

IA039

Paralelní počítače

Paralelní počítače

- Small-scale multiprocessing
 - 2–16 procesorů
 - převážně SMP (sdílená paměť)
- Large-scale multiprocessing
 - > 100 (i tisíce) procesorů
 - Zpravidla distribuovaná paměť

Paralelní počítače (II)

- Architektura
 - Single Instruction Multiple Data, SIMD
 - Multiple Instruction Multiple Data, MIMD
- Programovací modely
 - Single Program Multiple Data, SMPD
 - Multiple programs Multiple Data, MPMD

Architektura – SIMD

- Procesory synchronizovaný
 - Všechny vykonávají vždy stejnou instrukci
 - Analogie vektorových procesorů
- Jednoduché procesory
- Jednoduší programovací model

Architektura – MIMD

- Plně asynchronní systém
- Procesory zcela samostatné
 - Není třeba speciální výroba (off-the-shelf)
- Výhody
 - Vyšší flexibilita
 - Teoreticky vyšší efektivita
- Nevýhody
 - Explicitní synchronizace
 - Složité programování

Komunikační modely

- Sdílená paměť (Shared Memory Architecture)
- Předávání zpráv (Message passing)

Sdílená paměť

- Paměť odělená od procesorů
- Uniformní přístup k paměti
- Nejsnazší propojení – sběrnice
- „Levná“ komunikace
- Složité prokládání výpočtu a komunikace (aktivní čekání)

Předávání zpráv

- Každý procesor „viditelný“
- Vlastní paměť u každého procesoru
- Explicitní komunikace – předávání zpráv
- Vysoká cena komunikace (výměny dat)
- Možnost prokládání výpočtů a komunikace

Hybridní systémy

- Nonuniform memory access architecture (NUMA)
- Cache-only memory access architecture (COMA)
- Distributed shared-memory (DSM)

Non-uniform memory access

- Přístup k různým fyzickým adresám trvá různou dobu
- Umožňuje vyšší škálovatelnost
- Potenciálně nižší propostnost
- Koherence vyrovnávacích pamětí
 - ccNUMA

Cache only memory access

- NUMA s charakterem vyrovnávací paměti
- Data putují k procesorům, které je používají
- Pouze zdánlivá hierarchie
 - Systém musí hlídat, že má jedinou kopii
- Experimentální

Distributed shared-memory

- Distribuovaný systém – cluster
 - Lokální paměť každého uzlu
 - Vzdálená paměť ostatních uzlů
- „Fikce“ jedné rozsáhlé paměti
- Hardwarové řešení
 - Zpravidla využívá principů virtuální paměti
 - Transparentní
- Softwarové řešení
 - Knihovna
 - Netransparentní, programátor program musí explicitně přizpůsobit

Koherence vyrovnávacích pamětí

- Příčiny výpadku vyrovnávací paměti:
 - **Compulsory** miss: 1. přístup k datům
 - **Capacity** miss: nedostatečná kapacita
 - **Conflict** miss: různé adresy mapovány do stejného místa
 - **Coherence** miss: různá data v různých vyrovnávacích pamětích
- Poslední případ se týká multiprocesorů

Řešení problému koherence

- Vyrovnávací paměti musí vědět o změně
- Metody založené na broadcastu
- Adresářové metody

Snoopy cache

- Broadcastový přístup
 - Propojovací síť s „přirozeným“ broadcastem – sběrnice
- Každý procesor sleduje *všechny* přístupy k paměti

Zneplatnění

- Reakce na změnu dat ve vzdálené (vyrovnávací) paměti
- Řádka v aktuální (naslouchající) vyrovnávací paměti je zneplatněna
- V případě opětného přístupu je přehrána ze vzdálené paměti

Update

- Řádka je okamžitě obnovena
- Při opětovném přístupu je již k dispozici
- Nevýhody
 - Falešné sdílení (nepracují na stejných datech)
 - Přílišné zatížení sběrnice
- Nelze rozhodnout, zda update nebo zneplatnění je obecně lepší

Rozšiřitelnost (Scalability)

- Není jednotná definice
- Používané základní formulace – rozšiřitelný je takový systém, pro nějž platí:
 - Výkon roste lineárně s cenou
 - Je zachován konstantní poměr Cena/Výkon
- Alternativní parametr – **Míra rozšiřitelnosti**
 - Změna výkonu přidáním procesoru
 - Změna ceny přidáním procesoru
 - Smysluplný rozsah počtu procesorů

Zrychlení

$$\begin{aligned} S(N) &= \frac{T_{EXEC}(1)}{T_{EXEC}(N)} \\ &= \frac{T_{comp}(1) + T_{comm}(1)}{T_{comp}(N) + T_{comm}(N)} \end{aligned}$$

- Ideální zrychlení vyžaduje

$$T_{comp}(N) = T_{comp}(1)/N$$

$$T_{comm}(N) = T_{comm}(1)/N$$

Zrychlení – komentář

- Teoretický pojem, realita závisí na aplikaci
 - Různé hodnoty pro různé aplikace
 - Vliv paralelizovatelnosti problému (Amdalův zákon)

Rozšiřitelné propojovací sítě

- Požadavky na ideální síť:
 - Nízka cena rostoucí lineárně s počtem procesorů (N)
 - Minimální latence nezávislá na N
 - Propustnost rostoucí lineárně s N

Vlastnosti sítí

- Tři základní komponenty
 - Topologie
 - Přepínání dat (jak se data pohybují mezi uzly)
 - Směrování dat (jak se hledá cesta mezi uzly)

Propojovací sítě

- Rozlišujeme následující základní parametry
 - Velikost sítě – počet uzelů N
 - Stupeň uzlu d
 - Poloměr sítě D
 - * Nejdelší nejkratší cesta
 - Bisection width B
 - Redundance sítě A
 - * Minimální počet hran, které je třeba odstranit, aby se síť rozpadla na dvě
 - Cena C
 - * Počet komunikačních linek v síti

Bisection width

- Šířka rozpůlení
 - Minimální počet linek, které je třeba odstranit, aby se systém rozpadl na dvě stejné části
- **Bisection bandwidth** – propustnost při rozpůlení
 - Celková kapacita (propustnost) výše odstraněných linek
- Ideální vlastnost:
 - Bisection bandwidth vztažená na procesor je v daném systému konstantní.

Topologie přepínacích sítí

- Klasifikace na základě rozměru

- Jednorozměrné
- Dvourozměrné
- Třírozměrné
- Hyperkrychle

Jednorozměrné propojovací sítě

- Linerání pole
- Jednotlivé prvky navázány na sebe
 - „Korálky“
- Nejjednodušší
- Nejhorší vlastnosti

Dvourozměrné propojovací sítě

- Kruh
 - Uzavřené lineární pole
- Hvězda
- Strom
 - Snižuje poloměr sítě ($2 \log \frac{N+1}{2}$)
 - Stále špatná redundancy a bisection (band)width
 - Tlustý strom (fat tree)
 - * Přidává redundantní cesty ve vyšších úrovních

Dvouzměrná mřížka

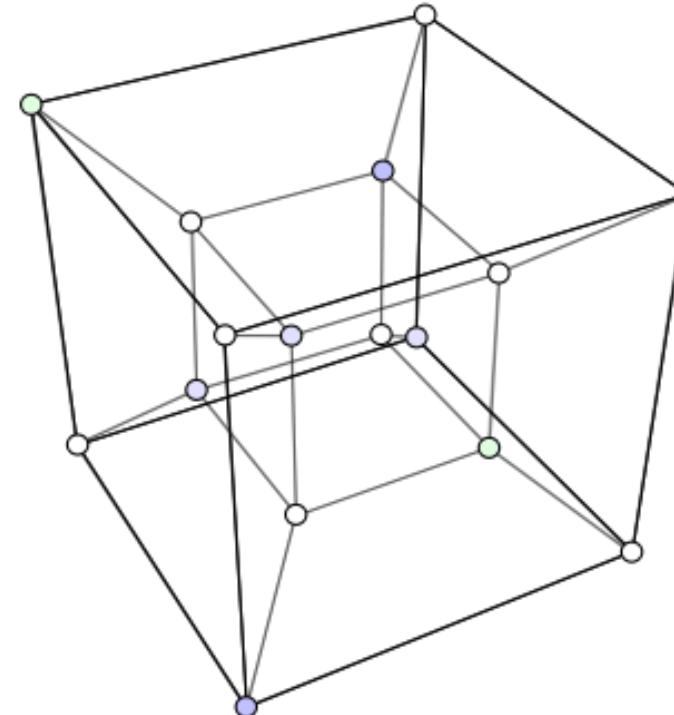
- **Velmi populární**
 - Dobré vlastnosti
 - * Poloměr $2(N^{1/2} - 1)$
 - * Bisection $N^{1/2}$
 - * Redundance 2
 - Avšak vyšší cena a proměnný stupeň uzlu
- **Torus**
 - Uzavřená dvouzměrná mřížka
 - * Poloměr $N^{1/2}$
 - * Bisection $2N^{1/2}$
 - * Redundance 4
 - * Vyšší cena – přidá $2N^{1/2}$ hran

Třírozměrná síť

- Vlastnosti
 - Poloměr $3(N^{1/3} - 1)$
 - Bisection $N^{2/3}$
 - Redundance 3
 - Cena akceptovatelná $2(N - N^{2/3})$
- Konstrukčně složitá

Hyperkrychle

- Velmi zajímavá topologie
- Obecně n -rozměrná krychle
- Základní parametry
 - Poloměr $\log N$
 - Bisection $N/2$
 - Redundance $\log N$
 - Vyšší cena $(N \log N)/2$
- Mřížky speciálními případy hyperkrychle
- Snadné nalezení cesty
 - Binární číslování uzlů



Plně propojené sítě

- Teoretická konstrukce
- Vynikající poloměr (1)
- Neakceptovatelná cena ($N * (N - 1)/2$) a stupeň uzlu ($N - 1$)

Přepínání

- Konkrétní mechanismus, jak se paket dostane ze vstupu na výstup
- Základní přístupy
 - Přepínání paketů, store-and-forward
 - Přepínaní obvodů
 - Virtuální propojení (cut-through)
 - Směrování červí dírou (wormhole routing)

Store-and-forward

- Celý paket se uloží
- A následně přepošle
- Jednoduché (první generace paralelních počítačů)
- Vysoká latence $\frac{P}{B} * D$
 - P je délka paketu, B je propustnost a D je počet „hopů“ (vzdálenost)

Přepínání okruhů

- Tři fáze
 - Ustavení spojení – zahájeno vzorkem (probe)
 - Vlastní přenos
 - Zrušení spojení
- Výrazně nižší latence $\frac{P}{B} * D + \frac{M}{B}$
 - P je v tomto případě délka vzorku a M je délka zprávy (nejsou nutné pakety)
 - Pro $P \ll M$ latence není závislá na délce cesty

Virtuální propojení

- Zprávu rozdělíme do menších bloků – flow control digits (flits)
- Posíláme jednotlivé flits kontinuálně
 - Jsou-li buffery dostatečně velké, odpovídá přepínání okruhů
- Latence $\frac{HF}{B} * D + \frac{M}{B}$
 - HF je délka flitsu, zpravidla $HF \ll M$

Červí díra

- Speciální případ virtuálního propojení
- Buffery mají právě délku flits
- Latence nezávisí na vzdálenosti
 - Analogie pipeline
- Podporuje replikace paketů
 - Vhodné pro multicast a broadcast

Virtuální kanály

- Sdílení fyzických kanálů
- Několik bufferů nad stejným kanálem
 - Flits uložen v příslušném bufferu
- Využití
 - Přetížená spojení
 - Zábrana deadlocku
 - Mapování logické na fyzickou topologii
 - Garance propustnosti systémovým datům

Směrování v propojovacích sítích

- Hledání cesty
- Vlastnosti
 - Statické směrování
 - * Zdrojové
 - * Distribuované
 - Adaptivní směrování (vždy distribuované)
- Minimální a ne-minimální

Fault tolerance propojovacích sítí

- Kontrola chyb
- Potvrzování zpráv
- Opakované zasílání zpráv

Koherence vyrovnávacích pamětí II

- Snoopy schema založené na broadcastu
 - Nepoužitelné u složitějších propojovacích sítí
 - Není rozšiřitelné (scalable)
- Redukce „oslovených“ vyrovnávacích pamětí – Adresáře
 - Položka u každého bloku paměti
 - Odkazy na vyrovnávací paměti s kopíí tohoto bloku
 - Označení exkluzivity (právo pro čtení)

Adresářové přístupy

- Tři základní schemata
 - Plně mapované adresáře
 - Částečně (Limited) mapované adresáře
 - Provázané (chained) adresáře
- Zhodnocení vlastností
 - Na základě velikosti potřebné paměti
 - Na základě složitosti (počtu příkazů) protokolu

Plně mapované adresáře

- Každá adresářová položka má tolik údajů, kolik je vyrovnávacích pamětí (procesorů)
- Bitový vektor „přítomnosti“
 - Nastavený bit znamená, že příslušná vyrovnávací data má kopii bloku paměti
- Příznak exkluzivity
 - Stačí jeden na blok
 - Jen jedna vyrovnávací paměť
- Příznaky v každé vyrovnávací paměti (každý blok)
 - Příznak platnosti
 - Příznak exkluzivity

Omezené adresáře

- Plné adresáře velmi paměťově náročné
 - Velikost paměti: P^2M/B
 - * P je počet vyrovnávacích pamětí
 - * M velikost hlavní paměti
 - * B velikost bloku
- Data nejsou zpravidla široce sdílena
 - Většina adresářových bitů má hodnotu nula
- Použití přímých odkazů
 - Nebude již stačit jeden bit

Omezené adresáře II

- Množina ukazatelů na vyrovnávací paměti
 - Dynamická alokace dle potřeby
- Vlastnosti
 - Počet bitů ukazatele: $\log_2 P$
 - Počet položek v poolu ukazatelů: k
 - Výhodnější než přímo mapovaná: pokud $k < \frac{P}{\log_2 P}$
- Informovány jen explicitně uvedené vyrovnávací paměti

Přetečení

- Pokud přestanou stačit položky
 - Příliš mnoho sdílených bloků
- Možné reakce
 - Zneplatnění všech sdílených (broadcast, Dir_iB)
 - Výběr jedné položky (i náhodně) a její zneplatnění (bez broadcastu, Dir_iNB)

Další schemata

- Coarse-vector ($\text{Dir}_i \text{CV}_r$)
 - r je velikost regionu (více procesorů), kterému odpovídá jeden bit (tedy více procesorů)
 - Přepnutí interpretace při přetečení
 - * Omezený broadcast všem procesorům v oblasti.
- LimitLESS: programové přerušení při přetečení

Provázaná schemata

- Cache-Based linked-list
- Centrálně pouze jediný ukazatel
- Ostatní ukazatele svázány s vyrovnávací pamětí
 - Vyrovnávací paměti „provázany“ ukazateli
- Výhody
 - Minimalizace paměťových nároků
- Nevýhody:
 - Složitý protokol.
 - Zvýšená komunikace (více zpráv než nutno)
 - Zápis je delší (sekvenční procházení seznamu)

Hierarchické adresáře

- Použité v systémech s vícenásobnými sběrnicemi
- Hierarchie vyrovnávacích pamětí
 - Vyšší úroveň na každém propojení sběrnic
 - Vyšší paměťové nároky
 - * Vyšší úroveň musí držet kopie paměťových bloků sdílených nižší úrovni
 - * Není třeba rychlá paměť
- V principu hierarchie snoopy protokolů

Zpoždění paměti

- Paměť výrazně pomalejší než procesor
 - Čekání na paměť podstatně snižuje výkon systému
- Možná řešení:
- *Snížením zpoždění* – zrychlení přístupu
- *Ukrytím zpoždění* – překryv přístupu a výpočtu

Snížení zpoždění paměti

- **NUMA:** NonUniform Memory Access
 - Každé logické adrese odpovídá konkrétní fyzická adresa
- **COMA:** Cache-Only Memory Architecture
 - Hlavní paměť je chápána jako *attraction memory*.
 - Řádky paměti se mohou volně přesouvat.
 - Mohou existovat sdílené kopie řádků paměti.

Rekapitulace

Communication to computation ratio	NUMA		COMA	
	Small work- ing set	Large work- ing set	Small work- ing set	Large work- ing set
Low	Good	Medium	Good	Good
High	Medium	Poor	Poor	Poor

Ukrytí zpoždění paměti

- Modely slabé konzistence
- Prefetch
- Procesory s vícenásobnými kontexty
- Komunikace iniciovaná producentem

Slabá konzistence

- Nepožaduje striktní uspořádání přístupů ke sdíleným proměným vyjma synchronizačních.
- **Release consistency:**
 - Zavedení operací *acquire* a *release*
- **Fence operace**
 - Vynucené dokončení rozpracovaných operací

Prefetch

- Přesun dat k procesoru s předstihem.
 - *Binding* prefetch
 - * Data přesunuta až k procesoru
 - * Možné porušení konzistence
 - *Nonbinding* prefetch
 - * Data přesunuta pouze do vyrovnávací paměti
- HW Prefetch
- SW Prefetch
- Speciální instrukce *prefetch-exclusive*: read následovaný příkazem write.

Procesory s vícenásobnými kontexty

- Podpora multitherading
- Vyžaduje
 - Velmi rychlé přepnutí kontextu
 - Vysoký počet registrů
- Řada experimentálních systémů
 - HEP (70. léta)
 - Tera
 - *T

Komunikace iniciovaná producentem

- Analogie invalidace a update při cache koherenci
- Specifické využití pro message-passing (Cray T3D) nebo block-copy (počítače se sdílenou pamětí).
- Vhodné např. pro přesun velkých bloků dat či pro synchronizaci zámky (locks).

Podpora synchronizace

- Synchronizace tvoří „horká místa“
- Základní synchronizační primitivy:
 - Vzájemné vyloučení
 - Dynamické rozložení zátěže
 - Informace o událostech
 - Globální serializace (bariéry)

Vzájemné vyloučení

- K dané proměnné má v daném okamžiku přístup nejvýše jeden proces
- Univerzální, ovšem zpravidla zbytečně drahé
- Synchronizační konstrukce vyšších jazyků
 - Semafore
 - Monitory
 - Kritické oblasti
- Základem – hardwarová podpora
 - test&set instrukce
 - test-and-test&set instrukce

test&set

- Vlastnosti

```
char *lock;
```

```
while (exchange(lock, CLOSED) == CLOSED );
```

- Busy waiting

- Vysoké požadavky na přenos (časté zneplatnění) u multiprocerů

test-and-test&set

- Vlastnosti

```
for (;;) {  
    while (*lock == CLOSED);  
    if (exchange(lock, CLOSED) != CLOSED)  
        break;  
}
```

- Využití vyrovnávacích pamětí

- první testy nad sdílenou kopíí

Použití front

- Výhodnější *Collision avoidance schemata*
- Queue on lock bit (QOLB) protokol
- Nejfektivnější implementace
- Procesy řazeny do fronty
 - Po uvolnění zámku aktivován proces v čele fronty
 - Není třeba žádný sdílený přenos dat

Zámky v multiprocesorech

- Souvisí i s možností dynamického rozložení zátěže
- Využití čitače s atomickou operací
 - Fetch&Op – čitače, např. Op==Add
`fetch&add (x, a)`
`int *x, a;`
`{ int temp;`
`temp = *x;`
`*x += a;`
`return (temp);`
`}`
 - Compare&Swap – seznamy

Použití

Informace o (globálních) událostech používána především producentem jako prostředek, kterým jsou konzumenti informováni o nově dostupných datech, a dále při informaci o globální změně ve skupině ekvivalentních procesů (změna určitého stavu, která musí být oznámena všem procesům).