24th Summer School on PARALLEL COMPUTING

Code Optimization part II

N. Sanna (n.sanna@cineca.it) V. Ruggiero (v.ruggiero@cineca.it)

Roma, 16 July 2015

SuperComputing Applications and Innovation Department

CINECA

Outline

Compilatori e ottimizzazione

Floating Point Computing

Makefile

Architectures

Power Perfomance

Linguaggi

- Esiste un'infinità di linguaggi differenti
- http://foldoc.org/contents/language.html

20-GATE; 2.PAK; 473L Query; 51forth; A#; A-0; a1; a56;
Abbreviated Test Language for Avionics Systems; ABC;
ABC ALGOL; ABCL/1; ABCL/c+; ABCL/R; ABCL/R2; ABLE;
ABSET; abstract machine; Abstract Machine Notation;
abstract syntax; Abstract Syntax Notation 1;
Abstract-Type and Scheme-Definition Language; ABSYS;
Accent; Acceptance, Test Or Launch Language; Access;
ACOM; ACOS; ACT++; Act1; Act2; Act3; Actalk; ACT ONE;
Actor; Actra; Actus; Ada; Ada++; Ada 83; Ada 95; Ada 9X;
Ada/Ed; Ada-O; Adaplan; Adaplex; ADAPT; Adaptive Simulated
Annealing; Ada Semantic Interface Specification;
Ada Software Repository; ADD 1 TO COBOL GIVING COBOL;
ADELE; ADES; ADL; AdLog; ADM; Advanced Function Presentation;
Advantage Gen; Adventure Definition Language; ADVSYS; Aeolus;
AFAC; AFP; AGORA; A Hardware Programming Language; AIDA;
AIr MAterial COmmand compiler; ALADIN; ALAM; A-language;
A Language Encouraging Program Hierarchy; A Language for Attributed ..

Linguaggi

- Linguaggi interpretati
  - il linguaggio viene "tradotto" statement per statement dall'interprete durante l'esecuzione
  - impossibili ottimizzazioni tra differenti statement
  - permette di verificare la correttezza statement dopo statement seguendo il flusso d'istruzioni (migliore gestione degli errori semantici)
  - Esempi: Python, PHP, Java, MATLAB,. . .
- Linguaggi compilati
  - il programma viene "tradotto" dal compilatore prima dell'esecuzione
  - possibili ottimizzazioni tra differenti statement
  - gestione minimale degli errori semantici
  - Fortran, C, C++

Le CPU

- È composta di:
  - registri (operandi delle istruzioni)
  - unità funzionali (eseguono le istruzioni)
- Unità funzionali:
  - aritmetica intera
  - operazioni logiche bitwise
  - aritmetica floating-point
  - calcolo di indirizzi
  - lettura e scrittura in memoria (load & store)
  - previsione ed esecuzione di "salti" (branch) nel flusso di esecuzione

Le CPU

- RISC: Reduced Instruction Set CPU (e.g. IBM Power)
  - istruzioni semplici
  - formato regolare delle istruzioni
  - decodifica ed esecuzione delle istruzioni semplificata
  - codice macchina molto "verboso"
- CISC: Complex Instruction Set CPU (e. g. Intel x86)
  - istruzioni di semantica "ricca"
  - formato irregolare delle istruzioni
  - decodifica ed esecuzione delle istruzioni complicata
  - codice macchina molto "compatto"
- Differenza non più rilevante quanto a prestazioni: le CPU CISC di oggi convertono le istruzioni in micro operazioni RISC-like

Statement & Istruzione

- Lo statement è una riga di un codice
  - `write(*,*)`
  - `printf();`
  - `do i = 1,n`
  - `x(i) = y(i) + 1`
- L'istruzione è l'operazione che la CPU "realmente" fa, nelle macchine RISC sono essenzialmente:
  - `load/store`
  - `somma/prodotto`
  - `operazioni tra bit` ...
- Uno statement può tradursi in una sola, poche o tante istruzioni

Architettura vs. Implementazione

- Architettura:
  - set di istruzioni
  - registri architetturali interi, floating point e di stato
- Implementazione
  - registri fisici ($2.5 \div 20 \times$ registri architetturali)
  - frequenza di clock e tempo di esecuzione delle istruzioni
  - numero di unità funzionali
  - dimensione, numero, caratteristiche delle cache
  - Out Of Order execution, Simultaneous Multi-Threading
- Una architettura, più implementazioni:
  - Power: Power4, Power5, Power6, ...
  - x86: Pentium III, Pentium 4, Xeon, Pentium M, Pentium D, Core, Core2, Athlon, Opteron, ...
  - prestazioni differenti
  - "regole" diverse per ottenere alte prestazioni

Il compilatore

- Traduce il codice sorgente in codice macchina
- Rifiuta codici sintatticamente errati
- Segnala (alcuni) potenziali problemi semantici
- Può tentare di ottimizzare il codice
  - ottimizzazioni indipendenti dal linguaggio
  - ottimizzazioni dipendenti dal linguaggio
  - ottimizzazioni dipendenti dalla CPU
  - ottimizzazioni dell'uso della memoria e della cache
- È uno strumento
  - potente: può risparmiare lavoro al programmatore
  - complesso: a volte può fare cose sorprendenti o controproducenti
  - limitato: è un sistema esperto, ma non ha l'intelligenza di un essere umano, non può capire pienamente il codice

HPC e Linguaggi

- Linguaggi ideali per l'High Performance Computing?
  - adatti all'implementazione di algoritmi "scientifici"
  - devono permettere elevati livelli di ottimizzazione
  - integrandosi nelle recenti architetture di supercalcolo
- Quali sono?
  - Fortran/C/C++, ci limitiamo a Fortran e C,cenno specifici a C++
  - il Python è in ascesa, ma per le parti computazionalmente intensive si usa appoggiarsi a C o Fortran
- I compilatori più usati per l'HPC (non sono molti)
  - GNU (gfortran, gcc, g++): "libero"
  - Intel (ifort, icc, icpc)
  - IBM (xlf, xlc, xlC)
  - Portland Group (pgf90, pgcc, pgCC)
  - PathScale, Oracle/Solaris, Fujitsu, Nag, Microsoft,...
- Linux, Windows or Mac OS X?
  - discorso complesso, ma la grande maggioranza delle architetture di supercalcolo ad oggi gira su piattaforma Linux

Il compilatore: schema

- Composto da differenti blocchi
- Front-end
  - Controllo sintassi
  - Analisi semantica
  - Traduzione rappresentazione intermedia
- Back-end
  - Ottimizzazione
  - Generazione codice eseguibile
- In genere
  - Front-end: dipende dal linguaggio
  - Back-end: indipendente dal linguaggio

Rappresentazione Intermedia

- Rappresenta gli stessi calcoli del codice di alto livello
  - in una forma più adatta per l'analisi
  - include calcoli non presenti nel sorgente, come il calcolo degli indirizzi
- C

```
while (j<n) {
k = k+j*2;
m = j*2;
j++
}
```

- Rappresentazione Intermedia

```
A: t1 = j t2 = n t3 = (t1<t2)
   jmp (B) t3
   jmp (C) TRUE
B: t4 = k t5 = j t6 = t5*2
   t7 t4+t6
   k=t7
   t8=j t9=t8*2
   m=t9
   t10=j t11=t10+1
   j=t11
   jmp(A) TRUE
C:
```

Assembler

- La rappresentazione intermedia, dopo l'ottimizzazione, è tradotta in assembly, e eventualmente ulteriormente ottimizzata

- C

```
int add (int a, int b)
{
   return a+b;
}
```

- Assembly

```
int add (int a , int b) {
  0:   55          push   %ebp
  1:   8b ec       mov    %esp,%ebp
/home/marco/Master10/prog/add.c:2
  return a+b;
   3:   8b 45 0c mov    0xc(%ebp),%eax
   6:   03 45 08 add    0x8(%ebp),%eax
   9:   c9          leave
   a:   c3          ret
   b:   90          nop
```

Building di un Programma

- Creare un eseguibile dai sorgenti è in generale un processo a tre fasi
- Pre-processing:
  - ogni sorgente è letto dal pre-processore
    - sostituire (**`#define`**) MACROs
    - inserire codice per gli statement **`#include`**
    - inserire o cancellare codice valutando **`#ifdef`**, **`#if`** ...
- Compilazione:
  - ogni sorgente è tradotto in un codice oggetto
    - un file oggetto è una collezione organizzata di simboli che si riferiscono a variabili e funzioni definite o usate nel sorgente
- Linking:
  - file oggetti sono combinati per costruire il singolo eseguibile finale ed ogni simbolo deve essere risolto
    - i simboli possono essere definiti nei file oggetto
    - o disponibili in altri codici oggetti (librerie esterne)

Compilare con GNU gfortran

- Quando si dà il comando:

```
user@$> gfortran dsp.f90 dsp_test.f90
```

vengono eseguiti automaticamente i tre passi

- Pre-processing (l'opzione `-E`)

```
user@$> gfortran -E  dsp.f90
user@$> gfortran -E  dsp_test.f90
```

  - si ha a stdout il file pre-processato

- Compilazione dei sorgenti (l'opzione `-c`)

```
user@$> gfortran -c dsp.f90
user@$> gfortran -c dsp_test.f90
```

  - da ogni sorgente viene prodotto un file oggetto `.o`

Linking con GNU gfortran

- Linkare oggetti tra di loro

```
user@$> gfortran dsp.o dsp_test.o
```

- Per risolvere i simboli definiti in librerie esterne specificare:
  - le librerie da usare (opzione `-l`)
  - le directory in cui stanno (opzione `-L`)
- Come linkare `libblas.a` nella cartella `/opt/lib`

```
user@$> gfortran file1.o file2.o -L/opt/lib -ldsp
```

- Come creare e linkare una libreria statica

```
user@$> gfortran -c dsp.f90
ar curv libdsp.a dsp.o
ranlib libdsp.a
gfortran test_dsp.f90 -L. -ldsp
```

  - `ar` archivia in `libdsp.a dsp.o`
  - `ranlib` genera l'indice dell'archivio

Prendere confidenza

- Per il manuale in linea

```
man gcc
```

  riporta le opzioni del compilatore C di GNU e il loro significato
- Attenzione: **`man gfortran`** dà solo le opzioni ulteriori rispetto a gcc, mentre per gli altri compilatori solitamente i man sono replicati nelle parti comuni
- Il numero di opzioni è notevole e purtroppo differisce da compilatore a compilatore
- Tipologia di opzioni
  - linguaggio: sullo standard (o sul dialetto) da seguire
  - ottimizzazione: argomento delle prossime slide...
  - target: per l'integrazione con l'architettura di calcolo
  - debugging: la più importante, **`-g`**, crea i simboli di debugging necessari per l'uso di debugger
  - warning: per avere informazioni sulla compilazione

Il compilatore cosa sa fare

- Esegue trasformazioni del codice come:
  - Register allocation
  - Register spilling
  - Copy propagation
  - Code motion
  - Dead and redundant code removal
  - Common subexpression elimination
  - Strength reduction
  - Inlining
  - Index reordering
  - Loop unrolling/merging
  - Loop blocking
  - . . .
- Lo scopo è massimizzare le prestazioni

Il compilatore cosa non sa fare

- Analizzare ed ottimizzare globalmente codici molto grossi (a meno di abilitare l'IPO, molto costoso in tempo e risorse)
- Capire dipendenze tra dati con indirizzamenti indiretti
- Strenght reduction di potenze non intere, o maggiori di $2 \div 4$
- Common subexpression elimination attraverso chiamate a funzione
- Unrolling, Merging, Blocking con:
  - chiamate a procedure
  - chiamate o statement di Input-Output in mezzo al codice
- Fare inlining di funzioni se non viene detto esplicitamente
- Sapere a run-time i valori delle variabili per i quali alcune ottimizzazioni sono inibite

Livelli di ottimizzazione

- I compilatori forniscono dei livelli di ottimizzazione "predefiniti" utilizzabili con la semplice opzione **`-O<n>`**
  - **`n`** accresce il livello di ottimizzazione, da 0 a 3 (a volte fino a 5)
- Fortran IBM:
  - **`-O0`**: nessuna ottimizzazione (utile insieme a **`-g`** in debugging)
  - **`-O2, -O`** : ottimizzazioni locali, compromesso tra velocità di compilazione, ottimizzazione e dimensioni dell'eseguibile
  - **`-O3`**: ottimizzazioni memory-intensive, può alterare la semantica del programma (da qui in poi da considerare l'uso si **`-qstrict`** per evitare risultati errati)
  - **`-O4`**: ottimizzazioni aggressive (**`-qarch=auto`**, **`-qhot`**, **`-qipa`**, **`-qtune=auto`**, **`-qcache=auto`**, **`-qsimd=auto`**)
  - **`-O5`**: come **`-O4`** con **`-qipa=level=2`** aggressiva e lenta
- Alcuni compilatori hanno **`-fast`**, che include **`On`** e altro
- Per GNU una scelta comune insieme a **`-O3`** é **`-funroll-loops`**
- Attenzione all'ottimizzazione di default: per GNU é **`-O0`** ,di solito é **`-O2`**

Loop con -O3 (Compilatore Intel)

```
icc (or ifort) -O3
```

- Automatic vectorization (use of packed SIMD instructions)
- Loop interchange (for more efficient memory access)
- Loop unrolling (more instruction level parallelism)
- Prefetching (for patterns not recognized by h/w prefetcher)
- Cache blocking (for more reuse of data in cache)
- Loop peeling (allow for misalignment)
- Loop versioning (for loop count; data alignment; runtime dependency tests)
- Memcpy recognition (call Intel's fast memcpy, memset)
- Loop splitting (facilitate vectorization)
- Loop fusion (more efficient vectorization)
- Scalar replacement (reduce array accesses by scalar temps)
- Loop rerolling (enable vectorization)
- Loop reversal (handle dependencies)

Dal sorgente all'eseguibile

- La macchina astratta "vista" a livello di sorgente è molto diversa da quella reale
- Esempio: prodotto di matrici

```
do j = 1, n
do k = 1, n
do i = 1, n
   c(i,j) = c(i,j) + a(i,k)*b(k,j)
end do
end do
end do
```

- Il "nocciolo"
  - carica dalla memoria tre valori
  - fa una moltiplicazione ed una somma
  - immagazzina il risultato

MatrixMul: performance

- Prodotto matrice-matrice, 1024×1024, doppia precisione
- Ordine dei loop ottimale per la cache
- Scritto in Fortran
- Architetture considerate per le prove (per nodo)
  - FERMI: IBM Blue Gene/Q system, 16 core single-socket PowerA2 a 1.6 GHz di frequenza
  - PLX: 2 esa-core XEON 5650 Westmere CPUs 2.40 GHz

FERMI - xlf

Opzione	secondi	Mflops
-O0	65.78	32.6
-O2	7.13	301
-O3	0.78	2735
-O4	55.52	38.7
-O5	0.65	3311

PLX - ifort

Opzione	secondi	MFlops
-O0	8.94	240
-O1	1.41	1514
-O2	0.72	2955
-O3	0.33	6392
-fast	0.32	6623

- Perché tanta varietà di risultati? Basta passare da -On a -On+1?

Cosa fa il compilatore: report

- Cosa accade ai diversi livelli di ottimizzazione?
  - Perché il compilatore IBM su Fermi al livello **`-O4`** degrada cosí le performance?
- Utilizzare le opzioni di report é un buon modo di capire cosa sta facendo il compilatore
- Su IBM **`-qreport`** mostra che per **`-O4`** l'ottimizzazione prende un percorso completamente diverso dagli altri casi
  - il compilatore riconosce il pattern del prodotto matrice-matrice e sostituisce le righe di codice con la chiamata a una funzione di libreria BLAS **`__xl_dgemm`**
  - che però si rivela molto lenta perché non fa parte delle librerie matematiche ottimizzate da IBM (ESSL)
  - anche il compilatore Intel fa questo per dgemm, ma invoca le efficienti MKL
- Aumentando il livello di ottimizzazione, solitamente le performance migliorano
  - ma è bene testare questo miglioramento per il proprio codice

Uno sguardo all'assembler

- Esempio datato, utile peró per capire

Matrix Multiply inner loop code with -qnoopt

38 instructions, 31.4 cycles per iteration

```
__L1:
   lwz     r3,160(SP)
   lwz     r9,STATIC_BSS
   lwz     r4,24(r9)
   subfi   r5,r4,-8
   lwz     r11,40(r9)
   mullw   r6,r4,r11
   lwz     r4,36(r9)
   rlwinm  r4,r4,3,0,28
   add     r7,r5,r6
   add     r7,r4,r7
   lfdx    fp1,r3,r7
   lwz     r7,152(SP)
   lwz     r12,0(r9)
   subfi   r10,r12,-8
   lwz     r8,44(r9)
   mullw   r12,r12,r8
   add     r10,r10,r12
   add     r10,r4,r10
   lfdx    fp2,r7,r10
   lwz     r7,156(SP)
   lwz     r10,12(r9)
   subfi   r9,r10,-8
   mullw   r10,r10,r11
   rlwinm  r8,r8,3,0,28
   add     r9,r9,r10
   add     r8,r8,r9
   lfdx    fp3,r7,r8
   fmadd   fp1,fp2,fp3,fp1
   add     r5,r5,r6
   add     r4,r4,r5
   stfdx   fp1,r3,r4
   lwz     r4,STATIC_BSS
   lwz     r3,44(r4)
   addi    r3,1(r3)
   stw     r3,44(r4)
   lwz     r3,112(SP)
   addic.  r3,r3,-1
   stw     r3,112(SP)
   bgt     __L1
```

L'essenziale

Matrix Multiply inner loop code with -qnoopt

necessary instructions

```
__L1:
   lwz     r3,160(SP)
   lwz     r9,STATIC_BSS
   lwz     r4,24(r9)
   subfi   r5,r4,-8
   lwz     r11,40(r9)
   mullw   r6,r4,r11
   lwz     r4,36(r9)
   rlwinm  r4,r4,3,0,28
   add     r7,r5,r6
   add     r7,r4,r7
   lfdx    fp1,r3,r7
   lwz     r7,152(SP)
   lwz     r12,0(r9)
   subfi   r10,r12,-8
   lwz     r8,44(r9)
   mullw   r12,r12,r8
   add     r10,r10,r12
   add     r10,r4,r10
   lfdx    fp2,r7,r10
   lwz     r7,156(SP)
   lwz     r10,12(r9)
   subfi   r9,r10,-8
   mullw   r10,r10,r11
   rlwinm  r8,r8,3,0,28
   add     r9,r9,r10
   add     r8,r8,r9
   lfdx    fp3,r7,r8
   fmadd   fp1,fp2,fp3,fp1
   add     r5,r5,r6
   add     r4,r4,r5
   stfdx   fp1,r3,r4
   lwz     r4,STATIC_BSS
   lwz     r3,44(r4)
   addi    r3,1(r3)
   stw     r3,44(r4)
   lwz     r3,112(SP)
   addic.  r3,r3,-1
   stw     r3,112(SP)
   bgt     __L1
```

Loop control

Matrix Multiply inner loop code with -qnoopt

necessary instructions loop control

```
__L1:
    lwz     r3,160(SP)
    lwz     r9,STATIC_BSS
    lwz     r4,24(r9)
    subfi   r5,r4,-8
    lwz     r11,40(r9)
    mullw   r6,r4,r11
    lwz     r4,36(r9)
    rlwinm  r4,r4,3,0,28
    add     r7,r5,r6
    add     r7,r4,r7
    lfdx    fp1,r3,r7
    lwz     r7,152(SP)
    lwz     r12,0(r9)
    subfi   r10,r12,-8
    lwz     r8,44(r9)
    mullw   r12,r12,r8
    add     r10,r10,r12
    add     r10,r4,r10
    lfdx    fp2,r7,r10
    lwz     r7,156(SP)
    lwz     r10,12(r9)
    subfi   r9,r10,-8
    mullw   r10,r10,r11
    rlwinm  r8,r8,3,0,28
    add     r9,r9,r10
    add     r8,r8,r9
    lfdx    fp3,r7,r8
    fmadd   fp1,fp2,fp3,fp1
    add     r5,r5,r6
    add     r4,r4,r5
    stfdx   fp1,r3,r4
    lwz     r4,STATIC_BSS
    lwz     r3,44(r4)
    addi    r3,1(r3)
    stw     r3,44(r4)
    lwz     r3,112(SP)
    addic.  r3,r3,-1
    stw     r3,112(SP)
    bgt     __L1
```

L'indirizzamento!

Matrix Multiply inner loop code with -qnoopt

necessary instructions loop control addressing code

```
__L1:
    lwz     r3,160(SP)
    lwz     r9,STATIC_BSS
    lwz     r4,24(r9)
    subfi   r5,r4,-8
    lwz     r11,40(r9)
    mullw   r6,r4,r11
    lwz     r4,36(r9)
    rlwinm  r4,r4,3,0,28
    add     r7,r5,r6
    add     r7,r4,r7
    lfdx    fp1,r3,r7
    lwz     r7,152(SP)
    lwz     r12,0(r9)
    subfi   r10,r12,-8
    lwz     r8,44(r9)
    mullw   r12,r12,r8
    add     r10,r10,r12
    add     r10,r4,r10
    lfdx    fp2,r7,r10
    lwz     r7,156(SP)
    lwz     r10,12(r9)
    subfi   r9,r10,-8
    mullw   r10,r10,r11
    rlwinm  r8,r8,3,0,28
    add     r9,r9,r10
    add     r8,r8,r9
    lfdx    fp3,r7,r8
    fmadd   fp1,fp2,fp3,fp1
    add     r5,r5,r6
    add     r4,r4,r5
    stfdx   fp1,r3,r4
    lwz     r4,STATIC_BSS
    lwz     r3,44(r4)
    addi    r3,1(r3)
    stw     r3,44(r4)
    lwz     r3,112(SP)
    addic.  r3,r3,-1
    stw     r3,112(SP)
    bgt     __L1
```

Cosa fare?

- Le operazioni dominanti sono quelle di conversione indici indirizzo di memoria
- Osservazioni:
  - il loop “percorre” la memoria sequenzialmente
  - gli indirizzi degli elementi successivi sono calcolabili facilmente sommando una costante
  - sfruttare una conversione indice indirizzo per piú elementi successivi
- Puó essere fatto automaticamente?

Ottimizziamo

Matrix Multiply inner loop code with -O3 -qtune=pwr4

```
__L1:
   fmadd   fp6,fp12,fp13,fp6
   lfdux   fp12,r12,r7
   lfd     fp13,8(r11)
   fmadd   fp7,fp8,fp9,fp7
   lfdux   fp8,r12,r7
   lfd     fp9,16(r11)
   lfdux   fp10,r12,r7
   lfd     fp11,24(r11)
   fmadd   fp1,fp12,fp13,fp1
   lfdux   fp12,r12,r7
   lfd     fp13,32(r11)
   fmadd   fp0,fp8,fp9,fp0
   lfdux   fp8,r12,r7
   lfd     fp9,40(r11)
   fmadd   fp2,fp10,fp11,fp2
   lfdux   fp10,r12,r7
   lfd     fp11,48(r11)
   fmadd   fp4,fp12,fp13,fp4
   lfdux   fp12,r12,r7
   lfd     fp13,56(r11)
   fmadd   fp3,fp8,fp9,fp3
   lfdux   fp8,r12,r7
   lfdu    fp9,64(r11)
   fmadd   fp5,fp10,fp11,fp5
   bdnz    __L1
```

unrolled by 8

dot product accumulated in
8 interleaved parts (fp0-fp7)
(combined after loop)

3 instructions, 1.6 cycles per iteration
2 loads and 1 fmadd per iteration

Ottimizziamo di piú

Matrix multiply inner loop code with -O3 -qhot -qtune=pwr4

```
__L1:
   fmadd    fp1,fp4,fp2,fp1
   fmadd    fp0,fp3,fp5,fp0
   lfdux    fp2,r29,r9
   lfdu     fp4,32(r30)
   fmadd    fp10,fp7,fp28,fp10
   fmadd    fp7,fp9,fp7,fp8
   lfdux    fp26,r27,r9
   lfd      fp25,8(r29)
   fmadd    fp31,fp30,fp27,fp31
   fmadd    fp6,fp11,fp30,fp6
   lfd      fp5,8(r27)
   lfd      fp8,16(r28)
   fmadd    fp30,fp4,fp28,fp29
   fmadd    fp12,fp13,fp11,fp12
   lfd      fp3,8(r30)
   lfd      fp11,8(r28)
   fmadd    fp1,fp4,fp9,fp1
   fmadd    fp0,fp13,fp27,fp0
   lfd      fp4,16(r30)
   lfd      fp13,24(r30)
   fmadd    fp10,fp8,fp25,fp10
   fmadd    fp8,fp2,fp8,fp7
   lfdux    fp9,r29,r9
   lfdu     fp7,32(r28)
   fmadd    fp31,fp11,fp5,fp31
   fmadd    fp6,fp26,fp11,fp6
   lfdux    fp11,r27,r9
   lfd      fp28,8(r29)
   fmadd    fp12,fp3,fp26,fp12
   fmadd    fp29,fp4,fp25,fp30
   lfd      fp30,-8(r28)
   lfd      fp27,8(r27)
   bdnz       L1
```

unroll-and-jam 2x2
inner unroll by 4
interchange "i" and "j" loops

2 instructions, 1.0 cycles per iteration
balanced: 1 load and 1 fmadd per iteration

Istruzioni macchina

- Istruzioni per `c(i,j) = c(i,j) + a(i,k)*b(k,j)`
- -O0: 24 istruzioni
  - 3 load/1 store
  - 1 floating point multiply+add Flop/istruzione 2/24
- -O2: 9 istruzioni (riuso calcolo indirizzi)
  - 4 load/1 store
  - 2 floating point multiply+add Flop/istruzione 4/9
- -O3: 150 istruzioni (unrolling)
  - 68 load/ 34 store
  - 48 floating point multiply+add Flop/istruzione 96/150
- -O4: 344 istruzioni (unrolling&blocking)
  - 139 load / 74 store
  - 100 floating point multiply+add Flop/istruzione 200/344

Fa tutto il compilatore?

- `-fast` realizza uno speed-up di 30 volte rispetto a `-O0` per il caso matrice-matrice (ifort su PLX)
  - mette in atto una vasta gamma di ottimizzazioni più o meno complicate
- **Ha senso ottimizzare il codice anche manualmente?**
- Il compilatore sa fare automaticamente
  - Dead code removal: per esempio rimuovere un if

```
b = a + 5.0;
if ((a>0.0) && (b<0.0)) {
    ......
}
```

  - Redudant code removal

```
integer, parameter :: c=1.0
f=c*f
```

- Ma la vita non è sempre così facile

Loop counters: attenzione ai tipi

- Usare sempre i tipi corretti
- Usare un real per l'indice dei loop implica una trasformazione implicita reale $\rightarrow$ intero . . .
- Secondo i recenti standard Fortran si tratta di un vero e proprio errore, ma i compilatori tendono a tollerarlo

```
real :: i,j,k
....
do j=1,n
do k=1,n
do i=1,n
c(i,j)=c(i,j)+a(i,k)*b(k,j)
enddo
enddo
enddo
```

Risultati in secondi

Compilazione	integer	real
(PLX) gfortran -O0	9.96	8.37
(PLX) gfortran -O3	0.75	2.63
(PLX) ifort -O0	6.72	8.28
(PLX) ifort -fast	0.33	1.74
(PLX) pgif90 -O0	4.73	4.85
(PLX) pgif90 -fast	0.68	2.30
(FERMI) bgxlf -O0	64.78	104.10
(FERMI) bgxlf -O5	0.64	12.38

Il compilatore può fare tutto?

- Il compilatore può fare molto . . . ma non è un essere umano
- È piuttosto facile intralciare il suo lavoro
  - corpo del loop troppo lungo
  - loop con i due estremi di iterazione variabili
  - uso eccessivo di costrutti condizionali (if)
  - uso eccessivo di puntatori ed indici
  - uso improprio di variabili intermedie
- Importante:
  - due codici semanticamente uguali possono avere prestazioni ben diverse
  - il compilatore può fare assunzioni erronee ed alterare la semantica

Index reordering

- Per un loop nest semplice ci pensa il compilatore
  - a patto di usare un opportuno livello di ottimizzazione

```
do i=1,n
do k=1,n
do j=1,n
   c(i,j) = c(i,j) + a(i,k)*b(k,j)
end do
end do
end do
```

- Tempi in secondi

Compilazione	j-k-i	i-k-j
(PLX) ifort -O0	6.72	21.8
(PLX) ifort -fast	0.34	0.33

Index reordering / 2

- Per loop nesting più complicati il compilatore a volte no...
  - anche al più alto livello di ottimizzazione
  - conoscere il meccanismo di cache è quindi utile!

```
do jj = 1, n, step
   do kk = 1, n, step
      do ii = 1, n, step
         do j = jj, jj+step-1
            do k = kk, kk+step-1
               do i = ii, ii+step-1
                  c(i,j) = c(i,j) + a(i,k)*b(k,j)
               enddo
            enddo
         enddo
      enddo
   enddo
enddo
```

- Tempi in secondi

Compilazione	j-k-i	i-k-j
(PLX) ifort -O0	10	11.5
(PLX) ifort -fast	1.	2.4

Modularizzazione e cache

```
do i=1,nwax+1
    do k=1,2*nwaz+1
       call diffus (u_1,invRe,qv,rv,sv,K2,i,k,Lu_1)
       call diffus (u_2,invRe,qv,rv,sv,K2,i,k,Lu_2)
....
    end do
 end do


 subroutine diffus (u_n,invRe,qv,rv,sv,K2,i,k,Lu_n)
   do j=2,Ny-1
     Lu_n(i,j,k)=invRe*(2.d0*qv(j-1)*u_n(i,j-1,k)-(2.d0*rv(j-1)
                 +K2(i,k))*u_n(i,j,k)+2.d0*sv(j-1)*u_n(i,j+1,k))
   end do
 end subroutine
```

- 5 accessi in memoria contigui in i
- 3 accessi in memoria contigui in j

Modularizzazione e cache / 2

```
call diffus (u_1,invRe,qv,rv,sv,K2,Lu_1)
call diffus (u_2,invRe,qv,rv,sv,K2,Lu_2)
....

subroutine diffus (u_n,invRe,qv,rv,sv,K2,i,k,Lu_n)
 do k=1,2*nwaz+1
  do j=2,Ny-1
   do i=1,nwax+1
    Lu_n(i,j,k)=invRe*(2.d0*qv(j-1)*u_n(i,j-1,k)-(2.d0*rv(j-1)
               +K2(i,k))*u_n(i,j,k)+2.d0*sv(j-1)*u_n(i,j+1,k))
   end do
  end do
 end do
end subroutine
```

- Modularizzare così permette di avere l'ordine ottimale dei loop
- A volte il compilatore trasforma da solo: in questo caso è richiesto l'"inlining"

Inlining

- Ottimizzazione manuale o effettuata dal compilatore che sostituisce una funzione col suo corpo
  - elimina il costo della chiamata e potenzialmente l'instruction cache
  - rende più facile l'ottimizzazione interprocedurale
- In C e C++ la keyword **`inline`** è un "suggerimento"
- Non ogni funzione è "inlinable" e in ogni caso dipende dalle capacitá del compilatore
  - oltre che dalle capacità del programmatore
- Intel (n: 0=disable, 1=secondo la keyword, 2=se opportuno)

```
-inline-level=n
```

- GNU (n: size, default is 600):

```
-finline-functions
-finline-limit=n
```

- In alcuni compilatori automaticamente attivate ad alti livelli di ottimizzazione

Common Subexpression Elimination

- Per i calcoli intermedi si riusano spesso alcune espressioni: può essere vantaggioso riciclare quantità già calcolate:
  A= B+C+D
  E= B+F+C
- Richiede: 4 load,2 store, 4 somme
  A=(B+C) + D
  E=(B+C) + F
- Richiede: 4 load, 2 store, 3 somme
- Attenzione: dal punto di vista numerico il risultato non è necessariamente identico
- Se la locazione di un array è acceduta più di una volta può convenire effettuare lo “Scalar replacement”
  - ad opportune ottimizzazioni il compilatore può farlo

Funzioni e Side Effects

- Lo scopo “primo” di una funzione é in genere dare un valore in ritorno
  - a volte, per vari motivi, peró non é cosí
  - la modifica di varaibili passate, o globali o anche l’I/O si chiamano comunque side effects (effetti collaterali)
- La presenza di funzioni con side effects può inibire il compilatore dal fare ottimizzazioni

```
function f(x)
   f=x+dx
end
```

allora `f(x)+f(x)+f(x)` puó essere valutato come `3*f(x)`

```
function f(x)
   x=x+dx
   f=x
end
```

allora la precedente valutazione non é piú corretta

CSE e chiamate a funzione

- Alterando l'ordine delle chiamate il compilatore non sa se si altera il risultato (possibili effetti collaterali)
- 5 chiamate a funzioni, 5 prodotti:

```
x=r*sin(a)*cos(b);
y=r*sin(a)*sin(b);
z=r*cos(a);
```

- 4 chiamate a funzioni, 4 prodotti (1 variabile temporanea):

```
temp=r*sin(a)
x=temp*cos(b);
y=temp*sin(b);
z=r*cos(a);
```

CSE: limitazioni

- Core loop troppo grossi:
  - il compilatore lavora su finestre di dimensioni finite: potrebbe non accorgersi di una grandezza da riutilizzare
- Funzioni:
  - se altero l'ordine delle chiamate ottengo lo stesso risultato?
- Ordine e valutazione:
  - solo ad alti livelli di ottimizzazione il compilatore altera l'ordine delle operazioni (`-qnostrict` per IBM)
  - per inibirla in certe espressioni: mettere le parantesi (il programmatore ha sempre ragione)
- Aumenta l'uso di registri per l'appoggio dei valori intermedi ("register spilling")

Cosa può fare il compilatore?

```
do k=1,n3m
   do j=n2i,n2do
      jj=my_node*n2do+j
      do i=1,n1m
         acc =1./(1.-coe*aciv(i)*(1.-int(forclo(nve,i,j,k))))
         aci(jj,i)= 1.
         api(jj,i)=-coe*apiv(i)*acc*(1.-int(forclo(nve,i,j,k)))
         ami(jj,i)=-coe*amiv(i)*acc*(1.-int(forclo(nve,i,j,k)))
         fi(jj,i)=qcap(i,j,k)*acc
     enddo
   enddo
enddo
...
...
do i=1,n1m
   do j=n2i,n2do
      jj=my_node*n2do+j
      do k=1,n3m
         acc =1./(1.-coe*ackv(k)*(1.-int(forclo(nve,i,j,k))))
         ack(jj,k)= 1.
         apk(jj,k)=-coe*apkv(k)*acc*(1.-int(forclo(nve,i,j,k)))
         amk(jj,k)=-coe*amkv(k)*acc*(1.-int(forclo(nve,i,j,k)))
         fk(jj,k)=qcap(i,j,k)*acc
      enddo
   enddo
enddo
```

Probabilmente questo

```
do k=1,n3m
   do j=n2i,n2do
      jj=my_node*n2do+j
      do i=1,n1m
         temp = 1.-int(forclo(nve,i,j,k))
         acc =1./(1.-coe*aciv(i)*temp)
         aci(jj,i)= 1.
         api(jj,i)=-coe*apiv(i)*acc*temp
         ami(jj,i)=-coe*amiv(i)*acc*temp
         fi(jj,i)=qcap(i,j,k)*acc
      enddo
   enddo
enddo
...
...
do i=1,n1m
   do j=n2i,n2do
      jj=my_node*n2do+j
      do k=1,n3m
         temp = 1.-int(forclo(nve,i,j,k))
         acc =1./(1.-coe*ackv(k)*temp)
         ack(jj,k)= 1.
         apk(jj,k)=-coe*apkv(k)*acc*temp
         amk(jj,k)=-coe*amkv(k)*acc*temp
         fk(jj,k)=qcap(i,j,k)*acc
      enddo
   enddo
enddo
```

Ma non questo

```
do k=1,n3m
   do j=n2i,n2do
      do i=1,n1m
         temp_fact(i,j,k) = 1.-int(forclo(nve,i,j,k))
      enddo
   enddo
enddo
...
...
do i=1,n1m
   do j=n2i,n2do
      jj=my_node*n2do+j
      do k=1,n3m
         temp = temp_fact(i,j,k)
         acc =1./(1.-coe*ackv(k)*temp)
         ack(jj,k)= 1.
         apk(jj,k)=-coe*apkv(k)*acc*temp
         amk(jj,k)=-coe*amkv(k)*acc*temp
         fk(jj,k)=qcap(i,j,k)*acc
      enddo
   enddo
enddo
...
...
!  idem per l'altro loop
```

Array syntax

- Traslazione dei primi due indici di un array a tre indici (512^3)
- Il “caro vecchio” loop (stile Fortran 77): 0.19 secondi
  - l’ordine dei cicli negli indici che traslano é inverso alla traslazione per evitare di “sporcare” i dati della matrice

```
do k = nd, 1, -1
  do j = nd, 1, -1
    do i = nd, 1, -1
      a03(i,j,k) = a03(i-1,j-1,k)
    enddo
  enddo
enddo
```

- Array syntax (stile Fortran 90): 0.75 secondi
  - secondo lo standard, le cose vanno “come se il membro a destra fosse tutto valutato prima di effettuare le operazioni richieste”

```
a03(1:nd, 1:nd, 1:nd) = a03(0:nd-1, 0:nd-1, 1:nd)
```

- Array syntax con un hint al compilatore: 0.19 secondi

```
a03(nd:1:-1,nd:1:-1,nd:1:-1) = a03(nd-1:0:-1, nd-1:0:-1, nd:1:-1)
```

Report di ottimizzazione

- Per capirne di piú in questo come in altri casi é bene attivare le flag di report di ottimizzazione
- Con Intel ifort attivare

```
-opt-report[n]      n=0(none),1(min),2(med),3(max)
-opt-report-file<file>
-opt-report-phase<phase>
-opt-report-routine<routine>
```

- Le tre modalitá sono alle righe 55,64,69 rispettivamente

```
Loop at line:55 simple MEMOP Intrinsic disabled-->SIMPLE reroll
Loop at line:64 memcopy generated
Loop at line:69 simple MEMOP Intrinsic disabled-->SIMPLE reroll
```

- Tutto questo é ovviamente molto dipendente dal compilatore

Report di ottimizzazione / 2

- Purtroppo non é presente un opzione equivalente con compilatori GNU
  - La migliore alternativa é specificare

```
-fdump-tree-all
```

    in modo che vengano stampate tutte le fase intermedie di compilazione
  - ma la lettura non é decisamente agevole
- Con il compilatore PGI

```
-Minfo=accel,inline,ipa,loop,lre,mp,opt,par,unified,vect
```

  oppure senza opzioni per averle tutte

Dare informazioni al compilatore

- Estremi del loop noti a compile time o solo a run-time:
  - puó inibire alcune ottimizzazioni, tra cui l'unrolling

```
real a(1:1024,1:1024)
real b(1:1024,1:1024)
real c(1:1024,1:1024)
...
read(*,*) i1,i2
read(*,*) j1,j2
read(*,*) k1,k2
...
do j = j1, j2
do k = k1, k2
do i = i1, i2
c(i,j)=c(i,j)+a(i,k)*b(k,j)
enddo
enddo
enddo
```

- Tempi in secondi (Loop Bounds Compile-Time o Run-Time)

Compilazione	LB-CT	LB-RT
(PLX) ifort -O0	6.72	9
(PLX) ifort -fast	0.34	0.75

- Molto dipendente dal tipo di loop, dal compilatore, etc.

Allocazione statica o dinamica ?

- Potenzialmente l'allocazione statica puó dare al compilatore piú informazioni per ottimizzare
  - a prezzo di un codice piú rigido
  - l'elasticitá permessa dall'allocazione dinamica é particolarmente utile nel calcolo parallelo

```
integer :: n
parameter(n=1024)
real a(1:n,1:n)
real b(1:n,1:n)
real c(1:n,1:n)
```

```
real, allocatable, dimension(:,:) :: a
real, allocatable, dimension(:,:) :: b
real, allocatable, dimension(:,:) :: c
print*,'Enter matrix size'
read(*,*) n
allocate(a(n,n),b(n,n),c(n,n))
```

Allocazione statica o dinamica ? / 2

- Per i compilatori recenti peró spesso le prestazioni statica vs dinamica si equivalgono
  - per il semplice matrice-matrice l'allocazione dinamica gestisce meglio i loop bounds letti da input

Compilazione	statica	dinamica	dinamica-LBRT
(PLX) ifort -O0	6.72	18.26	18.26
(PLX) ifort -fast	0.34	0.35	0.36

- L'allocazione statica viene fatta nella memoria cosiddetta "stack"
  - in compilazione possono esserci dei limiti di utilizzo per cui occorre specificare l'opzione **`-mcmodel=medium`**
  - a run-time assicurarsi che sul nodo la stack non sia limitata (se si usa bash)

```
ulimit -a
```

ed eventualmente

```
ulimit -s unlimited
```

Allocazione dinamica in C

- C non conosce matrici ma array di array
  - l'allocazione statica garantisce allocazione contigua di tutti i valori

```
double A[nrows][ncols];
```

- Con l'allocazione dinamica occorre fare attenzione
  - "the wrong way" (= non efficiente)

```
/* Allocate a double matrix with many malloc */
double** allocate_matrix(int nrows, int ncols) {
   double **A;
   /* Allocate space for row pointers */
   A = (double**) malloc(nrows*sizeof(double*) );
   /* Allocate space for each row */
   for (int ii=1; ii<nrows; ++ii) {
      A[ii] = (double*) malloc(ncols*sizeof(double));
   }
   return A;
}
```

Allocazione dinamica in C / 2

- Si puó allocare un array lineare

```
/* Allocate a double matrix with one malloc */
double* allocate_matrix_as_array(int nrows, int ncols) {
   double *arr_A;
   /* Allocate enough raw space */
   arr_A = (double*) malloc(nrows*ncols*sizeof(double));
   return arr_A;
}
```

- e usarlo come una matrice (linearizzazione dell'indice)

```
arr_A[i*ncols+j]
```

- le MACROs possono aiutare
- e, eventualmente aggiungere una matrice di puntatori che puntano all'array allocato

```
/* Allocate a double matrix with one malloc */
double** allocate_matrix(int nrows, int ncols, double* arr_A) {
   double **A;
   /* Prepare pointers for each matrix row */
   A = new double*[nrows];
   /* Initialize the pointers */
   for (int ii=0; ii<nrows; ++ii) {
      A[ii] = &(arr_A[ii*ncols]);
   }
   return A;
}
```

Aliasing e Restrict

- In C, se due puntatori puntano ad una stessa area di memoria, si parla di “aliasing”
- Il rischio di aliasing puó **molto** limitare l’ottimizzazione del compilatore
  - difficile invertire l’ordine delle operazioni
  - particolarmente per gli argomenti passati a una funzione
- Lo standard C99 introduce la keyword **`restrict`** per indicare che l’aliasing non é possibile

```
void saxpy(int n, float a, float *x, float* restrict y)
```

- In C++, si assume che l’aliasing non possa avvenire tra puntatori a tipi diversi (strict aliasing)

Aliasing e Restrict / 2

- Il Fortran assume che gli argomenti di procedure non possano puntare a identiche aree di memoria
  - tranne che per gli array per i quali gli indici permettono comunque un'analisi corretta
  - o per i **`pointer`** che peró vengono usati ove necessario
  - un motivo per cui il Fortran spesso ottimizza meglio del C!
- I compilatori permettono di configurare le assunzioni dell'aliasing (vedere il man)
  - GNU (solo strict-aliasing): **`-fstrict-aliasing`**
  - Intel (eliminazione completa): **`-fno-alias`**
  - IBM (no overlap per array): **`-qalias=noaryovrlp`**

Non solo compilatore

- Il compilatore ha associata una runtime library
- Contiene funzioni chiamate esplicitamente
  - funzioni trigonometriche e trascendenti
  - manipolazioni di bit
  - funzioni Input Output (C)
- Contiene funzioni chiamate implicitamente
  - funzioni Input Output (Fortran)
  - operatori complessi del linguaggio
  - routine di utilità generiche, gestione eccezioni, . . .
  - routine di supporto ad un particolare modello di calcolo (OpenMP, UPC, GAF)
- Può essere fondamentale per le prestazioni
  - qualità dell'implementazione
  - funzioni matematiche accurate vs. veloci

Input/Output

- È sempre mediato dal sistema operativo
  - causa chiamate di sistema
  - comporta lo svuotamento della pipeline
  - distrugge la coerenza dei dati in cache
  - può alterare la priorità di scheduling
  - è lento
- Regolo d'oro n.1: MAI mescolare calcolo intensivo con I/O
- Regolo d'oro n.2: leggere/scrivere i dati in blocco, non pochi per volta
- Attenzione ad I/O nascosti: swapping
  - avviene quando la RAM è insufficiente
  - usa il disco come surrogato
  - unica soluzione: fuggirlo come la peste

Ci sono più modi di fare I/O

```
do k=1,n  ;  do j=1,n  ;  do i=1,n
write(69,*) a(i,j,k)                                  ! formattato
enddo     ;  enddo     ;  enddo

do k=1,n  ;  do j=1,n  ;  do i=1,n
write(69) a(i,j,k)                                    ! binario
enddo     ;  enddo     ;  enddo

do k=1,n  ;  do j=1,n
write(69) (a(i,j,k),i=1,n)                            ! colonne
enddo     ;  enddo

do k=1,n
write(69) ((a(i,j,k),i=1),n,j=1,n)                    ! matrice
enddo

write(69) (((a(i,j,k),i=1,n),j=1,n),k=1,n)            ! blocco

write(69) a                                           ! dump
```

Con prestazioni differenti

Opzione	secondi	Kbyte
formattato	81.6	419430
binario	81.1	419430
colonne	60.1	268435
matrice	0.66	134742
blocco	0.94	134219
dump	0.66	134217

- Il file-system e anche il suo utilizzo hanno un notevole impatto sui tempi

I/O riassumendo

- La lettura/scrittura dei dati formattati è lenta
- Leggere/scrivere i dati in formato binario
- Leggere/scrivere in un blocco e non uno per volta
- Scegliere il file system più efficiente a disposizione
- I buffer di scrittura possono nascondere latenze
- Ma l'impatto sul calcolo sarà comunque devastante
- Attenzione al dump di array in caso di padding
- Soprattutto per il calcolo parallelo:
  - usare librerie di I/O: MPI-I/O, HDF5, NetCDF,...

Unità vettoriali

- Da non confondere con le macchine vettoriali!
- Le unità vettoriali lavorano con set di istruzioni SIMD e circuiti dedicati a operazioni floating-point simultanee
  - Intel MMX (1996), AMD 3DNow! (1998), Intel SSE (1999) che aggiungono nuovi registri e possibilità floating point
  - Nuove istruzioni (packet) SSE2, SSE3, SSE4, AVX
- Esempio di vettorizzazione: addizione di due array a 4 componenti puó diventare una singola istruzione

```
c(0) = a(0) + b(0)
c(1) = a(1) + b(1)
c(2) = a(2) + b(2)
c(3) = a(3) + b(3)
```

non vettorizzato

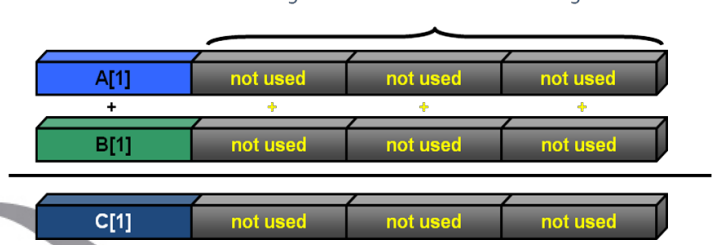

vettorizzato

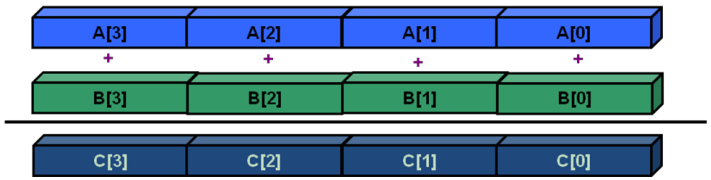

- L'esecuzione SSE é sincrona

Evoluzione unità SIMD

- SSE: registri a 128 bit (Intel Core - AMD Opteron)
  - 4 operazioni floating/integer in singola precisione
  - 2 operazioni floating/integer in doppia precisione
- AVX: registri a 256 bit (Intel Sandy Bridge - AMD Bulldozer)
  - 8 operazioni floating/integer in singola precisione
  - 4 operazioni floating/integer in doppia precisione
- MIC: registri a 512 bit (Intel Knights Corner - 2013)
  - 16 operazioni floating/integer in singola precisione
  - 8 operazioni floating/integer in doppia precisione

Vettorizzazione

- La vettorizzazione dei loop può incrementare drammaticamente le performance
- Ma per essere vettorizzabili, i loop devono obbedire a certi criteri
- E il programmatore deve aiutare il compilatore a verificarli
- Anzitutto, l'assenza di dipendenza tra i dati di diverse iterazioni
  - circostanza frequente ma non troppo in ambito HPC
- Altri criteri
  - Countable (numero delle iterate costante)
  - Single entry-single exit (nessun break or exit)
  - Straight-line code (nessun branch)
  - Deve essere il loop interno di nest
  - Nessuna chiamata a funzione (eccetto quelle matematiche o quelle inlined)
- AVX può essere una sorgente di risultati diversi in calcolo numerico (e.g., Fused Multiply Addiction)

Algoritmi e vettorizzazione

- Differenti algoritmi per lo stesso scopo possono comportarsi diversamente rispetto alla vettorizzazione
  - Gauss-Seidel: dipendenza tra le iterazioni, non vettorizzabile

```
for( i = 1; i < n-1; ++i )
  for( j = 1; j < m-1; ++j )
    a[i][j] = w0 * a[i][j] +
      w1*(a[i-1][j] + a[i+1][j] + a[i][j-1] + a[i][j+1]);
```

- Jacobi: nessuna dipendenza tra le iterazioni, vettorizzabile

```
for( i = 1; i < n-1; ++i )
  for( j = 1; j < m-1; ++j )
     b[i][j] = w0*a[i][j] +
       w1*(a[i-1][j] + a[i][j-1] + a[i+1][j] + a[i][j+1]);
for( i = 1; i < n-1; ++i )
  for( j = 1; j < m-1; ++j )
     a[i][j] = b[i][j];
```

Ottimizzazione e vettorizzazione

- Alcuni comuni “coding tricks” possono impedire la vettorizzazione
  - vettorizzabile

```
for( i = 0; i < n-1; ++i ){
   b[i] = a[i] + a[i+1];
}
```

  - `x` a una certa iterazione é necessaria per lo step successivo

```
x = a[0];
for( i = 0; i < n-1; ++i ){
  y = a[i+1];
  b[i] = x + y;
  x = y;
}
```

- Quando si compila é bene controllare se la vettorizzazione é stata attivata
- In caso contrario, si puó provare ad aiutare il compilatore
  - modificando il codice per renderlo vettorizzabile
  - inserendo direttive per forzare la vettorizzazione

Direttive di vettorizzazione

- Se il programmatore ha certezza che una certa dipendenza riscontrata dal compilatore sia in realtà solo apparente può forzare la vettorizzazione con direttive "compiler dependent"
  - Intel Fortran: **`!DIR$ simd`**
  - Intel C: **`#pragma simd`**
- Poichè **`inow`** è diverso da **`inew`**, la dipendenza è solo apparente

```
62     do k = 1,n
63!DIR$ simd
        do i = 1,l
...
66           x02 = a02(i-1,k+1,inow)
67           x04 = a04(i-1,k-1,inow)
68           x05 = a05(i-1,k  ,inow)
             x06 = a06(i  ,k-1,inow)
             x11 = a11(i+1,k+1,inow)
             x13 = a13(i+1,k-1,inow)
72           x14 = a14(i+1,k  ,inow)
73           x15 = a15(i  ,k+1,inow)
74           x19 = a19(i  ,k  ,inow)
75
76           rho =+x02+x04+x05+x06+x11+x13+x14+x15+x19
...
126          a05(i,k,inew) = x05 - omega*(x05-e05) + force
127          a06(i,k,inew) = x06 - omega*(x06-e06)
```

Vettorizzazione manuale

- É possibile istruire direttamente il codice delle funzioni vettoriali da utilizzare
- In pratica, si tratta di scrivere un loop che fa quattro iterazioni alla volta usando registri e operazioni vettoriali, ed essere pratici con le “mask”

```
void scalar(float* restrict result,
            const float* restrict v,
            unsigned length)
{
  for (unsigned i = 0; i < length; ++i)
  {
    float val = v[i];
    if (val >= 0.f)
      result[i] = sqrt(val);
    else
      result[i] = val;
  }
}
```

```
void sse(float* restrict result,
         const float* restrict v,
         unsigned length)
{
  __m128 zero = _mm_set1_ps(0.f);

  for (unsigned i = 0; i <= length - 4; i += 4)
  {
    __m128 vec  = _mm_load_ps(v + i);
    __m128 mask = _mm_cmpge_ps(vec, zero);
    __m128 sqrt = _mm_sqrt_ps(vec);
    __m128 res  =
         _mm_or_ps(_mm_and_ps(mask, sqrt),
         _mm_andnot_ps(mask, vec));
    _mm_store_ps(result + i, res);
  }
}
```

Parallelizzazione automatica

- Alcuni compilatori offrono opzioni per sfruttare il parallelismo architetturale delle macchina (e.g., i cores) senza modificare il codice sorgente
- Shared Memory Parallelism (solo intra-nodo)
- Simile a OpenMP ma non richiede direttive
  - performance attese piú limitate
- GNU:

```
-floop-parallelize-all
-ftree-parallelize-loops=n - n= number of threads
```

- Intel:

```
-parallel
-par-threshold[n] - set loop count threshold
-par-report{0|1|2|3}
```

- IBM:

```
-qsmp                    la abilita automaticamente
-qsmp=openmp:noauto      per disabilitare la
                         parallelizzazione automatica
```

Outline

Compilatori e ottimizzazione

Floating Point Computing

Makefile

Architectures

Power Perfomance

Aritmetica in virgola mobile

Dato un certo numero $x \epsilon \Re$ si può dimostrare che f, la sua rappresentazione in numero a virgola mobile può scriversi come

$f = \sigma \cdot s \cdot 2^e$

dove

$\sigma \epsilon [1,2)$, $s = 1 + k/2^{N-1}, k \epsilon (0,1,2,...2^{N-1} - 1)$,

$e \epsilon [\epsilon_{min}, \epsilon_{max}] \cap Z$ con $\epsilon_{min} = -2^{M-1} + 2, \epsilon_{max} = 2^{M-1} - 1$ e Z l'insieme dei numeri interi definiti positivi, dato un campo degli esponenti a M-bit, con N-bit significativi.

Aritmetica in virgola mobile

Ma vediamo in maniera più pratica come viene rappresentato in memoria un numero in virgola mobile:

Singola precisione

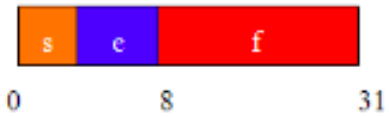

Doppia precisione

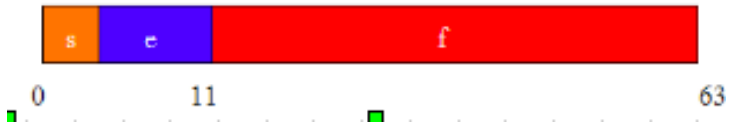

Aritmetica in virgola mobile

In entrambi i casi vediamo che abbiamo un bit di segno (s), un campo (e) e un campo di mantissa o significativo (f), ma con un differente numero di bit per campo.
Abbiamo detto in precedenza la definizione di rappresentazione floating-point, ma un numero a virgola mobile può anche essere scritto come

$$(-1)^s \cdot d_0 \cdot d_1 \cdot d_2 .... \cdot d_{p-1} \cdot \beta^e$$

dove p rappresenta il massimo numero di cifre significative nel significando e β è la base del sisetma numerico usato (generalmene 2 o 16).
È chiaro che rappresentare un numero reale con un sistema a virgola mobile presenta diversi problemi.
Due in particolare sono i più evidenti:

- Non si può rappresnetare in maiera esatta un numero reale in un sistema a virgola mobile.
- Un numero reale può essere troppo grande o troppo piccolo per poter essere rappresentato con un range di esponente disponibile.

Aritmetica in virgola mobile

Quale esempio del primo problema consideriamo di rappresentare il numero 0.2.
In base 10 (b=10) con una precisione pari a tre cifre (p=3) la rappresentazione è esatta: $2.00 \cdot 10^{-1}$.
Però, in base 2 (b=2) con diciamo, 6 cifre significative, abbiamo che 0.2 dovrebbe essere rappresentato come $1.10011 \cdot 2^{-3}$ (ci perdiamo una coda di $1.1001100110011... \cdot 2^{-9}$).

Quindi avremo sempre un errore nel rappresentare i valori che vogliamo usare nei nostri calcoli ed essi saranno contaminati da questi errori di rappresentazione anche se il calcolo in se stesso è esatto.

Per risolvere questa situazione dobbiamo far leva su di un compromesso tra precisione nella traduzione da numero reale a numero in virgola mobile e velocità di esecuzione nella traduzione stessa, funzione del numero di bit usati nella rappresentazione floating-point.

Lo standard IEEE754

Questi ed altri problemi(errori di arrotondamento, realtivi alla preecisione di macchina, etc.) furono affrontati diverso tempo fa.
Nel 1979, il benemerito Istituto USA di Ingegneria Elettrica ed Elettronica(IEEE) propose uno standard per i calcoli a virgola mobile, l'IEEE 754.
Questo standard che si è concretizzato nella sua forma definitiva nel 1981, come suggerisce il nome, non riguarda la rappresentazione di interi (a parte la conversione in numeri floating point), bensì quella dei numeri in virgola mobile.

Lo standard IEEE754

Lo standard assume che la base di rappresentazione sia 2 e tra le altre cose chiarisce in maniera precisa i seguenti punti:

- Il formato delle rappresentazioni dei numeri a virgola mobile
- I risultati delle operazioni di addizione, sottrazione, moltiplicazione, divisione, radice quadrata, resto e comparazione di numeri a virgola mobile
- La conversione tra interi e numeri floating-point
- La conversione tra il formato base a virgola mobile e stringhe decimali
- Le eccezioni (exception) e loro gestione incluso i non-numeri (i cosidetti, NaN, Not a Number).

Lo standard IEEE754

Lo standard non definisce i termini di applicazione di quanto sopra che può essere realizzato sia in hardware che in software, ma ha permesso di semplificare la gestione dei dati floating-point e di avere un comune standard di riferimento per essi.

Pe rquesto motivo, tutti i computer oggi in commercio adottano le soglie sui dati in virgola mobile definite dallo standard IEEE 754 che sono:

N.B La disposizione in memoria di numeri a virgola mobile a singola e doppia precisione data in precedenza è proprio quella prevista dallo standard IEEE754.

Lo standard IEEE754

Singola precisione

Precisione realtiva $2^{-23} \approx 1.1920929 \cdot 10^{-7}$

Numero più piccolo $(-1)^s 2^{-126} \approx 1.1754944 \cdot 10^{-38}$
Numero più grande $(-1)^s (1 - 2^{-24}) 2^{+128} \approx 3.402823510^{+38}$

Doppia precisione

Precisione realtiva $2^{-52} \approx 2.2204460492503 \cdot 10^{-16}$

Numero più piccolo $(-1)^s 2^{-1022} \approx 2.2250738585072 \cdot 10^{-308}$
Numero più grande
$(-1)^s (1 - 2^{-53}) 2^{+1024} \approx 1.7976931348623^{+308}$

Outline

Compilatori e ottimizzazione

Floating Point Computing

Makefile

Architectures

Power Perfomance

L'utility Make

L'utility *make* è essenzialmente un linguaggio di programmazione per automatizzare il processo di compilazione.
L'idea dietro *make* è che il programmatore non deve ricompilare un certo file se esiste già un file oggetto corrispondente. Il file oggetto si dice *corrente* se è stato compilato piřecentemente dell'ultimo cambiamento al suo file sorgente.
Come esempio consideriamo la seguente situazione:
Abbiamo appena modificato il file sorgente *program.f* e vogliamo compilarlo e "linkarlo" ai moduli *inputs.f* e *outputs.f*.
Il comando corrispondente (f77) sarà:

```
f77 program.f inputs.f outputs.f
```

Il quale esegue la compilazione ed il *linking* dei tre moduli correttamente.

L'utility Make

Sei i moduli oggetto *inputs.o* e *outputs.o* esistono già e se essi sono correnti (non modificati) avremmo potuto dare il comando (*):

```
f77 program.f inputs.o outputs.o
```

In questo caso f77 avrebbe compilato *program.f* e fatto solo il link di *program.o*, *inputs.o* e *outputs.o*.
Ovviamente compilando un solo programma invece di tre, il processo di compilazione-linking sarà molto più veloce ed efficiente.
Operare come nel secondo caso, quando si hanno molti file sorgenti e oggetto a disposizione, diviene un'operazione assai laboriosa e da qui, quindi, l'esigenza di una utility come *make* che può fare questo per noi in maiera automatica.

(*) in questo caso, non avendo usato l'opzione **-c**, il compilatore dopo aver generato il/i file oggetto invoca automaticamente il linker **ld** per generare l'eseguibile. In Unix, se non diamo un nome al nostro eseguibile mdiante l'opzione **-o**, il nome di default ad esso assegnato è **a.out**.

L'utility Make

Inoltre , *make* riduce la possibilità di errori di compilazione che possono verificarsi sia per errori nella liena di comando che nella scelta dei moduli d autilizzare.
Per capire come funziona *make*, dobbiamo prima definire alcuni termini:

target	Una operazione da eseguire. Nella maggior parte dei casi esso contiene il nome del file da creare.
dipendenza	Una relazione tra due target: il target A dipende dal target B se un cambiamento in B produce una variazione in A.
up-to-date	Un file che è più recente di ognuno dei file da cui dipende
makefile	Un file che descrive come creare uno o più target. In esso sono listati tutti i file dai quali i target dipendono e da le regole necessarie a compilare questi target correttamente.
make	Il comando che esegue quanto comtenuto in un makefile. Per deafult *make* cerca un file chiamato *makefile* o *Makefile* nella directory corrente. Come opzione si può usare il target da compilare.

L'utility Make

Ma facciamo un esempio pratico, riportando in un *makefile* il caso visto con f77 con due target diversi: ad es. usiamo due diverse opzioni per f77.

```
#
# Un semplice makefile
# (Le righe di commenti cominciano con #)
#
# Primo target:
#
program:
	f77 -o program -O program.f inputs.f outputs.f

#Secondo target:
#
program.db:
	f77 -o program -DDEBUG -g program.f inputs.f outputs.f
```

Se usiamo questo *makefile* con *make* possiamo scegliere tra i due target semplicemente scrivendoli dopo *make* ...

L'utility Make

Ad esempio,

```
make program
```

eseguirà il comando

```
f77 -o program -O program.f inputs.f outputs.f
```

e produrrà l'eseguibile **program**.
È importante ricordare che *make* creerà una nuova shell per ognuno dei comandi che incontra dopo il *target* e che questi vanno dati dopo il carattere **[TAB]** (ogni riga dei comandi per un *target* comincia con un **[TAB]**...)

L'utility Make

Se vogliamo che i nostri *target* dipendano da uno o più file, dobbiamo allora indicare le relative dipendenze. Questo si fa' aggiungendo il nome dei file da cui un certo *target* dipende dopo i [:]

```
program: program.o inputs.o outputs.o
	f77 -o program program.o inputs.o outputs.o
```

La prima riga ci dice che **program** dipende da *program.o*, *inputs.o* e *outputs.o*, mentre la seconda usa f77 (ovvero ld) per fare il link dei file oggetti se essi già esistono.
Se invece i file oggetto non esistono, essi dovranno avere le loro dipendenze nel *makefile* dovrà esserci un target per ognuno dei file oggetto. In questo modo *make* prima genera i file oggetto e poi l'eseguibile.

L'utility Make

In definitiva il nostro *makefile* completo sarà:

```
program: program.o inputs.o outputs.o
	f77 -o program program.o inputs.o outputs.o

program.o: program.f
	f77 -c -o program.o program.f

inputs.o: inputs.f header.f
	f77 -c -o inputs.o inputs.f

outputs.o outputs.f
	f77 -c -o outputs.o outputs.f
```

L'utility Make

Nel makefile si possono usare delle abbrevazioni e macro.
Tra le abbrevazioni più usate abbiamo

$@ Indica il nome completo del target
$* Indica il nome del target senza suffisso

Usandole in una riga dell'esempio precedente avremo:

```
program: program.o inputs.o outputs.o
      f77 –o $@ $*.o imputs.o outputs.o
```

Una macro, invece, serve in un *makefile* per raggruppare in un'unica variabile diversi nomi o comandi.
Ad esempio, se poniamo nella macro **DEPENDS** i nostri file oggetto, potremo scrivere la riga precedente come

```
DEPENDS = program.o inputs.o outputs.o

program: $(DEPENDS)
      f77 –o $@ $ (DEPENDS)
```

Outline

Compilatori e ottimizzazione

Floating Point Computing

Makefile

Architectures

Power Perfomance

Von Neumann Architecture

- Central Processing Unit (CPU)
  - Arithmetic logic unit (executes instructions)
  - Control unit
  - Registers (fast memory)
- Interconnection CPU RAM (Bus)
- Random Access Memory (RAM)
  - Address to access memory locations
  - Memory content (instructions, data)

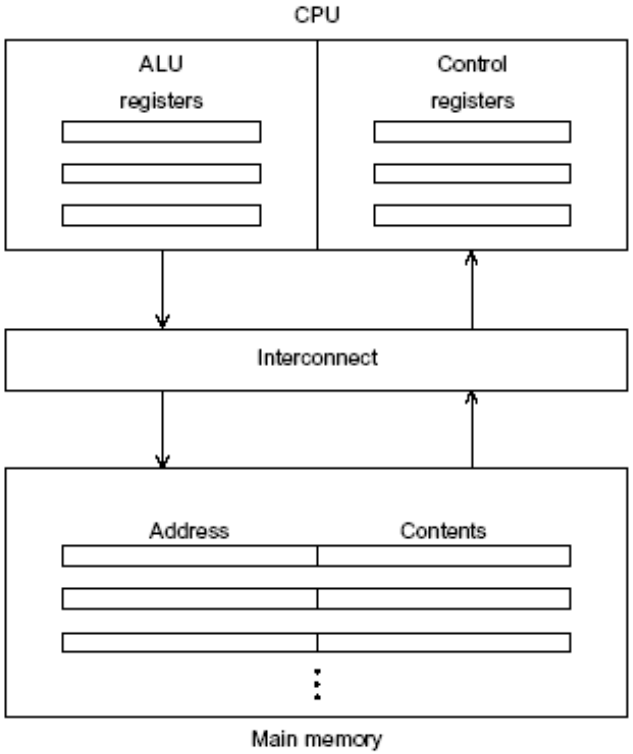

Von Neumann Architecture

- Data are sent from memory to CPU (fetch or read)
- Data are sent from CPU to memory (written to memory or stored)
- The separation between the CPU and memory leads to what is known as the «von Neumann bottleneck»: the limited throughput (data transfer rate) between the CPU and memory compared to the amount of memory
- In most modern computers, the throughput is one hundred smaller compared to the rate the CPU can process

Solutions to the von Neumann Bottleneck

- Caching
  Very fast memories integrated directly into the processor chip.
  There are first, second or third level caches
- Virtual memory
  The RAM is used as a cache for big data storage.
- Instruction level parallelism
  single CPU core, but multiple functional units to execute multiple nstructions in parallel (pipelining, multiple issues)

Flynn's taxonomy

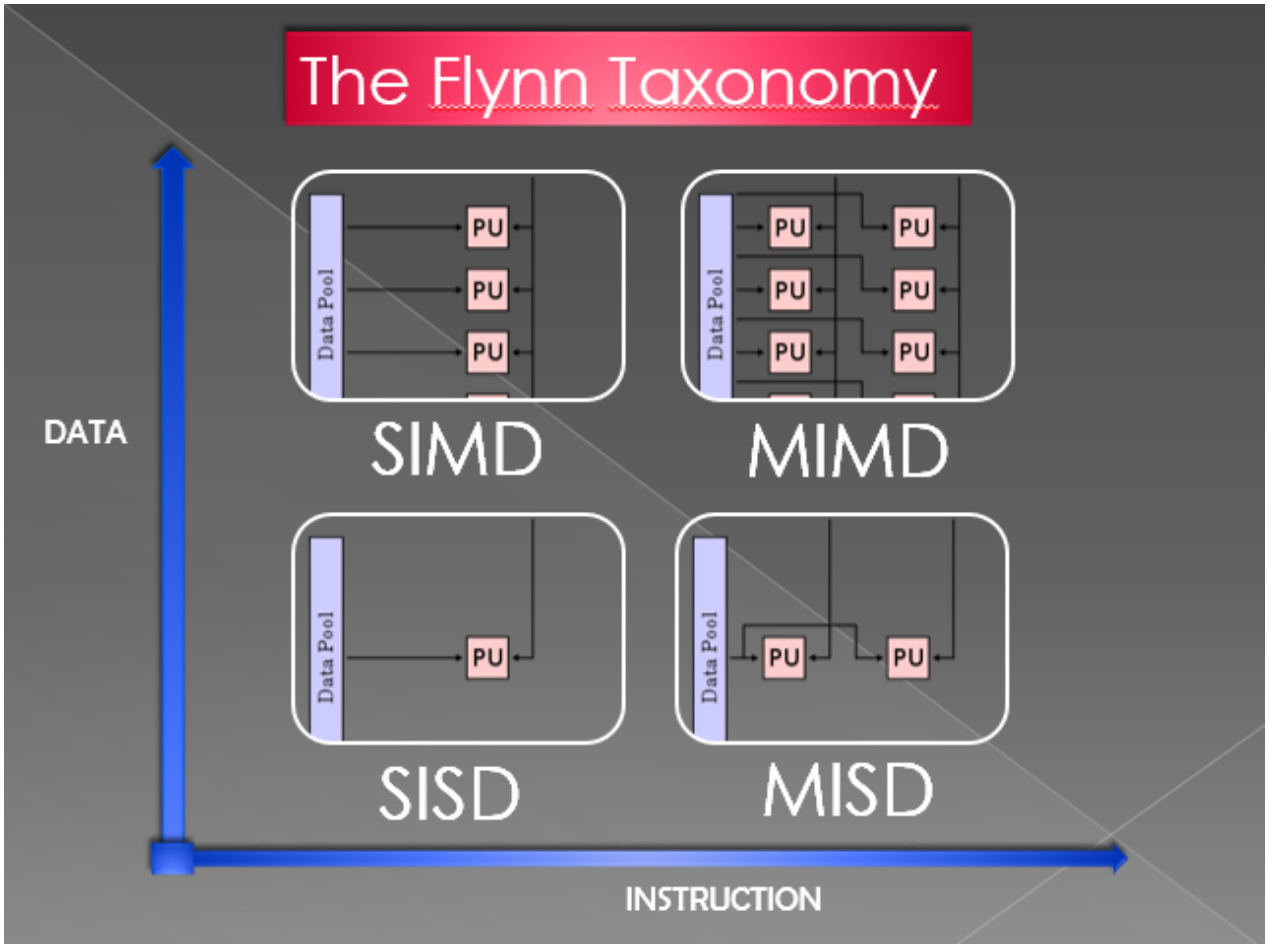

Flynn's taxonomy

- It classifies computer architectures based on the number of instructions that can be executed and how they operate on data.
  - SISD: single instruction, single data. Classical von Neumann architecture, scalar mono-processor system.
  - SIMD: single instruction, multiple data. Vectorial architectures, vectorial processors, GPU.
  - MISD: multiple instructions, single data. This hardware solution does not exist.
  - MIMD: multiple instructions, multiple data. Multiple processors/cores execute different instructions operating on different data
- The modern computer architectures combine features from the previous categories

SISD

- Classical von Neumann architecture
- Scalar mono-processor systems (single core).
- The execution of the instructions can be pipelined (Cyber 76).
- Each arithmetic instruction starts an arithmetic operation.

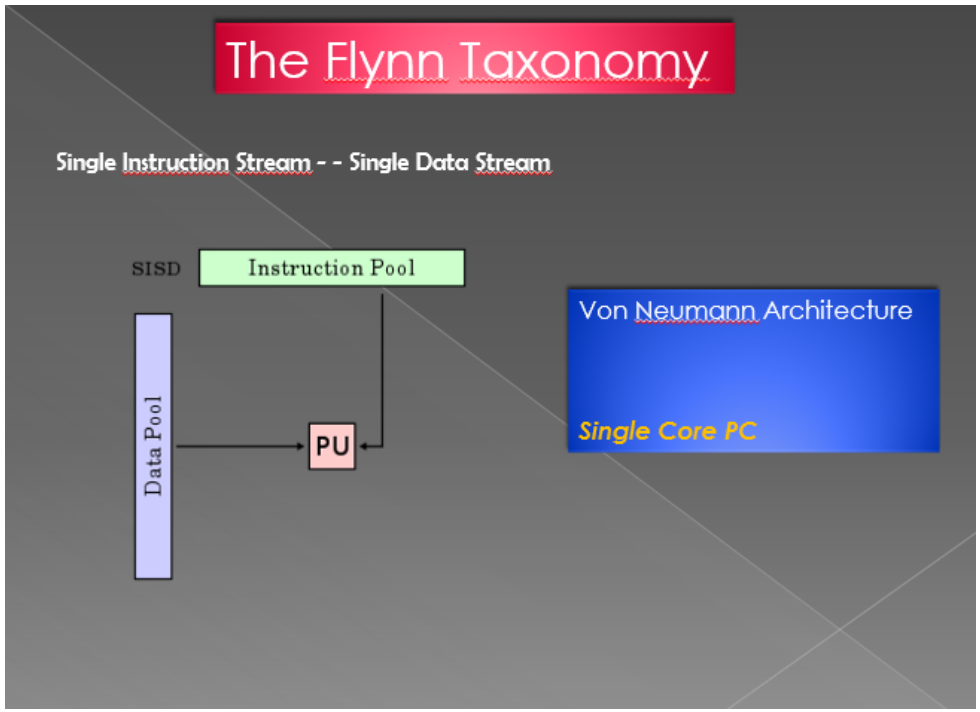

SIMD

A single instruction operates simultaneously on multiple data

Synchronous computational model

- Vectorial processors
  - Many ALU
  - Vectorial registers
  - Load/Store vector units
  - Vector instructions
  - Interleaved memory
  - OpenMP, MPI
- Graphical Processing Unit
  - Programmable GPU
  - many ALU
  - many Load/Store units
  - many SFU
  - one thousand threads that work in parallel
  - CUDA

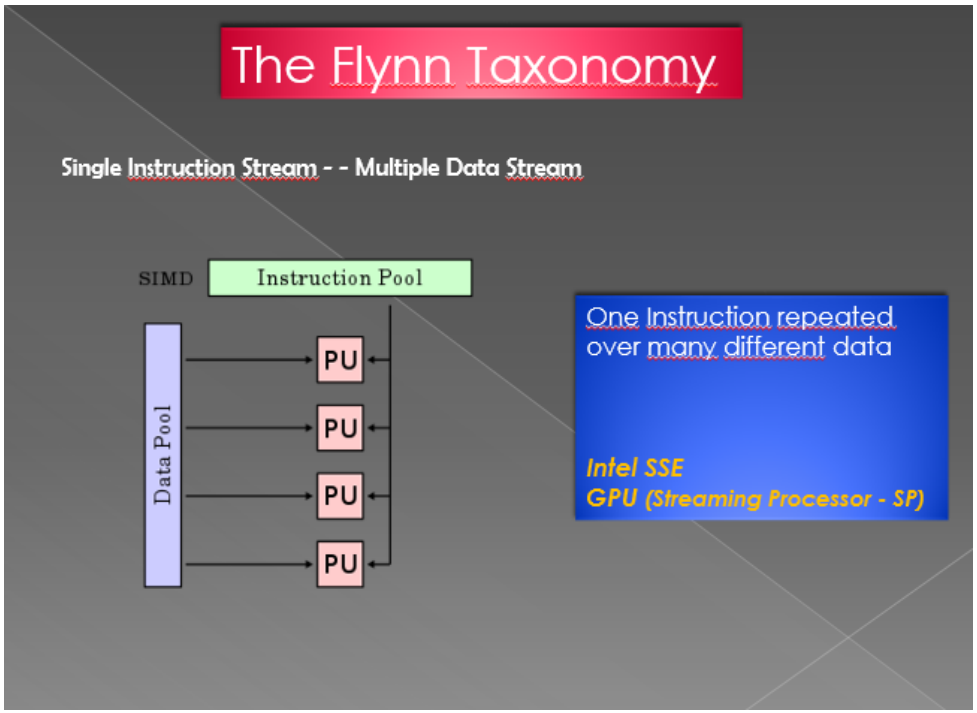

MIMD

Multiple processors execute different instructions operating on different data. Asynchronous computational model

- Cluster
  - many nodes (hundreds/thousands)
  - more multicore processors per node
  - shared RAM node
  - distributed RAM between nodes
  - hierarchy memory levels
  - OpenMP, MPI, MPI+OpenMP

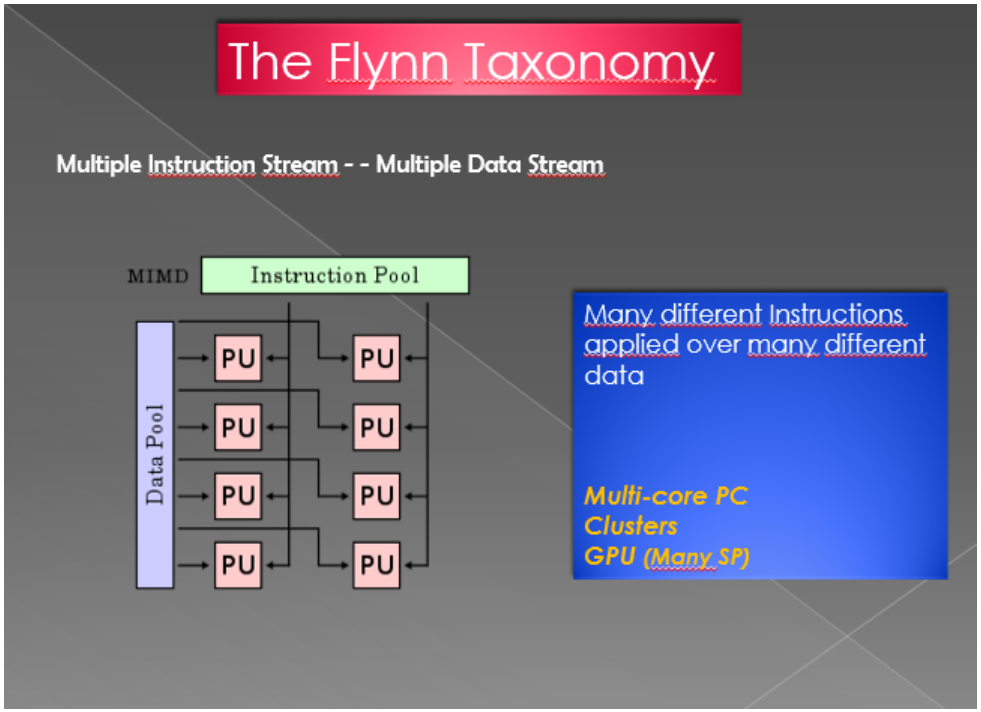

MIMD:Fermi Blue Gene/Q

Model: IBM-BlueGene /Q
Architecture: 10 BGQ Frame with 2 MidPlanes each
Front-end Nodes OS: Red-Hat EL 6.2
Compute Node Kernel: lightweight Linux-like kernel
Processor Type: IBM PowerA2, 16 cores, 1.6 GHz
Computing Nodes: 10.240
Computing Cores: 163.840
RAM: 16GB / node
Internal Network: Network interface
with 11 links ->5D Torus
Disk Space: more than 2PB of scratch space
Peak Performance: 2.1 PFlop/s

Cluster CPU GPU

- Hybrid Solution CPU multi-core + GPU many-core:
  - Each compute node has multi-core processors and graphics card with processors dedicated to GPU Computing.
  - Theoretical massive amount of power computing on single node.
  - Additional memory embedded inside GPU
  - OpenMP, MPI, CUDA and hybrid solutions MPI+OpenMP, MPI+CUDA, OpenMP+CUDA, OpenMP+MPI+CUDA

CPU vs GPU

- The CPU is a general purpose processor
  - threads dedicated to heavy computations, at most 1 thread per core
- The GPU is a processor dedicated to intense data-parallel computations
  - very easy flow control
  - many light-weight threads that work in parallel

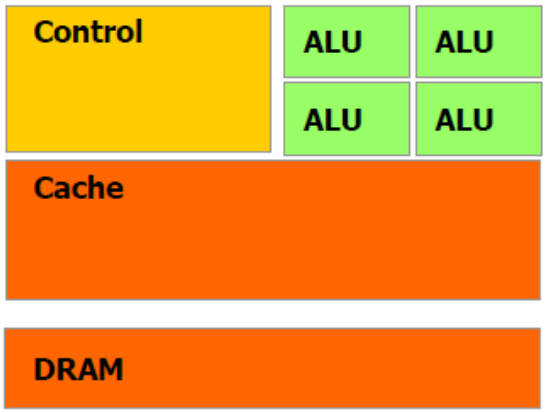

CPU

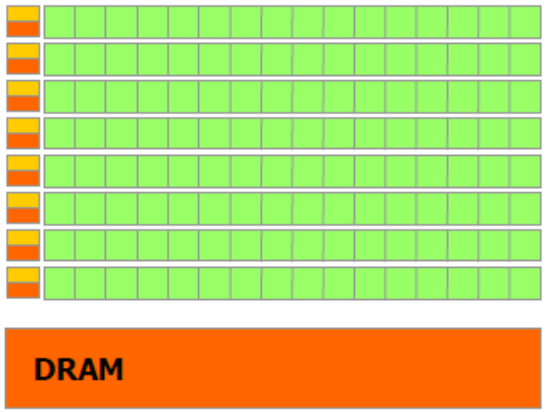

GPU

Multicore vs Manycore

- Recent trends in the microprocessor architectures:
  - increasing the overall computing power by increasing the number of cores rather than the computing power of a single core.
  - the computing power and the bandwidth of a GPU are 10 times larger compared to the CPU ones

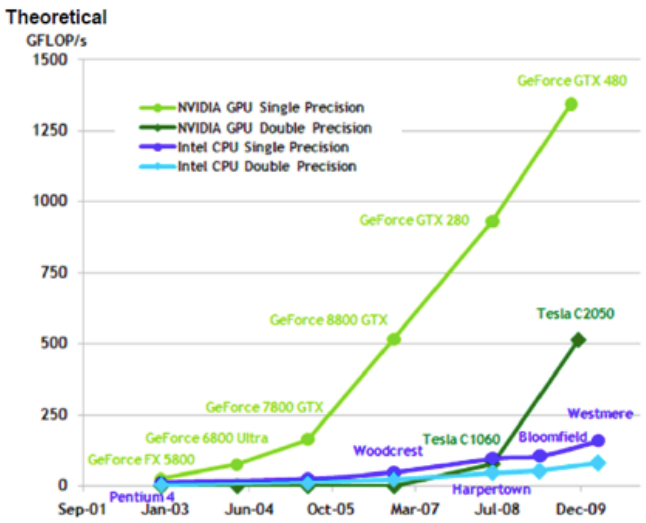

Numero di operazioni in virgola mobile al secondo per la CPU e la GPU

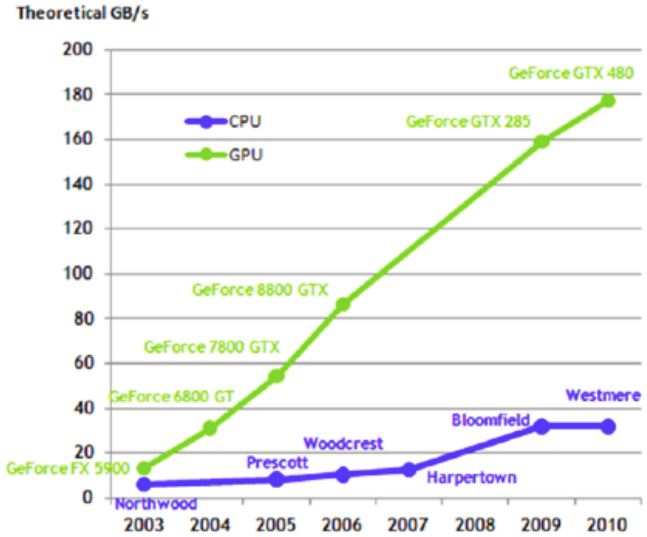

Larghezza di banda della memoria

INTEL MIC

- Intel Xeon Phy Coprocessor
  - Based on Intel Many Integrated Core (MIC) architecture
  - 60 core/1,053 GHz/240 threads
  - 8 GB memory and 320 GB/s bandwidth
  - Get up to 1 teraFLOPS of double precision peak performance
  - 512-bit SIMD units
  - Traditional parallel approach: MPI, OpenMP

Bandwidth

- Defined as the amount of data transferred per second between memory and processor
- Measured in number of bytes per second (Mb/s, Gb /s, etc..)
- A = B * C
  - B: data which is read from memory
  - C: data which is read from memory
  - Multiplication B * C is calculated
  - The result is saved to memory using the same place of the A variable
- 1 floating-point operation $\rightarrow$ 3 memory accesses

Stream

- The STREAM benchmark is a simple synthetic benchmark program that measures sustainable memory bandwidth (in MB/s) and the corresponding computation rate for simple vector kernels
- Time elapsed to:
  - a $\rightarrow$ c (copy)
  - a*b $\rightarrow$ c (scale)
  - a+b $\rightarrow$ c (add)
  - a+b*c $\rightarrow$ d (triad)
- It measures the maximum bandwidth
- http://www.cs.virginia.edu/stream/ref.html

Shared and Distributed memory

- The classical MIMD architectures and the hybrid CPU-GPU architectures are classified in two categories.
  - Shared memory systems: each core can access the entire system memory
  - Distributed memory systems: each processor can directly access only to its own local memory. The communication among different processors occurs via a specific communication protocol

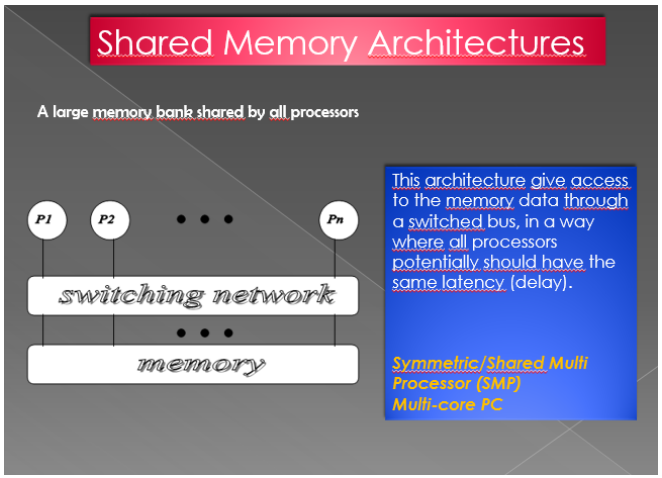

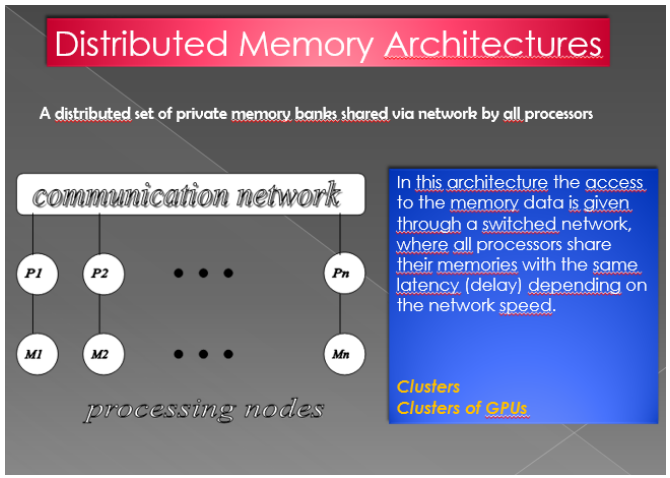

- In the modern multicore systems, the memory is shared within a single node and distributed between nodes.

Shared Memory

- Uniform Memory Access where all processors access the main memory at the same speed using the interconnection system.
- Non Uniform Memory Access where a multicore processor can access its own local memory faster than non-local memory. The non-local memory is memory local to another processor or memory shared between processors.

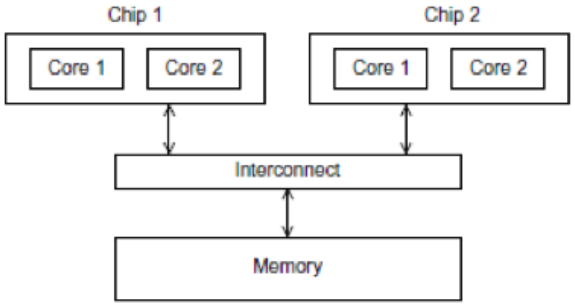

UMA

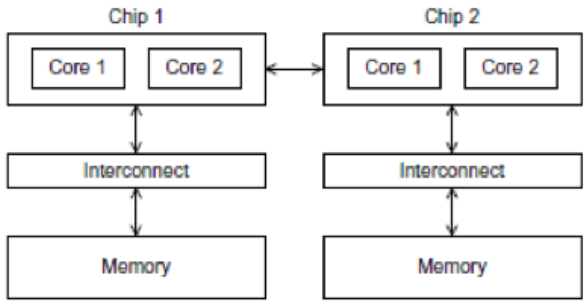

NUMA

UMA NUMA

- Main problems:
  - The efficiency of the cache optimization decreases when a process (or thread) is transferred from one CPU to another
  - UMA machines: memory intensive processes running on different CPUs may significantly decrease performance due to the bus contention
  - NUMA machines : Run slow down when CPU accesses non local memory data.
- Solutions:
  - binding of processes or binding of threads to CPU
  - memory affinity
  - for AIX architecture, set MEMORY_AFFINITY environment variable.
  - when implemented: use numactl

Networks

- In high performance systems, different processors are arranged on different nodes. The memory is shared between different processors in the same node, while it is distributed between nodes.
  - Nodes are connected to different networks.
  - Gigabit Ethernet: the most common, low cost, low performances
  - Infiniband: more common, high performances, very expensive
  - Myrinet: less common
- old networks
  - Quadrics
  - Cray

www.top500.org

Rank	Site	System	Cores	Rmax (TFlop/s)	Rpeak (TFlop/s)	Power (kW)
1	DOE/SC/Oak Ridge National Laboratory United States	**Titan** - Cray XK7 , Opteron 6274 16C 2.200GHz, Cray Gemini interconnect, NVIDIA K20x Cray Inc.	560640	17590.0	27112.5	8209
2	DOE/NNSA/LLNL United States	**Sequoia** - BlueGene/Q, Power BQC 16C 1.60 GHz, Custom IBM	1572864	16324.8	20132.7	7890
3	RIKEN Advanced Institute for Computational Science (AICS) Japan	K computer, SPARC64 VIIIfx 2.0GHz, Tofu interconnect Fujitsu	705024	10510.0	11280.4	12660
9	CINECA Italy	**Fermi** - BlueGene/Q, Power BQC 16C 1.60GHz, Custom IBM	163840	1725.5	2097.2	822

Outline

Compilatori e ottimizzazione

Floating Point Computing

Makefile

Architectures

Power Perfomance

Power Perfomance

PERFORMANCE

Power Perfomance

$$\frac{PERFORMANCE}{POWER}$$

Power Perfomance

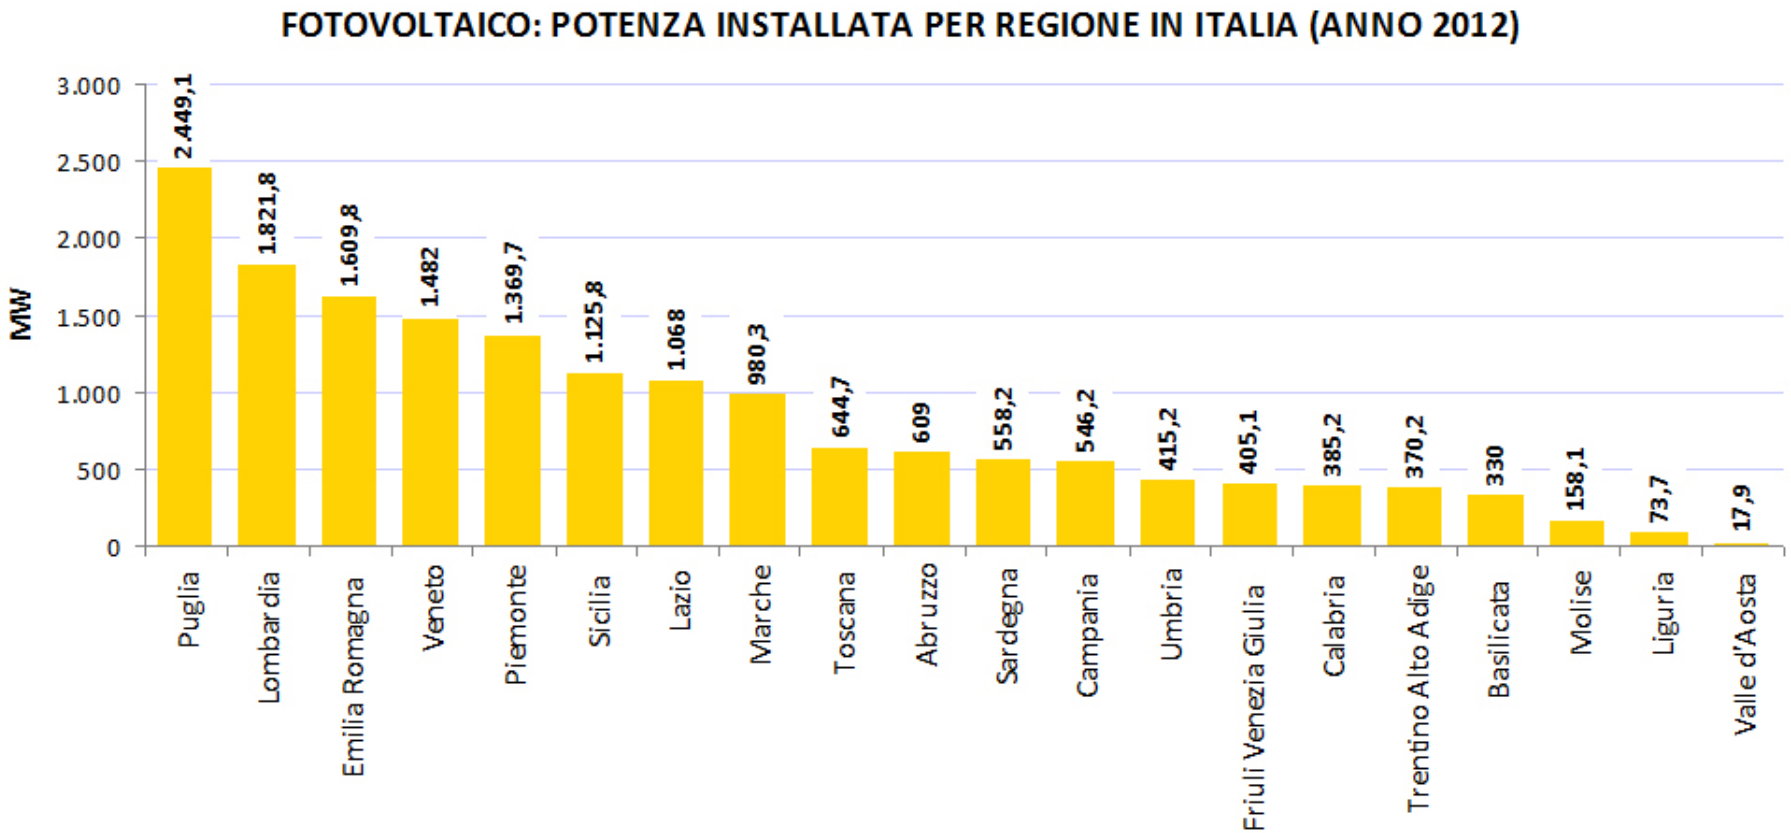

Power Perfomance

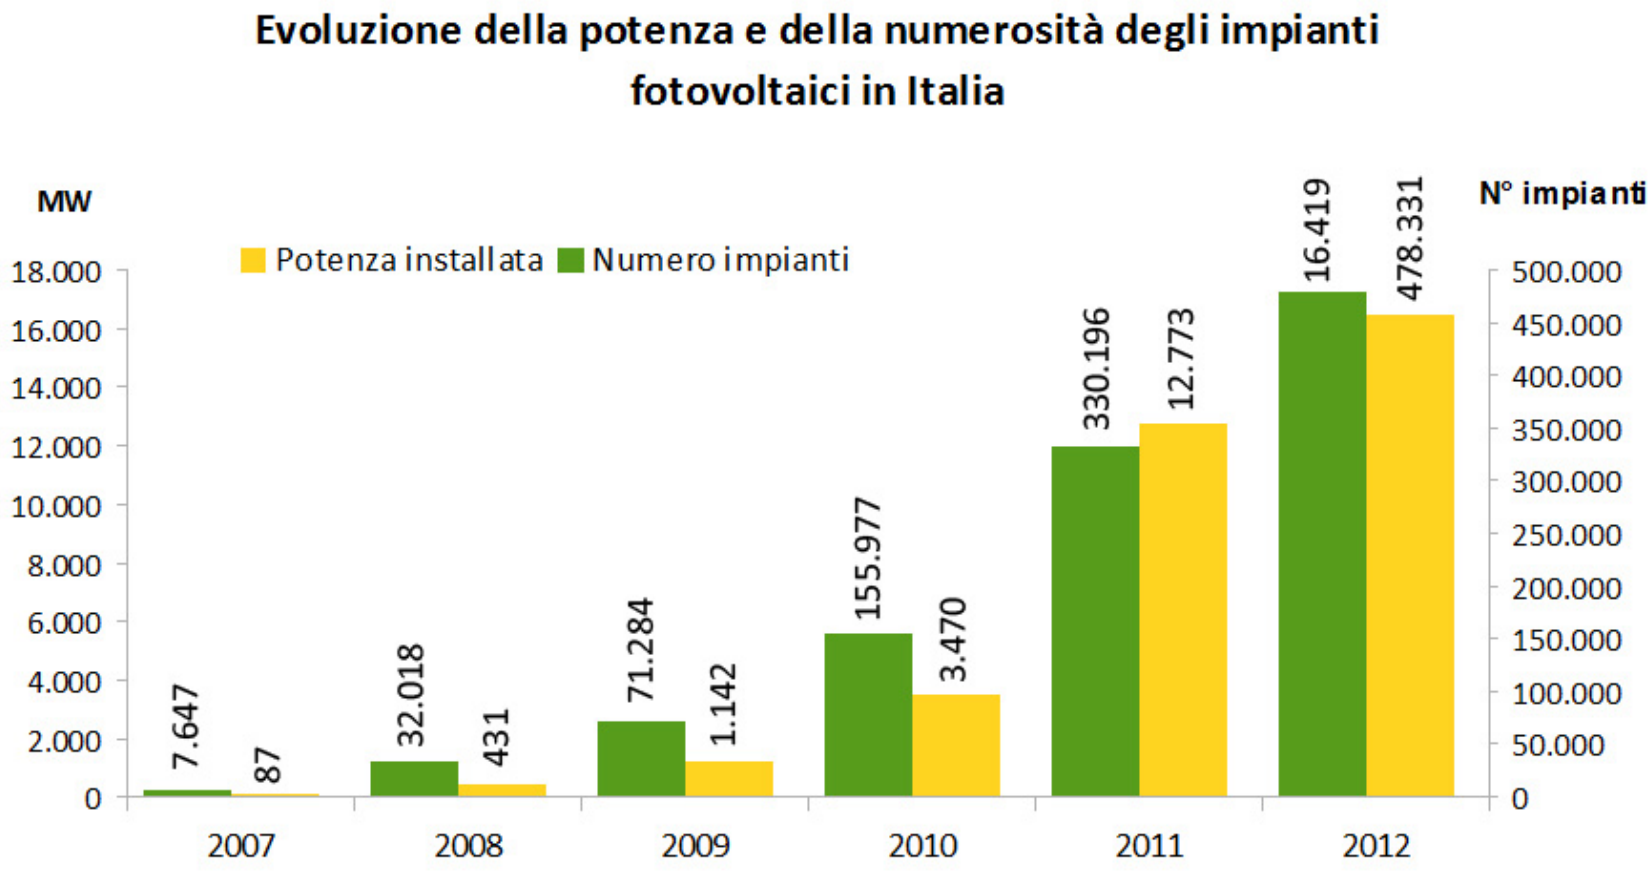

Power Perfomance

$$\frac{PERFORMANCE}{POWER} \quad \begin{matrix} > 1 EXAFLOP \\ < 20 MWATT \end{matrix}$$

Power Perfomance

$$\frac{NODE\ PERFORMANCE * \#NODES * CROSS\ NODE\ EFICIENCY}{NODE\ POWER * \#NODES + NETWORK\ POWER * \#NODES}$$

Power Perfomance

$$\frac{NPERF * NN * CNE}{NODEW * NN + NETWORK * NN}$$

Power Perfomance

$$\frac{NPERF * NN * CNE}{NODEW * NN + NETW * NN} \quad \begin{array}{l} > 1 \text{ EXAFLOP} \\ < 20 \text{ MWATT} \end{array}$$

Power Perfomance

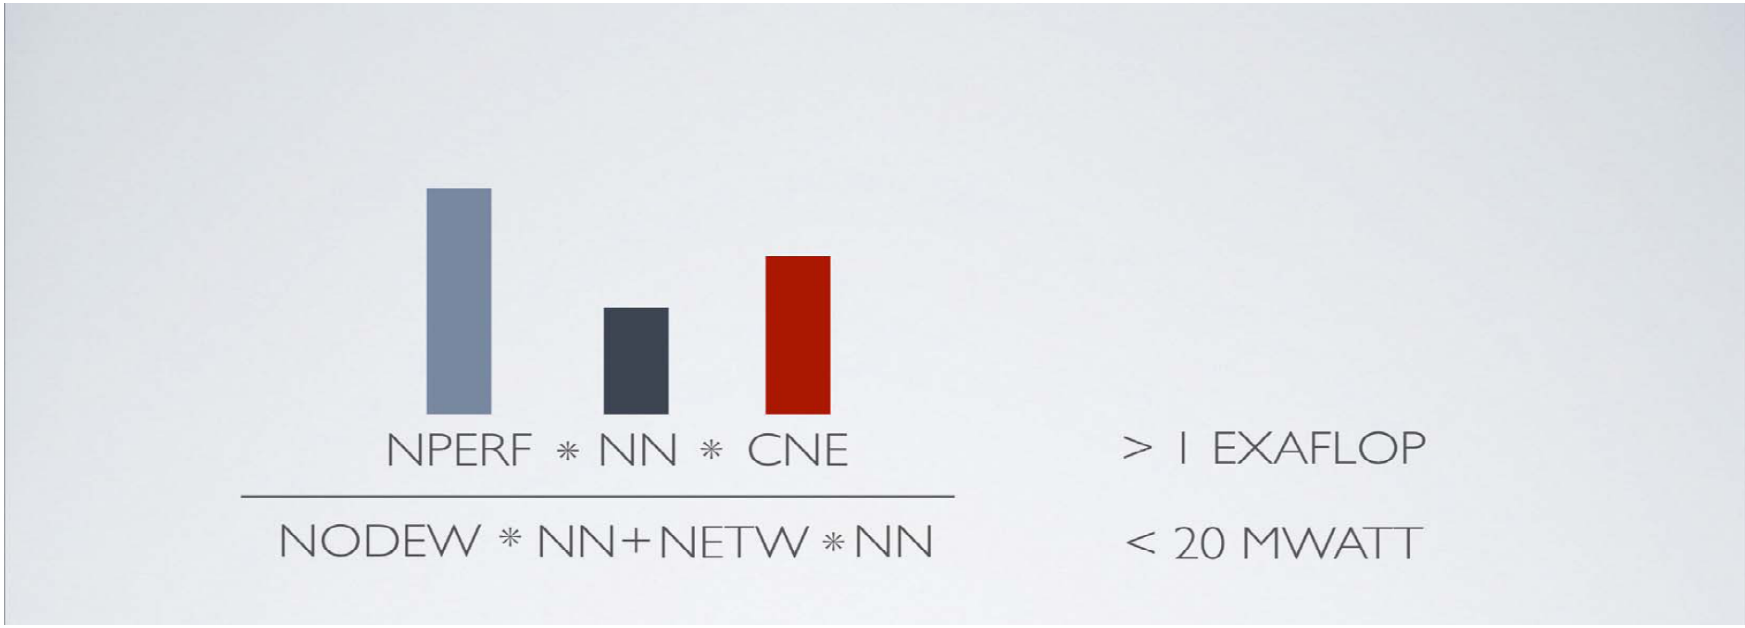

Power Perfomance

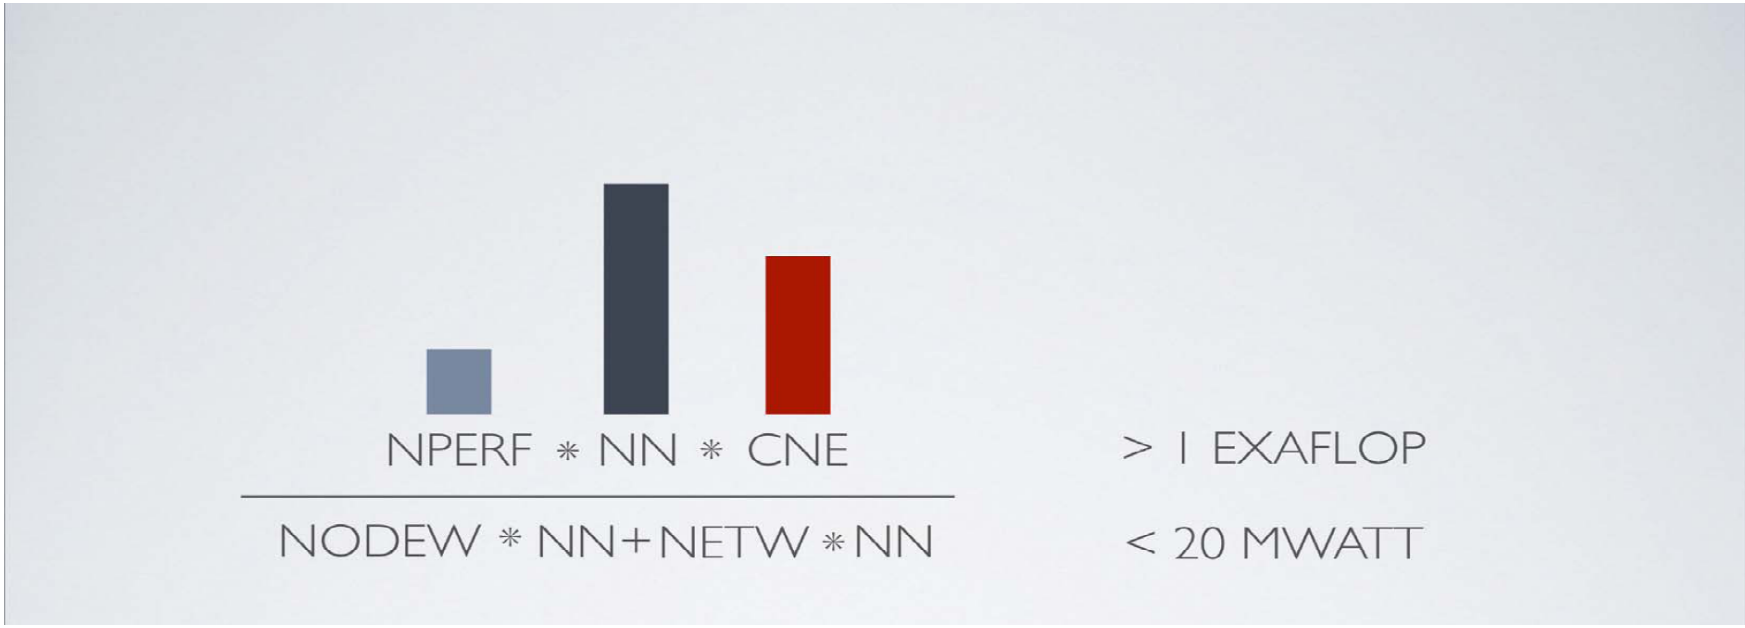

Power Perfomance

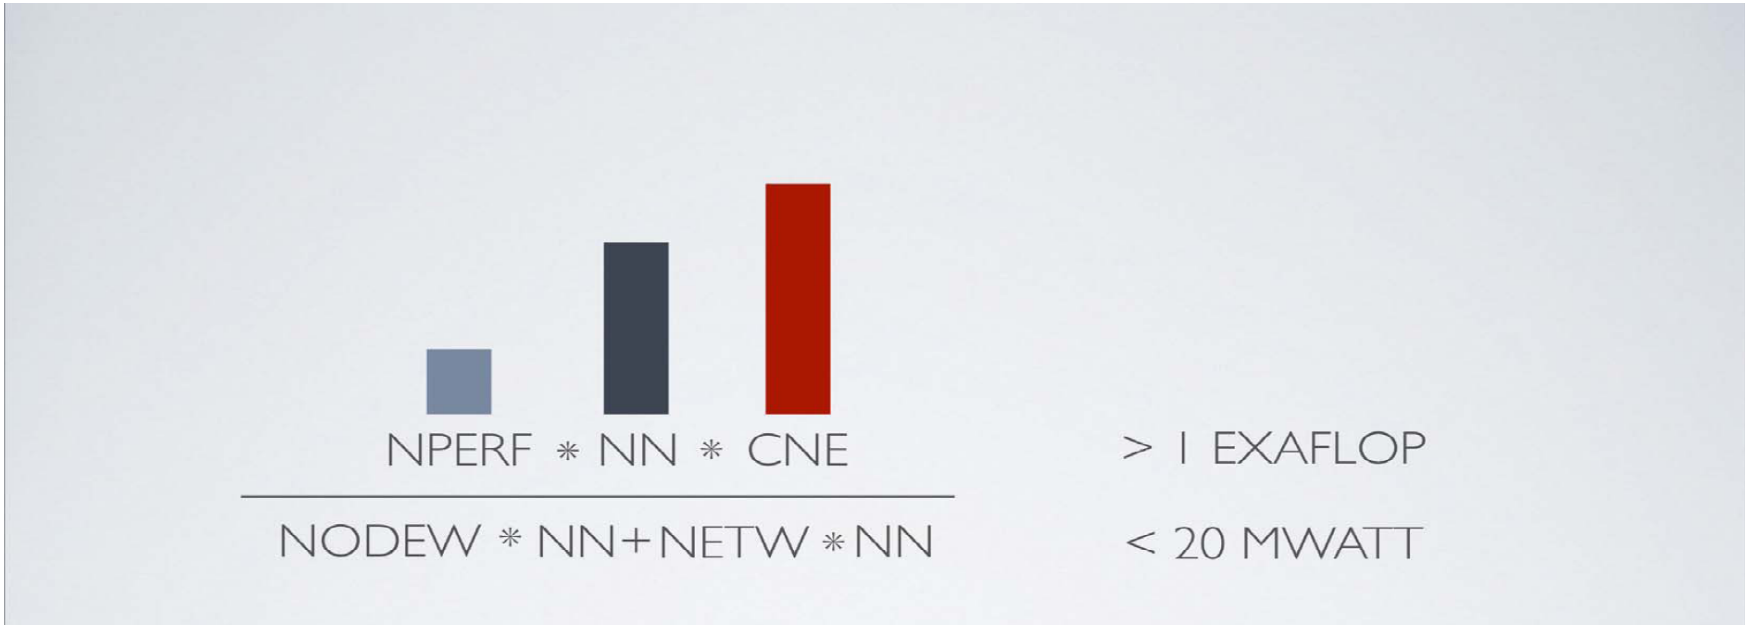

Power Perfomance

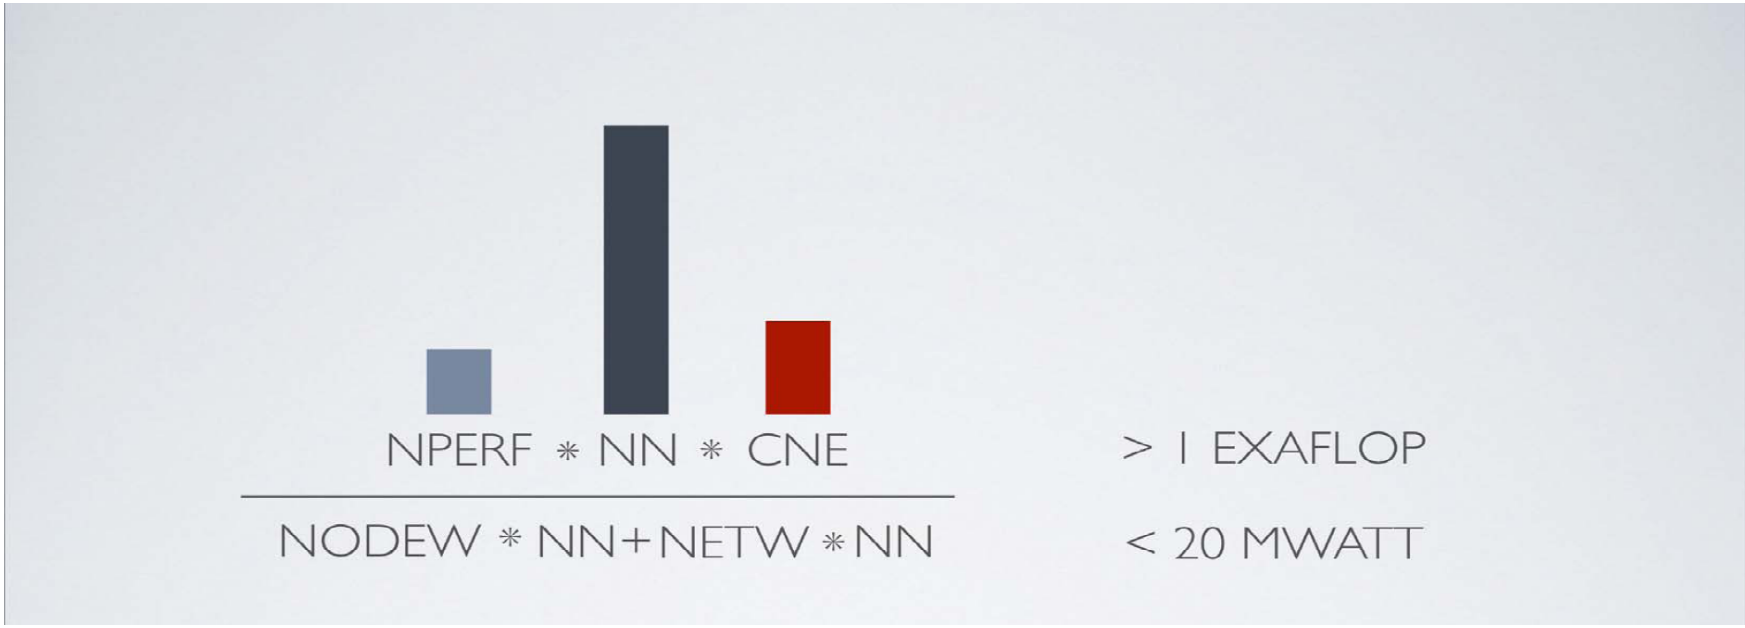

Power Perfomance

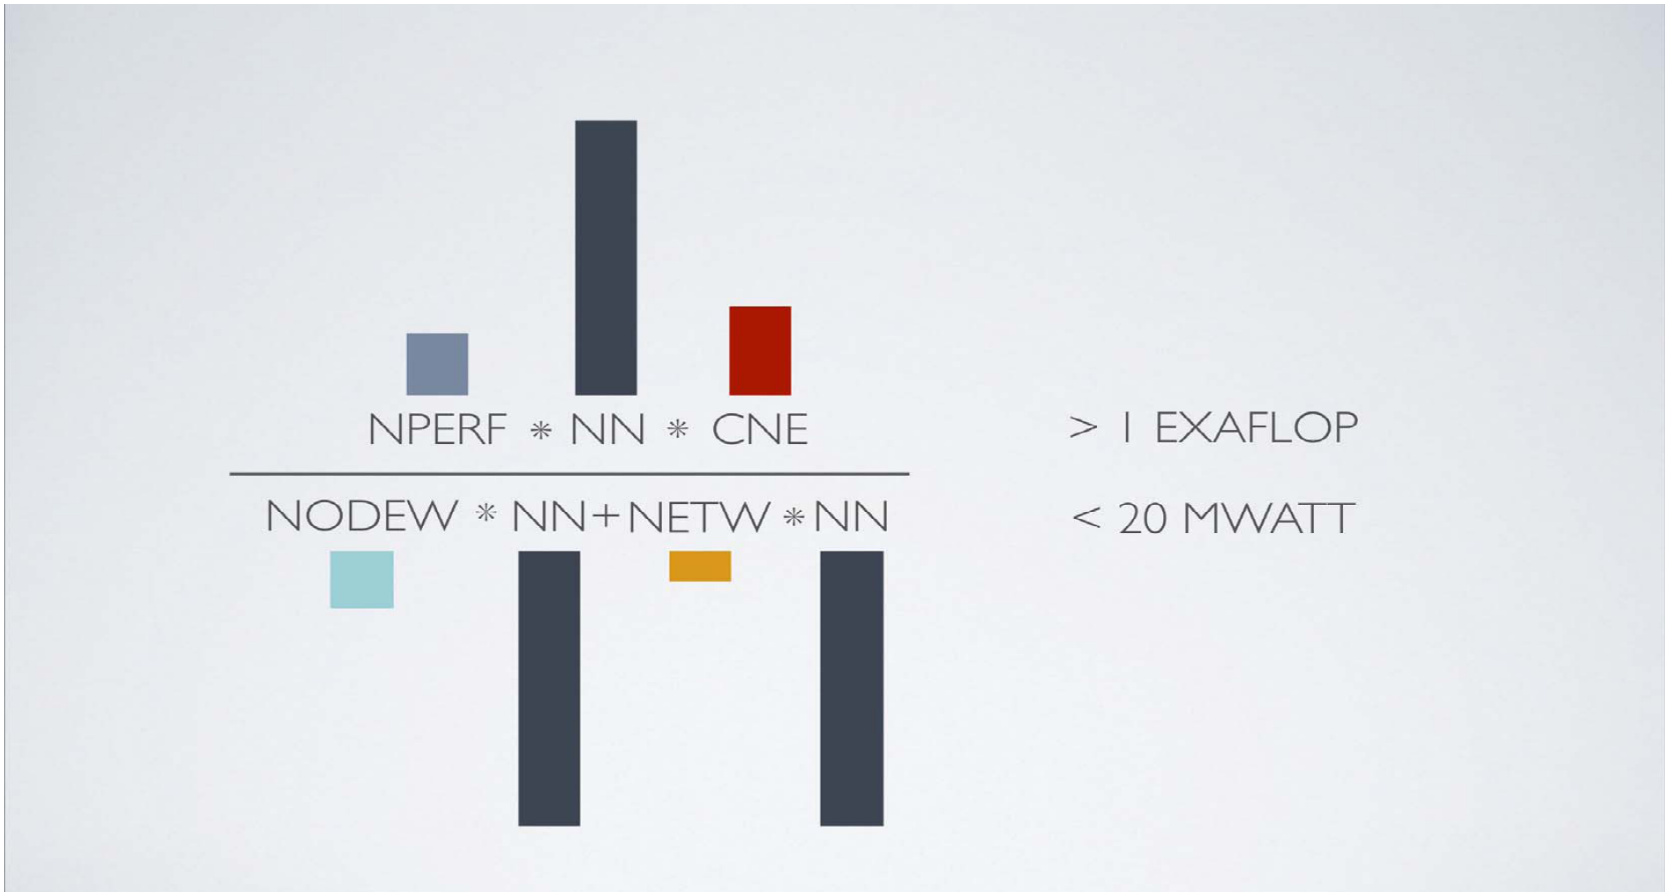

Power Perfomance

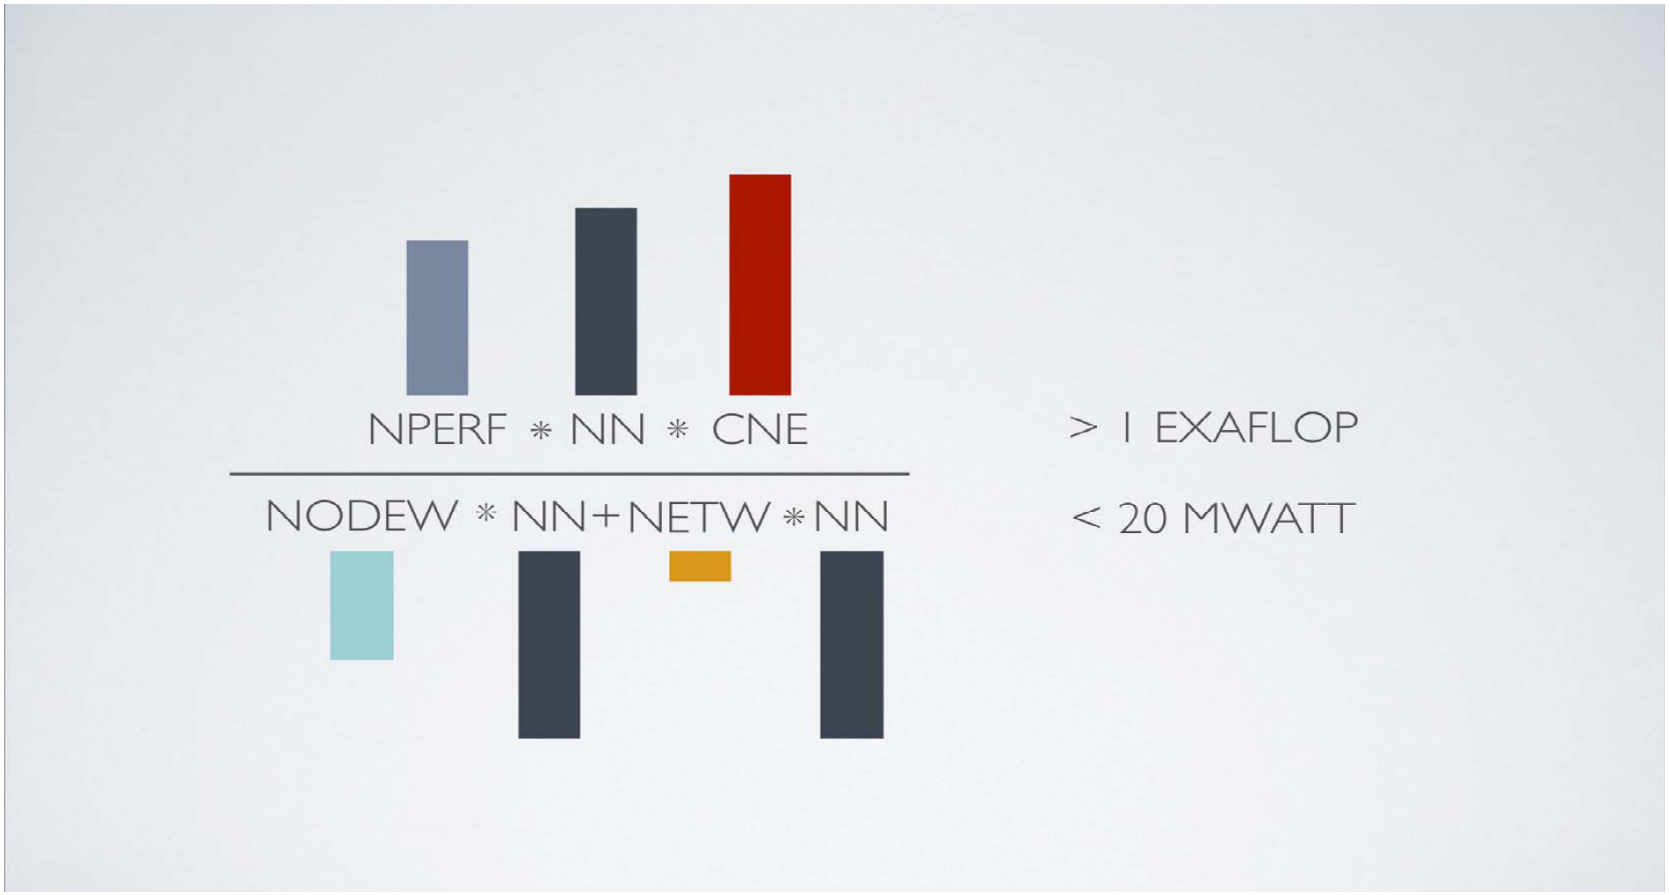

Power Perfomance

$$\frac{NPERF * NN * CNE}{NODEW * NN + NETWORK * NN} \quad \begin{array}{l} > 1 EXAFLOP \\ < 20 MWATT \end{array}$$

Power Perfomance

$$\frac{NPERF * NN * CNE}{NODEW * NN + NETWORK * NN}$$

Power Perfomance

NPERF = CORE PERF * NUM CORES * CROSS CORE EFFICIENCY

$$\frac{NPERF * NN * CNE}{NODEW * NN + NETWORK * NN}$$

NODEW = COREW + MEMW + UNCOREW

Power Perfomance

NPERF = CPERF * NC * CCE

$$\frac{NPERF * NN * CNE}{NODEW * NN + NETWORK * NN}$$

NODEW = CW + MW + UCW

Power Perfomance

$$\frac{(CPERF * NC * CCE) * NN * CNE}{(CW + MW + UCW) * NN + NETW * NN}$$

Power Perfomance

CPERF = TREAD PERF * NUM THREADS * CROSS THREAD EFFICIENCY

$$\frac{(CPERF * NC * CCE) * NN * CNE}{(CW + MW + UCW) * NN + NETW * NN}$$

CW = PEAKW * PEAK% + IDLEW * IDLE%

Power Perfomance

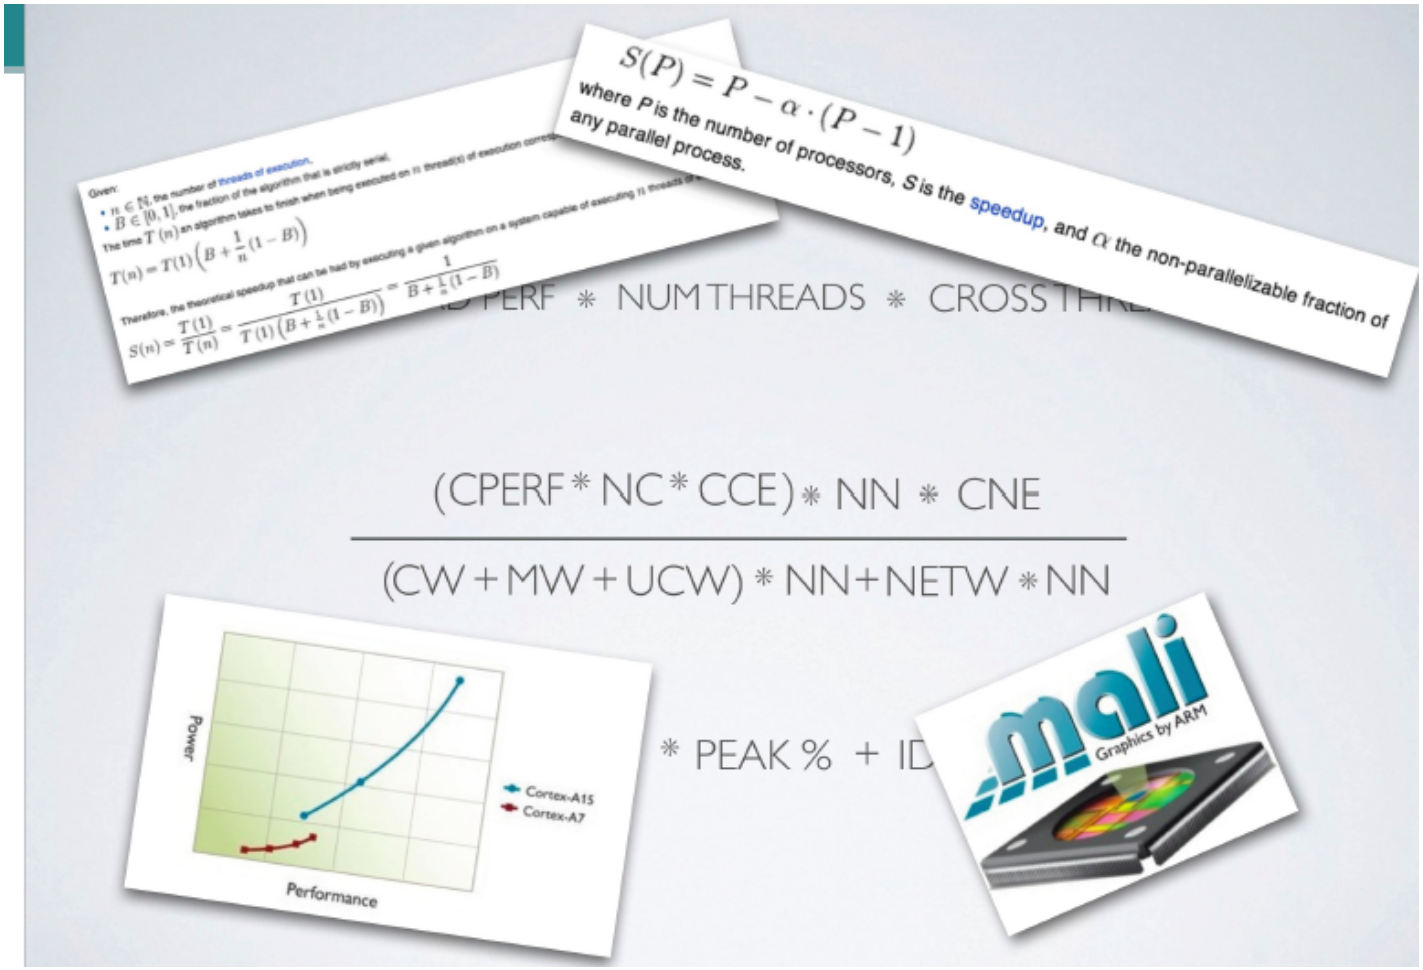

Power Perfomance

$$\frac{(CPERF * NC * CCE) * NN * CNE}{(CW + MW + UCW) * NN + NETW * NN}$$

Power Perfomance

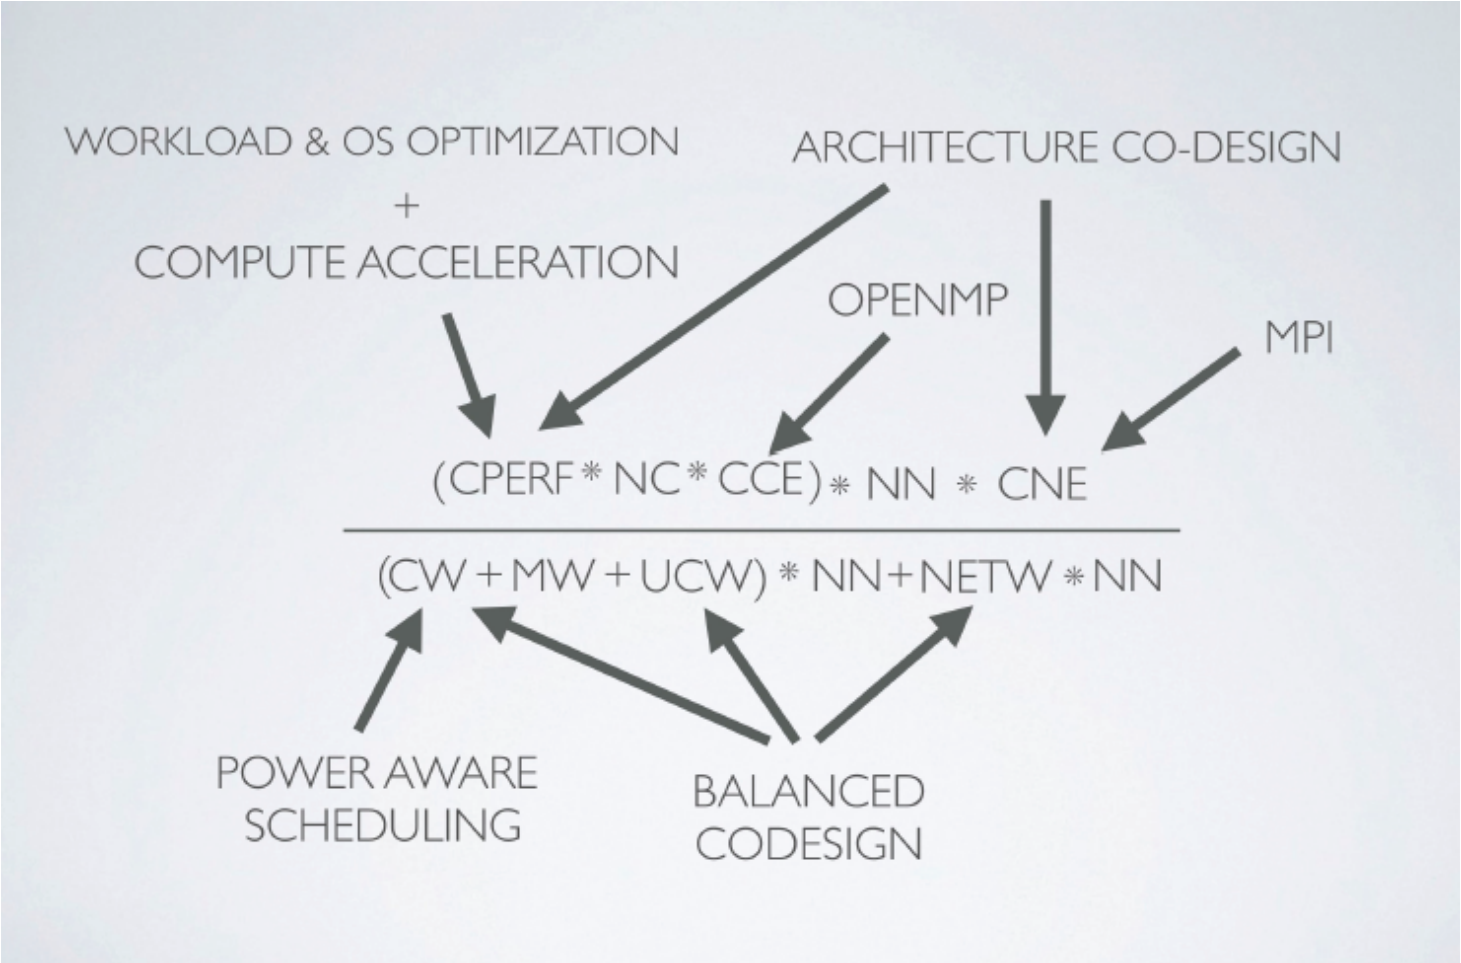

Thanks to Chris Adeniyi-Jones (ARM Ltd)