


Pokročilé architektury počítačů

01

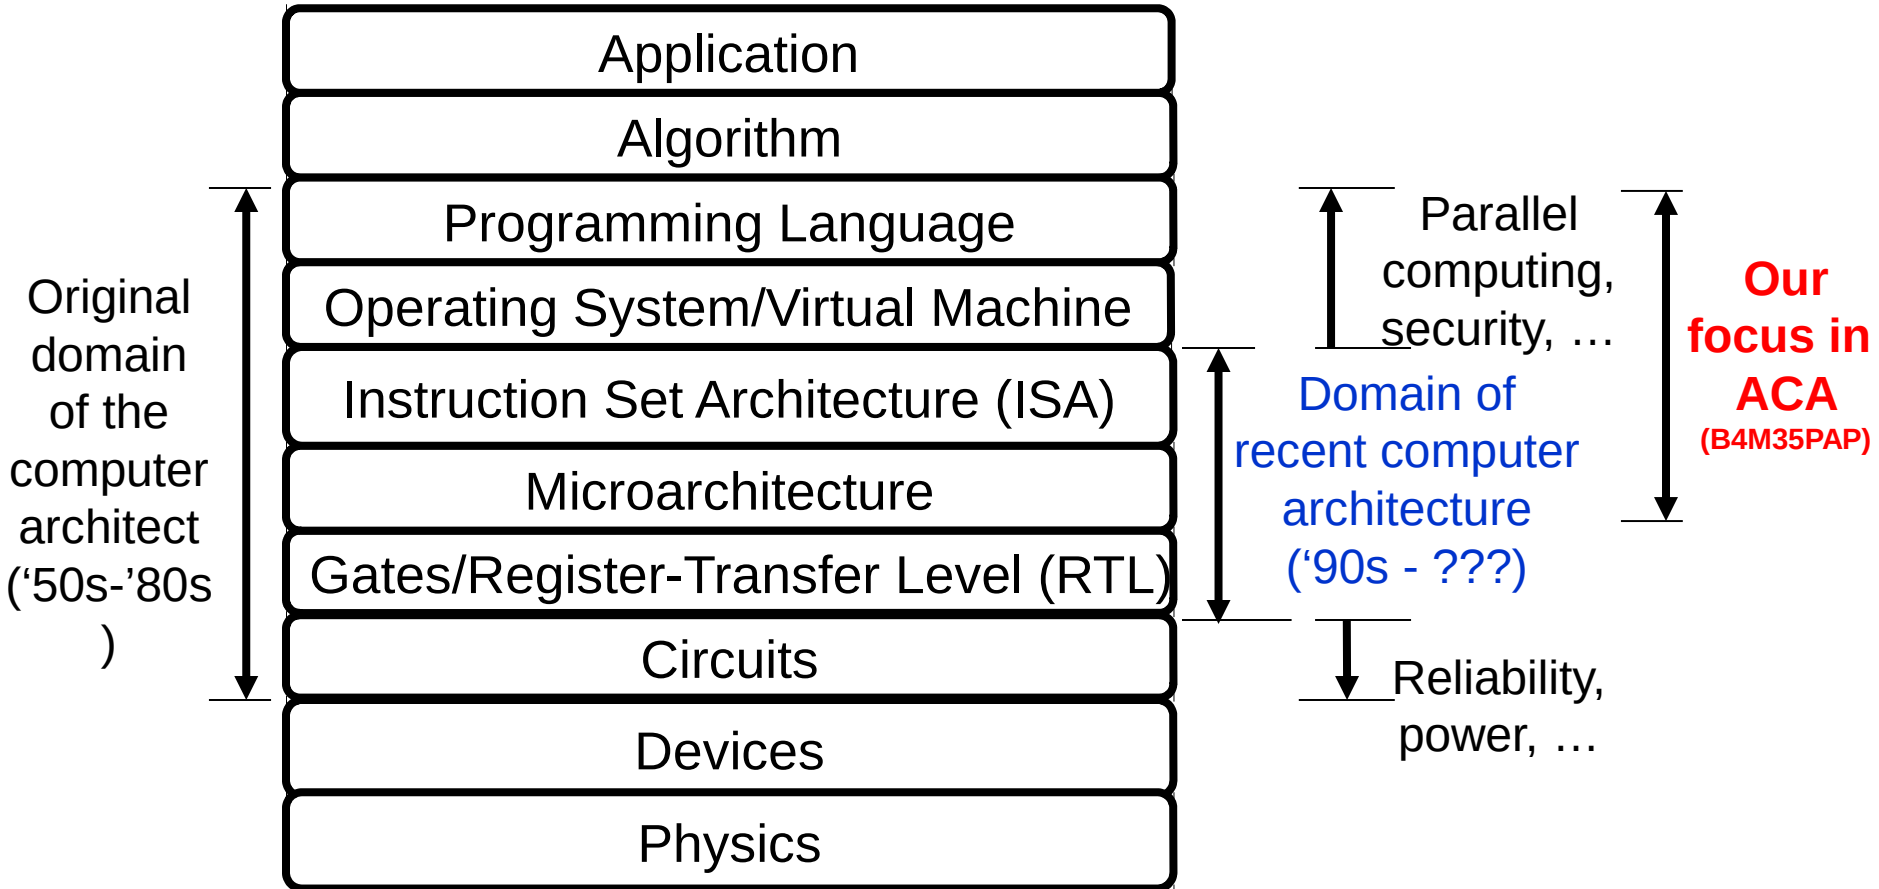
Úvodní přednáška



České vysoké učení technické, Fakulta elektrotechnická
Autor materiálu: Michal Štepanovský Přednášející: Pavel Píša


Ver.1.10

Abstraction Layers in Modern Systems




Reference: John Kubiatowicz: EECS 252 Graduate Computer Architecture, Lecture 1. University of California, Berkeley

Obsah a cíl předmětu




- Dva různé procesory mohou implementovat stejnou ISA, ale mohou se lišit v organizaci i v hardwarové realizaci (různé pipeline, organizace cache,...)
- Organizace – pohled „shora“ na návrh počítače (paměťový subsystém, struktura sběrnic,...)
- Hardware – pohled „zdola“ (logické obvody, technologie,...)

What is it?




First Transistor
(Bell Labs) – Dec. 23, 1947



First integrated circuit (IC)
Jack Kilby's original IC (Texas Instruments) - 1958


Technology constantly on the move!

- Num of transistors not limiting factor
 - Currently ~ 1 billion transistors/chip
 - Problems:
 - Too much Power, Heat, Latency
 - Not enough Parallelism
- 3-dimensional chip technology?
 - Sandwiches of silicon
 - “Through-Vias” for communication
- On-chip optical connections?
 - Power savings for large packets
- The Intel® Core™ i7 microprocessor (“Nehalem”)
 - 4 cores/chip
 - **45 nm**, Hafnium hi-k dielectric
 - 731M Transistors




Reference: John Kubiatowicz: EECS 252 Graduate Computer Architecture, Lecture 1. University of California, Berkeley


Transistors



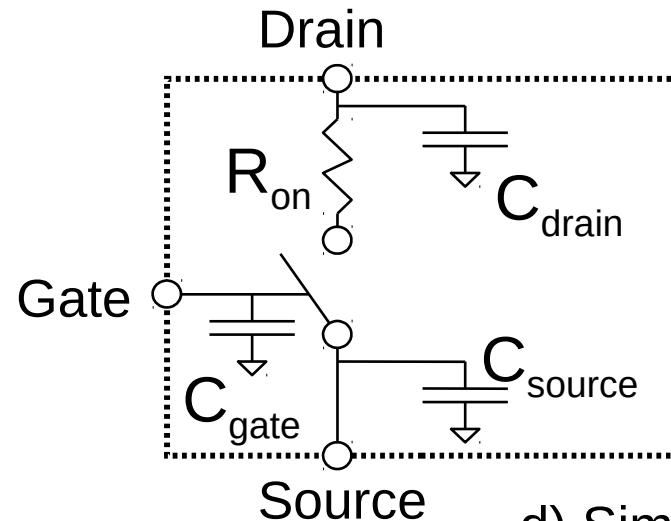
a) Circuit Symbol



b) Physical Realization




c) Layout View



d) Simple RC Model

Transistors - Today




©IBM

IBM SOI Technology

K.Asanovic: VLSI for Architects - Advanced VLSI Computer Architecture,
<http://groups.csail.mit.edu/cag/6.893-f2000/lectures/I02-vlsi-for-archs.pdf>, Copyright 2000, Krste Asanovic.

Gordon Moore



- Rychlost šíření elektrických signálů shora omezena rychlostí světla (při 3,6 GHz je perioda 0,278 ns \Rightarrow 8,3 cm) (zpoždění propojení dominuje nad zpožděním hradel)
- Ultimate minimum feature size may be determined by atomic spacing – in Si the lattice constant is ~ 0.5 nm.

Dmitri Nikonov: Beyond CMOS computing - 1. CMOS Scaling. h

http://nanohub.org/resources/18348/download/NikonovBeyondCMOS_1_scaling.pdf

S. Demlow: A Brief History of the field of VLSI, ECE 410, January 9, 2012

1. Úvodní přednáška

Úvod do moderní architektury počítačů; počítače řízené tokem instrukcí (control driven) a tokem údajů (data driven a demand driven). Klasifikace počítačových architektur podle Flynna; Vícejádrové, víceprocesorové a vícepočítačové systémy, pojem paralelního zpracování. Amdahlův a Gustafsonův zákon. Výkonové metriky.

2. Přednáška - Od skalárního procesoru k superskalárnímu (základní organizace superskalárního procesoru)

Superskalární procesory se statickým, dynamickým a hybridním plánováním vykonávání instrukcí.

3. Přednáška - Superskalární techniky I - Tok dat uvnitř procesoru (register data flow)

Přejmenování registrů (Tomasulův algoritmus) a datové spekulace. Podpora přesného přerušení.

4. Přednáška - Superskalární techniky II - Spekulativní vykonávání (řídící spekulace)

Predikce, prediktory a předvýběr instrukcí. Statické a dynamické predikce; Smithův prediktor, dvou-úrovňové prediktory s lokální a globální historií, dvou-módový prediktor, a další. Zotavení po nesprávné predikci.

5. Přednáška - Superkalární techniky III - Memory data flow, a Procesory VLIW a EPIC

Tok dat z/do paměti. Load bypassing a Load forwarding. Spekulativní load. Některé další způsoby redukce latence paměti. Procesory VLIW a EPIC. Využití datového paralelismu, SIMD a vektorové instrukce v ISA. Loop unrolling a Software pipelining - vykonání na WLIV a superskalárním procesoru.

6. Přednáška – Paměťový subsystém

Neblokující cache, Victim cache, Virtuální paměť a cache

7. Přednáška - Multiprocessorové systémy a problém koherence paměti

Architektury multiprocessorových počítačů. Systémy s distribuovanou a sdílenou pamětí (DMS, SMS). Architektury symetrických multiprocessorových počítačů Způsoby zajištění koherence v SMP.

8. Přednáška - Multiprocessorové systémy a problém konzistence paměti

Pravidla pro provádění paměťových operací, zajištění sekvenční konzistence, modely paměťové konzistence.

9. Přednáška - Programování paralelních systémů I

Způsoby programování paralelních systémů - použití Message Passing Interface (MPI) a Open Multi-Processing (OpenMP) pro tvorbu paralelních programů.

10. Přednáška - Programování paralelních systémů II

Synchronizace

11. Přednáška – I/O podsystém (do doby než přijdou absolventi APO z LS2014)

PCIe, HyperTransport, QuickPathInterconnect

12. Přednáška - Časový a prostorový paralelizmus v praxi

Ukázka vybraných partií na procesoru Intel Nehalem

13. MPP a clustery, propojovací síť

14. Perspektivy a omezení dalšího rozvoje

část I – Verilog a popis hardwaru počítače

Seminární projekt: Návrh jednoduchého procesoru

část II – Programování paralelních systémů

Seminární projekt: Tvorba paralelního programu pro vícejádrový víceprocesorový paralelní výpočetní systém

část III – Samostatná práce a prezentace výsledků seminárních projektů

Podmínky absolvování předmětu

- Účast na cvičeních – povinná
(2 absence bez doložení potvrzení od lékaře povoleny)
- Odevzdání všech seminárních projektů
- Zkouška:
 - úspěšné absolvování písemné části zkoušky (min. 60%)
 - ústní část zkoušky

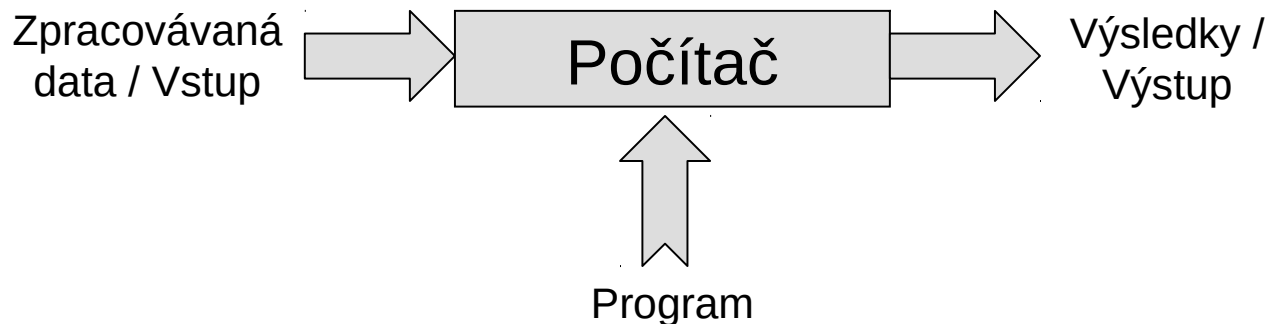
Stránky předmětu: <https://cw.fel.cvut.cz/wiki/courses/a4m35pap>

Literatura:

- Hennesy, J. L., Patterson, D. A.: Computer Architecture : A Quantitative Approach, Third Edition, San Francisco, Morgan Kaufmann Publishers, Inc., 2002
- Shen, J.P., Lipasti, M.H.: Modern Processor Design : Fundamentals of Superscalar Processors, First Edition, New York, McGraw-Hill Inc., 2004
- Grama A., Gupta, A. et al.: Introduction to Parallel Computing, Second Edition, Addison Wesley, 2003

Obecnější pohled na počítač a jeho činnost

- Pokud pod pojmem *počítač* budeme rozumět univerzálně použitelné zařízení na automatické zpracování dat, potom:



- Program může být definován jako specifikace množiny operací nad operandy (zpracovávanými daty), které jsou potřeba k vykonání požadované úlohy (získání výsledků).
- $F = (A*B + C*D) / (E+2)$,
A,B,C,D,E – vstupy; F – výstup;
zápis v programovacím jazyce vedoucí k výsledku – program

Uvažujme: $F = (A*B + C*D) / (E+2)$

Control Flow přístup:

- Mult Reg1, A, B
- Mult Reg2, C, D
- Add Reg1, Reg1, Reg2
- Add Reg2, E, 2
- Div F, Reg1, Reg2
- Write F

Činnost počítače je určena
sekvencí instrukcí...

Obecnější pohled na počítač a jeho činnost


$$\text{Uvažujme: } F = (A * B + C * D) / (E + 2)$$

Control Flow přístup:

- Mult Reg1, A, B
- Mult Reg2, C, D
- Add Reg1, Reg1, Reg2
- Add Reg2, E, 2
- Div F, Reg1, Reg2
- Write F

Činnost počítače je určena sekvencí instrukcí...

Data Flow přístup:

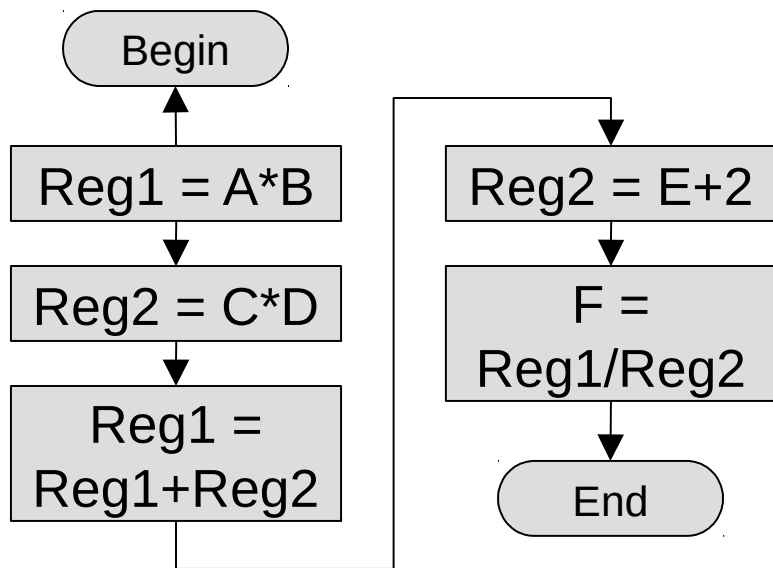


Činnost počítače určují žádosti o výsledek (demand driven), nebo přítomnost operandů (data driven)..

Obecnější pohled na počítač a jeho činnost


$$\text{Uvažujme: } F = (A*B + C*D) / (E+2)$$

Control Flow přístup:



Činnost počítače je určena sekvencí instrukcí...

Data Flow přístup:



Činnost počítače určují žádosti o výsledek (demand driven), nebo přítomnost operandů (data driven)..

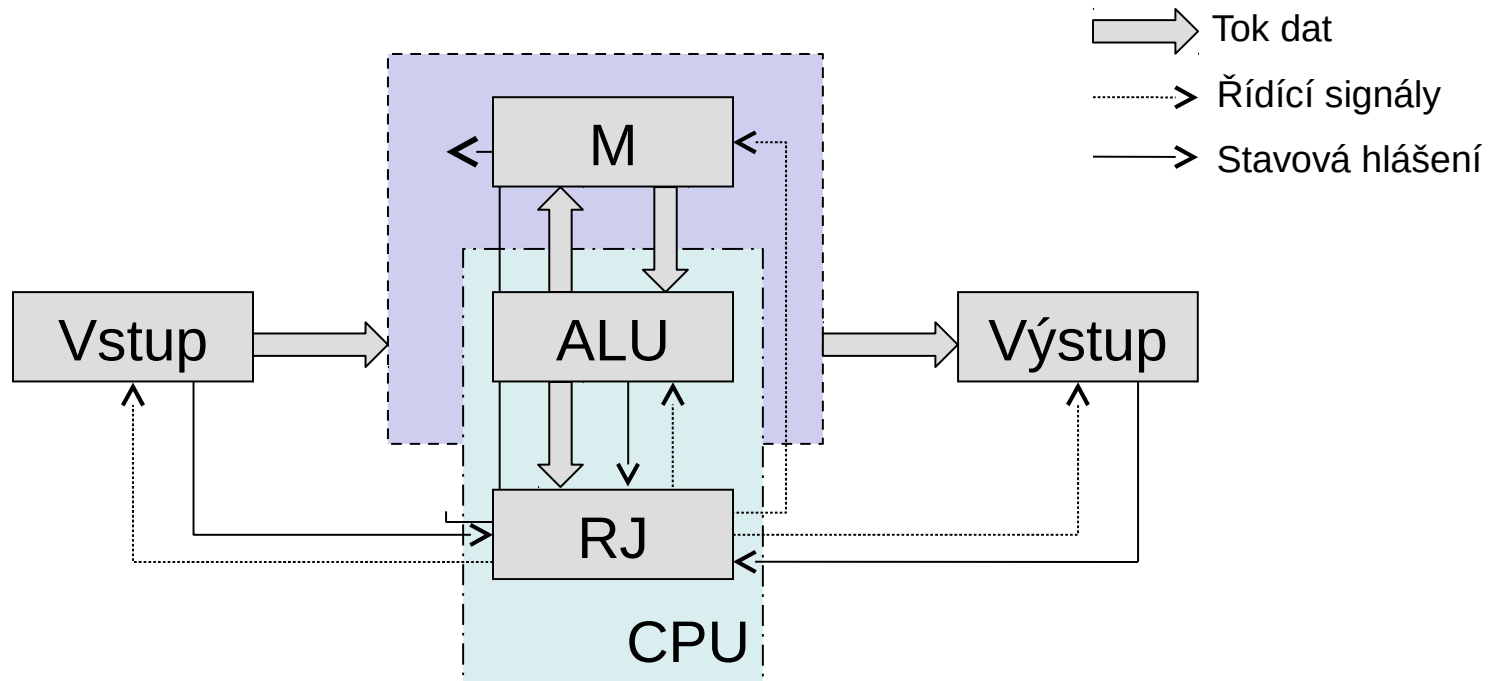
Control Flow vs. Data Flow

- Instrukce se vykonávají sekvenčně tak, jak jsou zapsány, resp. jak to určuje čítač instrukcí (program counter).
Explicitní přenosy řízení se realizují skokovými instrukcemi...
→ Imperativní programování
- Případné vykonávání instrukcí (z důvodu lepšího využití HW) v jiném pořadí nesmí dávat jiný výsledek!

- Instrukce v DF počítači se realizuje jako šablona, kterou tvoří operátor, příjemce operandu a určení výsledku. Instrukce se vykoná vždy, když jsou dispozici potřebné operandy...
- Pořadí vykonávání instrukcí je dáno datovými závislostmi a dostupností prostředků
→ Nezávislost instrukce od umístění v programu

Control Flow

- Čtyři hlavní subsystémy (von Neumann): Operační paměť (M), Aritmeticko-logická jednotka (ALU), Řídicí jednotka (RJ), Vstupně-výstupní subsystém (V/V)
- RJ – řídí vykonávání instrukčního cyklu (fáze výběru, dekódování, vykonání)



Základní elementy:

- Uzly (add, if, switch, merge, not,...), hrany (datové, řídicí), tokeny (datové, řídicí)

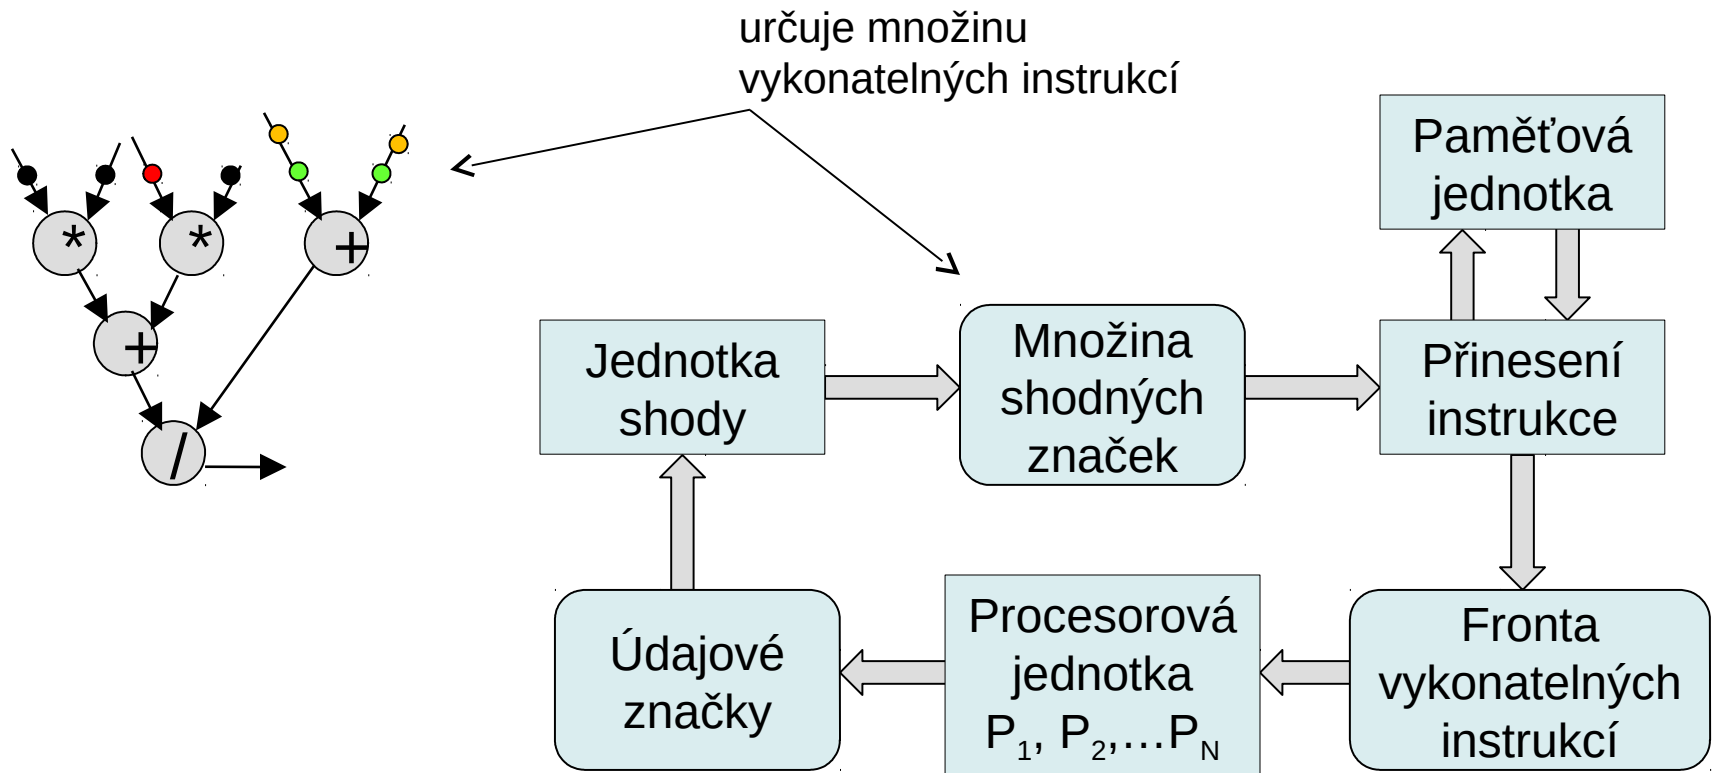
Architektura:

- Statická (povolen jeden token na hranu – dáno konstrukcí grafu.. takže není důvod umísťovat jeden uzel na vícero VE; programový graf je staticky alokován na fyzické VE)
- Dynamická (více tokenů, pořadí identifikováno značkou)
- Hybridní (více tokenů; dva módy vykonávání: 1. FIFO (přicházející tokeny jsou řazeny do fronty), 2. pořadí identifikováno značkou)

Vykonávání:

- Statické (vykonání operace pokud výstup neobsahuje tokeny, na vstupu může být i vícero tokenů),
- Dynamické

Dynamická architektura DF počítače



- Zjišťování podmínek vykonání uzlů a detekce vykonatelných uzlů
- Přiřazování vykonatelných uzlů procesorům
- Posouvání tokenů mezi uzly (posun vygenerovaného tokenu k příjemci)
- Dynamické vytváření instancí uzlů (příp. subgrafů) – smyčky v DF grafu...
- Rozlišení tokenů náležících různým instancím téhož uzlu
- Komunikace s vnějším světem
- Detekce ukončení programu

- Rozvoj v 70-tých až 80-tých letech
- Nyní princip DF v jednoúčelových zařízeních (zejména na bázi FPGA),
například v rekonfigurovatelném SoC např. pro dekódování MPEG4 videa [1] (9 hierarchických FSM, 31 stavů, 44 přechodů, 89 SDF uzlů),
nebo v koprocesoru pro zpracování obrazu [2] (rozpoznávání čárového kódu)
a jiných...

Zdroje:

- [1] Sunghyun Lee , Sungjoo Yoo , Kiyoungh Choi: Reconfigurable SoC Design with Hierarchical FSM and Synchronous Dataflow Model (2002).
- [2] Richard Thavot, Romuald Mosqueron et al. : Dataflow design of a co-processor architecture for image processing. DASIP 2008, Bruxelles, Belgium, 24-26 November 2008.
- [3] John A. Sharp: Data Flow Computing: Theory and Practice
- [4] <http://comjnl.oxfordjournals.org/cgi/reprint/33/3/230>


Klasifikace počítačových architektur podle Flynna

- **SISD** (Single Instruction stream Single Data stream)
klasická architektura von Neumann bez zavedení paralelizmu
- **SIMD** (Single Instruction stream Multiple Data stream)
vícenásobné VE/PE (processing element); historicky: CM-5, ILLIAC IV; maticové a vektorové počítače; dnes v podobě rozšíření ISA pro práci na krátkých vektorech (MMX, SSE,..), také v GPU → tj. lokální podpora
- **MISD** (Multiple Instruction stream Single Data stream)
pipelining? Ano/ne? ; Uplatnění ve Fault-tolerant systémech – zpracovávání stejného datového proudu, porovnávání výsledků;
- **MIMD** (Multiple Instruction stream Multiple Data stream)
vícevláknové, vícejádrové, víceprocesorové, vícepočítačové systémy (Cluster, Grid, Cloud)
 - SPMD (Single Program stream Multiple Data stream)
 - MPMD (Multiple Program stream Multiple Data stream)

Cray II

Nejrychlejší na světě od
1985 do 1989.

1,9 Gflops špičkový výkon



Cray I (1976)

Zdroj:<http://ed-thelen.org/comp-hist/Shustek/ShustekTour-03.html>

Další superpočítač své doby od firmy Cray



Další superpočítač své doby od firmy Cray

- **Cray XT5-HE (nejvýkonnější systém – září 2010)**
- **MPP (Massively Parallel Processor)**
- **Výkon 1 759 000 Gflops (Rmax), Rpeak = 2,3 PFlops**
- **224 162 výpočetních elementů (37 376 procesorů)**
- **dual hex-core AMD Opteron 2435 (Istanbul) procesory na 2.6GHz (10.4 GFlops)**
- **300TB paměti**
- **disková kapacita 10.7 PB**
- **Linux**


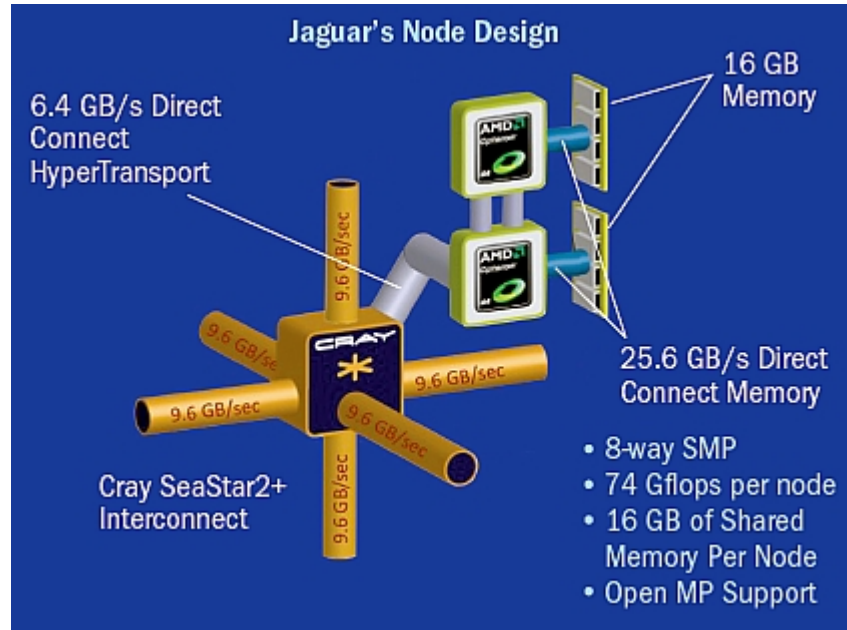
Zdroje informací:

<http://www.top500.org/system/details/10184>

<http://www.nccs.gov/computing-resources/jaguar/>



Cray XT5-HE



- Jeden uzel (node) – dva 6-jádrové procesory
- Každý uzel – 25.6 GB/s přístup do lokální paměti, 6.4GB/s do sítě
- Uzly jsou pospojovány do 3D toroidu
- 12 OpenMP nebo MPI úloh v uzlu, MPI mezi uzly
- Knihovny pro posílání zpráv: MPI 2.0, SHMEM

<http://www.scidacreview.org/0901/html/hardware.html>

Architektura

- Cluster (85%), MPP (15%), Jiné (0,4%)

Operační systém


- Linux (91%), Unix (4,4%), Windows (1%)

Počet výpočetních elementů (VE)

- 2049-4096 (22%), 4k - 8k (58%), 8k – 128k (18%),
více než 128 000 VE (1%)
- Nejpočetnější zastoupení výrobců v horní 30
Cray (9), IBM (7), Sun Microsystems (3)

Nejvýkonnější superpočítač - září 2011, září 2014 na 4.místě

- K computer, Fujitsu Cluster
- SPARC64 VIIIfx 2.0GHz (16 GFlops),
- Tofu interconnect (6-dimenzionální toroid)
- Cores: 548 352, (68 544 procesorů), 45nm
- Výkon 8 162 000 GFlops (Rmax), Rpeak = 8,77 Pflops
- Linux, Message Passing Interface (Open MPI)

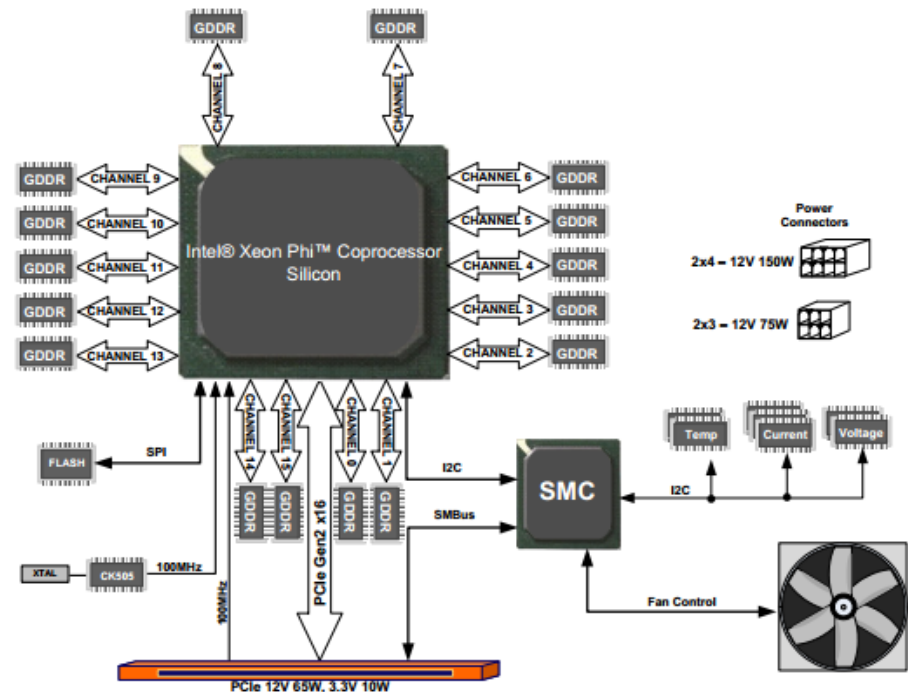


<http://top500.org/system/details/10810>

Zdroj obrázku: http://campaign.dubib.com/news/9257_supercomputer-k-computer-takes-first-place-in-world

Nejvýkonnější superpočítač - září 2014, září 2015

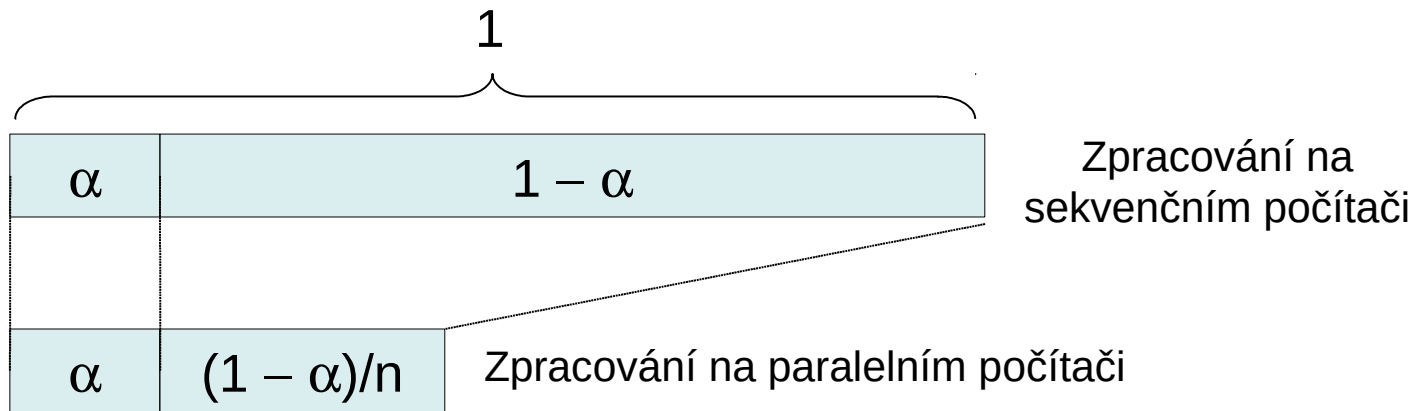
- Tianhe-2 (MilkyWay-2)
- Intel Xeon E5-2692 2.2GHz (12 cores, 24 threads, 12 x 32 KB L1 i caches, 12 x 32 KB L1 d caches, 12 x 256 KB L2 caches, 1 x 30 MB L3 cache)
- Intel Xeon Phi 31S1P (57/228)
- Each node: two Xeon processors and three Xeon Phi coprocessors
- Cores: 3 120 000
- **Výkon 33 862 700 GFlops (Rmax), Rpeak = 54.9 Pflops**
- **Nový trend: Gflops/Watt**



<http://www.intel.com/content/dam/www/public/us/en/documents/datasheets/xeon-phi-coprocessor-datasheet.pdf>

Amdahlův zákon

- Každý program obsahuje nějaké procento sekvenční části. Toto procento označme α .



$$S(n) = \frac{T(1)}{T(n)} = \frac{\alpha + 1 - \alpha}{\alpha + (1 - \alpha)/n} = \frac{n}{(n - 1)\alpha + 1}$$

$$\lim_{n \rightarrow \infty} S(n) = \lim_{n \rightarrow \infty} \frac{n}{(n - 1)\alpha + 1} = \frac{1}{\alpha}$$

Amdahlův zákon

- Zrychlení (Speed-up): Efektivnost:

$$S(n) = \frac{T(1)}{T(n)}$$

$$E(n) = \frac{S(n)}{n} = \frac{T(1)}{nT(n)}$$

kde $T(1)$ je čas vykonání úlohy na jednom VE,
 $T(n)$ na n VE, a n je počet VE.

Když použijeme 2 VE dosáhneme 2 krát lepší čas?

Amdahlův zákon

- Zrychlení (Speed-up): Efektivnost:

$$S(n) = \frac{T(1)}{T(n)} \qquad E(n) = \frac{S(n)}{n} = \frac{T(1)}{nT(n)}$$

kde $T(1)$ je čas vykonání úlohy na jednom VE,
 $T(n)$ na n VE, a n je počet VE.

Amdahlův zákon

- Příklad: Máme sekvenční počítač (jeden VE). Výpočet trvá 10 hodin, z toho 1 hodina je neparalelizovatelná část, zbytek může být paralelizován. Nezávisle na tom, kolik VE bychom měli k dispozici, nikdy nedosáhneme čas pod 1 hodinu. Tudíž pro $n \rightarrow \infty$:

$$\lim_{n \rightarrow \infty} S(n) = \lim_{n \rightarrow \infty} \frac{T(1)}{T(n)} = \frac{10}{1} = 10$$

Amdahlův zákon

- Příklad. Necht' $\alpha = 0,05$ (5%).


Pro $n = 5$: $S(5) = 4.17$

$n = 10$: $S(10) = 6.9$

$n = 100$: $S(100) = 16.9$

$n \rightarrow \infty$: $S(\infty) = 20$

Kolik VE by jste si koupili?



Amdahlův zákon

- Příklad. Necht' $\alpha = 0,05$ (5%).

Pro $n = 5$: $S(5) = 4.17$

$n = 10$: $S(10) = 6.9$


$n = 100$: $S(100) = 16.9$

$n \rightarrow \infty$: $S(\infty) = 20$

- Cray XT5-HE má však $n = 224\,162$,
K computer $n = 548\,352$.


77% nejvýkonnějších systémů má nad 4k VE.

Je takto velký počet jader efektivně využitelný? / Pro jaký typ problémů jsou tyto systémy určeny?



Gustafsonův zákon

- Příklad: Máme paralelní počítač (n VE). Výpočet trvá 10 hodin, z toho 1 hodina je neparalelizovatelná část, zbytek je paralelizován. Kdybychom tu samou úlohu řešili na sekvenčním počítači pak by výpočet trval $T(1) = 1 + n \cdot 9$ hodin. Tudíž je $S(n) = (1 + n \cdot 9) / 10$; a tedy $S(n \rightarrow \infty) = \infty$.



$$S(n) = \frac{T(1)}{T(n)} = \frac{\alpha' + (1 - \alpha')n}{\alpha' + 1 - \alpha'} = n - (n - 1)\alpha'$$

$$\alpha' \rightarrow 0 \Rightarrow S(n) \rightarrow n$$

Gustafsonův zákon

- Příklad. Necht' $\alpha' = 0,05$ (5%).

$$\text{Pro } n = 5: \quad S(5) = 4.8$$

$$n = 10: \quad S(10) = 9.55$$

$$n = 100: \quad S(100) = 95.05$$

$$n \rightarrow \infty: \quad S(\infty) = \infty$$

Shrnutí:

- Amdahl: Jak dlouho bude trvat zpracování sekvenční části programu na sekvenčním počítači, tak dlouho bude trvat zpracování sekvenční části programu na paralelním počítači.
- Gustafson: Jak dlouho bude trvat zpracování sekvenční části programu na paralelním počítači, tak dlouho bude trvat zpracování sekvenční části programu na sekvenčním počítači.

V čem se tedy liší? α není totéž co α' ; G. zákon předpokládá měnící se velikost problému s měnícím se výpočetním prostředím

Amdahl vs. Gustafson

- born November 16, 1922
- Amdahl, G.M., Validity of single-processor approach to achieving large-scale computing capability, *Proceedings of AFIPS Conference*, Reston, VA. 1967. pp. 483-485.



- born January 19, 1955
- Gustafson, J.L., Reevaluating Amdahl's Law, *CACM*, 31(5), 1988. pp. 532-533.



[1] http://en.wikipedia.org/wiki/Gene_Amdahl

[2] http://en.wikipedia.org/wiki/John_Gustafson_%28scientist%29

- **Příklad**


Máme možnost vyměnit stávající procesor (VE) za nový, 10 krát výkonnější. Současný procesor je vytížen na 50%, zbytek času (50%) čeká na I/O operace. Jaké celkové zvýšení výkonu by přinesla výměna procesoru?

- **Příklad**

Předpokládejme, že jsme dosáhli zrychlení 80x na systému se 100 procesory. Jaká část (procento) programu je sekvenční? Kolik procent času trvá zpracování sekvenční části programu na tomto systému? Jsou tyto procenta stejná?

Výkonové metriky

- Stupeň paralelizmu
definován počtem VE používaných na vykonávání programu v
daném časovém okamžiku



$$DOP_{STR} = \frac{\sum_i DOP_i \cdot \Delta t_i}{\sum_i \Delta t_i} = \frac{1}{t_n - t_0} \sum_i DOP_i \cdot \Delta t_i = \frac{1}{14 - 2} (1 \times 2 + 4 \times 2 + 7 \times 2 + \dots)$$

- Srovnávání výkonu – který počítač je nejlepší?

	počítač A	počítač B	počítač C
program 1	12 min	1 hod	1 hod
program 2	20 min	40 min	10 min
program 3	5 hod	1 hod	2 hod

- Čas vykonání programu:

$$T = IC \cdot CPI \cdot T_{CLK}$$

IC – počet instrukcí programu (Instruction Count)

CPI – počet cyklů na jednu instrukci (Cycles per Instruction)

T_{CLK} – perioda hod. signálu (doba cyklu)

Pro danou ISA je návrh procesoru zejména optimalizací CPI a T_{CLK} .

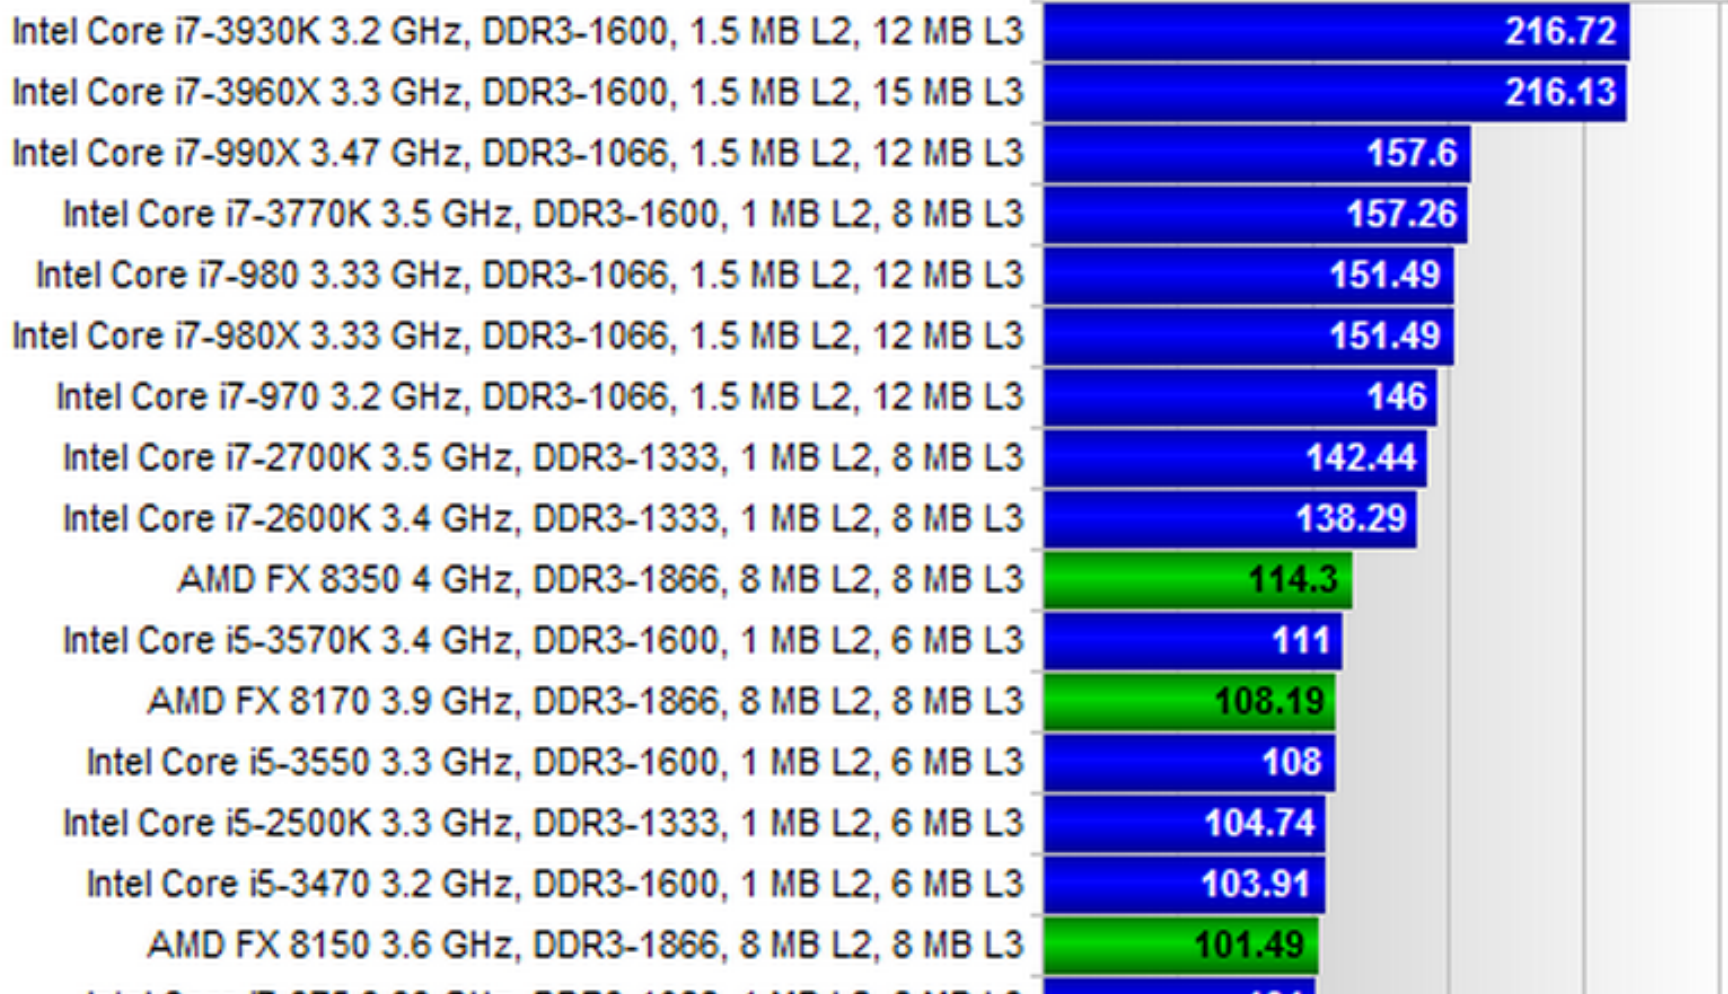
- MIPS (Milion Instructions per second) kde $IPS = IC / T = IPC_{str} \cdot f_{CLK}$,
MOPS (Operations), MFLOPS (Floating point Operations) - vše
relativně k ISA, závislé od samotného programu...
- Programová propustnost:

$$W = 1 / T = IPC_{str} \cdot f_{CLK} / IC$$

IPC – Instructions per Clock

Výkonové metriky

ALU Performance Dhrystone GIPS



Příklad

Procesor o frekvenci 2 GHz je použit na vykonání programu s následujícím mixem instrukcí a počtem hodinových cyklů. Určete střední hodnotu CPI, rychlost vykonávání programu MIPS, čas vykonání programu T, a programovou propustnost Wp.

Typ instrukce	Počet instrukcí	Počet hod. cyklů
Celočíselná aritmetika	45000	1
Přenos údajů	32000	2
Pohyblivá řádová čárka	15000	3
Přenos řízení(skoky)	8000	2

Značení

- Perioda hodinových cyklů: T_{CLK}
- Frekvence hodinových cyklů: f
- Velikost programu (počet instrukcí v programu): IC
- Celkový počet cyklů na vykonání programu: C

Necht' množina $\{ R_i \}$ jsou vykonávací rychlosti programů $i = 1, 2, \dots, m$ měřeny v MIPS (MFLOPS), resp. IPS (FLOPS)

- Střední aritmetický výkon:
$$R_a = \sum_{i=1}^m \frac{R_i}{m} = \frac{1}{m} \sum_{i=1}^m R_i$$

R_a je rovnoměrně váhován ($1/m$) ve všech programech a je úměrný součtu IPC, avšak ne součtu vykonávacích časů (nepřímo úměrně). Proto střední aritmetický výkon selhává...

$$\begin{aligned} R_a &= \frac{1}{2} (R_1 + R_2) = \frac{1}{2} \left(\frac{IC_1}{T_1} + \frac{IC_2}{T_2} \right) = \frac{1}{2} \left(\frac{IC_1}{IC_1 \cdot CPI_1 T_{CLK}} + \frac{IC_2}{IC_2 \cdot CPI_2 T_{CLK}} \right) = \\ &= \frac{1}{T_{CLK}} \left(\frac{IPC_1 + IPC_2}{2} \right) = \frac{1}{T_{CLK}} \left(\frac{IC_1}{2C_1} + \frac{IC_2}{2C_2} \right) \quad \text{avšak} \quad IPC_{1,2} = \frac{IC_1 + IC_2}{C_1 + C_2} \end{aligned}$$

Pokud však $C_1 = C_2$ (stejný celkový počet cyklů; tj. při téže frekvenci oba programy běží stejně dlouho) je R_a použitelný

- Střední geometrický výkon:
$$R_g = \prod_{i=1}^m R_i^{\frac{1}{m}}$$

Nesumarizuje reálný výkon, nemá inverzní relaci k celkovému času.
Pro porovnávání s normalizovanými údaji vzhledem na referenční stroj.

- Střední harmonický výkon:
$$R_h = \frac{m}{\sum_{i=1}^m \frac{1}{R_i}}$$

$$R_h = \frac{2}{\frac{1}{R_1} + \frac{1}{R_2}} = \dots = \frac{1}{T_{CLK}} \left(\frac{2}{CPI_1 + CPI_2} \right) = \frac{1}{T_{CLK}} \frac{2IC_1IC_2}{C_1IC_2 + C_2IC_1}$$

Pokud však $IC_1 = IC_2$ (oba programy jsou stejně velké) je R_h použitelný

- Existují taktéž vážené verze těchto výkonů...

Cílem je maximalizovat programovou propustnost

$$W = 1 / T = IPC \cdot f_{CLK} / IC$$

Technologie

- Rychlost šíření elektrických signálů shora omezena rychlostí světla (při 3,6 GHz je perioda 0,278 ns => 8,3 cm) (zpoždění propojení dominuje nad zpožděním hradel)
- Dnes již 32 nm CMOS technologie (atomový poloměr atomu křemíku je 0,111 nm)

Architektura (Hardware + Organizace HW + ISA)

- paralelismus podporovaný hardwarem na nejnižší úrovni (bit-level parallelism),
- instrukční paralelismus (zřetězení, superskalární a spekulativní vykonávání, vykonávání mimo pořadí,...),
- paralelismus na úrovni vláken,
- datový paralelismus (viz loop-level parallelism),
- paralelismus na úrovni úloh (funkční al. řídicí paralelismus)