

Il calcolo su larga scala

Dall'analisi dei dati genetici all'analisi del web

Luca Pireddu

CRS4—Distributed Computing Group



October 13, 2011

Mi presento

- Abito in Italia da 5 anni
- Sono nato e in gran parte cresciuto in Canada
- Sono un ricercatore al CRS4
- No, Pireddu non è un cognome tipico canadese; i miei genitori sono sardi al 100%!



- Ho studiato informatica in Canada
 - Laurentian University
 - University of Alberta

Da li sono partito nella mia carriera e dopo un po' sono arrivato qui da voi



O, più precisamente, al CRS4




- Centro per la ricerca applicata
- Particolarmente orientato all'informatica e le alte tecnologie
- Fondato nel 1990, in Sardegna
- Alcuni primati:
 - ha realizzato il primo sito web italiano
 - ha contribuito a creare il primo quotidiano sul web in Europa
 - ha contribuito a creare uno dei primi internet provider in Italia
 - prima laboratorio per il sequenziamento del DNA ad alta velocità in Italia
- Oggi principalmente ricerca l'applicazione dell'informatica a:
 - la biologia e medicina
 - le fonti di energia
 - la visualizzazione dei dati
 - la tecnologia/internet mobile
- Inoltre, possiede uno dei maggiori centri di calcolo in Italia

Introduzione al Calcolo su larga scala

In principio l'uomo creò un computer...

e vide che era cosa buona!

- Con il computer si elaboravano dati più velocemente che a mano
- Fino a 15-20 anni fa in genere si elaboravano quantità modeste di dati
- Di solito 1 computer o mainframe era sufficiente
 - e in molte situazioni questo è ancora vero!



- Da 15-20 anni c'è stata un'accelerazione importante della crescita della mole di dati da analizzare

Perché?

- In parte perché la tecnologia aumenta i limiti e propone nuove possibilità
- In parte perché abbiamo più fonti di dati o fonti più grandi
 - Internet! Viene letta interamente e ripetutamente
 - L'avanzamento della scienza (pensiamo al sequenziamento di genomi umani e al LHC al CERN)
 - Modelli meteorologici più dettagliati
 - Le varie carte fedeltà che ci danno i negozi
 - I dati raccolti dagli dispositivi informatici portabili (cellulari, sensori, lettori di codici a barre e RFID)
 - ecc.
- L'informazione è diventata un bene primario!

Ma quanti dati?

Il nostro PC a casa, se relativamente nuovo, potrà contenere circa:

- 20 giorni di video
- 50.000 foto

Un data center moderno può contenere dati a sufficienza per riempire:

- **un milione** dei nostri PC a casa
 - Almeno tutti i PC in Sardegna; forse di più!
- **decine di migliaia di anni** di video
 - Un documentario dalla fine dell'ultima era glaciale ad oggi!
- **decine di miliardi** di foto!
 - 1 foto ogni ha per l'intera superficie terrestre

Che fine farebbe un solo computer con tutti questi dati?

Che fine farebbe un solo computer con tutti questi dati?



- Questo è il fenomeno detto **Big Data**
- Lavorare con più dati spesso porta benefici
 - ricerche più accurate
 - analisi più sensibili
- Però ha il prezzo della sua complessità
 - In particolare, queste quantità di dati non sono manipolabili con strumenti tradizionali
 - Come risolvere?

- Quel che uno non riesce a fare da solo lo si può fare in tanti!
- Facciamo lavorare molti computer sullo stesso problema
- Ognuno può contribuire un po' e con la somma dei contributi arrivare all'obiettivo



Questo l'hanno fatto tante tante piccole termiti!


- Esiste un ramo di studio dedicato specificamente a come coordinare il lavoro di più computer

Calcolo Distribuito
in inglese,
Distributed Computing


...avrete sentito che

troppi cuochi rovinano il brodo!

- Lavorare assieme non è banale
- È necessario essere organizzati, altrimenti...



- Se invece coordiniamo bene



Quindi...

- Il calcolo distribuito è necessario per risolvere problemi di elaborazione di dati su larga scala.

Applicazioni del calcolo a larga scala

- Sicuramente avete visto, e forse usate giornalmente, prodotti di questo genere di tecnologia
- Conoscete qualcuna di queste aziende?





Google Oregon



Facebook Rutherford



Microsoft Dublin



Bank of NY Mellon

Anche il CRS4 ha il suo data center!



- 600 computer (≈ 4000 core)
- migliaia di dischi


- Queste macchine sono condivise da tutti i gruppi del CRS4
- Vengono usate per vari compiti, tra i quali:

L'analisi del DNA

- Anche grazie al lavoro del mio gruppo!

Tra i nostri progetti c'è Seal

- In origine il nome venne da SEquence ALignment
- Ora è un gruppo di programmi fatti per analizzare i dati prodotti dal sequenziamento del DNA
 - Come quelli prodotti dalla Dr.ssa Maria Francesca Urru
- A differenza dei programmi tradizionali, Seal è creato per il *calcolo distribuito*



Tra i vantaggi del nostro approccio:

- Maggiore velocità
- Miglior utilizzo delle risorse computazionali
- Minor attenzione richiesta dagli operatori
 - Tenete conto: più computer avete maggiore è la probabilità che uno si rompa!
- Oltre che al CRS4, Seal è attualmente in prova anche in centri di sequenziamento in Finlandia e Olanda
 - Fatto interessante: anche loro stanno facendo degli studi genetici simili a quelli che stiamo conducendo in Sardegna

Conclusione

Riassumendo...

- I problemi di larga scala (“Big Data”) non possono essere risolti con l’utilizzo di un unico computer
 - Tra i problemi di larga scala includiamo lo studio del DNA, della società su Internet, del meteo, dell’economia, ecc.
- Il calcolo distribuito consiste nel coordinare molti computer che lavorano assieme su un unico problema
- Il calcolo distribuito è necessario per risolvere i problemi di larga scala
- Usufruiamo dei risultati di calcoli di larga scala quotidianamente
- Al CRS4 lavoriamo anche su problemi di calcolo a larga scala con tecniche di calcolo distribuito, come l’analisi del DNA

Ringrazio. . .

- Massimo Mancini
- Greca Meloni
- Gli organizzatori della manifestazione
- Voi che mi ascoltate!

Grazie!

Ringrazio. . .

- Massimo Mancini
- Greca Meloni
- Gli organizzatori della manifestazione
- Voi che mi ascoltate!

Grazie!

Domande?