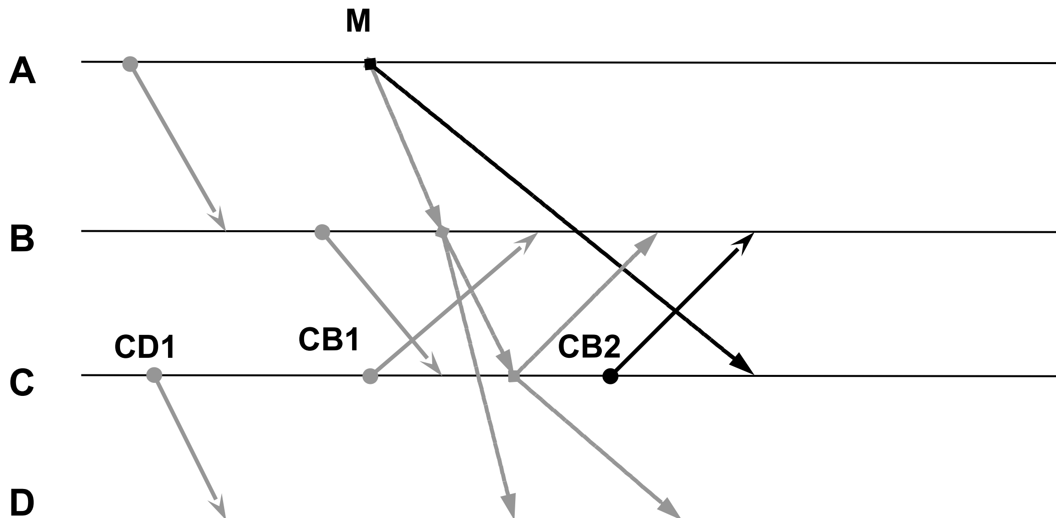

A	A→B	1
	A→C	0
B	A→B	◊
	C→B	◊1
	B→C	1
	B→D	0
C	A→C	◊
	B→C	◊
	C→B	1
	C→D	1
D	B→D	◊
	C→D	◊

Průběh detekce GS - výsledek

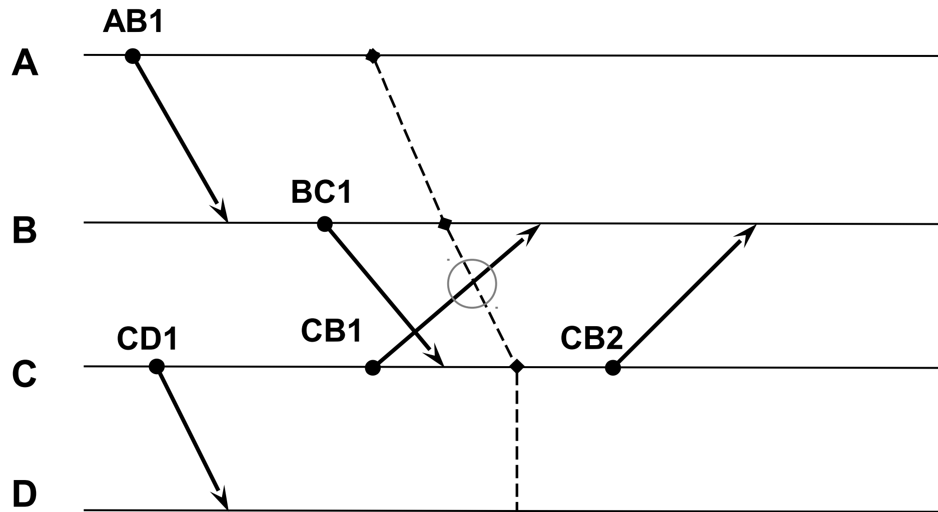

A	A→B	1
	A→C	0
B	A→B	◇
	C→B	◇1
	B→C	1
	B→D	0
C	A→C	◇
	B→C	◇
	C→B	1
	C→D	1
D	B→D	◇
	C→D	◇

Modely distribuovaných výpočtů

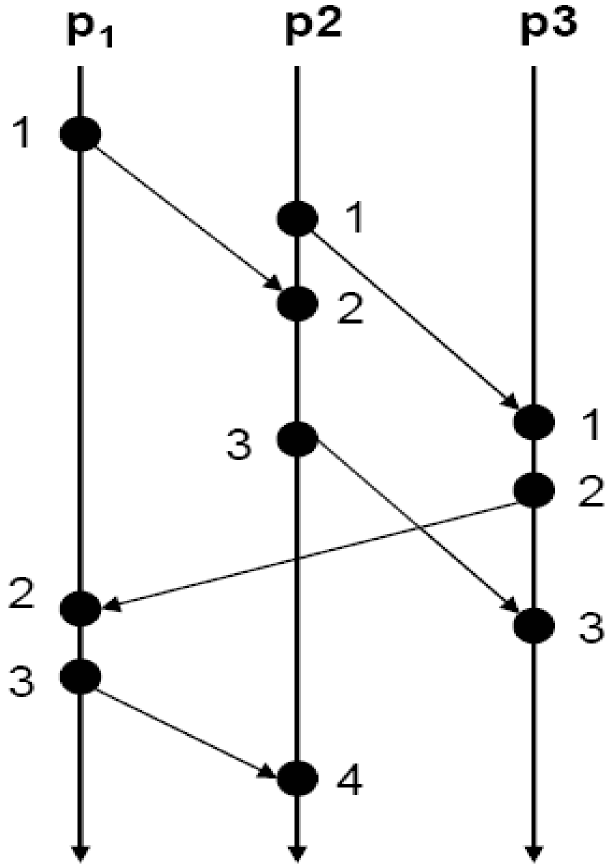

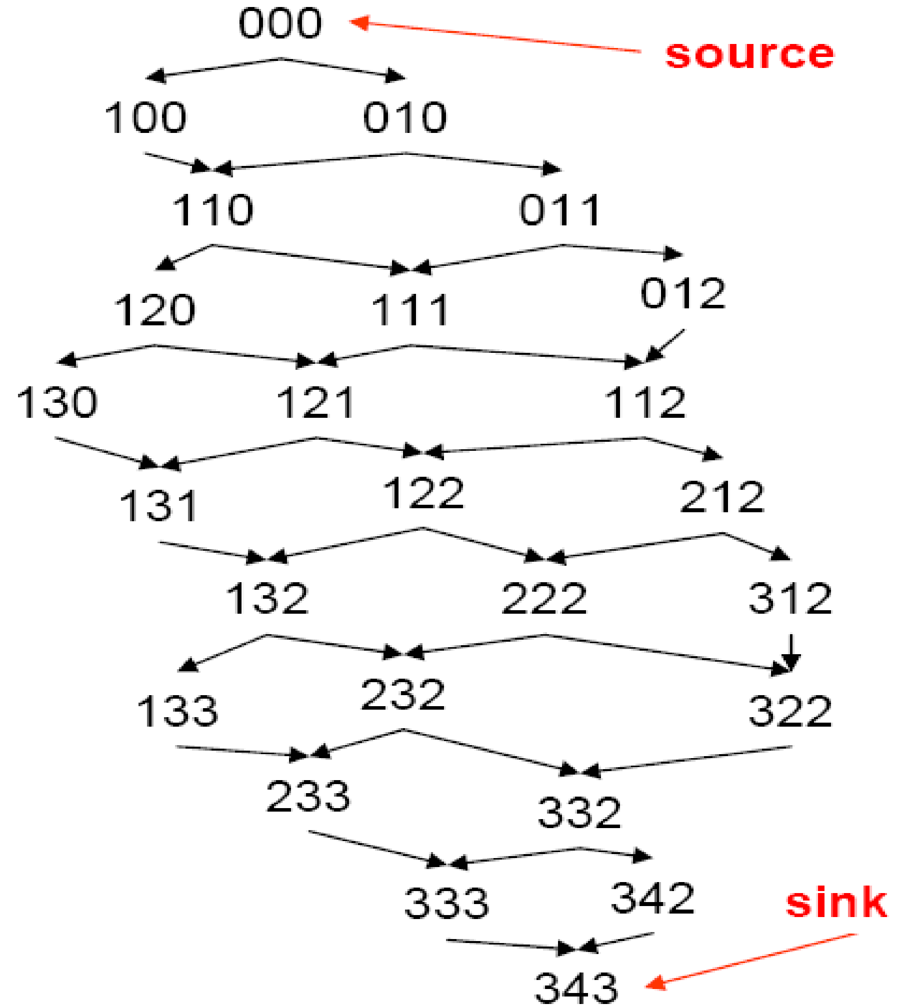

globální stavy, globální predikáty

stabilní vlastnosti, důkazy korektnosti

inevitable states - nevyhnutelné

Distribuovaný konsensus

Problém dvou armád

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

Řešení NEEXISTUJE!!!

A1->A2: Attack! *(A1 neví, jestli zprávu A2 dostal)*
A2->A1: ACK *(A2 neví, jestli A1 dostal potvrzení)*
A1->A2: ACK *(A1 neví, jestli A2 dostal potvrzení)*
A2->A1: ACK *(A2 neví, jestli A1 dostal potvrzení)*
A1->A2: ACK *(A1 neví, jestli A2 dostal potvrzení)*
A2->A1: ACK *(A2 neví, jestli A1 dostal potvrzení)*
A1->A2: ACK *(A1 neví, jestli A2 dostal potvrzení)*
……. ….. ……………………….
… …. ……………

Distribuovaný konsensus

Problém dvou armád

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

Striktní řešení NEEXISTUJE !!!

A1->A2:	Attack!	*(A1 neví, jestli zprávu A2 dostal)*
A2->A1:	ACK	*(A2 neví, jestli A1 dostal potvrzení)*
A1->A2:	ACK	*(A1 neví, jestli A2 dostal potvrzení)*
A2->A1:	ACK	*(A2 neví, jestli A1 dostal potvrzení)*
A1->A2:	ACK	*(A1 neví, jestli A2 dostal potvrzení)*
A2->A1:	ACK	*(A2 neví, jestli A1 dostal potvrzení)*
A1->A2:	ACK	*(A1 neví, jestli A2 dostal potvrzení)*
....	.....	....
...	....	....

formální důkaz indukcí

Problém dvou armád

Praktická řešení

- Agresivní strategie
  - první generál vyšle větší množství zpráv oznamující čas útoku
  - a zaútočí!
  - předpoklad: při vysokém počtu poslaných zpráv alespoň jedna projde
  - druhý generál nemusí ani odpovídat
- Pravděpodobnostní strategie
  - první generál vyšle větší množství (N_0) zpráv
  - kromě času útoku přidá i počet poslaných zpráv
  - druhý generál odpoví na každou zprávu, 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

Byzantine Generals Problem

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 důstojnící
  - jak generál tak důstojníci mohou být zrádci
  - generál vydá rozkaz, důstojnící ho předají ostatním
  - rozkaz bude vydán na základě většiny
- Cíl protokolu:
  - C1: uzly se shodnou na jedné hodnotě
    - *všichni loajální důstojníci vydají stejný rozkaz*
  - C2: pokud hodnotu navrhl nehavarovaný uzel, uzly se shodnou na této hodnotě
    - *je-li generál loajální, pak každý loajální důstojník vydá rozkaz generála*

Problém Byzantských generálů - 3 uzly

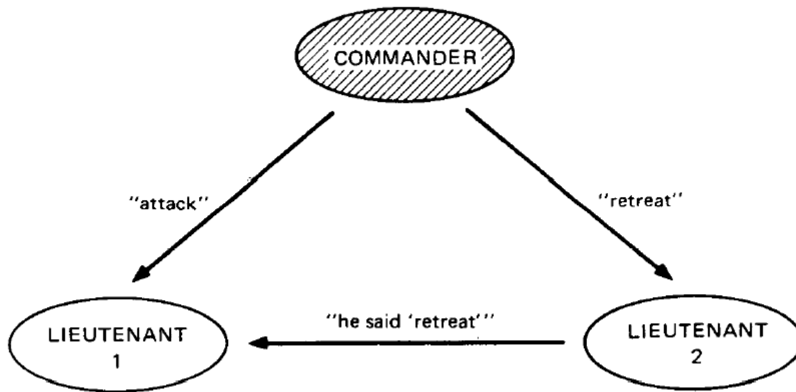

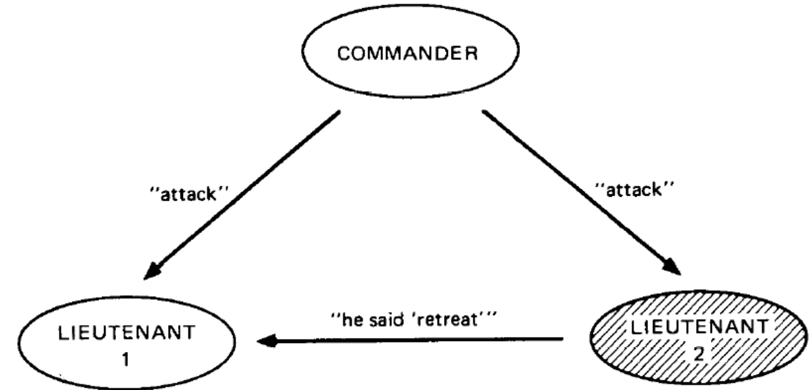

- Zrádce generál
  - různé rozkazy důstojníkům
  - důstojník 1 dostane 2 různé rozkazy
- Zrádce důstojník
  - falešné předání rozkazu
  - důstojník 1 dostane 2 různé rozkazy

Řešení pro 3 uzly s 1 zrádcem neexistuje

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

Problém Byzantských generálů - 3 uzly

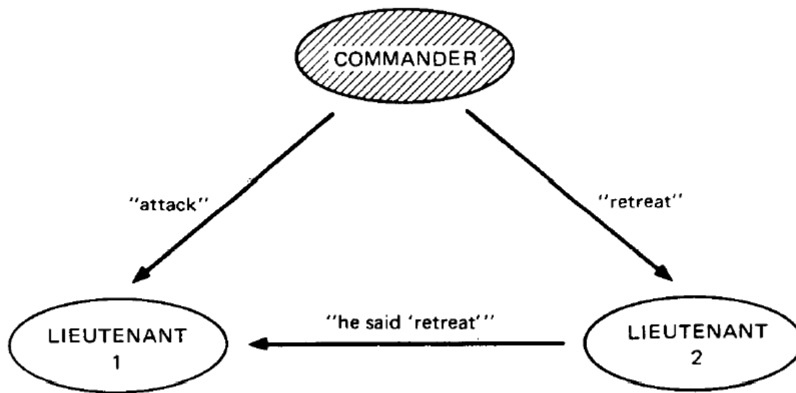

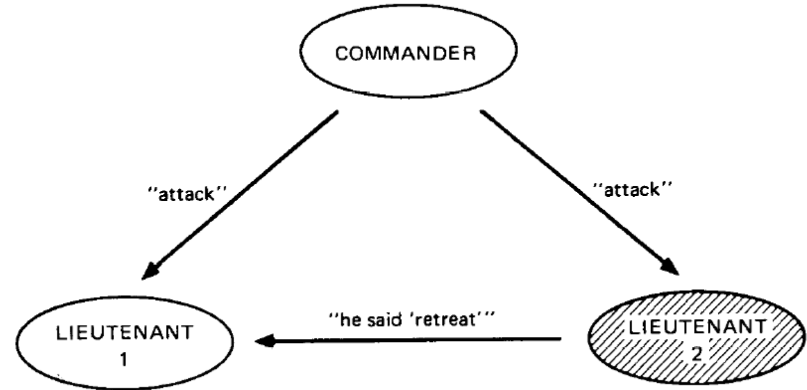

- Zrádce generál
  - různé rozkazy důstojníkům
  - důstojník 1 dostane 2 různé rozkazy
- Zrádce důstojník
  - falešné předání rozkazu
  - důstojník 1 dostane 2 různé rozkazy

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

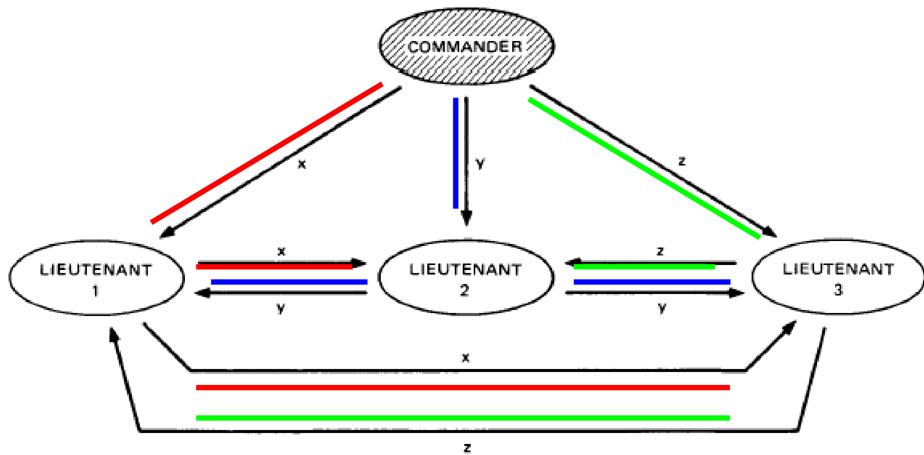

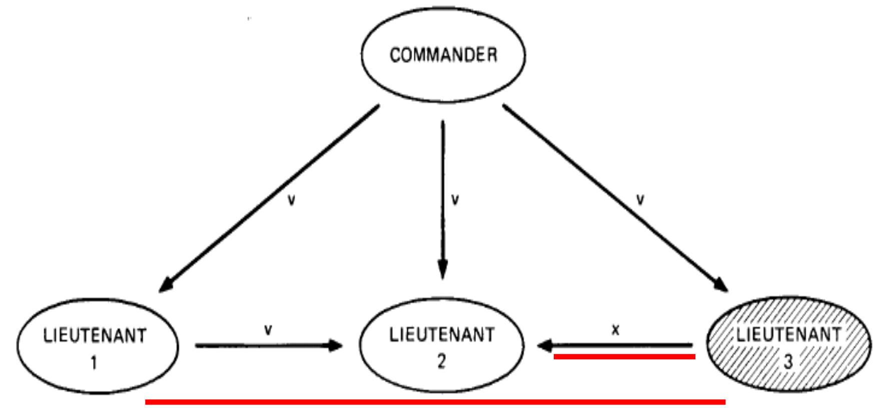

- Zrádce generál
  - alespoň 2 stejné rozkazy
    - důstojníci si vzájemně přepošlou většinový rozkaz (C2)
  - 3 různé rozkazy
    - důstojníci se shodnou na tom, že generál je zrádce (C1)

- Zrádce důstojník
  - nejhorší případ: falešné předání rozkazu všem ostatním
  - loajální důstojníci dostanou většinu správných rozkazů (C2)

Problém Byzantských generálů - 4 uzly

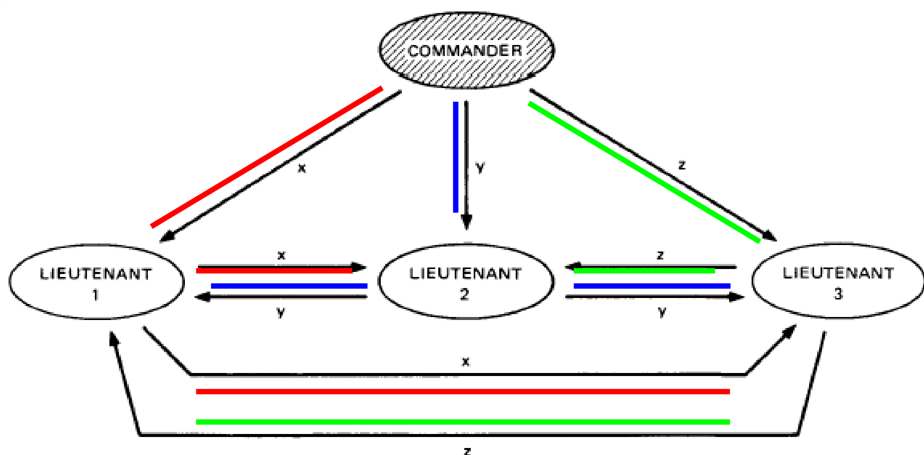

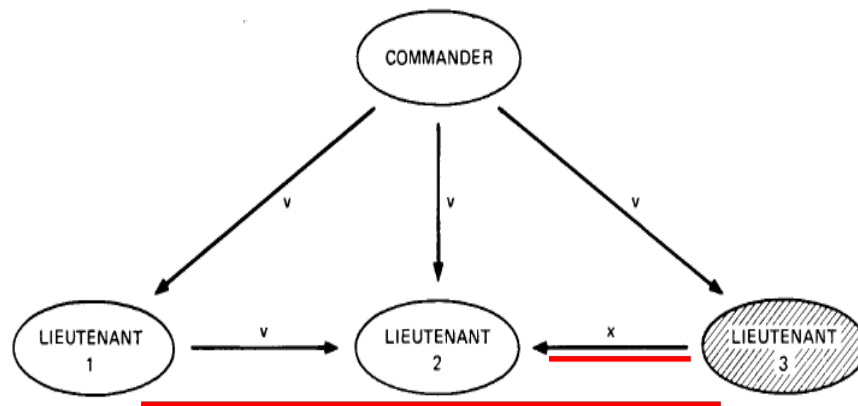

Řešení pro 4 uzly s 1 zrádcem existuje

Obecně: Pro m zrádců exsituje řešení pro n ≥ 3m+1 uzlů

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

- Idea algoritmu: rekurzivní dle m (počet možných zrádců)
  - celkem m+1 kol
- BGP(0)
  - generál pošle hodnotu všem důstojníkům
- BGP(m)
  - důstojník jako generál
  - pošle vektor hodnot z BGM(m-1) ostatním důstojníkům, kteří je ještě nemají
  - výběr většinové hodnoty

exponenciální počet zpráv !

Karel řekl, že Josef řekl, že ...

Klasifikace problémů distribuovaného konsensu

- Byzantský konsensus *(Byzantine agreement)*
  - inicátor 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

$1 \rightarrow 1$

- Konsensus
  - 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
  - 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

Klasifikace problémů distribuovaného konsensu

- Byzantský konsensus *(Byzantine agreement)*
  - inicátor 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

$1 \rightarrow 1$

- Konsensus
  - 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

$n \rightarrow 1$

- Interaktivní konzistence
  - 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

Klasifikace problémů distribuovaného konsensu

- Byzantský konsensus *(Byzantine agreement)* — $1 \rightarrow 1$
  - inicátor 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 — $n \rightarrow 1$
  - 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 — $n \rightarrow n$
  - 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

Klasifikace problémů distribuovaného konsensu

- Byzantský konsensus *(Byzantine agreement)* — $1 \rightarrow 1$
  - inicátor 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 — $n \rightarrow 1$
  - 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 — $n \rightarrow n$
  - 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

Konsensus & fault-tolerance

- Reálné prostředí
  - nespolehlivé uzly, neomezená doba zpracování a reakce, výpadky
  - nespolehlivá síť, neomezená doba doručení zprávy, ztráta, duplikace, pořadí

- **Paxos**
  - rodina protokolů pro asynchronní fault-tolerantní konsensus
    - *výpadek není výjimka, ale běžný stav*
  - Lamport:
    - 1989 *rejected!*
    - 1998 The Part-Time Parliament
    - 2001 Paxos Made Simple
  - výpadek F uzlů tolerován při celkem 2F+1 uzlech
    - formálně dokázaná korektnost
    - neřeší se úmyslné podvádění
    - Byzantine Paxos
  - základ řady moderních systémů:
    - Chubby (Google), Zookeeper (Yahoo), ...

Part-Time Parliament

- Part-time parliament
  - poslanci *(legislators, procesy)* - schvalují zákóny
  - poslíčci *(messengers, zprávy)* - doručují zprávy mezi Lagislatory
  - poslanci/poslíčci můžou na čas odejít (havárie/výpadek)
- Problém
  - poslanci nejsou ochotni zůstat na celé jednání
  - poslíček je důvěryhodný, ale nespolehlivý
    - nemění zprávy, může ale odejít na 5 minut, na 3 týdny nebo navždy
  - poslíček může zprávu doručit několikrát
- Způsob řešení
  - každý poslanec má zákoník a nesmazatelný inkoust
  - zaznamenává všechny návrhy
- Vlastnosti
  - Netrivialita: akceptovaná může být pouze navržená hodnota
  - Korektost: všechny uzly se shodnou na stejné hodnotě
  - Konečnost: v konečném čase všechny uzly akceptují navrženou hodnostu

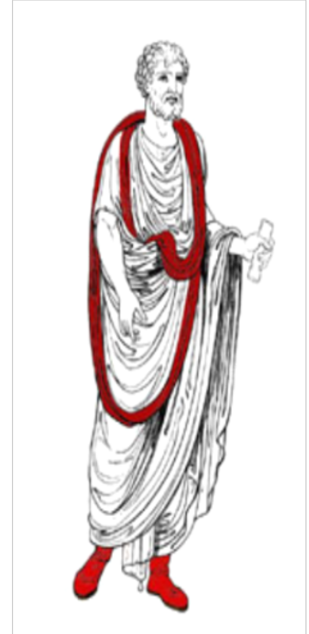

Paxos - role

Hlavní role

- **Proposer**
  - navrhuje nový stav, řeší konflikty
- **Acceptor**
  - přijímá nebo odmítá návrhy, sdružení v Quoru
- **Learner**
  - reprezentuje repliky, provádí změnu na základě akceptovaného stavu

Další role

- **Client**
  - zadává požadavek na změnu stavu
- **Leader** (Primary Proposer)
  - vybraný Proposer - pro přechod do dalšího stavu

Quorum

- libovolná většinová podmnožina Acceptorů
- zpráva od Acceptora je platná až po příjmu zpráv celého Quora

Ballot numbers

Uspořádání

- **Ballot numbers** - sekvenční čísla [num, process id]
  - [n1, p1] > [n2, p2]
    - n1 > n2
    - n1 = n2 & p1 > p2
    - lokálně monotónní globální uspořádání, jednoznačné
- Volba Ballot
  - poslední známý Ballot [n, q]
  - pak p zvolí [n+1, p]
- Procesy akceptují pouze zprávy s **nejvyšším** Ballot

volební číslo

Proměnné (lokální pro každou roli)

- LastBallot - poslední Ballot (návrh) iniciálně [0,0]
- AcceptBallot - poslední akceptovaný Ballot iniciálně [0,0]
- AcceptValue - poslední akceptovaná hodnota iniciálně ∅

Základní Paxos protokol

- **1. fáze**

Proposer : Prepare
if isLeader
Ballot ← [Ballot.num+1,myId]
send Prepare(Ballot) Acceptorům

Acceptor : Promise
receive Prepare(bal)
if bal ≥ LastBallot
LastBallot ← bal
send Promise(bal, AcceptBallot, AcceptValue)

- **2. fáze**

Proposer : Accept
Quorum * receive Promise(bal, ab, av)
if ∃ av ≠ ∅ myVal ← av s nejvyšším ab
else myVal ← □
send Accept (Ballot, myVal) Acceptorům

Acceptor : Accepted
recieve Accept(bal, val)
if bal ≥ LastBallot
AcceptBallot ← bal; AcceptVal ← val
send Accepted(bal, val) všem Proposerům a Learnerům

podmínka: alespoň **Quoru** Acceptorů

nekaceptuje 'starší' návrhy

poslední **akceptovaná** hodnota

opt.: else NAK

musí respektovat nejvyšší návrh

jinak vlastní návrh

pouze nejnovější

akceptace návrhu

presistent store

Paxos - základní komunikace

client proposer acceptor learner

Request

Prepare(1)

1. fáze

Promise(1,0,0)

2. fáze

Accept(1,x)

Accepted(1,x)

Response

Paxos - výpadky bez režie

client proposer acceptor learner

Výpadek Acceptora
|Acceptorts | ≥ Quorum

Výpadek Learnera

výpadek není výjimka
ale běžný stav

Paxos - výpadek Proposera

client proposer acceptor learner

výpadek před dosažením konsensu

Leader election

Request

Prepare(n)

Promise(n)

Accept(n) - nekompletní

Prepare(**n+1**)

Promise(n+1)

Accept(n+1)

Paxos - competing Proposers

Konflikt

- více Proposerů se střídavě prohlašuje za Leadery
  - např. při oživení po havárii
  - mezitím volba nového Leadera
- konečnost není deterministicky zaručena
- praktická implementace OK
  - komunikace mezi Proposery
- není porušena korektnost!

Paxos - pozorování

- Fáze 1
  - neposílají se žádné hodnoty
  - Leader očekává většinu (Quorum) hlasů pro jeho návrh
  - k čemu je fáze dobrá: zajištění konzistence s nižšími Ballot
- Fáze 2
  - Leader navrhuje hodnotu s nejvyšším Ballot z fáze 1
    - nebo může navrhnout vlastní hodnotu
  - akceptace hodnoty ⇒ potvrzení leadera
- Stabilní úložiště
  - musí přežít výpadek uzlu
    - obsahuje informace, které si musí uzel pamatovat po znovuoživení
  - Acceptor uloží stav před vlastní odpovědí
- Počet zpráv Learnerům
  - každý Acceptor každému Learneru
  - jeden vybraný Learner / množina
  - více Learnerů ⇒ vyšší spolehlivost / vyšší komunikace

Paxos – invarianty, formální důkaz

$I1(p) \triangleq$ [Associated variable: $outcome[p]$]

$$(outcome[p] \neq \text{BLANK}) \Rightarrow \exists B \in \mathcal{B} : (B_{qrm} \subseteq B_{vot}) \wedge (B_{dec} = outcome[p])$$

$I2(p) \triangleq$ [Associated variable: $lastTried[p]$]

$$\begin{aligned}&\wedge\ owner(lastTried[p]) = p\\ &\wedge\ \forall B \in \mathcal{B} : (owner(B_{bal}) = p) \Rightarrow\\ &\qquad\qquad \wedge\ B_{bal} \leq lastTried[p]\\ &\qquad\qquad \wedge\ (status[p] = trying) \Rightarrow (B_{bal} < lastTried[p])\end{aligned}$$

$I3(p) \triangleq$ [Associated variables: $prevBal[p]$, $prevDec[p]$, $nextBal[p]$]

$$\begin{aligned}&\wedge\ prevBal[p] = MaxVote(\infty, p, \mathcal{B})_{bal}\\ &\wedge\ prevDec[p] = MaxVote(\infty, p, \mathcal{B})_{dec}\\ &\wedge\ nextBal[p] \geq prevBal[p]\end{aligned}$$

$I4(p) \triangleq$ [Associated variable: $prevVotes[p]$]

$$\begin{aligned}&(status[p] \neq idle) \Rightarrow\\ &\quad \forall v \in prevVotes[p] : \wedge\ v = MaxVote(lastTried[p], v_{pst}, \mathcal{B})\\ &\qquad\qquad\qquad\qquad\quad \wedge\ nextBal[v_{pst}] \geq lastTried[p]\end{aligned}$$

$I5(p) \triangleq$ [Associated variables: $quorum[p]$, $voters[p]$, $decree[p]$]

$$\begin{aligned}&(status[p] = polling) \Rightarrow\\ &\quad \wedge\ quorum[p] \subseteq \{v_{pst} : v \in prevVotes[p]\}\\ &\quad \wedge\ \exists B \in \mathcal{B} : \wedge\ quorum[p] = B_{qrm}\\ &\qquad\qquad\qquad\quad \wedge\ decree[p] = B_{dec}\\ &\qquad\qquad\qquad\quad \wedge\ voters[p] \subseteq B_{vot}\\ &\qquad\qquad\qquad\quad \wedge\ lastTried[p] = B_{bal}\end{aligned}$$

$I6 \triangleq$ [Associated variable: $\mathcal{B}$]

$$\begin{aligned}&\wedge\ B1(\mathcal{B}) \wedge B2(\mathcal{B}) \wedge B3(\mathcal{B})\\ &\wedge\ \forall B \in \mathcal{B} : B_{qrm} \text{ is a majority set}\end{aligned}$$

$I7 \triangleq$ [Associated variable: $\mathcal{M}$]

$$\begin{aligned}&\wedge\ \forall NextBallot(b) \in \mathcal{M} : (b \leq lastTried[owner(b)])\\ &\wedge\ \forall LastVote(b, v) \in \mathcal{M} : \wedge\ v = MaxVote(b, v_{pst}, \mathcal{B})\\ &\qquad\qquad\qquad\qquad\qquad\quad \wedge\ nextBal[v_{pst}] \geq b\\ &\wedge\ \forall BeginBallot(b, d) \in \mathcal{M} : \exists B \in \mathcal{B} : (B_{bal} = b) \wedge (B_{dec} = d)\\ &\wedge\ \forall Voted(b, p) \in \mathcal{M} : \exists B \in \mathcal{B} : (B_{bal} = b) \wedge (p \in B_{vot})\\ &\wedge\ \forall Success(d) \in \mathcal{M} : \exists p : outcome[p] = d \neq \text{BLANK}\end{aligned}$$

Paxos - protokoly

Paxos Family

- Basic Paxos - základní verze protokolu, konsensus pouze jedné hodnoty
  - prakticky nepoužitelný
- Multi-Paxos - kontinuální opakování, základ typické implementace
- Cheap Paxos - rozšíření pro 'levnou' (nahraditelnou) toleranci havarovaných uzlů
- Fast Paxos - optimalizace doručování zpráv
- Byzantine Paxos - rozšíření pro záškodníky *byzantine failures*
  - Generalized Paxos - optimalizace pro konkurentní komutativní operace
- další protokoly, optimalizace, rozšíření
  - Disk P., Vertical P., Stoppable P., Egalitarian P., Leaderless P., ...

- 2008 Google: Paxos Made Live
- 2014 Meling, Jehl: Paxos Explained from Scratch
- 2015 Van Renesse, Altinbuken: Paxos Made Moderately Complex

RAFT

- 2014 Ongaro, Ousterhout: In Search of an Understandable Consensus Algorithm

Multi-Paxos

- Fáze 1
  - zajištění konzistence s nižšími Ballot
- Optimalizace
  - fáze 1 nutná jen při změně Leadera
  - implementační názvosloví: "view change", "recovery mode"

- Multi-Paxos
  - kontinuální pokračování Basic Paxos
  - nejčastější základ praktické implementace
  - stabilní Leader ⇒ pouze fáze 2
  - technicky protokol doplněn o číslo 'instance'
  - implementace: uzly mohou zastávat více rolí
    - třeba i všechny

Accept(n,i,v1); Accepted(n,i,v1)
Accept(n,i+1,v2); Accepted(n,i+1,v2)

- Distributed State Machine
    - deterministické změny stavů dle akceptovaných hodnot
    - replikované úložiště dat

Multi-paxos - komunikace

client proposer acceptor learner

Request

Prepare(1,i,...)

Promise(1,i,...)

Accept(1,**i**,...)

Accepted(1,**i**,...)

Response

Request

Accept(1,**i+1**,...)

Accepted(1,**i+1**,...)

Response

Fast Paxos

- Optimalizace - redukce prodlev při doručování zpráv
  - Basic Paxos - 3 zprávy do přijetí hodnoty
  - Fast Paxos - 2 zprávy - za cenu zaslání požadavku Clientem více uzlům
- Protokol
  - Client zašle Accept přímo Acceptorům
  - Accepted Leaderu a Learnerům
- Kolize - více konkurentních Clientů
  - Leader určí pořadí a pošle serializovaně nové Accepty

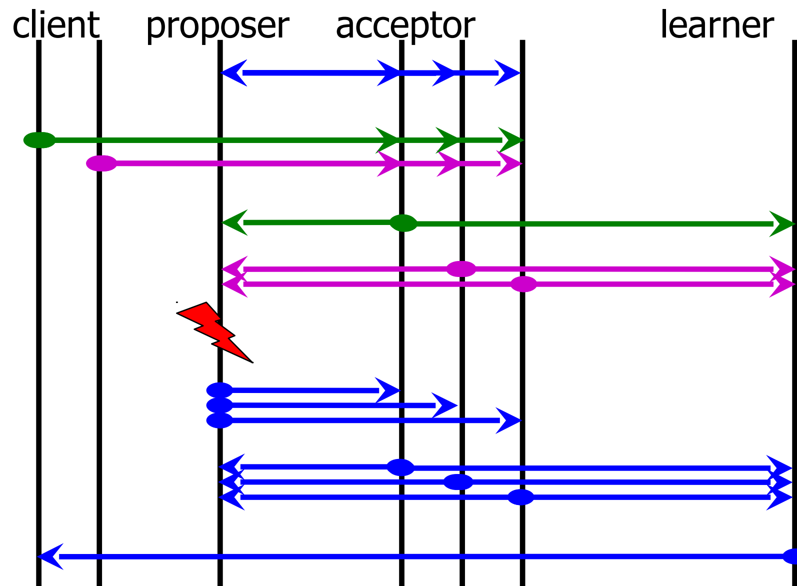

Prepare/Promise(n,i)

Accept - doručení v různém pořadí

Accepted(c1)

Accepted(c2)

Detekce kolize

Leader přebírá synchronizaci

Cheap Paxos

- Rozšíření - tolerance F havarujících uzlů při F+1 uzlech celkově
  - potřeba dalších F uzlů připravených v záloze
  - dynamická rekonfigurace po každé havárii
  - redukce uzlů potřebných k fault-tolerantnosti za cenu zvýšené režie při výpadku

proposer acceptor aux learner

Quorum = 3

Accept

Výpadek

Acepted - detekce havárie

Rekonfigurace

Accept - retransmise

Accepted

Byzantine Paxos

- Ochrana před (ne)úmyslně nekorektním chováním
  - uzel může měnit zprávy, nerespektovat protokol apod.
- Přidáno kolo vzájemně ověřovacích zpráv - Verify
  - lze optimalizovat - broadcast zároveň s Accepted
- V případě nekonzistence si korektní Acceptoři vzájemně přeposílají hodnoty
- Learner čeká, dokud nepřijme alespoň F+1 stejných rozhodnutí

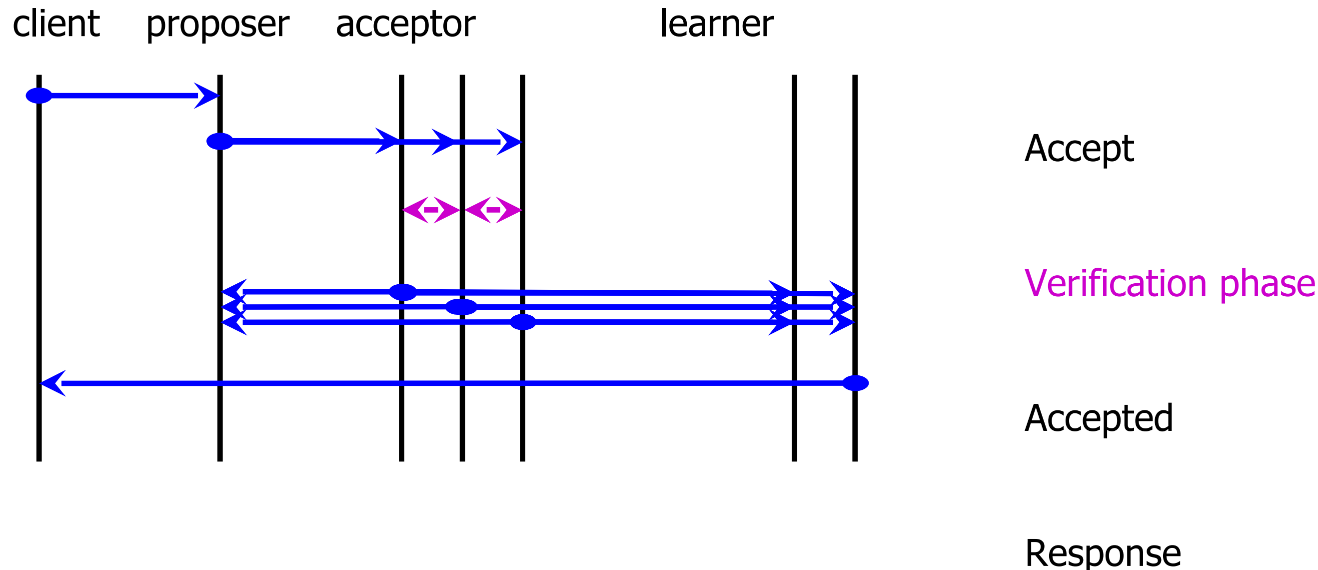

Paxos - reálné použití

- Google Chubby
  - fault-tolerant distributed coarse-grained locking
  - typicky 5 replik, 1 master
    - periodický lease
  - při havárii automatická volba nového leadera
  - hierarchický prostor jmen
    - filesystem API
    - permanent/ephemeral files
  - exclusive/shared lock (rw/ro)
  - dobrovolná sémantika
  - client-side write-through caching

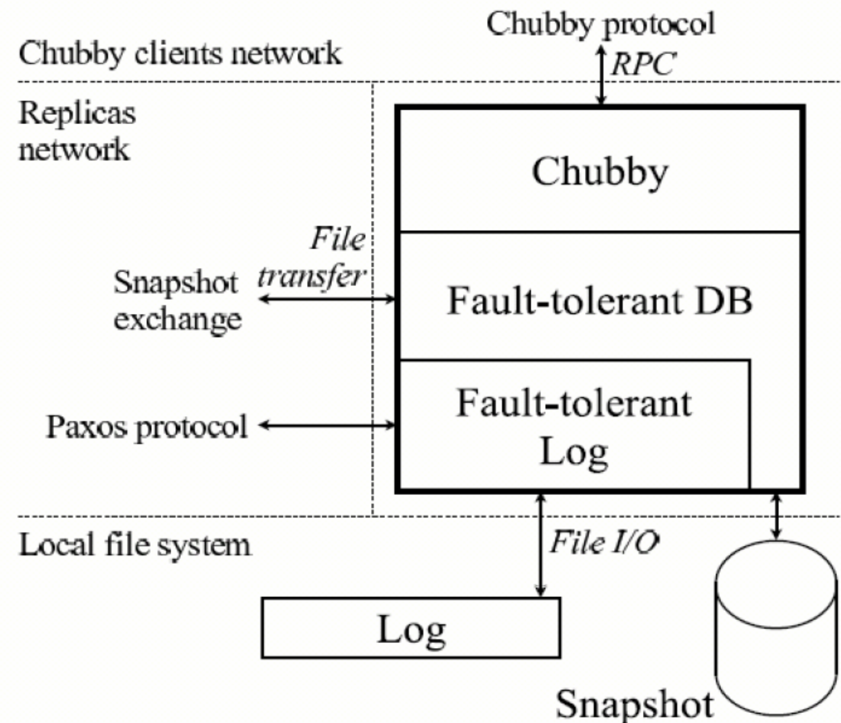

Paxos - reálné použití

- Yahoo Zookeeper
  - high-performance coordination service for distributed applications
  - naming, synchronization, consensus, group membership, leader election, queues, event notifications, configuration, workflow & cluster management, sharding, ...
  - na principech Paxosu, implementační detaily odlišné
- Microsoft Autopilot
  - automatic data center management infrastructure
    - až 100.000 uzlů
  - informace o stavu v replikovaném stavovém automatu
    - 1-10 replik
- Cassandra
  - NoSQL column-oriented DB
- BigTable
  - distributed storage at Google, BigDataAnalytics
- OpenReplica
  - OO coordination service for distributed applications
- ...

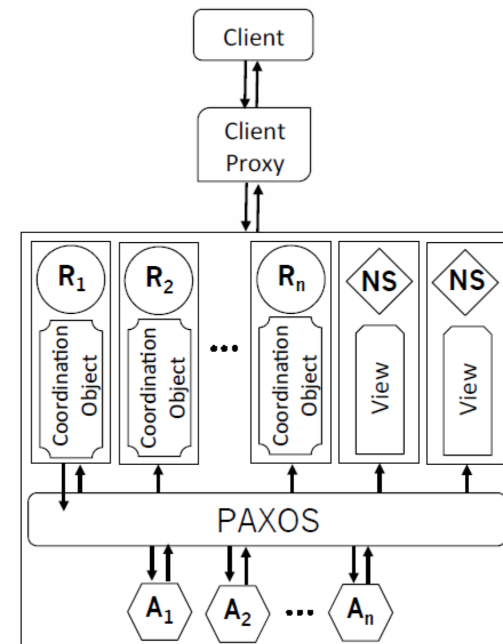

Distribuovaná sdílená paměť

Distribuovaná sdílená paměť

- Paralelní výpočty
  - multiprocesory
    - malý počet procesorů
    - hardwarově náročné, 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
    - virtual memory
  - Distribuované sdílené proměnné a objekty
    - languages / libraries / frameworks

Mechanismy sdílení paměti

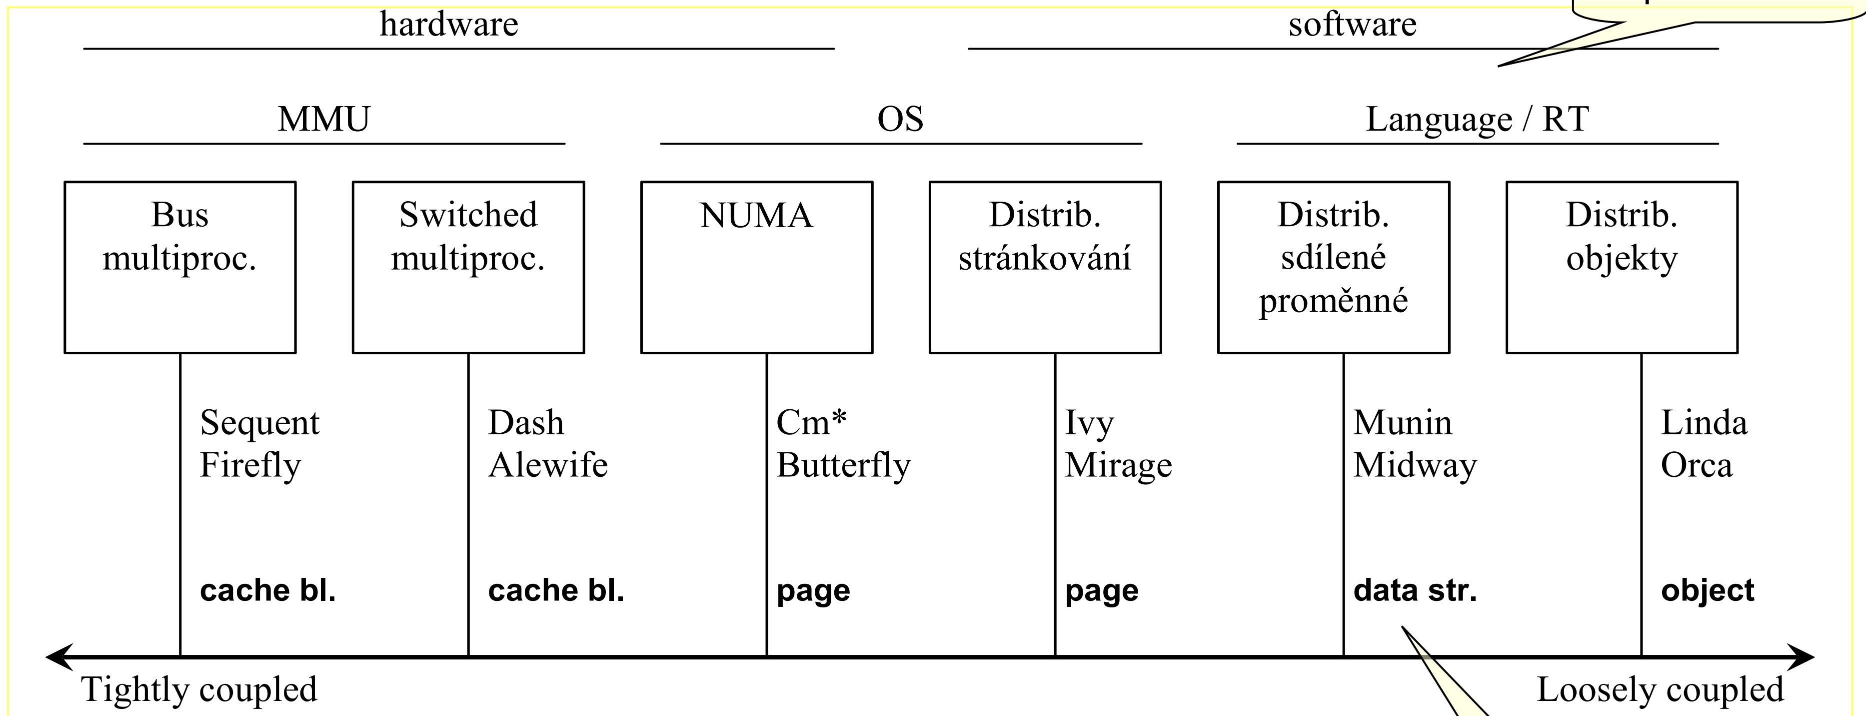

BusMP - Firefly - DEC, 5xVAX on a bus, snoopy cache
SwMP - Dash - Stanford, Alewife - MIT
Cm - hw přístup do maměti, sw caching*

Distributed paging - Ivy, Li ... T4
Mirage - Bershad 1990
Munin - Benett 1990

Konzistenční modely DSM

- Primitiva
  - Read, Write
  - sdílený adresový prostor

- Konzistenční model
  - specifikace co implementace musí splňovat vzhledem k operacím čtení a zápis
  - konzistenční modely pro virtuální paměť
  - konzistenční modely pro knihovny / spec. jazyky - explicitní synchronizace

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 adresy x vrátí hodnotu uloženou při posledním zápisu na adresu x

- zajišťuje absolutní časové uspořádání
- nejsilnější, na jednoprocesorových 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 ekvivalentní s
- všechny operace všech uzlů jsou vykonávány v nějakém sekvenčním uspořádání
- operace každého uzlu jsou vykonávány v pořadí daném programem

- o něco slabší model
  - snadno implementovatelná
  - příjemná pro programování
  - povoleno libovolné prokládání instrukcí na různých procesorech
  - **všechny** procesy vidí **stejné** 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:	P2:	P3:
a=1;	b=1;	c=1;
print(b,c);	print(a,c);	print(a,b);

šest instrukcí - 6!=720 možných uspořádání

pouze 3*(5!/4)=90 nenarušuje konzistenci

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

- 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

Sekvenční konzistence

```
a=1;     b=1;     c=1;
print(b,c);     print(a,c);     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 v sekvenčně konzistenčním modelu nedosažitelná

- 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

Kauzální konzistence

Causal consistency

Kauzálně závislé zápisy musí být viděny všemi uzly 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 ≈ odeslání, čtení ≈ přijetí

konkurenční zápisy

rozdílné čtení konkurenčních zápisů

P1:	W(x)1			W(x)3		
P2:		R(x)1	W(x)2			
P3:		R(x)1			R(x)3	R(x)2
P4:		R(x)1			R(x)2	R(x)3

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

porušení kauzální konzistence (přidaná operace čtení)

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

není kauzálně konzistentní

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

PRAM konzistence

PRAM (Pipelined RAM) consistency

Zápisy prováděné jedním uzlem jsou viděny ostatními uzly v pořadí provádění.
Zápisy různých uzlů mohou být viděny různými uzly 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:	***P2:***	***P3:***
`a=1;`	`b=1;`	`c=1;`
`print(b,c);`	`print(a,c);`	`print(a,b);`

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

Konzistenční modely se synchronizační proměnnou

- Doposud 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)

Konzistenční modely se synchronizační proměnnou

- Doposud 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

Slabá konzistence

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

po synchronizaci musí být data aktuální

P1: W(x)1 W(x)2 **S**
P2: **S R(x)1**

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

Výstupní konzistence

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

Výstupní konzistence

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

P2: **Acq** R(x)2 **Rel**

P3: R(x)1

release consisteny

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
    - optimlizace síťového provozu

Vstupní konzistence

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 vstupovat a vystupovat z k.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

Shrnutí konzistenčních modelů

bez SP

s SP

Konzistence	*Vlastnosti*
Striktní	Absolutní časové uspořádání
Sekvenční	Všechny události jsou vidět ve stejném pořadí
Kauzální	Kauzálně vázané události jsou vidět ve stejném pořadí
PRAM	Události jednoho uzlu jsou vidět ve stejném pořadí
Slow mem	Zápisy jednoho uzlu na jedno místo jsou vidět ve stejném pořadí
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
  - potenciálně 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*

Distribuované stránkování

- Obdoba virtuální paměti
  - přístup k nenamapované stránce - přerušení, obsluha, načtení
- Problémy
  - replikace → konzistence *jak udržovat data konzistentní*
    - read-only mapování, při zápisu přerušení → synchronizační akce
    - invalidace vs. aktualizace
  - nalezení stránky *jak nalézt distribuovaná data*
    - centralizovaný manager
    - replikovaný manager - indexace spodními n bity / hash
    - broadcast
  - 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*

Distribuované stránkování

- Obdoba virtuální paměti
  - přístup k nenamapované stránce - přerušení, obsluha, načtení
- Problémy
  - replikace → konzistence *jak udržovat data konzistentní*
    - read-only mapování, při zápisu přerušení → synchronizační akce
    - invalidace vs. aktualizace
  - nalezení stránky *jak nalézt distribuovaná data*
    - centralizovaný manager
    - replikovaný manager - indexace spodními n bity / hash
    - broadcast
  - 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*

Distribuované stránkování

- Obdoba virtuální paměti
  - přístup k nenamapované stránce - přerušení, obsluha, načtení
- Problémy
  - replikace → konzistence *jak udržovat data konzistentní*
    - read-only mapování, při zápisu přerušení → synchronizační akce
    - invalidace vs. aktualizace
  - nalezení stránky *jak nalézt distribuovaná data*
    - centralizovaný manager
    - replikovaný manager - indexace spodními n bity / hash
    - broadcast
  - 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*

Distribuované stránkování

- Obdoba virtuální paměti
  - přístup k nenamapované stránce - přerušení, obsluha, načtení
- Problémy
  - replikace → konzistence *jak udržovat data konzistentní*
    - read-only mapování, při zápisu přerušení → synchronizační akce
    - invalidace vs. aktualizace
  - nalezení stránky *jak nalézt distribuovaná data*
    - centralizovaný manager
    - replikovaný manager - indexace spodními n bity / hash
    - broadcast
  - 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*

Distribuované stránkování - falešné sdílení

- Problémy
  - falešné sdílení *nezávislá data na stejné stránce*

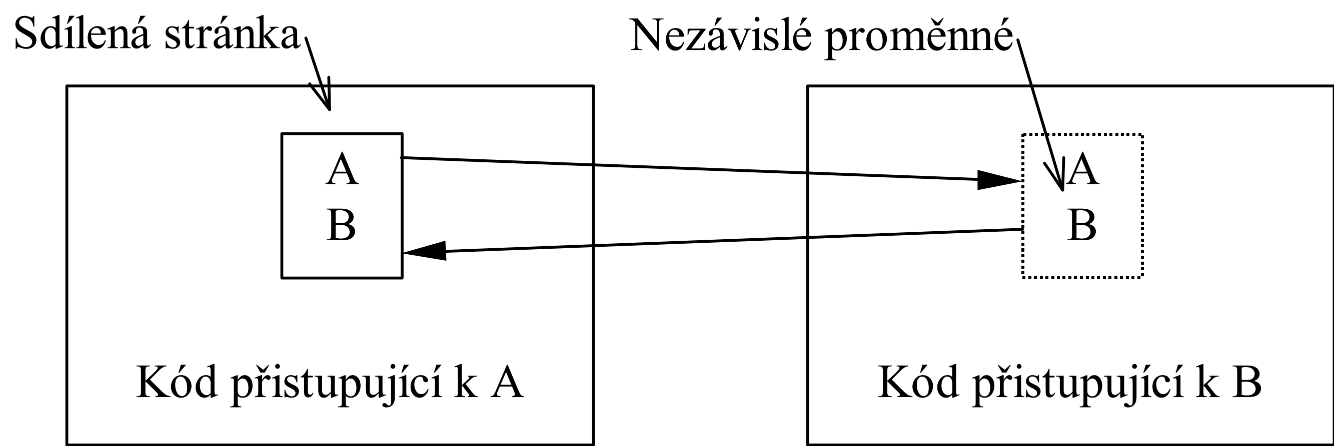

Sekvenčně konzistentní distribuované stránkování

čtení

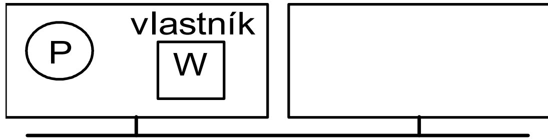

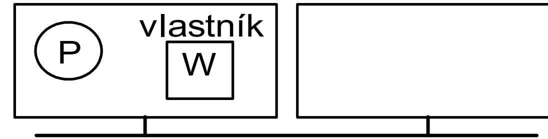

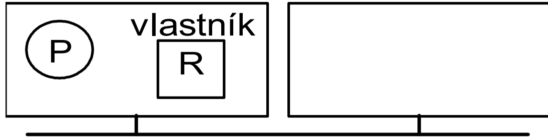

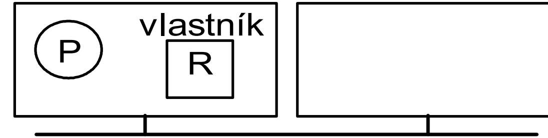

Povýšení

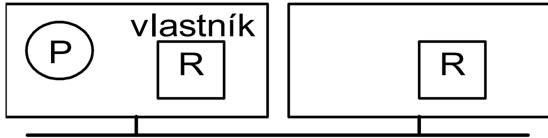

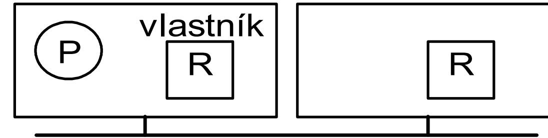

Invalidace, povýšení

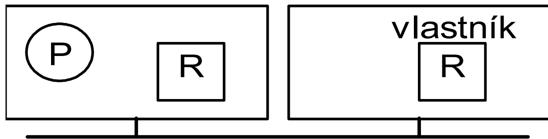

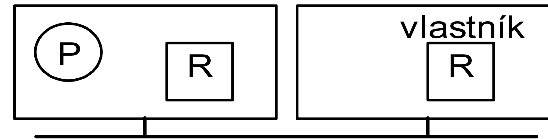

Invalidace, změna vlastníka, povýšení

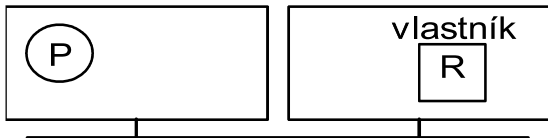

Kopie

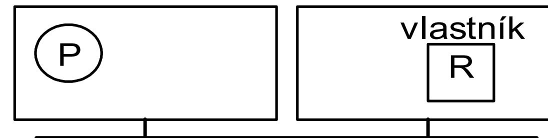

Invalidace, kopie, změna vlastníka, povýšení

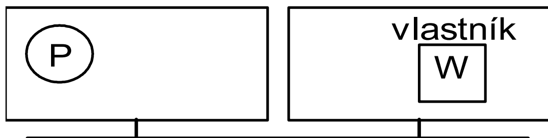

Degradace, kopie

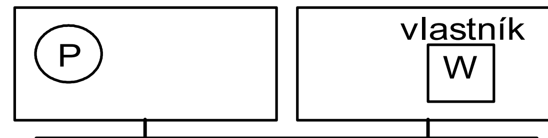

Invalidace, kopie, změna vlastníka, povýšení

kradení - viskozita

Kauzálně konzistentní distribuované stránkování

- základní idea – graf závislostí
- vektorové hodiny:
  - VT_S jednotka granularity (stránky)
  - VT_P procesy
- $VT[i] \approx$ stránka i
- výpadek stránky – přenos dat, $VT_P = \max(VT_S, VT_P)$
- zápis do stránky – $VT_S = \mathrm{inc}(VT_P)$
- aktualizace VT_P – zneplatnění stránek i: $VT_{Si}[i] < VT_P[i]$

na kterých stránkách závisí obsah

z kterých stránek znám data

jak OS pozná zápis?
změna mapování

- Problémy:
  - velká prostorová režie (1 MB = 256 stránek = 512 B / stránku)
  - propagace konkurentních zápisů
    - zámky, bariéry, timeouty

Kauzálně konzistentní distribuované stránkování

	P1	A	B		P2	A	B		P3	A	B
	00	$_{00}$**R**0			00		$_{00}$**R**0		00		
wA1	10	$_{10}$**W**1		**wB1**	01		$_{01}$**W**1				
							$_{01}$**R**1	**rB1**	01		$_{01}$**K**1
				wB2	02		$_{02}$**W**2				
rB2	12	$_{10}$**W**1	$_{02}$**K**2				$_{02}$**R**2	**rB1**			
wA2	22	$_{22}$**W**2									
	22	$_{22}$**R**2						**rA2**	22	$_{22}$**K**2	02 -

W - právo zápisu, R - r/o vlastník, K - r/o kopie

Kauzálně konzistentní distribuované stránkování

- základní idea – graf závislostí
- vektorové hodiny:
  - VT_S jednotka granularity (stránky)
  - VT_P procesy

na kterých stránkách závisí obsah

z kterých stránek znám data

- VT[i] ≈ stránka i
- výpadek stránky – přenos dat, $VT_P = \max(VT_S, VT_P)$
- zápis do stránky – $VT_S = inc(VT_P)$
- 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
    - zámky, bariéry, timeouty

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 rekompilace

- 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, ...

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 rekompilace

- 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, ...

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

Správa prostředků a procesů

Distribuovaná správa prostředků

- Centralizované řešení - resource manager
  - teoretické pokusy o distribuovanou správu
  - prakticky nepoužitelné - *distribuované vyloučení procesů*
- Migrace - identifikace, komunikace
- Replikované servery – aktualizační protokol

- Uváznutí (deadlock)
  - časté řešení - pštrosí algoritmus
  - detekce - větší problém než u centralizovaných systémů
  - WFG – Wait-For-Graph
    - orientovaný graf (procesů, transakcí)
    - P1 → P2 proces P1 je blokován procesem P2
    - P → R proces P žádá o prostředek R
    - R → P proces P drží prostředek R
    - orientovaná kružnice – uváznutí

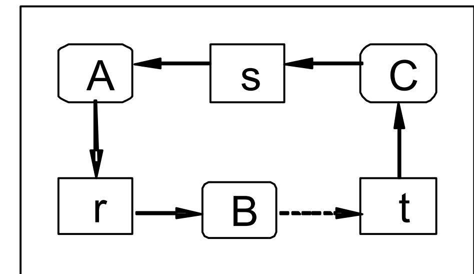

Algoritmy detekce deadlocků

- 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*

Algoritmy detekce deadlocků

- 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

Centralizovaný algoritmus

- *Ho-Ramamoorthy, Bernstein*
- Přenos informací:
  - po každé změně lokálního stavu
  - v pravidelných intervalech
  - na požádání
- Problém - falešné uváznutí kvůli zpoždění zpráv
  - řešení: logické hodiny, kauzální doručování
  - alternativně: při podezření kontrola
- Rozšíření - hierarchický algoritmus
  - uzel řeší deadlocky lokálně
  - koordinátor řeší deadlocky podřízených uzlů

fyzické pořadí: rel r->B, acq B->t
doručení: acq B->t, rel r->B

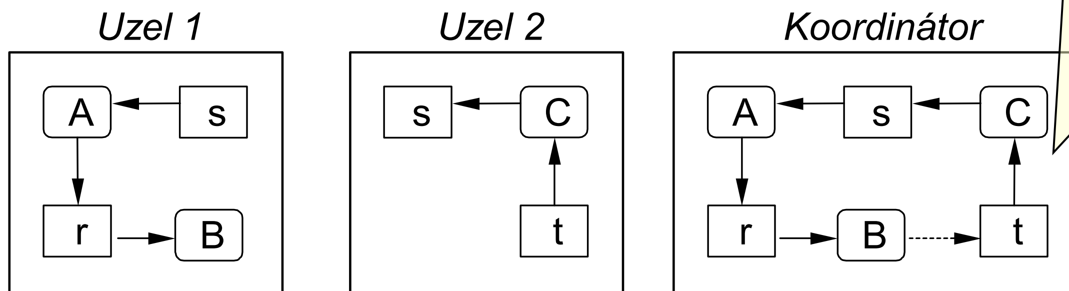

Detekce falešného deadlocku

p_1 r_1 r_2 p_2

Req

Ok

Req

o_1

o_2

Ok

Rel

Req

Ok

o_3

Req

o_4

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

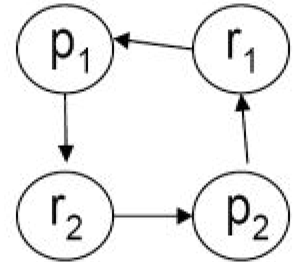

From $O=\{o_1,o_2,o_3,o_4\}$ the deadlock detector concludes there is a deadlock!

Path-pushing

- *Obermarck, Menasce-Muntz, Gligor-Shattuck, Ho-Ramamoorthy*
- WFG distribuovaný, uzly spravují lokální části WFG
- Sousedním uzlům jsou zasílány externí závislosti
- Některé publikované algoritmy/protokoly nekorektní
    - phantom deadlock

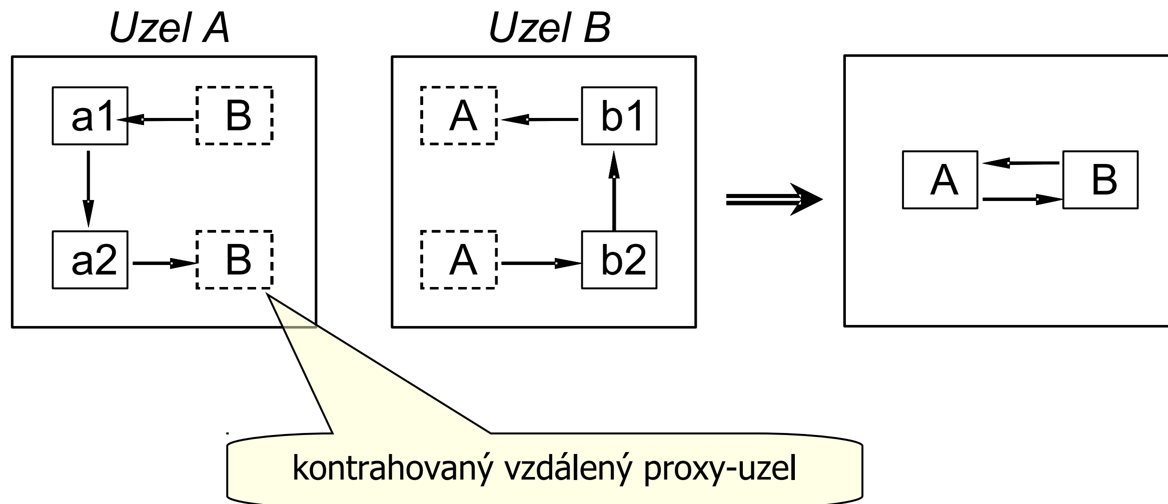

Path-pushing

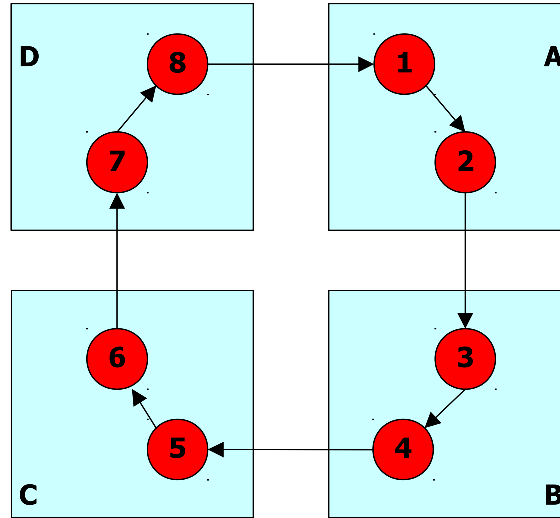

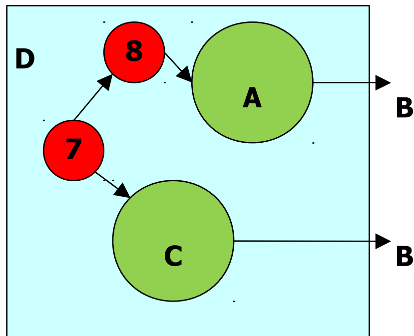

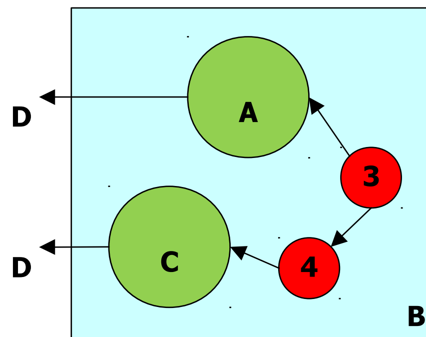

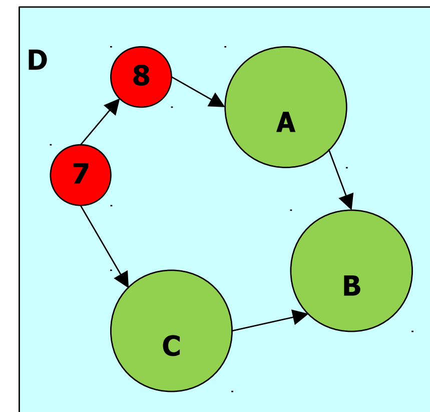

Edge-chasing

- *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 odesilateli – deadlock (orientovaná kružnice)
  - kratší zprávy, nezjišťuje ale celý WFG
- Paralelní spuštění - overkill
  - zpráva zároveň hledá vhodného kandidáta

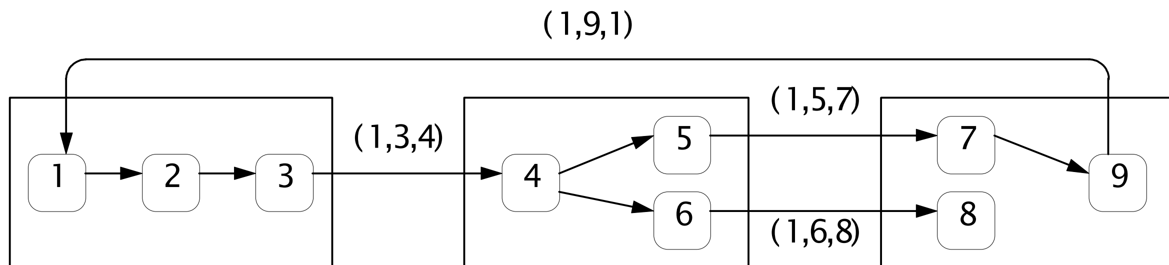

Edge-chasing Chandy-Misra-Haas

Sending the probe:

if Pi is locally dependent on itself then deadlock

else for(all Pj and Pk such that Pi is locally dependent upon Pj

& Pj is waiting on Pk & Pj and Pk are on different sites)

send probe(i,j,k) to the home site of Pk

Receiving the probe(i,j,k):

if Pk is blocked & $dependent_k(i)$ is false & Pk has not replied to all requests of Pj {

$dependent_k(i)$:= true;

if k = i then Pi is deadlocked

else ... *(send)*

}

Pk ví o tom, že
Pi čeká na Pk

Další algoritmy detekce deadlocků

- **Diffusing computation**
  - *Chandy-Misra-Haas, Chandy-Herrmann*
  - ‘distribuovaný výpočet’ podél WFG
    - aplikace značkového algoritmu pro detekci ukončení
  - první zpráva: propagace, další zprávy: signál, všechny signály: signál otci
  - pokud se zpráva dostane k iniciátorovi, vracejí se signály
  - iniciátor po obržení signálu může rozhodnout
  - vhodné pro složitější modely *(OR, n-nad-m)*

- **Detekce globálního stavu**
  - *Bracha-Toueg, Kshemkalyani-Singhal*
  - jestliže WFG → 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
  - varianty
    - celý WFG iniciátorovi
    - lokální kontrakce WFG, externí závislosti zaslány iniciátorovi
    - redukovaný WFG sousedům (ala edge-chasing)

Další algoritmy detekce deadlocků

- **Diffusing computation**
  - *Chandy-Misra-Haas, Chandy-Herrmann*
  - 'distribuovaný výpočet' podél WFG
    - aplikace značkového algoritmu pro detekci ukončení
  - první zpráva: propagace, další zprávy: signál, všechny signály: signál otci
  - pokud se zpráva dostane k iniciátorovi, vracejí se signály
  - iniciátor po obržení 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
  - varianty
    - celý WFG iniciátorovi
    - lokální kontrakce WFG, externí závislosti zaslány iniciátorovi
    - redukovaný WFG sousedům (ala edge-chasing)

Distribuované procesy

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

- Rozdílné cíle i prostředky
  - kooperativní systém, distribuované výpočty
    - rovnoměrné sdílení výkonu
    - decentralizovaná / peer-to-peer správa
  - služby vnějším klientům, cluster
    - krátkodobé úlohy - minimalizace response-time
    - dlouhodobé úlohy - maximalizace výkonu
    - centralizovaná / hierarchická správa

- Load balancing / vyvažování zátěže
- Kooperativní systémy
- Migrace procesů

Load balancing

- homogenní prostředí
- centralizovaná / replikovaná správa
- load balancer / task scheduler

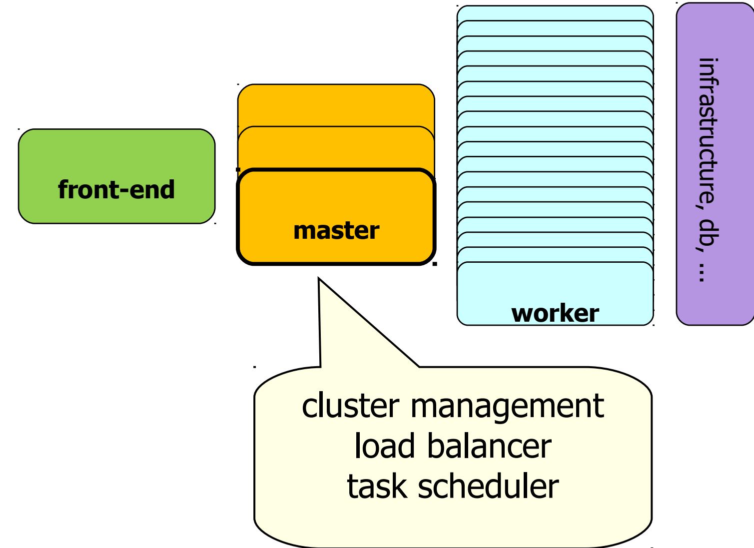

- vyvažovací strategie
  - Round Robin
    - homogenní systém, krátké/srovnatelné úlohy
  - Weighted Round Robin
    - váha dle výkonnosti
  - Dynamic Round Robin
    - periodické měření aktuální výkonnosti, vyhlazení, klouzavý průměr
  - Agent-Based Adaptive Balancing, Resource-based Scheduling
    - 'chytřejší' algoritmy na základě aktuální výkonnosti a dalších parametrů
  - Random
    - heterogenní výkonnost i úlohy, neznámé vlastnosti
  - Least Connections, Weighted LC
    - nejmenší počet otevřených úloh

Kooperativní systémy - spouštění procesů

- Spuštění vzdáleného procesu
  - transparentnost
  - přenesení kódu a dat – *nezajímavé*
    - heterogenní prostředí
  - vytvoření prostředí odpovídající domovskému uzlu
    - kontexty (fs, naming, environment)
    - systémová volání – vzdálená / přesměrování

- Hostitelský uzel přestane být volný
  (uživatel se vrátil z oběda, potřeba restartu, ...)
  - doběhnutí
  - zabití
  - čas na uložení / uzavření
  - *migrace*

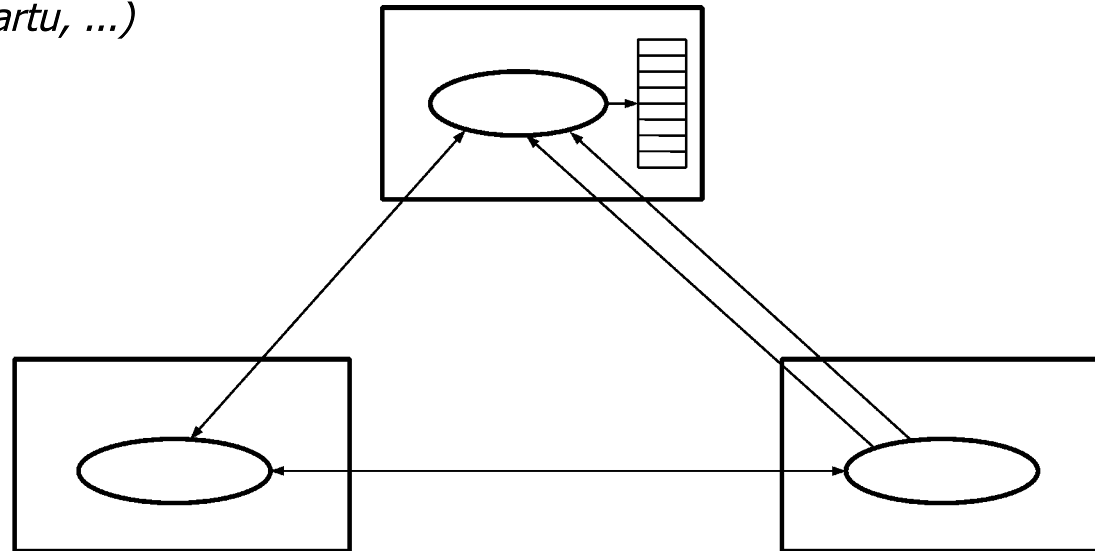

Kooperativní load balancing

- Distribuovaný výpočet, uzly inicují další procesy
  - centralizaované/hierarchické řízení přístupu
    - manažeři skupin, při neúspěchu žádost nadřazenému
    - up-down algoritmus
  - distribuovaný heuristický algoritmus
    - *k* náhodných výběrů cíle
    - server / receiver initiated
  - deterministický grafový algoritmus
    - minimalizace komunikace
    - nutnost znalosti komunikační složitosti
    - optimální deterministický algoritmus – tok v sítích
  - bidding (obchodní, nabídkový) algoritmus
    - procesy kupují výpočetní sílu, procesory ji nabízejí

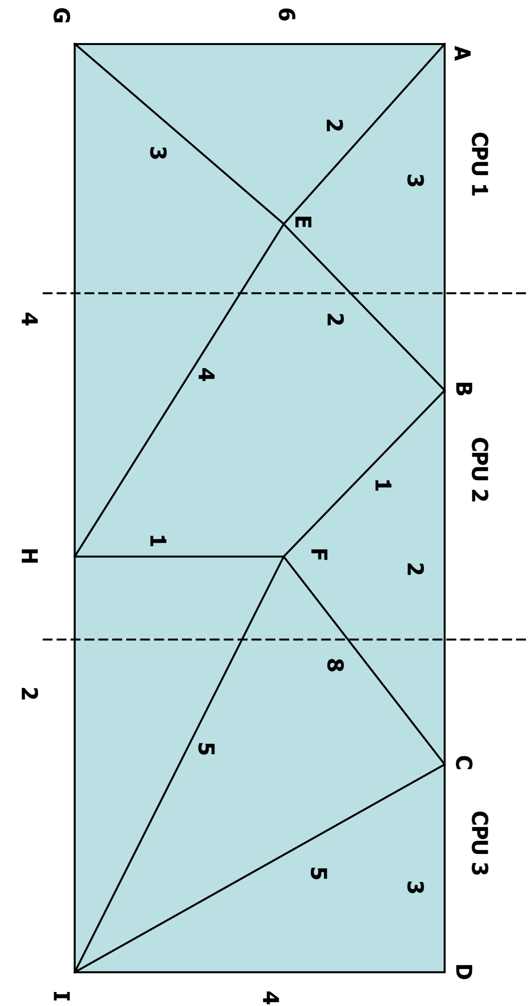

Up-down algoritmus

- Mutka-Livny 1987
- Optimalizace na stejnoměrné sdílení výkonu

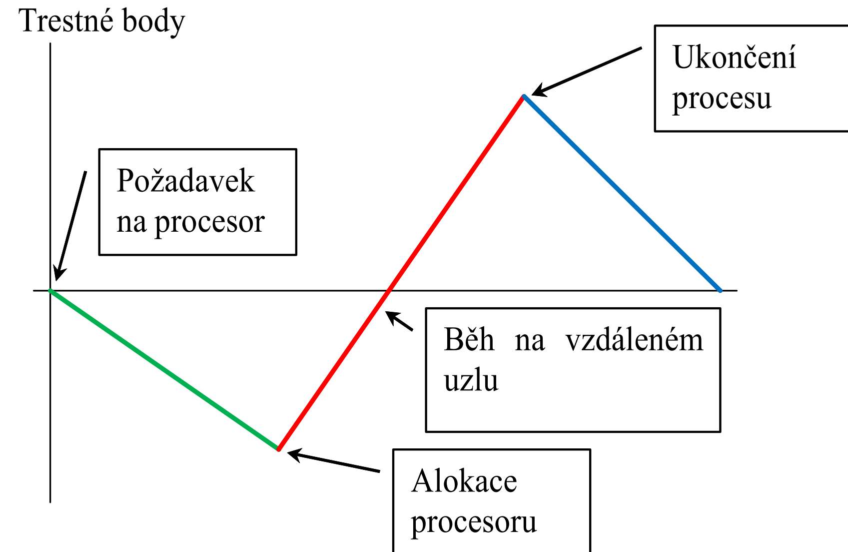

- Koordinátor
  - tabulka se záznamem pro každý uzel obsahující "trestné body"

- Při významné akci
  (vytvoření procesu, ukončení procesu, tik hodin)
  zpráva koordinátoru, který provede změny:
  - každý proces běžící na jiném uzlu - plus trestné body
  - každý neuspokojený požadavek - mínus trestné body
  - jestliže nic z tohoto - směrem k nule

- V okamžiku uvolnění uzlu se vezme ten proces z fronty *(neuspokojených požadavků)*, jehož vysílající uzel má nejméně trestných bodů

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
  - komunikace s ostatními procesy
  - reziduální dependence - žádná, domácí, průběžná, dočasná
  - vícenásobná migrace - viskozita
  - migrace procesů ※ virtuálních strojů

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 ...
  - komunikace s ostatními procesy
  - reziduální dependence - žádná, domácí, průběžná, dočasná
  - vícenásobná migrace - viskozita, hystereze

  - Migrace procesů ※ virtuálních strojů

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 přenese 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 přenese a na zdrojové stanici se smaže

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 přenese 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 přenese a na zdrojové stanici se smaže

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 přenese 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 přenese
    - nutnost evidence různých zdrojů dat pro každou stránku
      - swap, vícenásobná migrace, DSM, ...

Přehled některých migračních systémů

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

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

DEMOS/MP

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 - cílový uzel si proces „tahá“ k sobě
- Přesun adresového prostoru a paměti (*Cíl*)
- Forward čekajících zpráv na cílový uzel (*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

Charlotte

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 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 zdrojovém uzlu zavolá „Migrate Out"
  - podrobnější informace o procesu na cílový uzel - „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 zdrojového uzlu

V

Stanford (Cheriton) 1984-86

síťově transparentní prostředí, 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 zdrojovém uzlu kopíruje adresový prostor; proces stále běží
- migrovaný logický host je zamražen, dokončí se kopírování modifikované paměti
- kopírování stavu z jádra zdrojového uzlu

Odmražení, přesměrování odkazů

- smaže se stará kopie logical hostu, nová se odmrazí
- broadcast nové adresy logical hostu

MOSIX

Technion (Barak, Shiloh, ...) 1988-2008(!)

FreeMosix, Linux Process Migration Infrastructure

UNIX adaptovaný na distribuované prostředí, rozsáhlé vyvažování zátěže

Jeden z mála dlouhodobě reálně používaných distribuovaných systémů

Rozšíření struktury procesu:

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

Vlastní migrace

Příprava

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

Přesun dat - adresový prostor

Rozběhnutí odmigrovaného procesu

Na zdrojém uzlu se smažou lokální data procesu

Sprite

Berkley (Douglis, Ousterhout, Welch) 1992

- Předpoklady:
  - mnoho nevyužitých uzlů
  - 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 uzel
  - transparence vs. reziduálních dependence
  - ze 106 volání Sprite: 91 lokálně, 11 forwardováno, 4 se řeší kooperací
- Virtuální paměť
  - kombinace přesunu veškeré paměti najednou a „copy-on-reference"
- Jednotný mechanismus migrace různých entit
  - každá součást stavu má definovány 4 rutiny
  - pre-migration, encapsulation, de-encapsulation, post-migration routine

T4

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 (málo), výzkum jiným směrem
- pro běžné každodenní použití
  - -- aplikace !!!

Migratory load balancing

- 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 s výpisem 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

Migratory load balancing

- 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

Vektorový algoritmus

- Barak & Shiloh - Mosix
  - distribuce a aktualizace zátěže
  - pevný vektor zátěže L, L[0] = 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

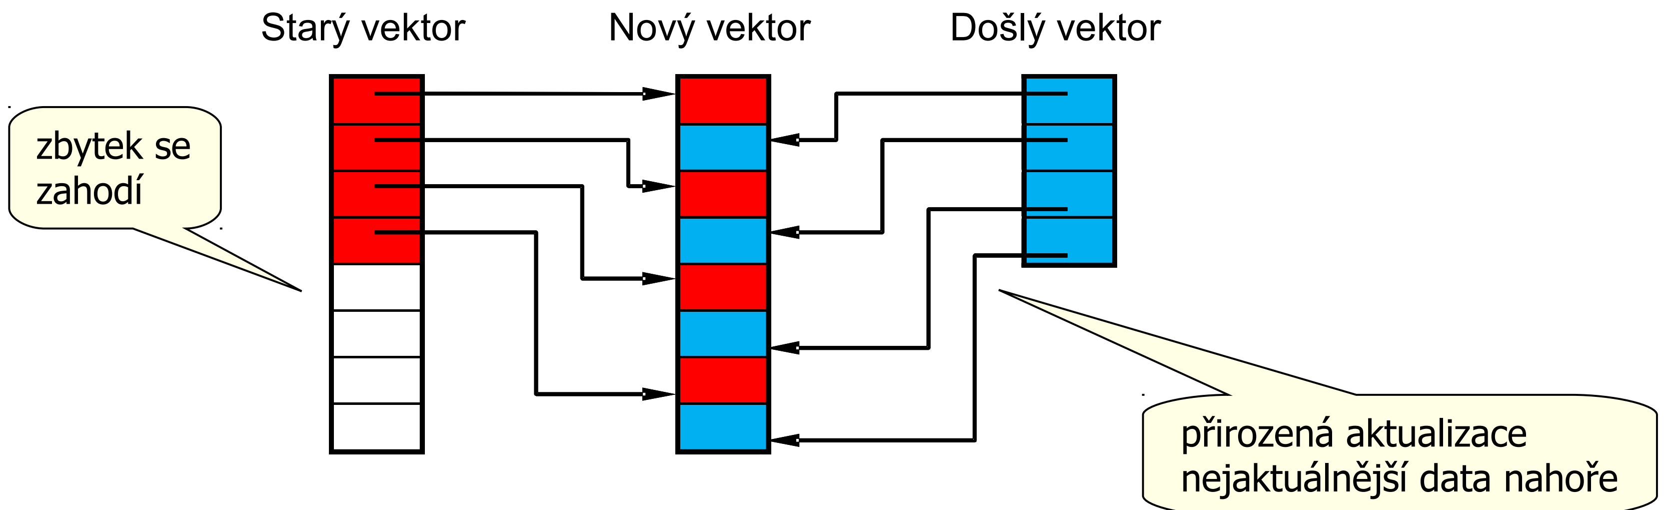

'Inteligentní' vyvažovací algoritmy

- **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

Prakticky použitelné vyvažovací algoritmy

- **Centralizovaný / hierarchický algoritmus**
  - centralizovaný manažer, zná zátěž všech uzlů, velí
  - virtualizace, datová centra: ≈1000 uzlů / manažer
  - hierarchicky organizované skupiny, nadřazení manažeři

idea:
vyvažující se skupiny
nebývají příliš velké

- **'Lokální' algoritmus**
  - známa pouze lokální zátěž, prahová hodnota
  - žádost n uzlům, podprahová / nejlepší odpověď OK
  - sender/receiver initiated

velmi jednoduchý
velmi suboptimální
velmi použitelný ☺

- **Virtuální stroje**
  - primární: paměť, procesor
  - sekundární: síťování, disky
  - požadavky:
    - stejná architektura (společná podmnožina)
    - nízká latence síťového spojení
    - sdílený filesystem

Replikace

Replikace

- 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)* - přístup k nejbližším datům, rozdělení výkonu

- explicitní replikace
  - klient se sám stará o udržování konzistence
- odložená replikace
  - zápis do primární repliky, aktualizace sekundárních
- skupinová komunikace
  - zápisy simultánně zasílány všem dostupným replikám

Replikace

- 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)* - přístup k nejbližším datům, rozdělení výkonu
- explicitní replikace
  - klient se sám stará o udržování konzistence

typicky knihovny

- odložená replikace
  - zápis do primární repliky, aktualizace sekundárních
- skupinová komunikace
  - zápisy simultánně zasílány všem dostupným replikám

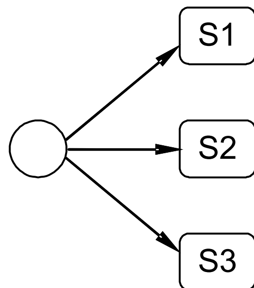

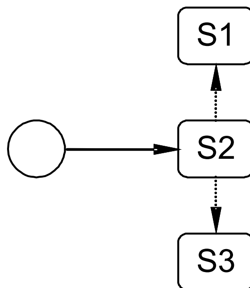

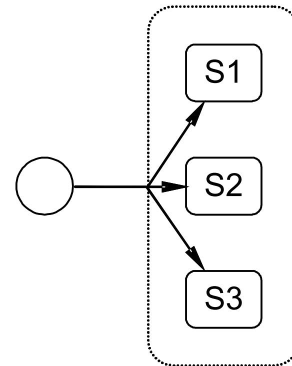

Aktualizační protokoly

- Problém aktualizací kopií
  - primární kopie
  - většinové hlasování *(majority voting)*
  - vážené hlasování *(weighted voting)*
    - read / write quorum: Nr + Nw > N
    - *většinové hlasování ≈ vážené při Nr = Nw*
    - optimalizace čtení × zápis
    - problém při 'totální optimalizaci' (Nr=1) - častá 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

kdy a které kopie budou aktualizovány

Aktualizační protokoly

- Problém aktualizací kopií
  - primární kopie
  - většinové hlasování *(majority voting)*
    - Nr > N/2
    - Nw > N/2

speciální případ váženého hlasování

Aktualizační protokoly

- Problém aktualizací kopií
  - primární kopie
  - většinové hlasování *(majority voting)*
  - vážené hlasování *(weighted/quorum voting)*
    - read / write quorum: Nr + Nw > N, 2 * Nw > N
      - většinové hlasování ≈ vážené při Nr = Nw
      - ≈ sekvenční rozvrh *(one copy serializability)*
    - optimalizace čtení × zápis
    - problém při *'totální optimalizaci'* (Nr=1)
      - potenciální nemožnost zápisu

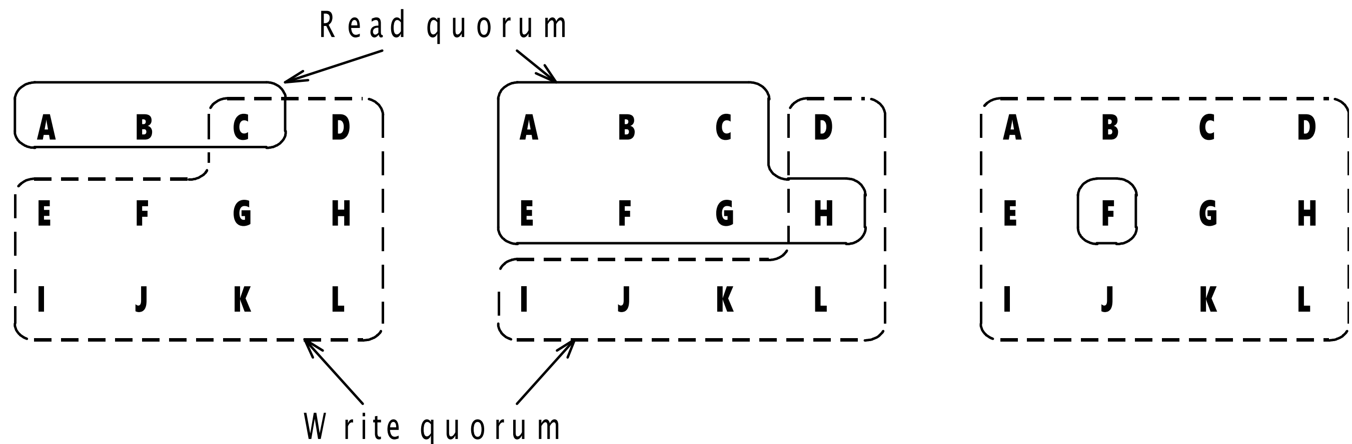

Aktualizační protokoly

- Problém aktualizací kopií
  - primární kopie
  - většinové hlasování *(majority voting)*
  - vážené hlasování *(weighted/quorum voting)*
    - read / write quorum: Nr + Nw > N, 2 * Nw > N
    - optimalizace čtení × zápis
    - problém při *'totální optimalizaci'* (Nr=1)
  - 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

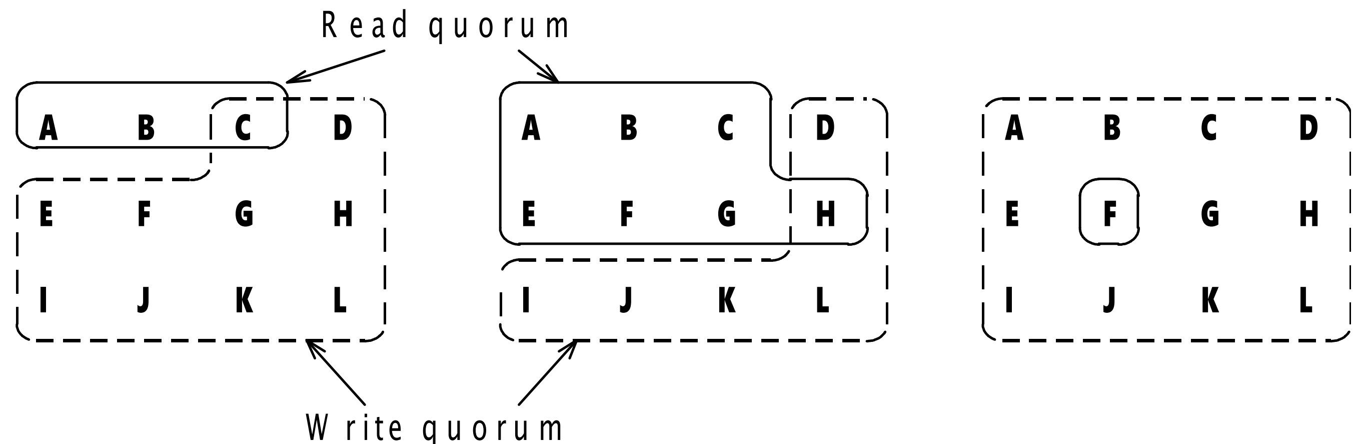

Klientocentrické konzistenční modely

- Konzistenční modely DSM - pohled na sdílená data různými klienty
- 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 klientem (procesem)

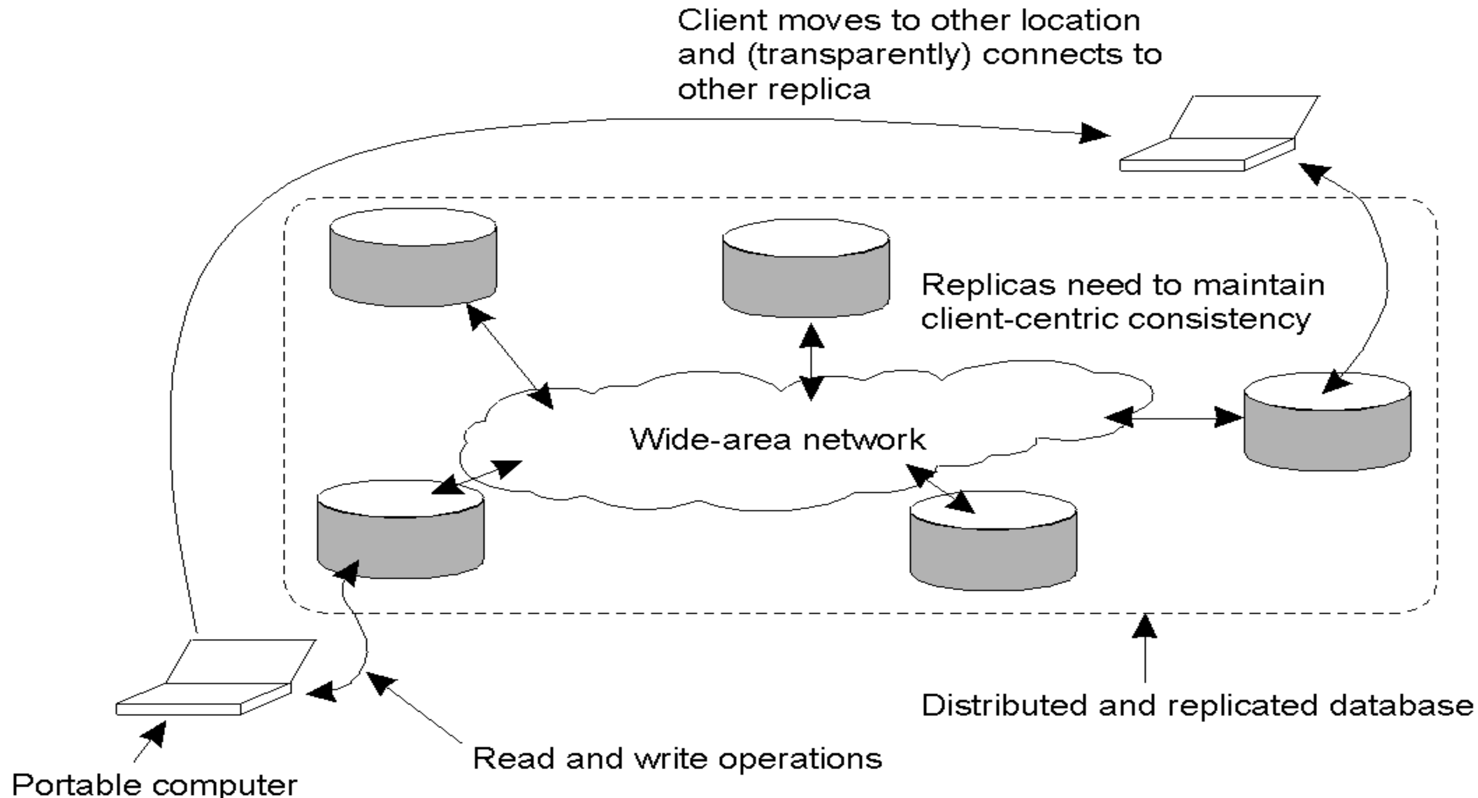

Eventuální konzistence

- Eventual consistency

Po ukončení všech zápisů budou všechny repliky v konečném čase aktualizovány

- Problém: pohled jednoho klienta na data různých replik

Značení:

x_i	hodnota proměnné x na replice L_i
$W(x_i)$	prvotní zápis hodnoty x_i
$S(x_i)$	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(x1)	R(x1)	
B:	S(x2)	R(x2)	S(x1;x2)

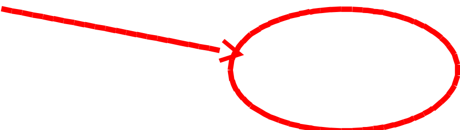

Příklad: při připojení k jedné replice uživatel vidí zprávy, po připojení k jiné replice některé zprávy (které již viděl) 'ještě' nevidí

Monotonní čtení

- Monotonic read consistency

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

Vyhovuje monotónnímu čtení

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

Nevyhovuje monotónnímu čtení

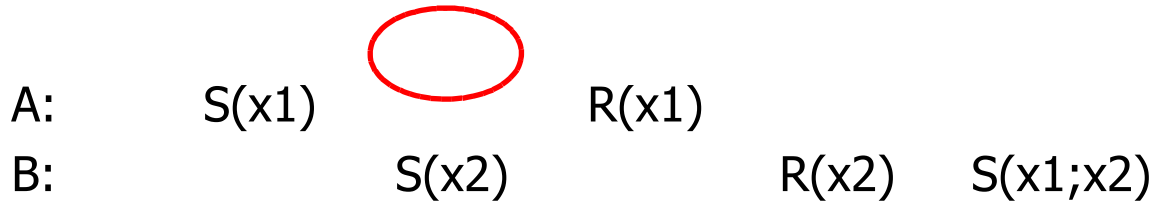

Příklad: při připojení k jiné replice klient vidí všechny dosud přečtené zprávy

Monotonní zápis

- Monotonic write consistency

Zápis proměnné je proveden před jakýmkoliv následným zápisem této proměnné

Vyhovuje monotónnímu zápisu

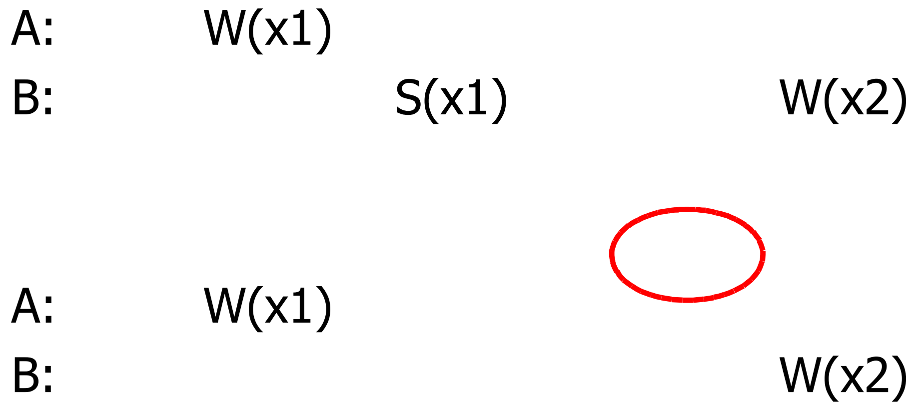

Nevyhovuje monotónnímu zápisu

Příklad: SVN commit na různých replikách

Čtení vlastních zápisů

- Read your writes consistency

Zápis proměnné je proveden před jakýmkoliv následným čtením této proměnné

Vyhovuje č.v.z.

A: W(x1)

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

Nevyhovuje č.v.z.

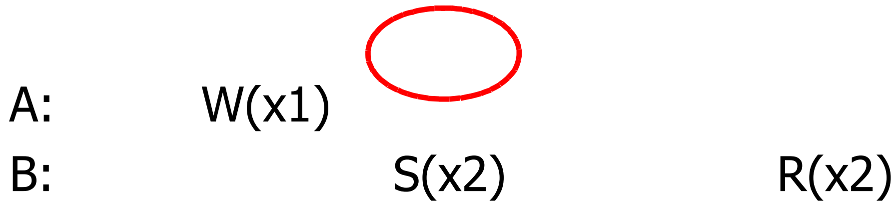

A: W(x1)

B: S(x2) R(x2)

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

Vyhovuje z.n.č.

A: S(x1) R(x1)

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

Nevyhovuje z.n.č.

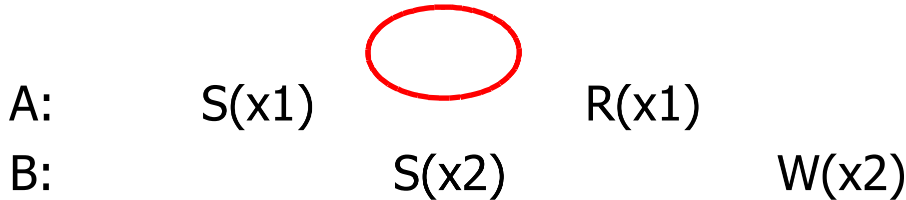

Příklad: zápis odpovědi do diskusního fóra se provede tam, kde je i přečtená hodnota

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 serveru 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

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 serveru 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

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

Problém: neomezený růst read/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

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

Efektivnější implementace

- Problém: read-set i write-set neomezeně rostou
- Možné řešení: seskupení do relací (session)

- Reprezentace množin - vektorové hodiny
  - *Bayou - distributed high-availability service*
  - replika serveru při zápisu přiřadí WID a lokální TS(WID)
  - každá replika Si udržuje RCV(i)[j]
    - TS poslední operace zápisu přijatá Si od Sj
  - při přijetí žádosti o čtení nebo zápis replika vrátí aktuální RCV(i)
    - read-set i write-set jsou reprezentovány vektorovými hodinami

myšlenka:
stačí detekovat
poslední R/W

obecná pravidla:

- VT(A)[i] = max TS operací z A iniciovaných na replice S
- 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

Epidemické protokoly

Možná implementace eventuální konzistence

Optimalizace komunikace ve **VELMI** rozsáhlých systémech

100 000
1 000 000
… … … …

- 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

  P → Q při velkém počtu infikovaných uzlů malá pravděpodobnost rozšíření

  pull

  P ← Q zpočátku pomalé rozšiřování, nakonec infekce celé množiny

  push/pull

  P ↔ Q lze spojit výhody předchozích postupů

- problém: kdy má uzel přestat infikovat

Epidemické protokoly

Možná 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, pull, push/pull
- 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: masivní škálovatelnost
- složitější topologie - hierarchie, rychlejší infekce

Epidemické protokoly

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

- *mouchy, spočítejte se!*
- *která jste největší?*
- *kolik dohromady vážíte?*

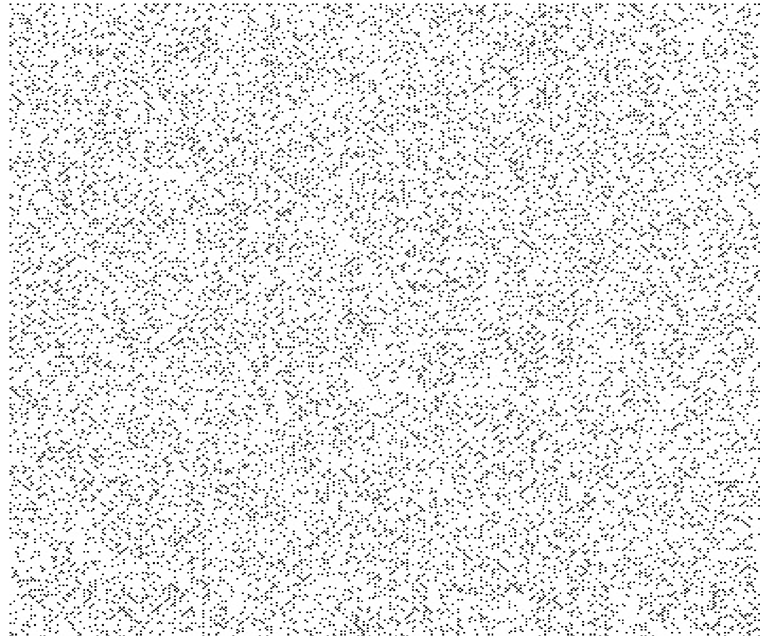

Epidemické protokoly

Problém mazání dat

- naivní implementace: smazání dat $\rightarrow$ 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

- *mouchy, spočítejte se!*
- podproblém: spočítejte průměr
  - uzel i: x_i = iniciální (libovolná) hodnota
  - epidemicky: $(x_i, x_k) = (x_i + x_k) / 2$
  - $x_i \longrightarrow avg_{\forall n}(x_n)$
- iniciátor $x_i = 1$, ostatní $x_i = 0$
  - $x_i \longrightarrow 1 / N$

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 ...

  - Živý výzkum v oblasti velmi rozsáhlých systémů

Trendy '94 .... 22 years ago

- Nový hardware
  - ☺ síť ≈ rychlá sběrnice, multicomputery ≈ 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:

$1.8^{22} \approx 413\,000$

velikost disků:

1994: 100 MB

2016: 10 TB

- Globální systémy
  - 😐 algoritmy - hierarchické / distribuované, masivní škálovatelnost a paralelizace
  - ☺ 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
- ...

The End.

Ocharna přístupu

- Access Control Matrix
  - user × resource → effective right

	Afile	Bfile	Cfile	Dfile
Anna	rwx	r	x	
Bill	r	rx	x	
Charles	r	r	rw	r
Damian		r		rw

- Access Control List
  - prostředek má seznam uprávněných uživatelů
- Capabilities
  - certifikát
  - uživatel drží oprávnění k prostředkům
  - datová struktura umožňující jednoznačnou identifikaci objektu
    - obsahuje navíc přístupová práva pro držitele kapability
    - serializace, perzistence
  - ochrana objektů, šifrování, redundance
  - k jednomu objektu typicky několik různých kapabilit
    - vlastník, zapisovatel, čtenář, ... další druhy služeb
  - uživatelským procesům znemožněno vlastní generování kapabilit i změny práv

Kapability

- Výhody
  - snadný test oprávěnosti přístupu
    - škálovatelnost
  - flexibilita
    - každý správce prostředků může nadefinovat vlastní druhy práv
  - anonymita
- Nevýhody
  - kontrola propagace
    - copy bit, čítač - chráněný způsob přenosu
  - review - seznam oprávněných uživatelů
  - revocation - odejmutí práva
    - zrušení objektu a vytvoření nového, notifikace ostatních uživatelů
    - expirace

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

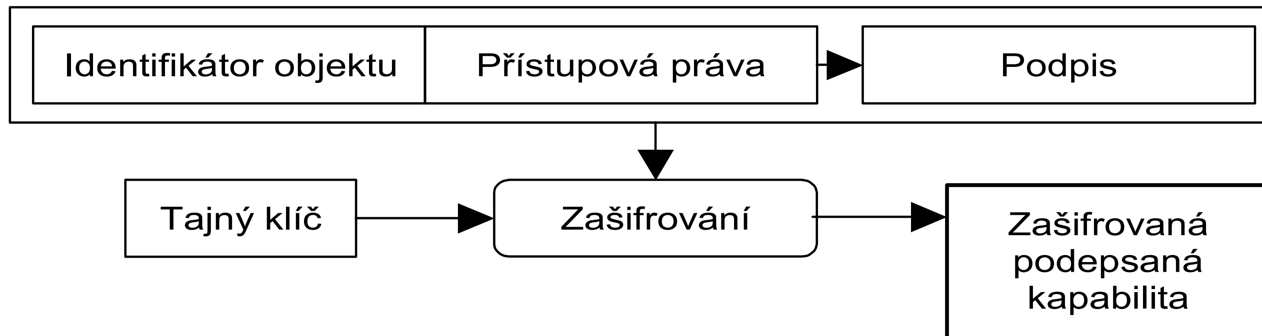

Implementace kapabilit

- Kapabilita s redundantní kontrolou
  - port serveru a identifikátor objektu jsou volně přístupné
  - přístupová práva a náhodně vygenerované binárním 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

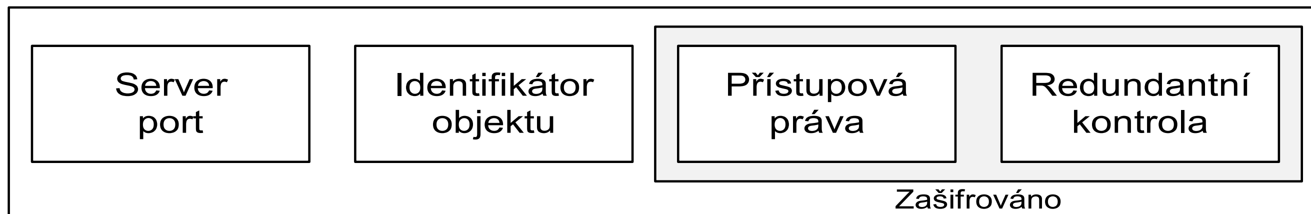

Distribuovaná správa jmen

- 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

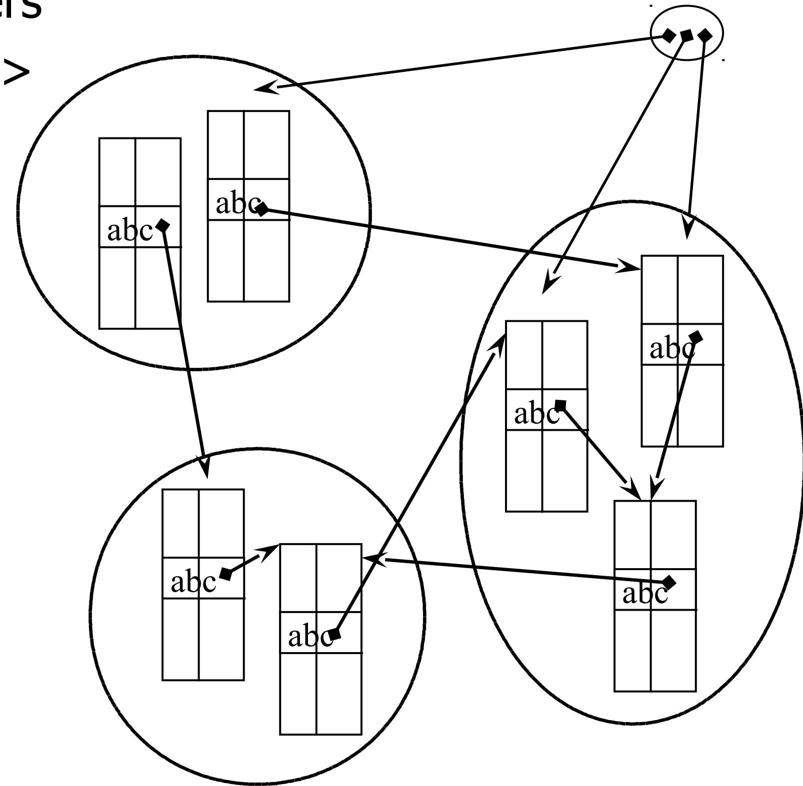

- Základní operace:
  - **adresář -> set(jmeno, hodnota);**
  - **adresář -> lookup(slozene_jmeno);**
    - `adresář -> lookup("A") -> lookup("B") -> lookup("C");`
- Klientský proces – několik základních 'adresářů'
  - filesystem, objekty, služby a servery, registry, ...

Přístup k objektům

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

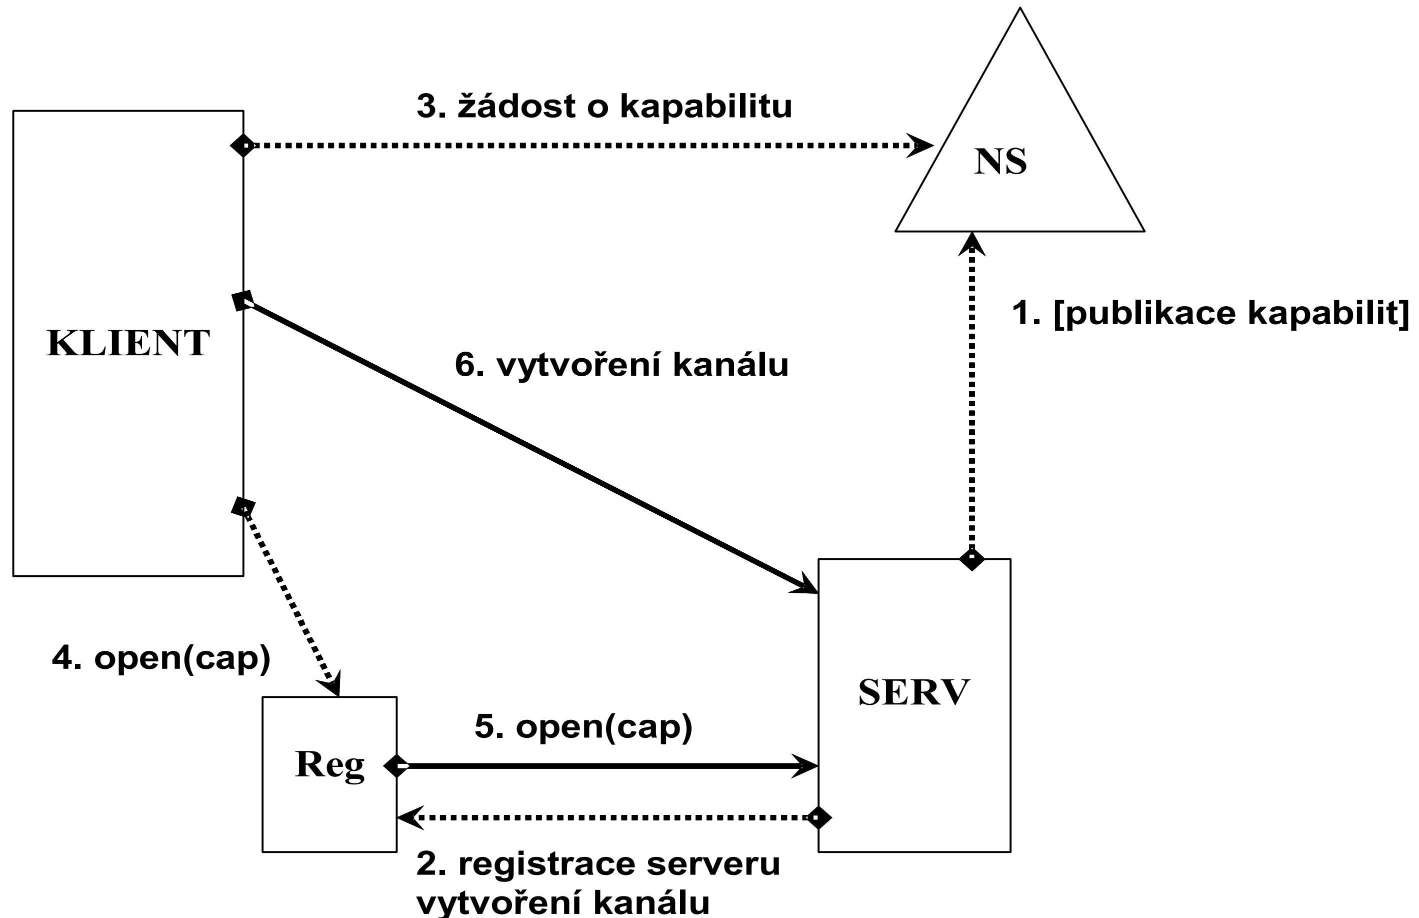

Služby pro přístup k objektům

porty ≈ objekty
služby ≈ metody

- vytvoření objektu, tranzientní reference

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

- 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);
```

Implementace migrace - zprávy

- Zprávy
  - přesměrování - dočasné / trvalé
  - migrace kanálů, spojení front

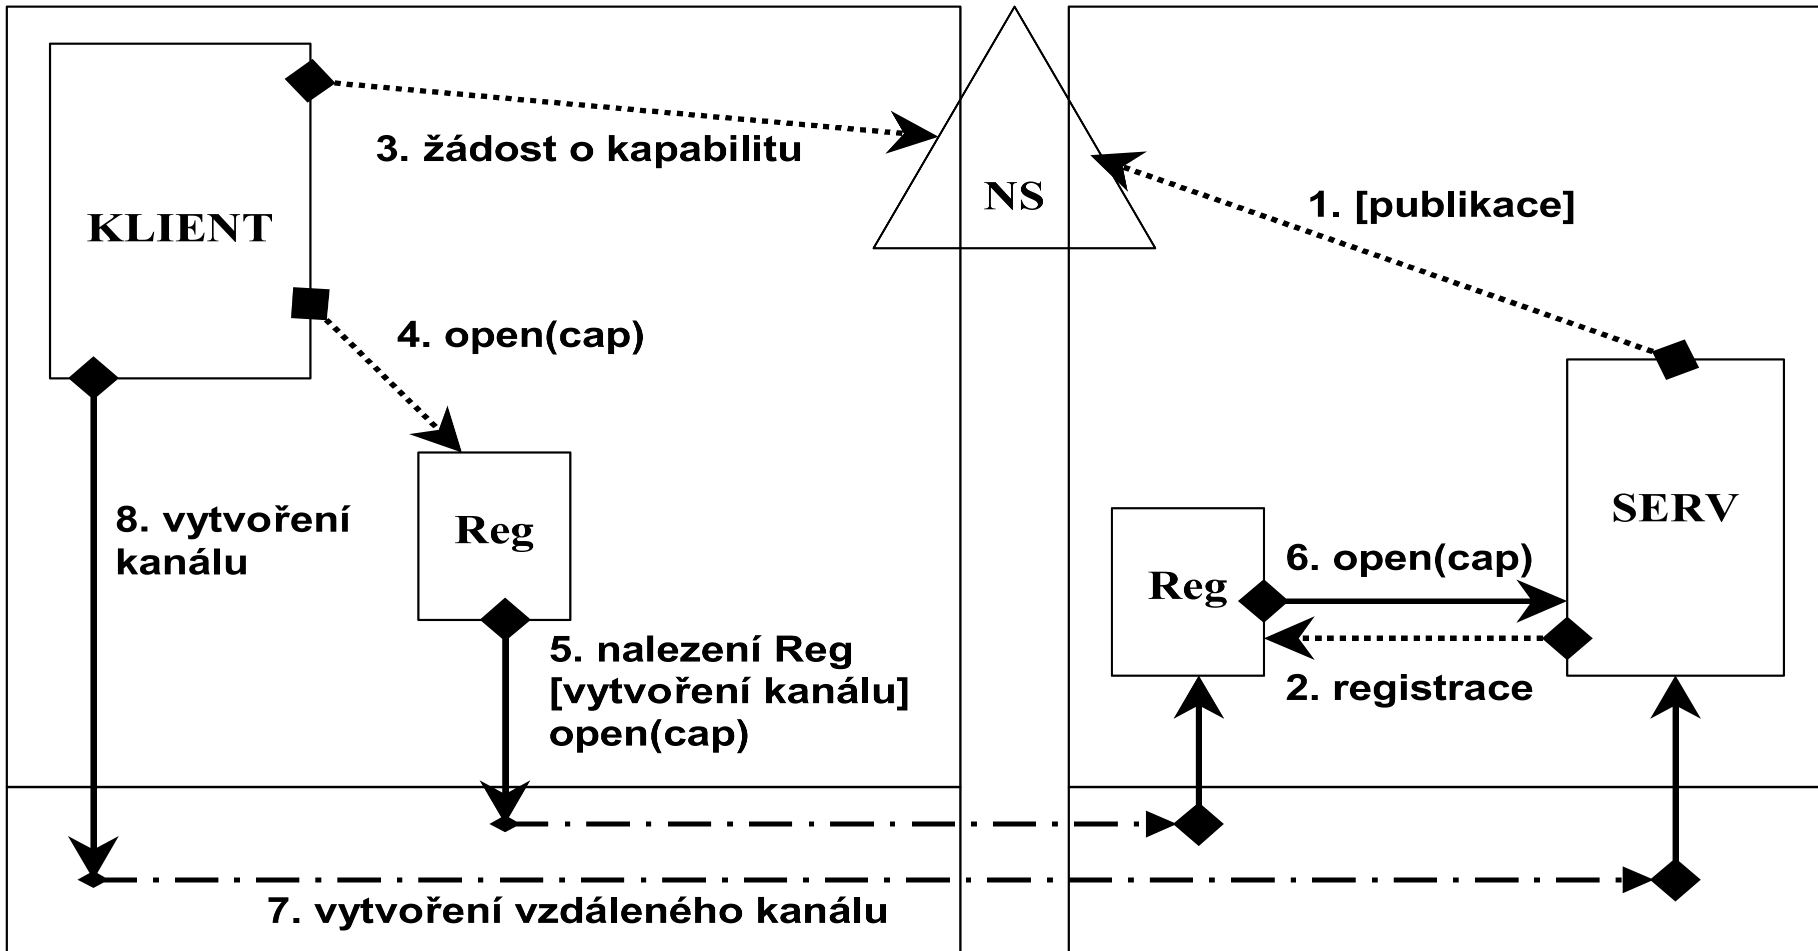

Klasifikace vyvažovacích algoritmů

- zda jsou předem známy údaje o procesech, podle kterých se algoritmus rozhoduje
  - deterministické / <u>heuristické</u>
- do jaké míry se provádí optimalizace
  - optimální / <u>suboptimální</u>
- co se snaží optimalizovat
  - využití CPU / čas odpovědi / přidělování prostředků / komunikační složitost, ...
- rozdíly mezi hw uzlů, speciální požadavky procesů na hw vlastnosti
  - <u>homogenní</u> / heterogenní
- podle charakteru algoritmu
  - centralizované / distribuované
- podle jakých informací se provádí rozhodnutí o vzdáleném spuštění procesu
  - lokální / globální
- zda umožňují přemístění již rozběhnutého procesu
  - migrační / <u>nemigrační</u>

Migrace zpráv a služeb

- Zprávy
  - přesměrování - dočasné / trvalé
  - migrace kanálů, spojení front