



# Computing / Data Science: Attività di ricerca tecnologica nel campo del calcolo scientifico

Daniele Spiga

# INFN Scientific computing facilities



# Computing, software and data science nella fisica: Partiamo dall'esempio di LHC



- Le particelle in collisione creano nuove particelle, i cui prodotti di decadimento fluiscono attraverso strati di rivelatori



Quindi...

Higgs boson-like particle discovery  
claimed at LHC

By Paul Rincon  
Science editor, BBC News website, Geneva



Come si passa da  
qui

A questo

# Da dove vengono i dati... e dove vanno ?



- I rivelatori producono segnali elettrici in risposta ai flussi di particelle
- Le informazioni provenienti da ogni parte del rilevatore vengono combinate per creare un riepilogo digitale dell "evento di collisione".

Ma poi ci sono anche i dati simulati dai ricercatori: "la verità MonteCarlo"

I segnali elettrici rilasciati dalle particelle negli apparati vengono digitalizzati e scritti su Hard Disk


# Quindi come si arriva ad una scoperta

Acceleratore ➔ Experimento ➔ Scoperta

Produce  
Dati



“Fotografa”  
Dati



Analisi dei Dati  
(Computing)  
Grid / Cloud  
Big Data



Oggi ci concentriamo su questo

Higgs boson-like particle discovery  
claimed at LHC

By Paul Rincon  
Science editor, BBC News website, Geneva



Cern scientists reporting from the Large Hadron Collider (LHC) have claimed the discovery of a new particle consistent with the Higgs boson.

# Cosa è stato fatto negli ultimi 20 anni.

La Grid:

“Coordinated resource sharing and problem solving in dynamic, multi institutional virtual organizations”

Ian Foster e Karl Kesselman

Dal punto di vista dell'utente:


- Io voglio usare le risorse di calcolo ogni volta che ne ho bisogno
- Non mi interessa chi è il proprietario o dove sono
- I miei programmi devono girare sulle risorse disponibili.

## The Worldwide LHC Computing Grid



# INFN Scientific computing facilities

- INFN ~ 10% of WLCG for 2017
  - 15-20% ALICE
  - ~13% CMS
  - ~7-10% ATLAS
  - ~10-12% LHCb




# WLCG A Success Story



# Quindi, è tutto fatto?


NO!! Per quanto riguarda l'evoluzione degli esperimenti al CERN si va verso HL-LHC.

- Questo significa un acceleratore più potente, e dei rivelatori capaci di immagazzinare più quantità di dati ( fare più fotografie )
- Questo pone nuove sfide di fisica ma porta sfide notevoli anche dal punto di vista della **mole di dati da immagazzinare e da processare**




# Quantifichiamo un pochino...

Punto di vista CMS:



Questo è il problema computazionale da risolvere




**CPU: 3x rispetto alla proiezione.**


- NOTA: questo conto non incorpora l'effetto degli acceleratori

**Esigenze disco: 2.5x rispetto alla disponibilità prevista**

# Ma NON solo CERN ed LHC, tanti altri esperimenti....



# Un po di numeri a confronto





# e non solo fisica... i dati eterogenei (Data Science)

ISTAT  
ISTAT Censimento  
ID (Dr. N. Caranci)  
Dati covid Regione Umbria  
ARPA Umbria

Partendo dai **dati RAW** raccolti e archiviati nel formato originale possiamo generare datasets integrati funzionali all'analisi

- primo dataset integrato per avviare la fase di "validazione" ed esplorazione


	City	Population	Density	Surface	Lattante	Prima infanzia	Seconda infanzia	Terza infanzia	Adolescenza	Primaadulta	Secondaadulta	Terza
0	Acquasparta	4611	57.0	81.61	48.0	22.0	150.0	222.0	484.0		1368.0	915.0
1	Allerona	1722	21.0	82.61	20.0	13.0	53.0	63.0		503.0	370.0	

Quarta	Quinta	TotaleEta	MediaEta	Depriv_idx	Depriv_cat	Covid	Deceased	MaxIntensiveCare	AvgIntensiveCare	
579.0	74.0	4570.0	47.441357	1.0	1	3	0.380952	2	1	0.027211
207.0	29.0	1724.0	48.408353	-1.3	41	2	0.262238	0	0	0.000000

mean_pm10_ug/m3_mean_2019	mean_pm10_ug/m3_std_2019	mean_pm10_ug/m3_median_2019	mean_pm10_ug/m3_mean_2020	mean_pm10_ug/m3_std_2020
16.183606	7.358666	14.376109	15.833302	6.970052
15.828832	7.167570	14.451391	14.905208	7.113094




# Intanto: l'evoluzione tecnologica



Cloud Computing

High Performance Computing  
- GPU, FPGA, PowerPC..



# Quindi, cosa si fa? Quali **settori** di ricerca?

Si fa ricerca tecnologica per testare e studiare

nuove infrastrutture di calcolo, come **Cloud e HPC** per costruire soluzioni di :

- **Analysis Facility, Datalake**

Si sviluppano di nuovi algoritmi per trovare soluzioni intelligenti basati su tecniche di:

- **Machine Learning** e quindi --> **Intelligenza artificiale**

Si integrano tecnologie per la gestione, il trattamento e l'analisi di dati eterogenei applicando soluzioni di :



- **Data Science**



Fornire una struttura a blocchi (i.e Mattoncini Lego) flessibile a livello PaaS, basata su standard aperti dell'industria per seguire il paradigma "service composition model"

- per supportare workflow scientifici su grandi quantità di dati (Big Data) sfruttando una Cloud ibrida

- ❑ User oriented
- ❑ Highly customizable
- ❑ Community agnostic




Fully compatible with Cloud  
orchestrator engines, such as the  
INDIGO-PaaS Orchestrator

# Il Data Lake

**Integrare e rendere disponibile una piattaforma “open” e generica (riutilizzabile):**

- Integrazione di dati da sorgenti informative multiple
- Processamento ( analisi descrittiva, predittiva e real time)
- Federazione di risorse di calcolo attraverso la tecnologia abilitante di INFN-Cloud





# Intelligenza Artificiale

Per risolvere questo



Progetto per creare un sistema di cache intelligente tramite l'utilizzo di algoritmi di IA nel contesto dell'esperimento CMS:

- L'IA manipola la memoria della cache, decidendo cosa scrivere o cancellare
- Il risultato che si vuole ottenere è quello di avere un algoritmo che usa meno risorse di storage in confronto agli algoritmi classici (LRU, LFU, etc..), mantenendo performance comparabili



# Analysis Facility per Data Science

- Analisi interattiva tramite notebook jupyter
- Utilizzo di tecnologie standard per l'attuale approccio all'analisi dati in ambito "data science"




"software di CMS sempre più pythonico"  
quindi perfetto per questo approccio..








# Analisi dati eterogenei con tecniche di Data Science

Integrare e rendere disponibile una piattaforma “open” e generica (riutilizzabile) per

- Integrazione di dati da sorgenti informative multiple, Processamento, Federazione di risorse attraverso soluzioni di INFN-Cloud



# Esempio: Covid-19 e inquinamento in Umbria



a Magistrale

# Riassumendo quali attività di tesi:

Il Calcolo Scientifico offre molte opportunità di ricerca in settori all'avanguardia. In particolare a Perugia:

- **Cloud Computing:**
  - Sviluppo di servizi per l'analisi dei dati ad LHC
  - Integrazione di HPC nel modello di calcolo di CMS
  - Sviluppo di soluzioni di Data Lake per la gestione di dati eterogenei
- **Intelligenza Artificiale:**
  - Sviluppo di sistemi intelligenti per la gestione dei bigdata
  - Sviluppo di algoritmi per l'ottimizzazione della selezione dei dati nella fisica di CMS
    - signal vs background discrimination for Vector Boson Scattering same sign WW with hadronic tau decay
- **Data Science:**
  - Progetto PLANET per lo studio dell'associazione Covid-19 e Inquinamento Atmosferico

Contatti [daniele.spiga@pg.infn.it](mailto:daniele.spiga@pg.infn.it)