# Základní pojmy

- Program, programový kód
  - statický popis výpočetního postupu, tj. co bude počítač provádět
  - nemá stav

- Assembler
  - Překladač do strojového kódu cílového procesoru
  - I když formálně nesprávně, používá se i k označení jazyka symbolických adres, ve kterém budou některé ilustrativní příklady
    - x86/x86-64
  - dokud neuvidíte, do čeho vlastně procesor nutíte, neznáte skutečné náklady kódu ve vyšším jazyku

- Vlákno (fiber, thread, task)
  - vykonávaný programový kód
  - tj. aktivita v čase, která má svůj stav, který je určen
    - aktuálním místem v programu (CS:RIP),
    - obsahem registrů procesoru
    - a obsahem zpracovávaných dat
  - vlákno v jednom časovém okamžiku běží pouze na jednom procesoru

- Proces
  - Dynamická kolekce vláken => má stav daný vlákny
  - Vždy obsahuje alespoň jedno vlákno, které vytvořil operační systém/interpret (např. JVM)
  - Vlastní prostředky, které operační systém/interpret přidělil důsledkem činnosti některého vlákna
  - Vlákna jednoho procesu mohou běžet současně, je-li k dispozici více než jeden procesor

- Distribuovaná aplikace
  - Několik spolupracujících procesů
  - Obvykle jsou distribuovány na uzly počítačové sítě
    - Jeden uzel má *n* procesorů
  - V extrémním případě mohou být na jednom uzlu
    - Dříve, kdy ještě platilo 1 proces = 1 vlákno, se spouštělo několik instancí jednoho programu

- Paralelní výpočet
  - Buď vícevláknový program,
  - Nebo distribuovaná aplikace
  - Výpočet je dynamicky strukturován na procesy a vlákna

- Paralelní program
  - Kód je staticky strukturován na podprogramy vláken
  - Má deklarovaná sdílená data

- Interakce
  - Spolupráce na úrovni vláken uvnitř procesů
  - Spolupráce na úrovni procesů distribuované aplikace
  - Výměna informací

- Synchronizace
  - Forma interakce
  - Zajištění správné návaznosti operací

# Symetrický multiprocesor (SMP)

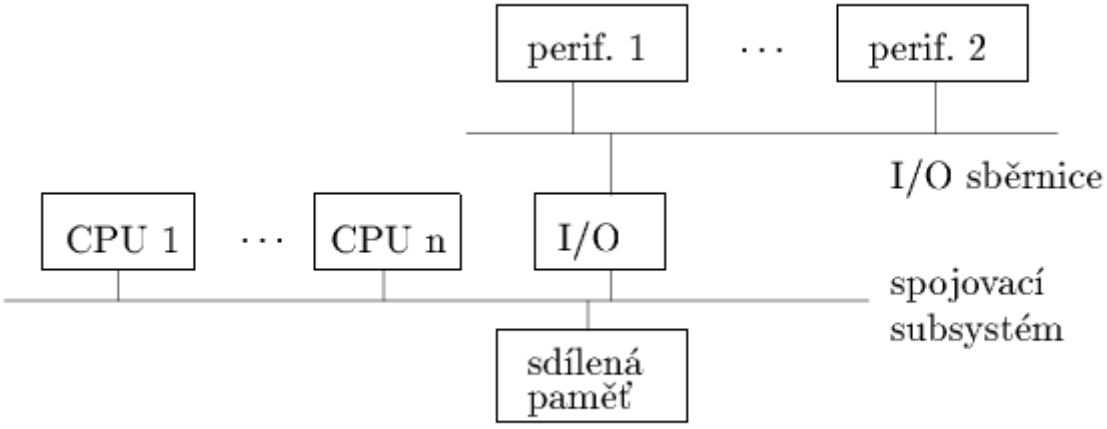


- Všechny procesory jsou identické
- Vlákno může být alokováno na libovolný procesor
- Pro plánovač OS je to jednodušší, než kdyby se procesory významně lišily
- Procesory sdílejí jednu paměť – úzké hrdlo je sběrnice
  - Řešením je spojit jednotlivé procesory přímo – tzv. point-to-point
  - Hyper Transport (Consortium)

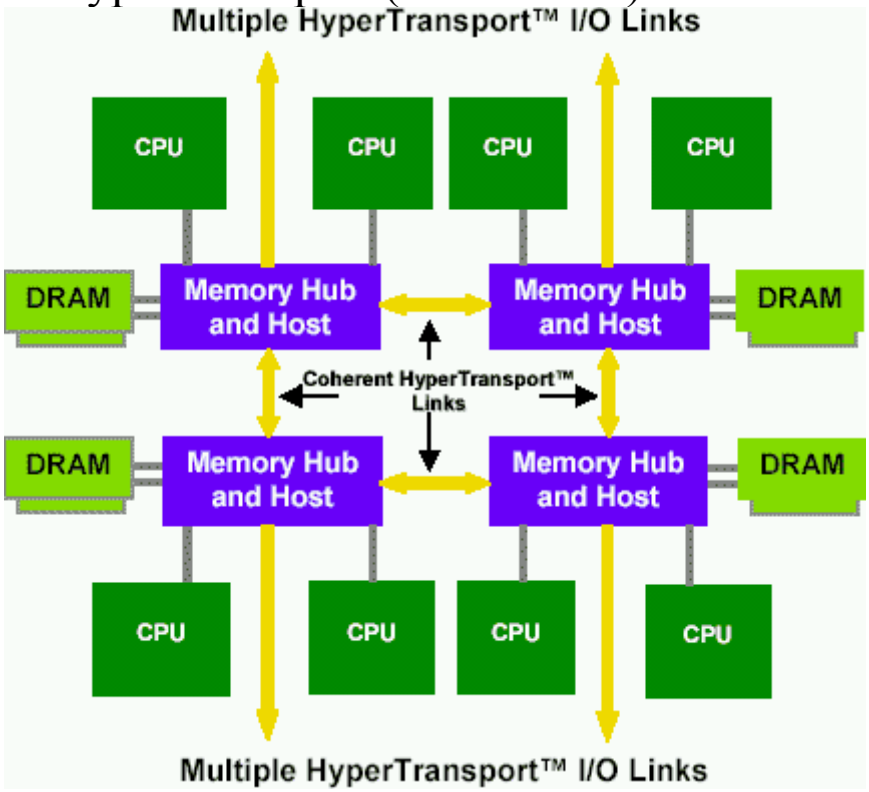

- Intel QuickPath Interconnect
  - Též známo jako Common System Interface (CSI) nebo jenom QuickPath

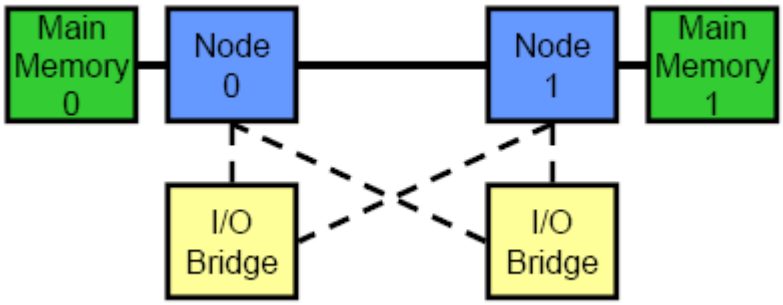


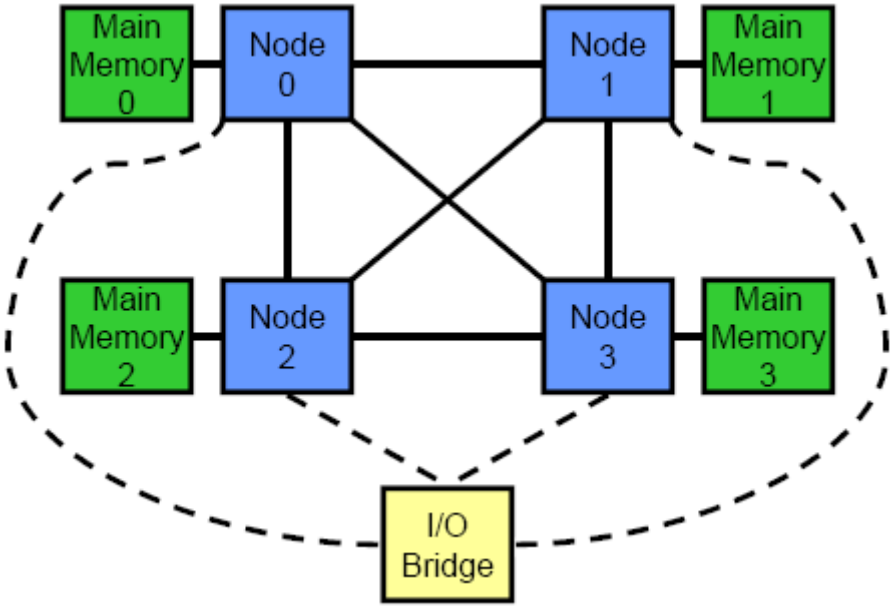


http://www.realworldtech.com/page.cfm?ArticleID=RWT082807020032&p=8

# Asymetrický multiprocesor (ASMP)

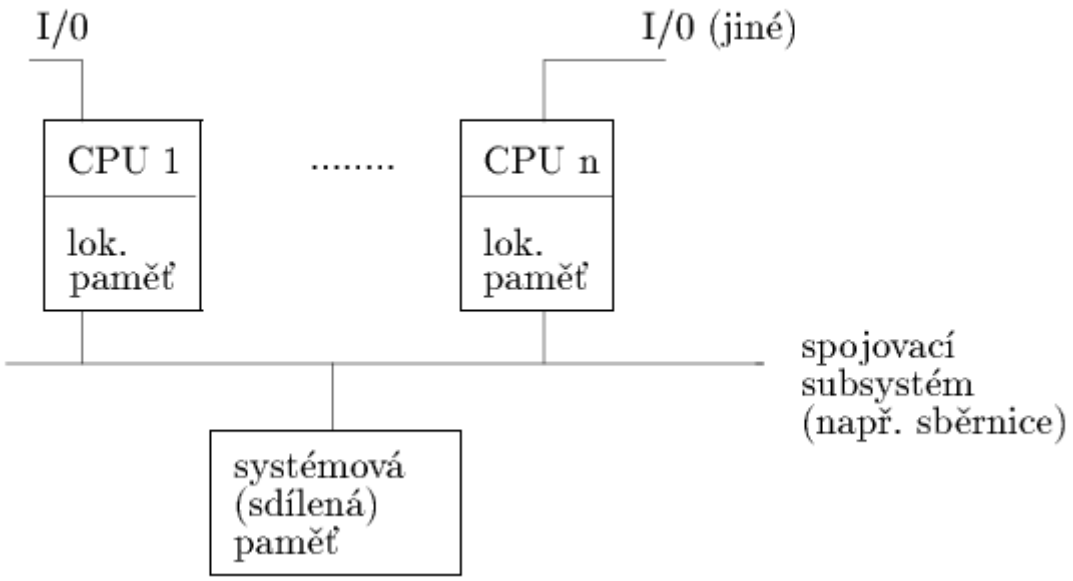


- Kromě sdílené paměti, každý procesor má vlastní lokální paměť a vlastní připojení I/O
- Každý procesor může mít jinou instrukční sadu
  - v extrémním případě na každém z nich běží jiný OS
- OS nemůže alokovat libovolný proces na libovolný procesor
- Jednotlivé procesory mohou vykonávat specifické úkoly
- Sdílená paměť může obsahovat pouze minimum dat
  - Minimalizace úzkého hrdla sběrnice
- V ’80 prohrál se SMP na poli univerzálních počítačů
  - Řešení ATI, kdy jedna karta renderovala scénu a druhá se starala fyziku, je softwarový ASMP
  - Sony PS3 – každý procesor pouze pro určité úkoly

# Multiprocesor s distribuovanou pamětí

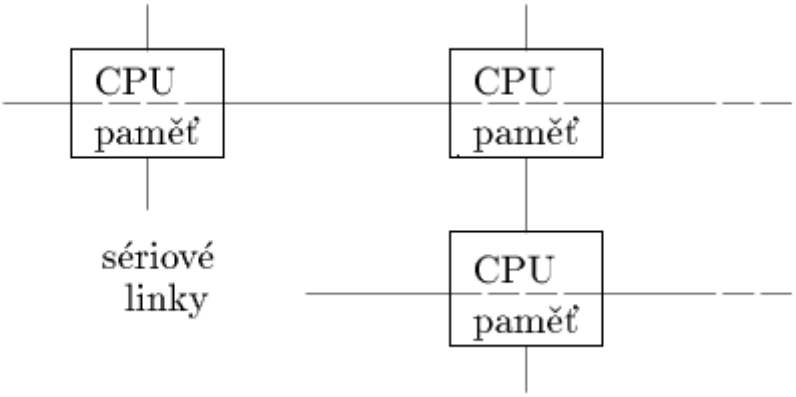


- Každý procesor má svou lokální paměť
- Sdílná paměť není
- Každý uzel je v podstatě počítač s omezeným I/O
- Komunikuje se zasíláním zpráv
- Typické topologie jsou 2D cyklicky uzavřené mřížky, nebo n-rozměrná krychle
- Výhodou je odstranění jedné sběrnice jako úzkého hrdla
- Nevýhodou je však malá univerzálnost – výkonnost záleží na způsobu alokace procesů na uzly a použitém komunikačním schématu
- Vhodné např. pro tzv. pipe-lines
- Transputery - Occam

# NUMA

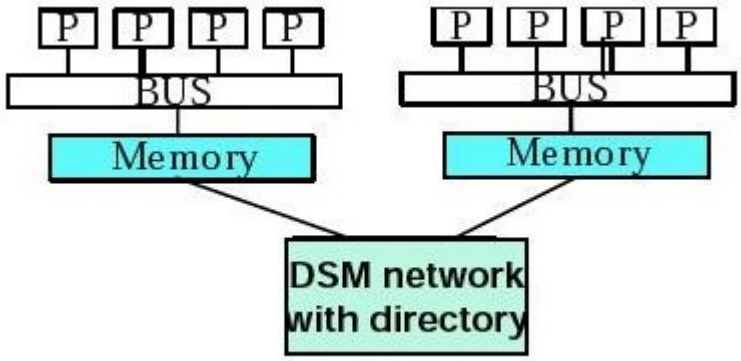


http://upload.wikimedia.org/wikipedia/en/c/c1/Numa.jpg

- Non-Uniform Memory Access
- DSM – Distributed Shared Memory
- Další pokus o vylepšení škálovatelnosti, kde jedna sběrnice SMP systémů představuje limit
  - Existuje několik sběrnic, které jsou vzájemně propojené
- Zavádí pojem lokální a vzdálené paměti
- Každý procesor má svůj „kus“ paměti
- Doba přístupu do paměti procesorem se může lišit, podle toho, kde paměť fyzicky je => non-uniform
- Problém, když proces odmigruje příliš daleko na jiný procesor

- Podporováno AMD Opteron – viz Hyper Transfer
- Podporováno Intel Nehalem a Tukwila – viz QuickPath

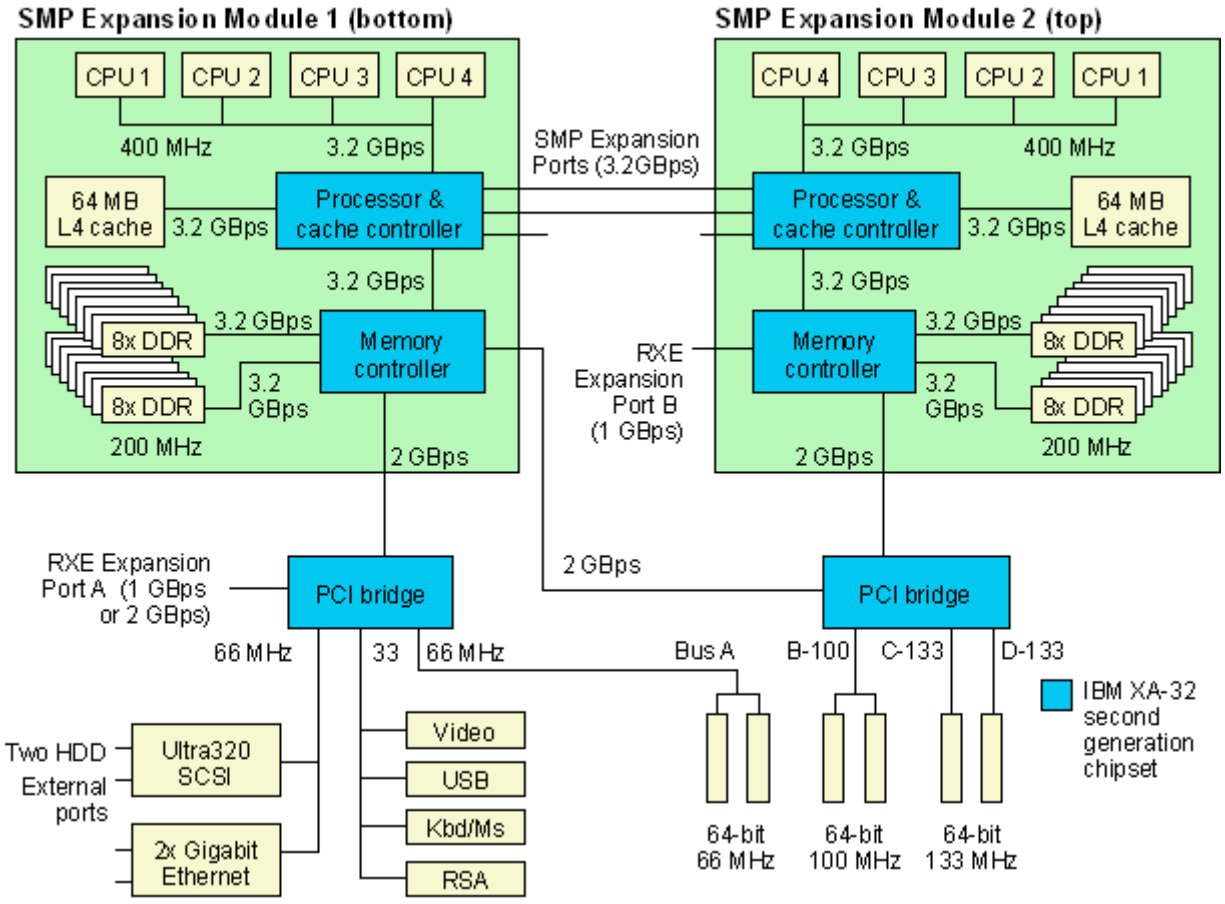


http://www.redbooks.ibm.com/abstracts/tips0476.html?Open

# SUMO

- AMD Opteron
- Sufficiently Uniform Memory Organization
- Fyzicky podobné NUMA
- Pro OS se tváří jako SMP => aneb jak spustit normální jádro OS na NUMA

# COMA

- Cache Only Memory Architecture
- NUMA – lokální paměti tvoří celou paměť, při vzdáleném přístupu vznikají repliky
- COMA – lokální paměti jsou použity jenom jako cache, lepší využití paměti, ale je zde problém platnosti replik
- Byly navrženy i hybridní kombinace NUMA-COMA
    - Sun WildFire

# Distribuovaný systém

- De facto počítačová síť, která se může tvářit jako jeden stroj
- Dědí problémy multiprocesoru s distribuovanou pamětí
- Každý uzel je plnohodnotný počítač, na kterém může běžet několik procesů zároveň
- Např. cluster
    - Počítače propojené velmi rychlou lokální sítí

# Vektorový paralelní počítač

- Vector Processor, Array Processor
- Mohou provádět operace s vektory čísel na úrovni instrukcí strojového kódu
- Dříve doména superpočítačů jako Cray-1, dnes
  - MMX (Intel) – Matrix Math eXtension?
  - SSE1-5 (Intel, AMD) – Streaming SIMD Extensions
  - 3DNow! (AMD)
  - AVX (Intel) – Advanced Vector Extensions
  - AltiVec (IBM, Apple, Motorola)

- Paralelizaci tohoto typu využívá překladač
  - Některé (např. GCC v4) umí tzv. auto-vektorizaci, kdy je část kódu rovnou převedena na vektorové instrukce
  - Programátor může překladači pomoci správným zápisem kódu

```
procedure VectorAdd (dst, src:PVector); assembler;
asm
…
   mov ecx, VectorSize   //128 bits = 16 bytes => 4
@loop:

   fld  [eax]  //dst -> ST0
   fadd [edx]  //src
   fst  [eax]  //ST0 -> dst
   add   eax, 4
   add   edx, 4

   dec   ecx
   cmp   ecx, 0
   jne  @loop
…
end;
```

```
type
  PVector = ^TVector;
  TVector = packed record
    x, y, z, w: single;
      //sizeof(single) = 4
 end;
```

```
SSE
movups  xmm0, [eax] //dst
movups  xmm1, [edx] //src
addps   xmm0,  xmm1
movups [eax],  xmm0 //dst
```

# Základní modely paralelní dekompozice

- Vlastnímu programování předchází fáze analýzy!
- Dekompozice výpočtu na paralelizovatelné složky
- Návrh, co bude řešit ten který proces/vlákno
- Dekompozice dat pro jednotlivé procesy/vlákna
- Obecně rozhodování nemusí být ovlivněno cílovou architekturou
  - Uvedené modely jsou dostatečně obecné
  - Nicméně, lokální a distribuovaná paměť představují dost zásadní rozdíl, než aby se nevzal do úvahy
  - Analogie lze nalézt/postupy lze uplatnit i v běžném životě (je-li to politicky průchodné:-)

# Flynnova taxonomie

| | **Single Instruction** | **Multiple Instruction** |
|---|---|---|
| **Single Data** | SISD | MISD |
| **Multiple Data** | SIMD | MIMD |

- Uvedené jsou čtyři základní klasifikace podle Flynna
  - Počet konkurenčně prováděných instrukcí
    - tj. programů a někdy používanému počeštěnému označování např. SPMD, což ale není formálně správně právě podle Flynna – viz dále
  - Počet existujících dat (Data Streams)
- MIMD – dále se dělí na
  - SPMD – Single Program, Multiple Data Streams
  - MPMD – Multiple Program, Multiple Data Streams
- Používají se termíny funkční a datový paralelismus

# SISD

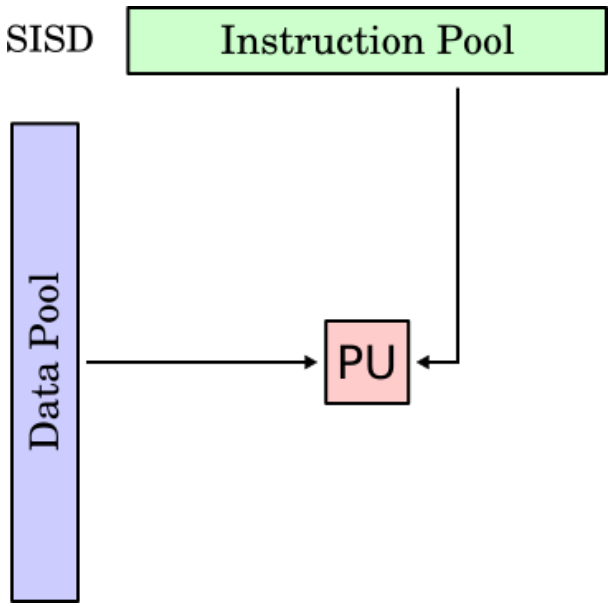


http://en.wikipedia.org/wiki/Image:SISD.svg

- Single Instruction, Single Data Stream
- Sekvenční výpočet, žádný paralelismus
- Např. i386 s MS-DOSem

```
COsoba princ, princezna, kral;
CPotvora drak;
CObjekt kralovstvi;

HRESULT __fairytale Edvenčra() {

  if (princ.sila > drak.sila) {
      delete drak;
      princ += princezna + kralovstvi/2;
      return S_OK;
  }

   else if (princ.sila < drak.sila) {
      princ -= hlava;
      drak.hmotnost += princezna.hmotnost;
      kral.status = "Smutny";
      return E_FAIL;
   }

   else if (princ.sila == drak.sila) {
      princ.perform("BuyBiggerGun");
      return S_ToBeContinued;
   }
}
```

# SIMD

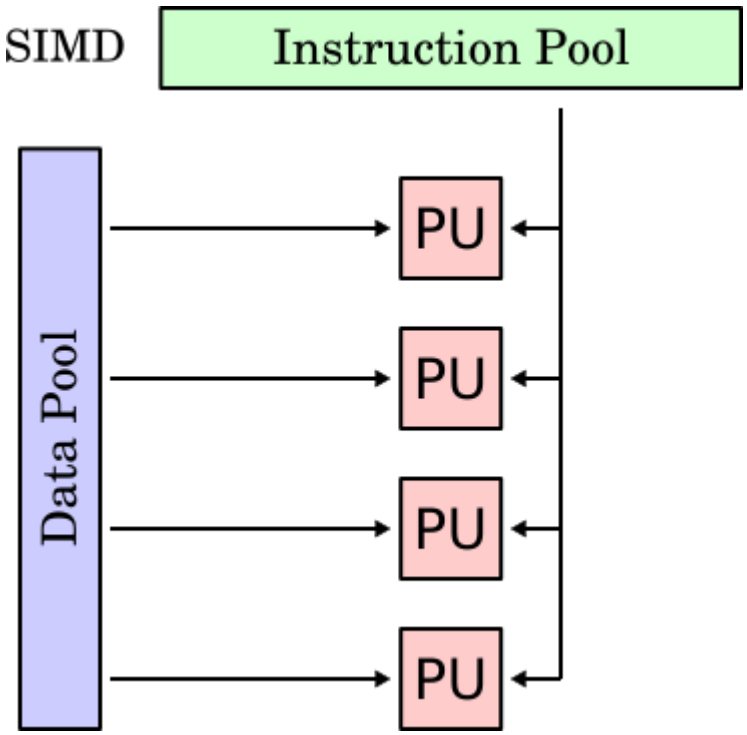


http://en.wikipedia.org/wiki/Image:SIMD.svg

- Single Instruction, Multiple Data Streams
- Viz výše vektorový paralelní počítač

# MISD (MPSD)

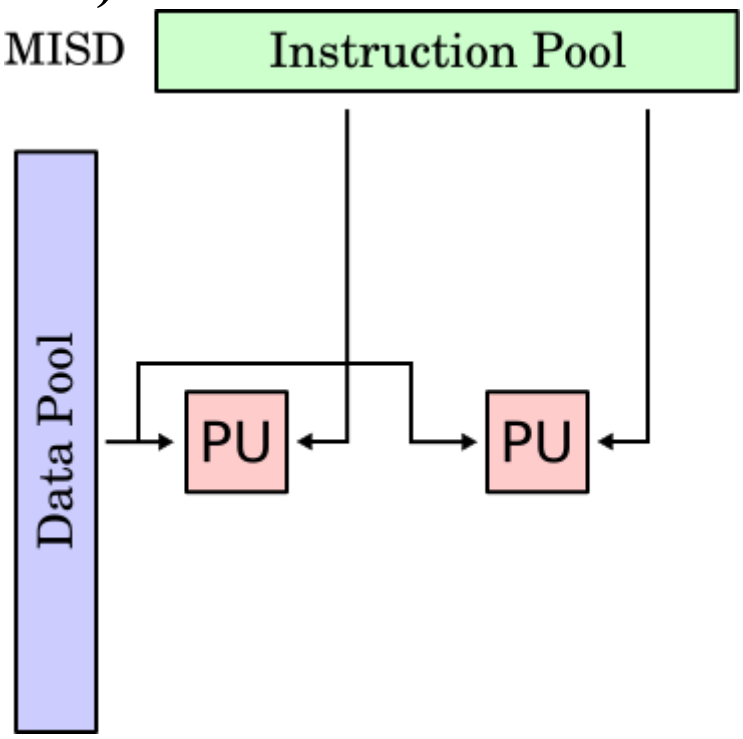


http://en.wikipedia.org/wiki/Image:MISD.svg

- Multiple Instruction (Program), Single Data Stream
- Používáno pro výpočty odolné proti poruchám (Fault Tolerant)
  - Několik různých systémů zpracovává ty samá data a musejí se shodnout na výsledku – např. řízení letu raketoplánu, letadla, atd.
- Používá se v tzv. Pipeline architektuře
  - několik procesů zpracovává data v jednom datovém proudu
  - analogií je montážní linka v továrně
  - Např. instrukční pipeline procesoru

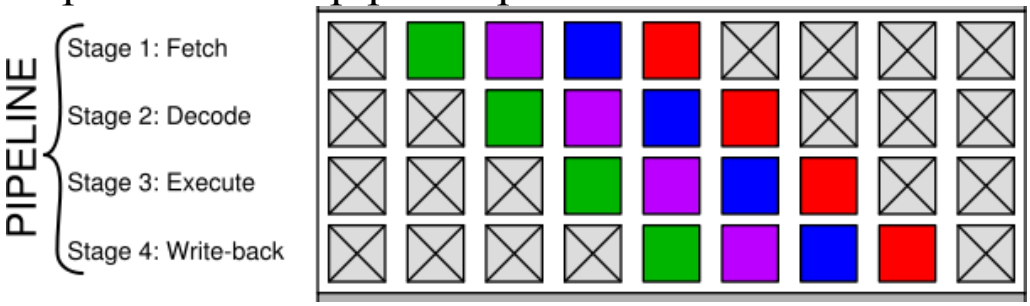


http://en.wikipedia.org/wiki/Image:Pipeline%2C_4_stage.svg

# MIMD

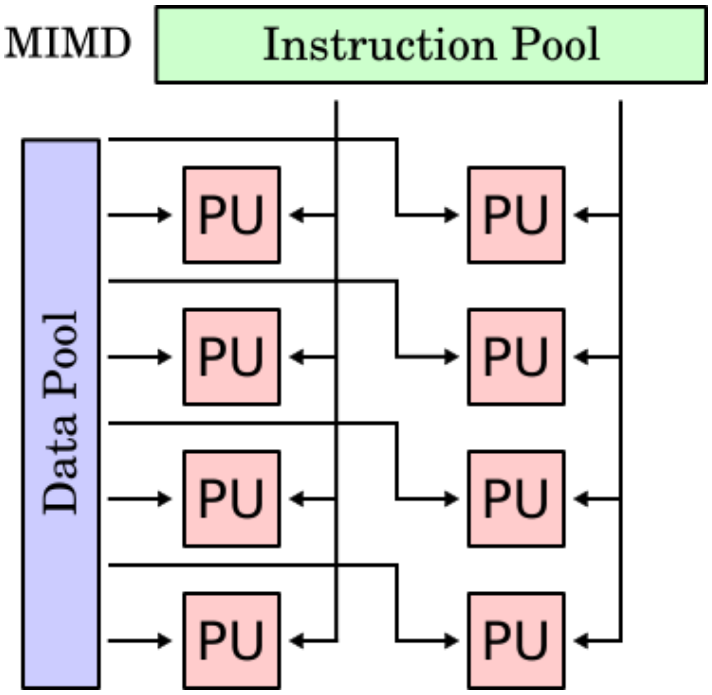


http://en.wikipedia.org/wiki/Image:MIMD.svg

- Multiple Instruction, Multiple Data Streams
- Několik procesorů zároveň vykonává různé instrukce nad několika různými daty
- Procesory pracují asynchronně a nezávisle na sobě
- Procesory buď mají sdílenou paměť,
  - Programátorovi snáze srozumitelný přístup
  - O zajištění integrity dat se stará OS
- nebo distribuovanou
  - má lepší škálovatelnost
- Distribuovaný systém – viz výše i dále

- MIMD programy lze odladit i na jednom počítači
  - Virtualizace jednoho procesoru pro sdílenou paměť
  - localhost a pro distribuovanou paměť
  - Samozřejmě, některé chyby takto mohou uniknout, protože se neprojeví díky jinému komunikačnímu zpoždění, nebo díky virtualizaci jednoho procesoru, kdy žádná dvě vlákna neběží současně

# SPMD

- Single Program, Multiple Data Streams
- Několik procesorů autonomně vykonává jeden program nad různými daty
- Bod vykonávání programu nemusí být na všech procesorech stejný
- Označuje se též jako dekompozice dat
- Používá se ke zpracovávání velkých objemů dat
  - *k* procesů běžících podle stejného programu zpracovává strukturně stejná, ale hodnotově různé části dat
  - např. násobení matic – každý prvek, řádek, či sloupec matice lze spočítat jedním procesem/vláknem
- Sleduje se čistě výkonnostní hledisko
- Předpokládá se, že každý z procesorů je schopen vykonávat ten samý program

# MPMD

- Multiple Program, Multiple Data Streams
- Několik procesorů autonomně vykonává více než jeden program nad různými daty
- Např. farmer-worker, kdy jeden proces úkoluje ostatní
- Nemusí jít nutně pouze o urychlení výpočtu
  - Může jít o aplikaci, kdy se každý proces stará „o to svoje“ a zároveň spolupracuje s ostatními
  - Např. Cisco IOS – síť A s OSPF, síť B s EIGRP, border router vyplní směrovací tabulku podle obou
- Dist. Simulace – systém spolupracujících komponent

# Interakce

- Po výběru modelu dekompozice výpočtu je třeba stanovit model interakce procesů
- Rozhodnutí je výrazně ovlivněno
  - architekturou systému, který máme k dispozici,
    - distribuovaná vs. sdílená paměť
  - prostředky poskytovanými OS, nebo interpretem
    - WinAPI vs. POSIX vs. Java
  - a použitými knihovnami funkcí
    - PVM vs. MPI vs. využití programovatelné sítě
- Interakce zahrnuje synchronizaci a výměnu dat
  - Žádoucí je
    - Minimální interakce
    - Rychlostní nezávislost výpočtu
    - Škálovatelnost

- Minimální interakce
  - Co největší samostatnost procesů
  - Častá komunikace zatěžuje komunikační kanál (sběrnice, Ethernet) a tím zpomaluje celý systém
    - Tedy i samotný výpočet
    - Communication overhead
  - Čím řidší komunikace, tím snáze se odhalí chyby vzniklé chybnou interakcí procesů
  - Při použití blokujících funkcí, zejména receive, dochází u časté komunikace k výraznému zpomalení příjemce
  - Totálně asynchronní paralelní algoritmus – minimální potřeba interakce procesů

- Rychlostní nezávislost výpočtu
  - Obecně nelze dopředu stanovit rychlost, s jakou poběží vlákna procesů
    - Počet běžících vláken na daném procesoru
    - I/O operace
    - Heterogenní hardware v síti
  - Paralelní výpočet musí skončit správným výsledkem bez ohledu na to, jakou rychlostí běží vlákna jeho procesů
  - V programu se definují synchronizační body, kdy se čeká až požadovaný počet ostatních vláken bude v požadovaném stavu
    - Odeslání a přijmutí zprávy
    - Bariéra
    - P/V (KIV/ZOS)
  - Nedojde k zablokování výpočtu (deadlock, livelock)
  - Procesy a jejich vlákna skončí za předem definovaných podmínek
  - K modelování lze použít Petriho sítě (KIV/VSP)

- Škálovatelnost
  - Nezávislost na počtu dostupných procesorů
  - S rostoucím počtem procesů narůstá i komunikační režie a dochází ke zpomalování výpočtu

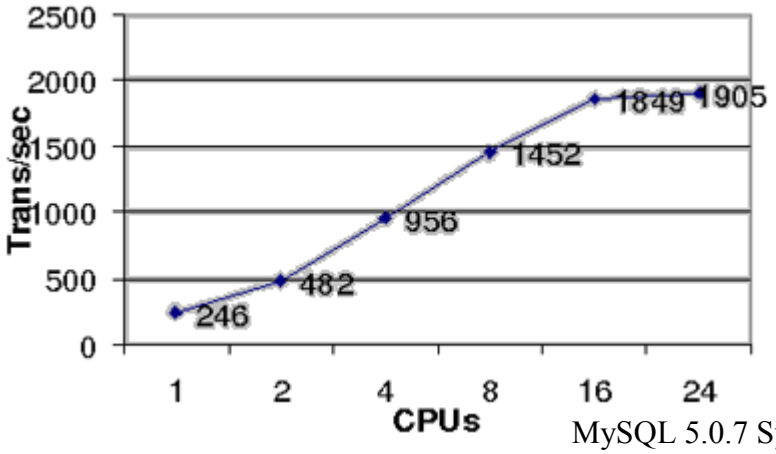


MySQL 5.0.7 SysBench CPU Scalability Test
http://developers.sun.com/solaris/articles/mysql_perf_tune.html

# Komunikace

- Sdílení dat
  - Realizovatelné pouze na počítačích se sdílenou pamětí
  - Procesy sdílejí popis datových struktur
  - Procesy se nemusejí vzájemně znát, ale musí vědět, kde jsou uložena data
  - Prostředky pro přístup k datům jim dává OS
  - Může dojít ke konfliktu při přístupu k datům
    - Jeden proces je může číst
    - Jiný proces je bude zapisovat
  - Příslušný kód programu se nazývá kritická sekce
  - K jejímu zabezpečení se používají synchronizační primitiva
    - Nízkoúrovňové: semafory, zámky, bariéry
    - Vysokoúrovňové: monitory, rendez-vous

- Zasílání zpráv
  - Jediná možná v systémech s distribuovanou pamětí
  - Lze ji použít i v systémech se sdílenou pamětí
    - WinAPI: SendMessage
  - Univerzální technika
    - Ne, když se použijí funkce specifické pro jednu cílovou architekturu
  - Je pomalejší než sdílení dat

  - Synchronní – blokující
    - zpráva je předána, až jsou na to oba připraveni
  - Asynchronní – neblokující
    - Odesílatel ji odešle, vloží do vyrovnávací paměti a příjemce si ji vyzvedne později

  - Symetrické – zpráva obsahuje adresu odesílajícího i příjemce
  - Asymetrické – zpráva obsahuje jen adresu příjemce
  - Nepřímé – zpráva obsahuje adresu komunikačního kanálu, tj. komunikující procesy se vůbec nemusí nijak znát

# Výkonnost

- Složitost
  - Complexity, worst-case complexity
  - Maximální doba výpočtu algoritmu pro všechny možné kombinace vstupních dat
  - *O(n) = n*
    - složitost sekvenčního algoritmu, která je lineárně závislá na *n* počtu prvků
    - např. součet čísel
    - KIV/PPA2
  - Paralelní součet na *p = n/2* procesorech má složitost *O(log n)*
    - Logaritmus s libovolným základem

- Cena (paralelního algoritmu)
  - Cost
  - Složitost vzhledem k počtu použitých procesorů
    - Kolik celkového strojového času, tj. všech použitých procesorů, výpočet spotřebuje
    - Např. *(log n)*n/2*
  - Je úměrná celkovému strojovému času všech použitých procesorů

- Urychlení
  - Speedup
  - Existuje několik způsobů, jak ho vyjádřit, následující je nejrozšířenější/nejznámější způsob
  - Poměr doby výpočtu referenčního algoritmu a porovnávaného algoritmu
    - Např. nejlepšího známého sekvenčního algoritmu a paralelního algoritmu na témže (paralelním) počítači
      - Lze ovšem porovnat i urychlení referenčního sekvenčního algoritmu oproti provedené optimalizaci
      - Anebo porovnat dva různé paralelní algoritmy
  - $S(p) = E(1) / E(p)$
    - >1 znamená urychlení
  - Perfektní urychlení
    - Poměr je přesně roven počtu procesorů
      - Asi těžko ho dosáhnete :-)

- Účinnost
  - Efficiency
  - Urychlení dělené počtem procesorů
    - Uvažujeme urychlení proti sekvenčnímu algoritmu
  - Sekvenční výpočet trvá 10s,
    paralelní algoritmus na 4 procesorech trvá 5s
    - Urychlení: 2
    - Účinnost: 0,5

- Amdahlův zákon
  - Nelze dosáhnout perfektního urychlení, protože vždy bude nějaká část výpočtu provedena sekvenčně
  - *G, H* – čas strávený sekvenčně provedeným výpočtem
  - *G*
    - čas strávený vykonáváním neparalelizovatelného kódu, tj. sekvenčně
    - Unavoidably Serial
  - *H*
    - čas strávený vykonáváním paralelizovaného kódu, ale sekvenčně
    - Serialized-Parallel
  - $E(p) = G + H/p$
  - $S(p) = (G+H)/(G+H/p)$
  - Pro velké *p* platí $S(p) = 1+H/G$
    - To by znamenalo, že dosažení perfektního urychlení je možné, pokud se můžeme vyhnout kódu, který nelze paralelizovat
      - Má vliv na *H*
    - Ale – čím větší počet procesorů, tím např. větší režie jejich komunikace => takže přece jenom nepůjde…
      - Režie OS (plánování, I/O, atd.) se o to také postará
  - Lze ho také zapsat s $0 < f < 1$ (čas sekvenčně prováděné části kódu) $S \leq \frac{1}{f + \frac{1-f}{p}} \leq \frac{1}{f}$

$$\max speedup \leq \frac{p}{1 + f \times (p-1)}$$

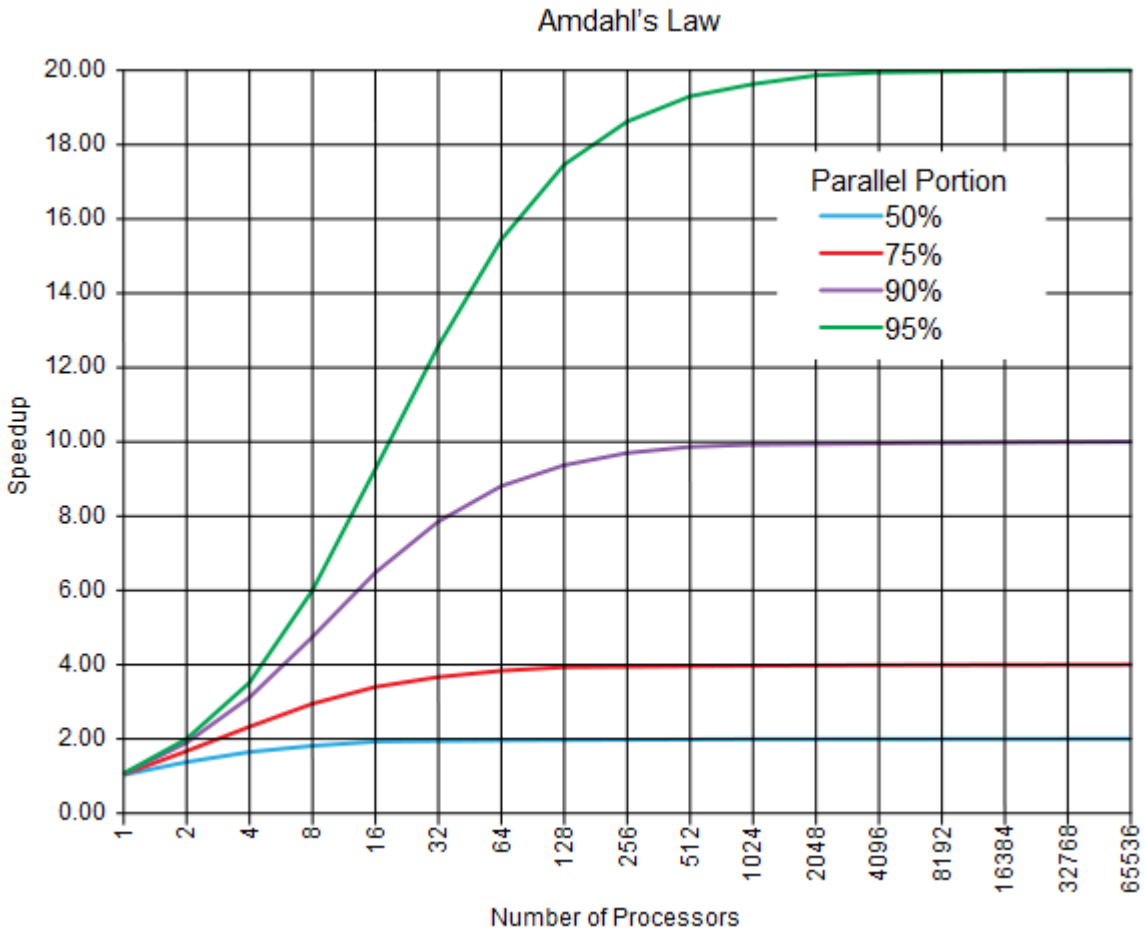


http://upload.wikimedia.org/wikipedia/en/e/ea/AmdahlsLaw.svg

- Anomální urychlení
  - Distribuce rozsáhlých dat u distribuované aplikace může omezit nutnost stránkovat RAM
  - S dostatečně rychlými komunikačními kanály pak dojde k rychlejšímu vykonávání programového kódu, protože odpadá čekání na zpomalující I/O operace provázející stránkování, včetně obsluhy příslušných přerušení (KIV/OS)

  - Např. paralelizované vyhledávací algoritmy mohou mít větší než lineární urychlení
    - Lze rychleji upřesnit výběrová kritéria

- Superlineární urychlení
  - Nicméně, v některých případech je skutečně možné, aby *S* vyšlo lépe než je perfektní urychlení
    - V těchto případech se nejedná o chybu ve výpočtu
    - Zejména, porovnáváme-li oproti nejlepšímu sekvenčnímu algoritmu

  - Cache procesoru
    - Mnohem častější cache-hit než je obvyklé
    - Výpočet je pak prováděn mnohem rychleji, než když se programový kód dostává k procesoru z pomalejší paměti
    - Záleží na konkrétním programovém kódu, zda se ho bude dostatečné množství nalézat právě v lokálních cache jednotlivých procesorů

  - Analogicky datová cache

# Výpočetní čas

- Nejjednodušeji čas strávený výpočtem a čas strávený čekáním

- Výpočetní čas procesoru
  - Díky spekulativním snahám procesorů o urychlování vykonávání kódu (řetězení instrukcí, vykonávání mimo pořadí, atd.), sběrnici, atd. je třeba uvažovat čas všech procesorů

- Komunikační čas
  - Zpoždění, které vznikne při interakci procesů a jejich vláken

- Další časové prodlevy
  - Nedostatek práce
  - Nedostupnost dat
    - Např. čekání na I/O
  - Režie OS
  - Nicméně, velké časové prodlevy také mohou znamenat nevhodný algoritmus, který je způsobuje svou činností

# Testy výkonnosti

- Testování jednotlivých komponent systému dohromady i zvlášť
- Několikrát po sobě se provede specifická sekvence operací a vyhodnotí se doba trvání
- Je třeba si být vědom efektů jako je např. vliv velikost cache na vykonávání kódu, spekulativní vykonávání kódu, atd.

- Průmyslové standardy
  - Standard Performance Evaluation Corporation (SPEC)
  - Transaction Processing Performance Council (TPC)

- OpenSource
  - Dhrystone – celočíselná aritmetika
  - Whetstone – čísla s plovoucí čárkou
  - Linpack/LAPACK – numerické výpočty

# Gustafsonův zákon

- $S(P) = P - \alpha \cdot (P-1)$
  - S – urychlení
  - P – počet procesorů
  - $\alpha$ - část procesu, kterou nelze paralelizovat

- Co když budeme mít k dispozici hodně procesorů s distribuovanou pamětí a výpočet složitý tak, že sériově prováděná část bude zanedbatelná?
  - Amdahl si s tím neporadí…

- Nerozdílíme výpočet podle paralelizovatelnosti kódu, ale podle podílů času – sériově vs. paralelně

- $a(n)+b(n) = 1$
  - 1 – čas výpočtu na p procesorech
  - a(n) – sériově
  - b(n) – paralelně

- $a(n) + p \cdot b(n)$
  - čas výpočtu na jednom procesoru

- $$S = \frac{a(n) + p \cdot b(n)}{a(n) + b(n)}$$

- Ideální urychlení
  - Do S se dosadí $a(n)+b(n) = 1$
  - $p \rightarrow P$
  - => $S(P) = P - \alpha \cdot (P-1)$
    - A lze vyhodnotit pro $a(n)$ aka $\alpha = \lim_{x \to 0+} x$

# Karp-Flattova metrika

- $$e = \frac{\frac{1}{\psi} - \frac{1}{p}}{1 - \frac{1}{p}}$$
  - e – metrika, podíl, kolik kódu se provedlo sériově
  - p – počet procesorů
  - $\psi$ - urychlení na p procesorech
    - Určí se z naměřených časů

- $T(p) = Ts + \frac{Tp}{p}$
  - Čas výpočtu na p procesorech
  - Ts – čas po který kód běžel sériově
  - Tp – čas po který kód běžel paralelně

- $T(1) = Ts + Tp$

- $e = \frac{Ts}{T(1)}$
  - Dosadí se do T(p)

- $\psi = \frac{T(1)}{T(p)}$

- $\frac{1}{\psi} = e + \frac{1-e}{p}$

- A úpravou dostaneme *e*