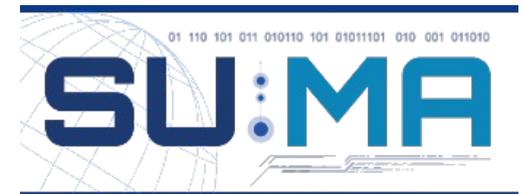


***Suma:
primo compleanno***

*R. (lele) Tripiccione
tripiccione@fe.infn.it*

Roma, 8 novembre 2013



SUMA: what does it mean?

*We have drunk suma and become immortal;
We have attained the light, the Gods discovered.
(Rigveda 8,48,3)*

*One cubic centimetre
cures ten gloomy
sentiments.*

*(A. Huxley,
Brave New World, 1932)*



Il menu del giorno

*Cosa e' successo negli ultimi 12 mesi:
(un certo numero di buone notizie)*

Post docs, at last !

Super-calcolo al CINECA

Il nuovo cluster di Pisa

Una lenta migrazione verso le “nuove” macchine:

Test di efficienza sugli “acceleratori”

----->

Opzioni per il “large prototype” del progetto SUMA

Iniziamo con un po' di buone notizie



Gli assegni di ricerca ...

<i>Pisa</i>	<i>(WP2)</i>	<i>02/09/2013:</i>	<i>Giuseppe Caruso</i>
<i>Roma I</i>	<i>(WP1)</i>	<i>01/11/2013:</i>	<i>Pol Vilaseca Mainar</i>
<i>Roma 3</i>	<i>(WP1)</i>	<i>concorso 09/2013:</i>	<i>A. Shreck</i>
<i>TOV</i>	<i>(WP1/4)</i>	<i>15/10/2013:</i>	<i>Francesco Stellato</i>
<i>Trento</i>	<i>(WP1)</i>	<i>01/10/2013:</i>	<i>Gigi Scorzato</i>
<i>Roma 1</i>	<i>(WP4):</i>	<i>da ribandire.....</i>	

Accordo INFN-Cineca

Accordo discusso tra varie difficoltà in primavera 2012, in vista dell'installazione del Blue-Gene/Q

100 Mcore-hours su BG/Q a disposizione dell'INFN tra "giugno" 2012 e giugno 2013, da suddividere tra i vari gruppi interessati.

Coordinamento informale (S. Simula, LT + S. Bassini[Cineca])

Preventivo

IS	Responsabile	Mcore-hour – prod.	Mcore-hour – test	TOTAL
MI11	Di Renzo	10	2	12
PI11	Pelissetto	10		10
PI12	D' Elia	16	2	18
RM123	Simula	30		30
PD32	Viviani		2	2
OG51	De Pietri	3	2	5
TV62	Mazzino	8	5	13
Grand Tot		77	13	90

Interesse anche di PR21, MB31, RM61, TO61

Consuntivo

Utilizzo di BG/Q da ~ 1 Settembre 2012 a 15 Ottobre 2013

account	start	end	total	Consumed	%
INFN_OG51	20120703	20140630	22.000.000	6.008.941	27.3
INFN_RM123	20120703	20140630	77.000.000	40.533.604	52.6
INFN_T061	20120703	20140630	6.500.000	2.287.703	35.2
INFN_PI12	20120703	20140630	35.000.000	27.803.322	79.4
INFN_TV62	20120703	20140630	27.000.000	9.658.315	35.8
INFN_MI11	20120703	20140630	32.975.000	27.710.427	84.0
INFN_MB31	20120910	20140730	2.000.000	1.019.362	51.0
INFN_PD32	20120703	20130630	3.500.000	254.297	7.3
INFN_PI11	20120817	20140630	17.000.000	6.558.015	38.6
Total			222.975.000	121.833.991	54.6

Pur con non pochi problemi di gestione, l' iniziativa sta dando i risultati promessi.

INFN – Cineca: Consuntivo

Consuntivo del primo anno:

~ 120 Mcore-hours effettivamente utilizzate

~ 250 Mcore-hours ottenute tramite PRACE + ISCRA (in principio scorrelate, pero')

Storage CNAF<--> CINECA still a problem...

Accordo rinnovato per altri 2 anni all' ultimo CD.

ZEFIRO: il nuovo cluster teorico

Il nuovo cluster di HPC e' stato istallato a Pisa a partire dai primi di settembre.

25 nodi di calcolo

4 processori AMD opteron 6380 (2.5 GHz) (16 x 4 cores)

512 Gbyte di memoria

Rete Infiniband QDR

Switch Mellanox 36 porte ---> ~ 100 porte

*In totale **1600** core di calcolo (~ 10 Gflops / core)*

ZEFIRO: il nuovo cluster teorico



ZEFIRO: il nuovo cluster teorico

Infrastruttura accesa e funzionante,

Sotto test da parte di un set limitato di utenti “smart”

Apertura ufficiale alla comunita' CSN4 il 22 Ottobre (OGGI...)

Joint venture di:

SUMA 140 Keuro;

CSN4 70 Keuro (+20 Keuro /anno di operation..);

CCR contributo al nuovo switch

Upgrade di ~ 60 KE (~ 500 core) da CSN4 su fondi 2014

ZEFIRO: il nuovo cluster teorico

Accesso esclusivamente tramite un sistema di code via una userinterface locale (code controllate da LSF)

Debug (4 cores / 30 min)

Parallel (256 cores / 6 ore)

Longparallel (512 cores / 24 ore)

Approssimativamente 1.2 Mcore-hour all' anno (?!....)

Struttura analoga a quella utilizzata nella maggior parte dei Computer Center HPC

ZEFIRO: Modalita' di utilizzo

- + *Accessibile a tutti i componenti delle sigle della CSN4*
 - + *altri se richiesto da un componente della CSN4*
(studenti / ospiti / collaboratori)
- + *In principio in modo automatico, tramite AAI*
- + *Accesso "illimitato" sperimentale fino a fine anno 2013*
- + *Accesso regolamentato a partire da gennaio 2014 ????*
(vecchia commissione?)

ZEFIRO: Modalita' di utilizzo

+ *Istruzioni per l' uso --->*

http://wiki.infn.it/strutture/pi/computing_center/theocluster

+ *In caso di problemi ---->*

localq-support@lists.pi.infn.it

+ *Fineprints a voce*

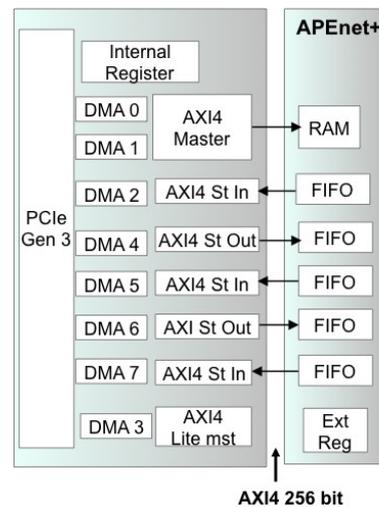
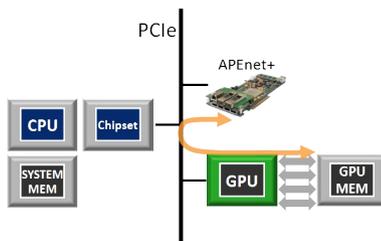
- WP4 -

Valorizzare gli sviluppi tecnologici in ambito INFN e svilupparli ulteriormente. → Ulteriori progressi di APEnet

Punto di partenza: scheda APEnet+ V4, integrata su STRATIX IV (40nm)

PCI Gen2 x8 (5Gb / s per lane)

Supporto per P2P (GPUdirect RDMA)

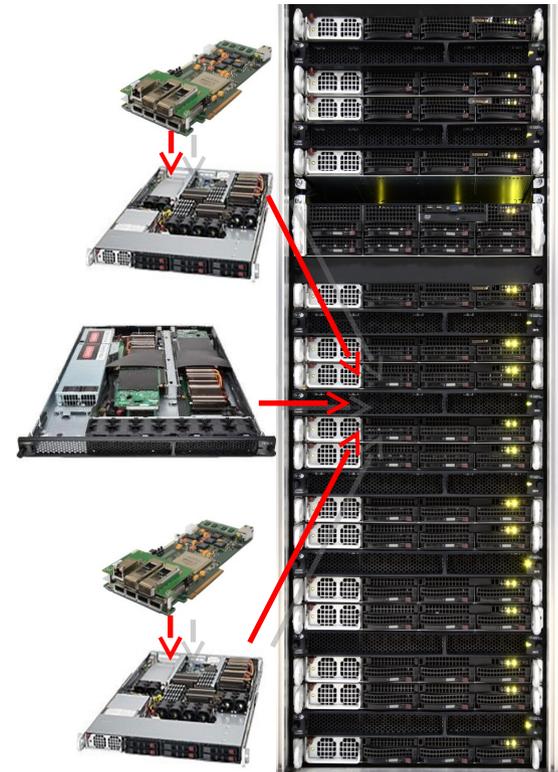


- WP4 -

Valorizzare gli sviluppi tecnologici in ambito INFN e svilupparli ulteriormente. → Ulteriori progressi di APEnet

Assemblato un sistema di 16 nodi (4x4x1)

Ancora relativamente instabile (problemi di integrazione OS / software NVIDIA / software APEnet)



- WP4 -

Iniziato il porting su Eurora:

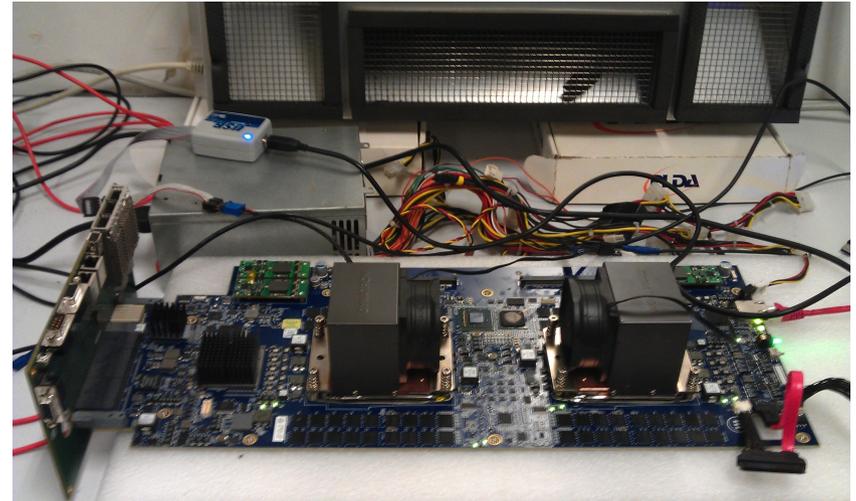
- *Infrastruttura di test disponibile*
- *Compilato il firmware APEnet v4 sulle FPGA della scheda Eurora*
- *Verificate le funzionalita' di base*
- *Iniziati test sui link X,Y,Z*
- *Y, Z OK ----- X NO!???*

- passi a breve (Dicembre 2013)

Completamento del test su banco

Test in corpore vili (Eurora / CINECA)

Rapporti con Eurotech → da decidere



- WP4 -

In parallelo:

Sviluppo della V5 di APEnet

Nuova generazione di FPGA

Upgrade Gen2 → Gen3

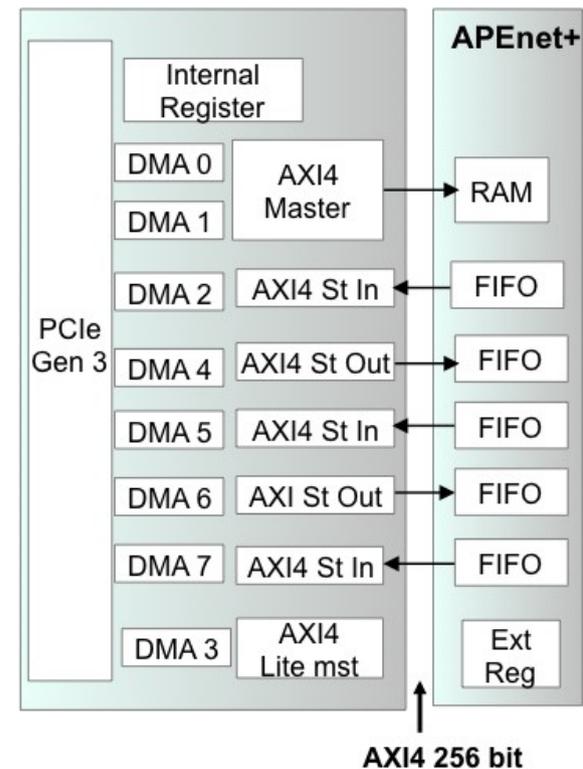
Link piu' veloci

(in teoria 7 → 11 Gb / sec)

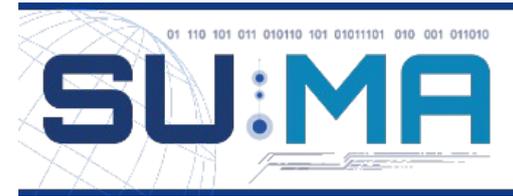
Realisticamente (5 Gb / s → 8 Gb / s)

Encoding piu' efficiente (8 / 10 → 128 / 130)

Prototipo su scheda di sviluppo per fine 2013



Tra gli obiettivi del progetto SUMA



Obiettivi del progetto:

Imparare a utilizzare i processori e i sistemi di nuova generazione in contesti tipici della comunita' teorica INFN, visto che prima o poi tutti li dovremo utilizzare....

Istallare un "large prototype" basato su questo tipo di processori

+ come workhorse di calcolo per l' INFN

+ come proof-of-concept di una futura macchina per il calcolo scientifico ad alte prestazioni

Il progetto premiale SUMA

Dopo un anno di esperienza →

*Provare a scommettere su una promettente struttura di macchina
E realizzare un “large prototype”*

E.g. 100 – 200 Tflops peak

Istallato al CINECA →

Ancora insufficiente per essere autosufficienti in LQCD ...

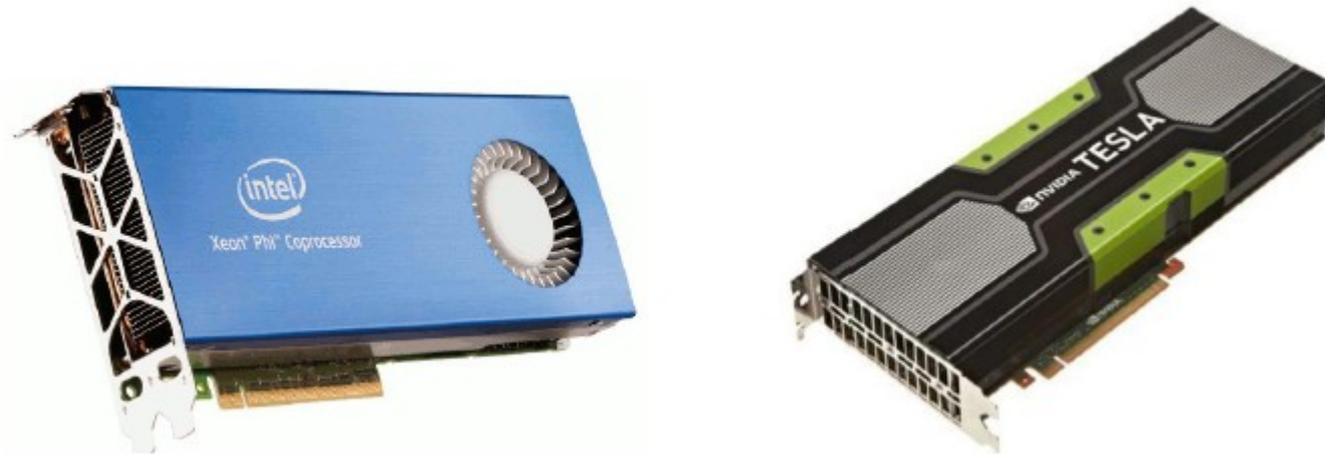
*... Ma del tutto sufficiente per uno studio sistematico di
algorithm development in LQCD*

+ Fluid-dynamics / Complex-Systems / Quantitative-biology....

Dal talk di un anno fa....

Guardiamo al prossimo futuro ...

Questo sembra essere quello con cui dovremo convivere ...



Guardiamo al prossimo futuro ...

1 core di calcolo: 10 → 15 → 50 Gflops

1 nodo di calcolo: 40 → 200 → 400 Gflops

*Un nodo di calcolo di “**prossima generazione**” ~ 2000 Gflops*

GPU (Nvidia) – MIC (Intel) - ?

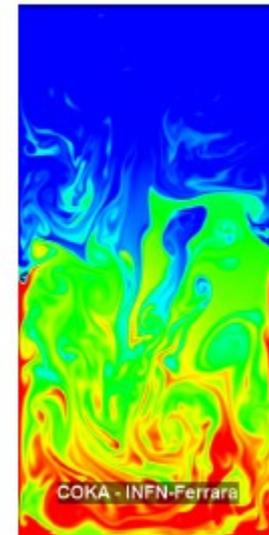
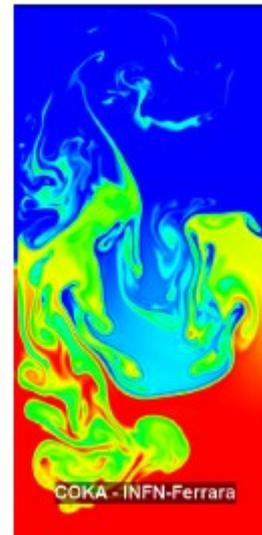
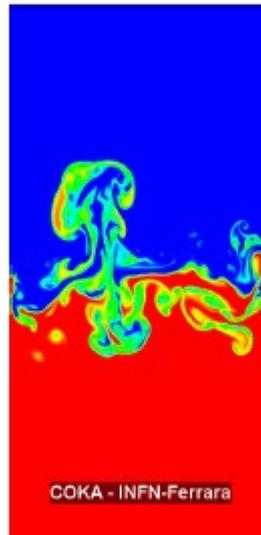
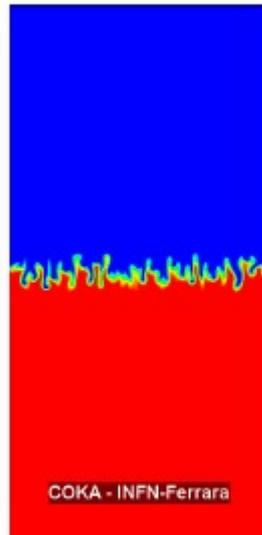
Grazie ad un sostanziale aumento del parallelismo del processore

Impariamo a usare queste bestie ...

Molte misure svolte utilizzando un programma di simulazione di fluidodinamica computazionale a la' Lattice Boltzmann (D2Q37)

Sufficientemente semplice per permettere test "arditi"

Sufficientemente complesso da essere un buon benchmark sia per il calcolo che per l'efficienza della memoria

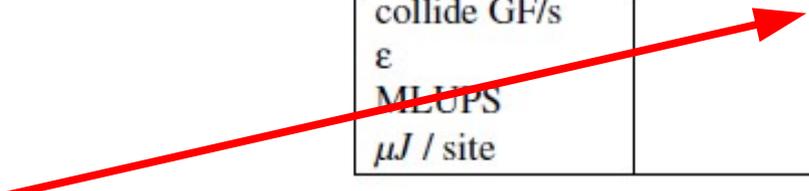


Impariamo a usare le GPU ...

La bottom line non e' pero' del tutto soddisfacente....

Un programma accuratamente ottimizzato su un acceleratore ha una performance ~ 3 volte migliore dello stesso programma accuratamente ottimizzato su un SB

	Intel dual E5-2680	Intel Xeon-Phi 7120X	Nvidia K20X
propagate GB/s	60	98	155
ϵ	70%	28%	62%
collide GF/s	220	362	565
ϵ	63%	30%	43%
MLUPS	29	54	64
μJ / site	8.96	5.55	3.67



- WP3 - Back of envelope estimates

La quantita' di calcolo scala come il volume, la comunicazione con l' area

Dunque se aumento il volume (a potenza di calcolo costante) i problemi di comunicazione diventano meno gravi

$$T_p = \alpha V \quad I \propto V^{2/3} \quad B \propto P/V^{1/3} \quad \leftarrow$$

... d' altra parte la memoria e' limitata: se aumento il volume per nodo devo aumentare le GPU dedicate a quel volume

$$B \propto P(V)/V^{1/3} \quad P(V) \propto V \quad B \propto V^{2/3} \quad \leftarrow$$

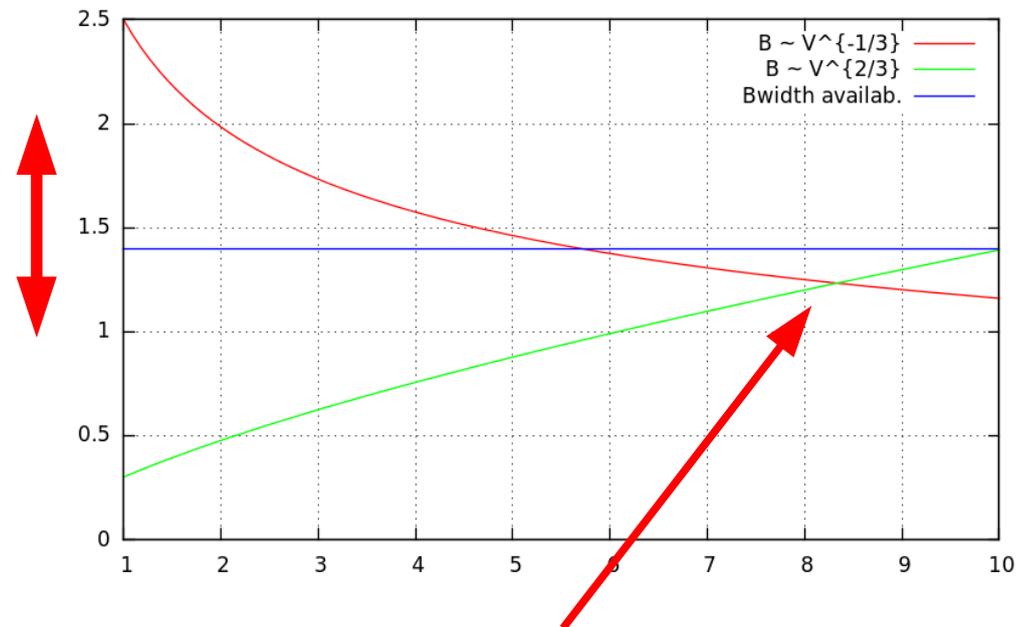
- WP3 - Back of envelope estimates

Esiste un range di volumi senza significativi colli di bottiglia????

Il livello della linea blu dipende dai dettagli del meccanismo di comunicazione

*Il Cross-over verde / rosso
Dipende dalla memoria
Disponibile sul nodo*

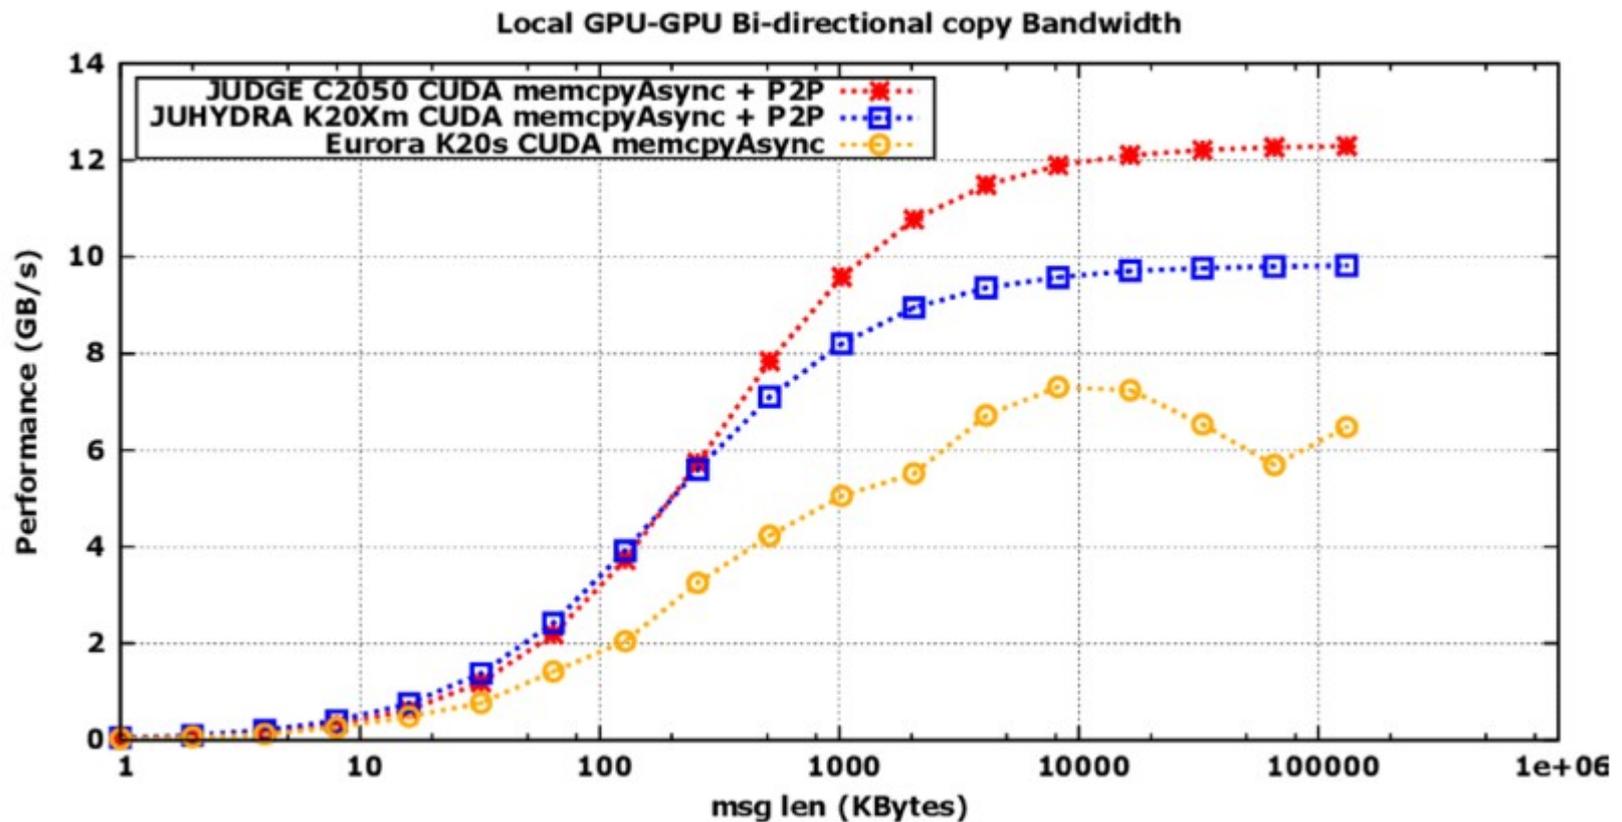
*La normalizzazione delle
Curve verde / rosso dall' algoritmo*



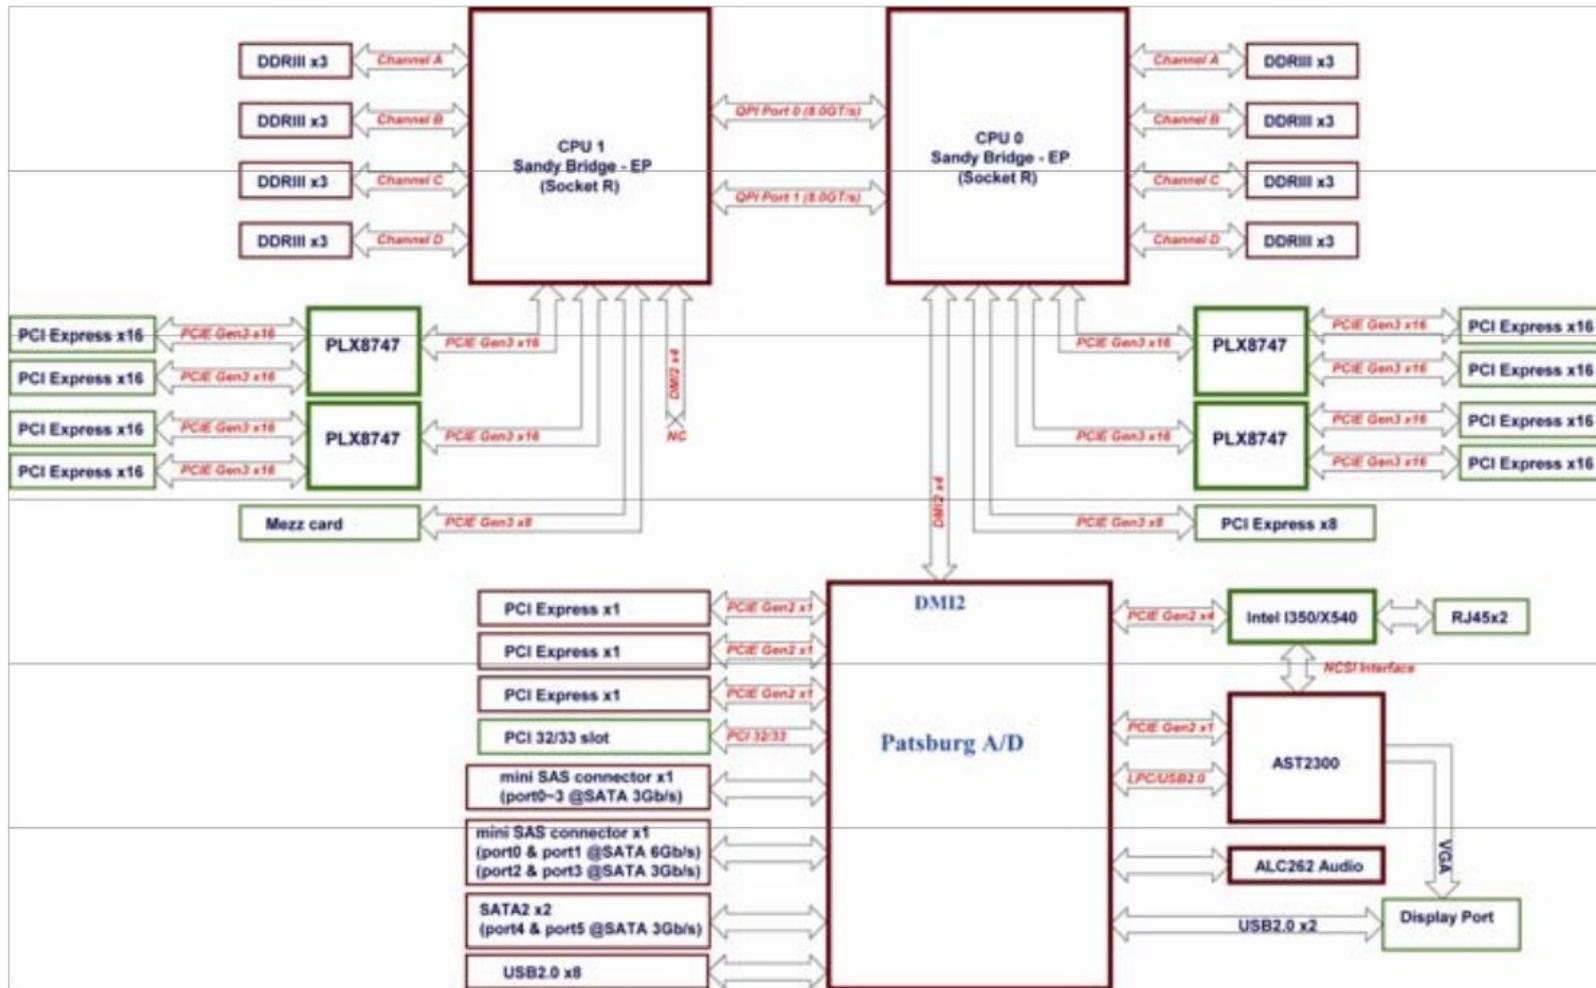
- WP3 -

Le risposte a queste domande non meno banali di come vengono di solito raccontate.....

Ad esempio:



Un "tipico" nodo di calcolo....



S7059 Block Diagram

A piu' tardi

Ipotesi CINECA

*CINECA quasi pronto per il procurement di una macchina
“Tier1” con:*

- “sufficienti aspetti di innovazione”*
- “potenza di picco accelerata ~ 1 Pflops” --->*

Che vuol dire!?

.

Ipotesi CINECA

CINECA quasi pronto per il procurement di una macchina “Tier1” con:

- *relativamente bassa “densita” di GPU (1 GPU per CPU)*
- *nodo con 2X:
processore Haswell (~ 400 Gflops) +
Nvidia K20 (1000 Gflops) → 2.8 Tflops nodo*
- *~ 360 nodi @ 5500 Euro/nodo*

Sulla base di queste stime

Ipotesi CINECA

Contributo aggiuntivo INFN (versione 1)

*- indicativamente 80 nodi addizionali → 224 Tflops picco
64 (CPU) + 160 (GPU)*

Confronto con BG/Q

1 core Haswell → ~ 4 core BG/Q

*80 x 2 x 8 x 4 x 24 x 360 ~ 45 Mcore hour (CPU) (x 1.4)
+ 120 Mcore(eq) hour (GPU) (x 1.4)*

Ipotesi CINECA

Contributo aggiuntivo INFN (versione 2)

*- indicativamente 120 nodi addizionali
SENZA GPU → 96 Tflops picco (CPU)*

Confronto con BG/Q

1 core Haswell → ~ 4 core BG/Q

120 x 2 x 8 x 4 x 24 x 360 ~ 65 Mcore hour (CPU) (x 1.2)

+ 50 Mcore / hour GPU [Cineca]))

Domande “rilevanti”

- 1) Confronto tra i tempi di installazione*
- 2) Confronto tra le potenze di picco*
- 3) Cosa sappiamo fare ORA con “poche” GPU*
- 4) Cosa sappiamo fare ORA con “tante” GPU*
- 5) Come cambiano le risposte alle domande di 3) - 4) tra 6 mesi*
- 6) Chi vuole fare cosa, perche' 5) sia diverso da 3) - 4)*

---->

- 7) Vogliamo un uovo oggi o una gallina un anno dopo*

Situazione budget

Assegni	570	366	204
Cluster Pi	140	140	0
Trasferte	105	5	100
Large P	500	0	500
Tech. Dev.	160	35	125
TOTAL	1475	546	929

- WP3 - Back of envelope estimates

Esiste un range di volumi senza significativi colli di bottiglia????

