



Financiado por
la Unión Europea
NextGenerationEU



GOBIERNO DE ESPAÑA

MINISTERIO
DE CIENCIA, INNOVACIÓN
Y UNIVERSIDADES

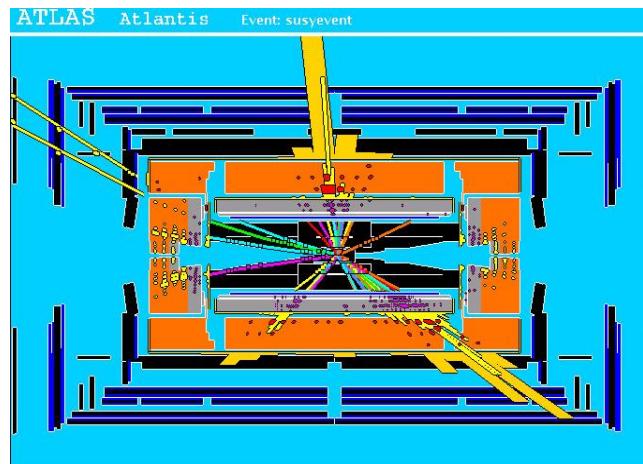


Plan de Recuperación,
Transformación
y Resiliencia

GENERALITAT
VALENCIANA
Conselleria de Educación,
Universidades y Empleo

GVANEXT
Fondos Next Generation en la Comunitat Valenciana

La Computación (i y el software !) en la era del LHC



Dr. José F. SALT CAIROLAS
Profesor de Investigación CSIC
Instituto de Física Corpuscular
(Jose.Salt@ific.uv.es)



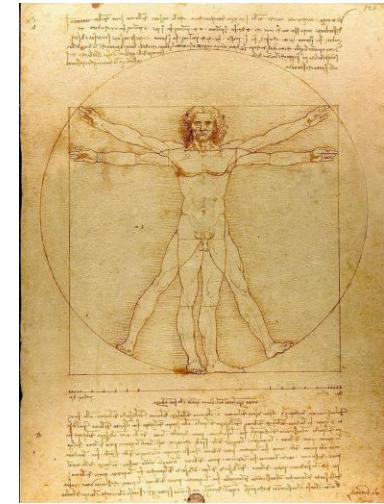
Contenido

- 1) Introducción: Física y Computing**
=> Un poco de historia
- 2) El Problema de la Computación y los Datos en el LHC**
- 3) La Solución al problema: las Tecnologías GRID**
- 4) El Modelo (Dinámico) de Computación de ATLAS**
- 5) El Tier-2 Español de ATLAS**
- 6) El GRID y el Higgs**
- 7) Retos de Computación en el futuro.**
- 8) Mensajes a retener/Conclusiones**

1- Introducción: Física y Computing

- **Físico Experimental (perfil amplio de un físico)**

- Hardware,
 - constructor de detectores, R&D
 - Calibración, Performance, Análisis de datos de los detectores
 - Software
 - Análisis de datos (Physics Analysis) y su interpretación
 - Especialista en MC /Simulación
 - Computing
 -



- **La computación:** La tecnologías de la Información y las comunicaciones son pieza fundamental en muchas actividades. En la Ciencia su papel es esencial para la obtención de resultados

```

EEy+o<UTBX
PaR2O4>as
q+sF12? LF
c 0**U10q k
F -e-CJH Z x 0 3
q FR+t+5 z qed
l UxJ+3 LNL
A g+8TBU+ kvl7 2U
)1+upV6Y
-r3rh =g n471 Iy
lo/t H : ss- T*
(5tc H en- 6g
+v+s: k ? , 4B
vPwpD +6K P1B
L8 N YZ? n4? 2zpp
1V X 91= 9 (p
-c 4 B C2T[9<udd
UC H q!0zxt sH E
B8 N j l p1T+>
-5X B 5 1990> zp0
CQI X K "x+hdz po
T+I q : npS8Ch+
K- x 1*5&|JU

```

El origen (?)

- Física y Computación: confluyen en los años 30 y 40 del pasado siglo
- Un aspecto muy importante: la aparición de las Técnicas de Simulación (Monte Carlo) a partir de la concentración de científicos en Los Álamos cálculo de secciones eficaces, etc



• Modelo Matemático de Implosión



John Von Neumann

Stanislaw Ulam

- Los físicos y matemáticos pioneros y visionarios:
 - Von Neuman, Ulam, Metropolis--- Fermi, Wigner, ...



Nicholas Metropolis



E. Fermi



R.P. Feynmann

- Feynmann y la Informática Cuántica:
 - Charla en 1981, 'Simulating Physics with Computers' -> Propone el uso de fenómenos cuánticos para realizar cálculos computacionales (dada la naturaleza de complejidad de los cálculos)- Ordenador Cuántico

Evolución Computing Distribuido

- **Agregación de recursos:**
 - Sistema SHIFT (“granjas” RISC Unix, L.Robertson, CERN)
 - Clusters de PCs (Sistemas Beowulf, “fábricas” de PC...)
- **Recursos distribuidos compartidos:**
 - Sistema Condor (M.Livny)
 - gestión de tiempo inactivo en sistemas Linux de la red local
 - Red Entropía, Programa SETI@home
 - Sistemas “Peer to Peer”
- **Aparición de la Web:**
 - 1989: primera propuesta, CERN, Tim Berners-Lee y Robert Cailliau
 - Primeros servidores web en laboratorios de Física europeos
 - 1991: un prototipo del sistema WWW suministrado para la comunidad de HEP



Les Robertson, left, accepted on behalf of CERN



SETI@HOME
Needs your Help
Donate to SETI@home

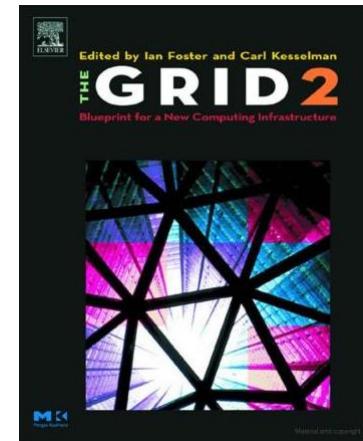


Tim Berners-Lee

Robert Cailliau



- **1995: Supercomputing '95**
 - Experiencia I-WAY: 17 centros USA conectados a 155Mbps
 - Primeras iniciativas Grid:
 - NASA Information Power Grid
 - Iniciativa de la NSF con los centros NCSA y SDC
 - Advanced Strategic Computing Initiative (DoE)
- **La era de los clusters/granjas/fabricas de PCs**
 - Nodos con CPUs (duales)
 - Disco local + acceso a servidores (NFS-NAS, AFS)
 - Limitación:
 - Interconexión de red: Gigabit casi popular, pero Latencia baja requiere Myrinet o similar, solución mas costosa
 - Perfectos para HTC (High Throughput Computing)
 - Las aplicaciones HPC (High Performance Computing) necesitan adaptarse:
 - La memoria no está compartida
 - Las herramientas: PVM, MPI
 - Instalación y control: funciona bien para cientos de ordenadores “homogeneos”



La ‘Biblia’ del GRID



‘Granjas’ de ordenadores



- ... Y además de forma distribuida mediante la conexión de clusters
 - Gracias a la interconexión de la Red
 - Llegar a obtener la sensación de que trabajamos con un Superordenador formado por varios clusters de ordenadores (Metacomputación)

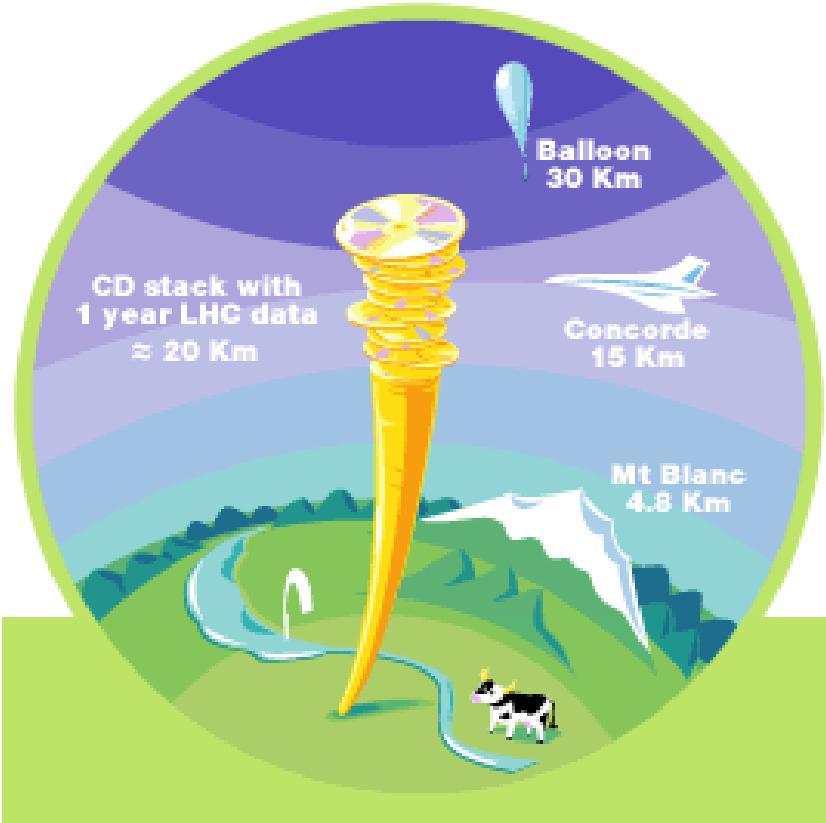


2- El Problema de la Computación y los Datos en el LHC



- La infraestructura computacional del CERN **NO** era suficiente para procesar todos los datos

- Se necesitaba un sistema ‘robusto’: que haya redundancia, sin ‘únicos puntos de fallo’



Los 4 experimentos del LHC:
Europa: 267 institutos, 4603 usuarios
Resto mundo: 208 institutos, 1632 usuarios

Tecnologías Computación GRID



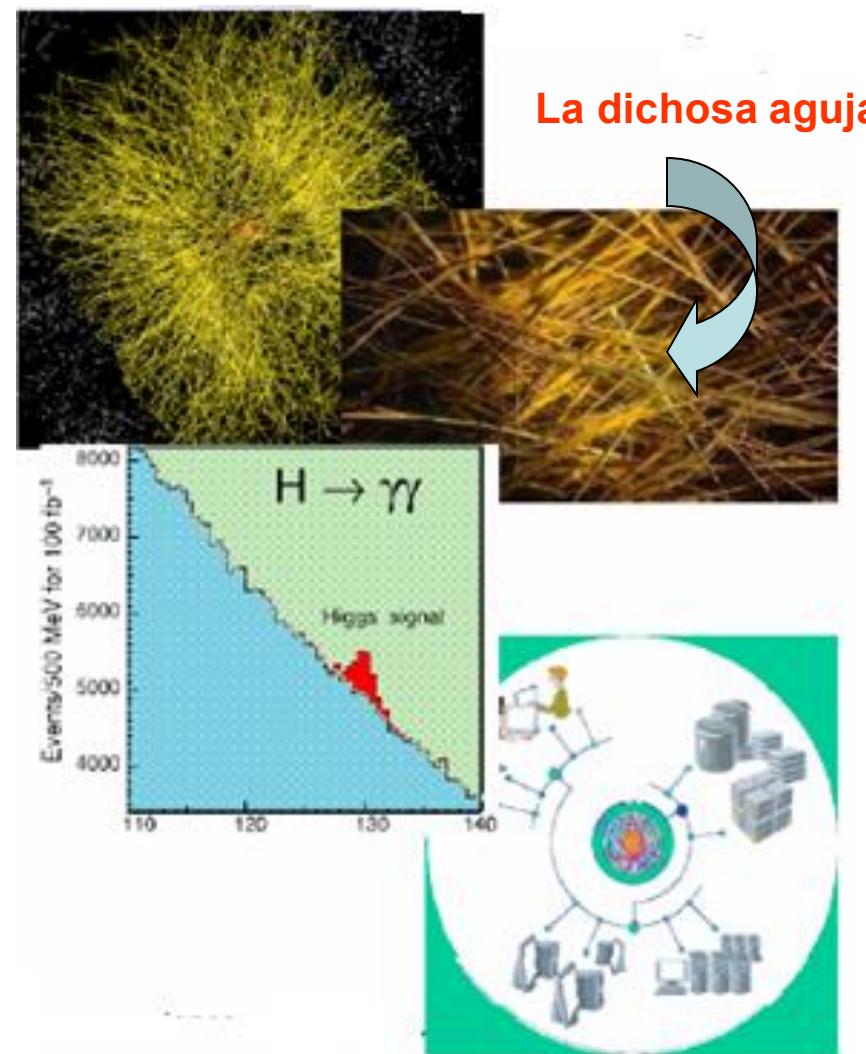
3.- La Solución al Problema: las Tecnologías GRID

¿Qué es la Computación GRID?

- **Definición:** la computación GRID es una evolución de la computación distribuida: su base está en tecnologías que permiten a las organizaciones compartir recursos informáticos para hacer frente a diferentes tipos de necesidades . En general, dichos recursos están dispersos geográficamente y conectados por Internet pero dicha red proporciona la impresión de estar trabajando con un único sistema informático virtual
- intenta resolver problemas actuales de la Sociedad de la Información:
 - Acceso rápido a bases de datos/almacenamiento...
 - Proporcionar su procesamiento y análisis utilizando potencia de cálculo distribuida y potentes facilidades de visualización...
 - Mediante la utilización de la red (Internet)

Las Tecnologías de la Información nos ayudan a ‘buscar una aguja en un pajar’

- La Señal es extremadamente baja (**1 sobre 10 billones de colisiones**)
- Volumen de datos:
 - (Frecuencia alta) *(gran número de canales) *(4 experimentos) = **15 PB de nuevos datos/año**
- Potencia de cálculo:
 - (Complejidad de sucesos) *(número de sucesos) *(miles de usuarios)=
100 K de los CPUs más rápidos actuales
45 PB de almacenamiento de disco (Simulación +Análisis)
- Análisis y financiación mundial:
 - Financiación local de recursos de computación en los principales países y regiones



Simil del GRID Computacional con la Red Eléctrica

Red Eléctrica

- Plantas de producción de electricidad



- Distribución jerárquica del flujo eléctrico



Subestación Eléctrica →

- Tendidos eléctricos



- Usuario final: acceso a las prestaciones de la electricidad



• GRID Computacional

- Grandes centros de almacenamiento de datos/potencia de cálculo

(Supercomputador/GranCentro de Cálculo)

- Distribución jerárquica (Centros de cálculo medianos)



- Red Internet

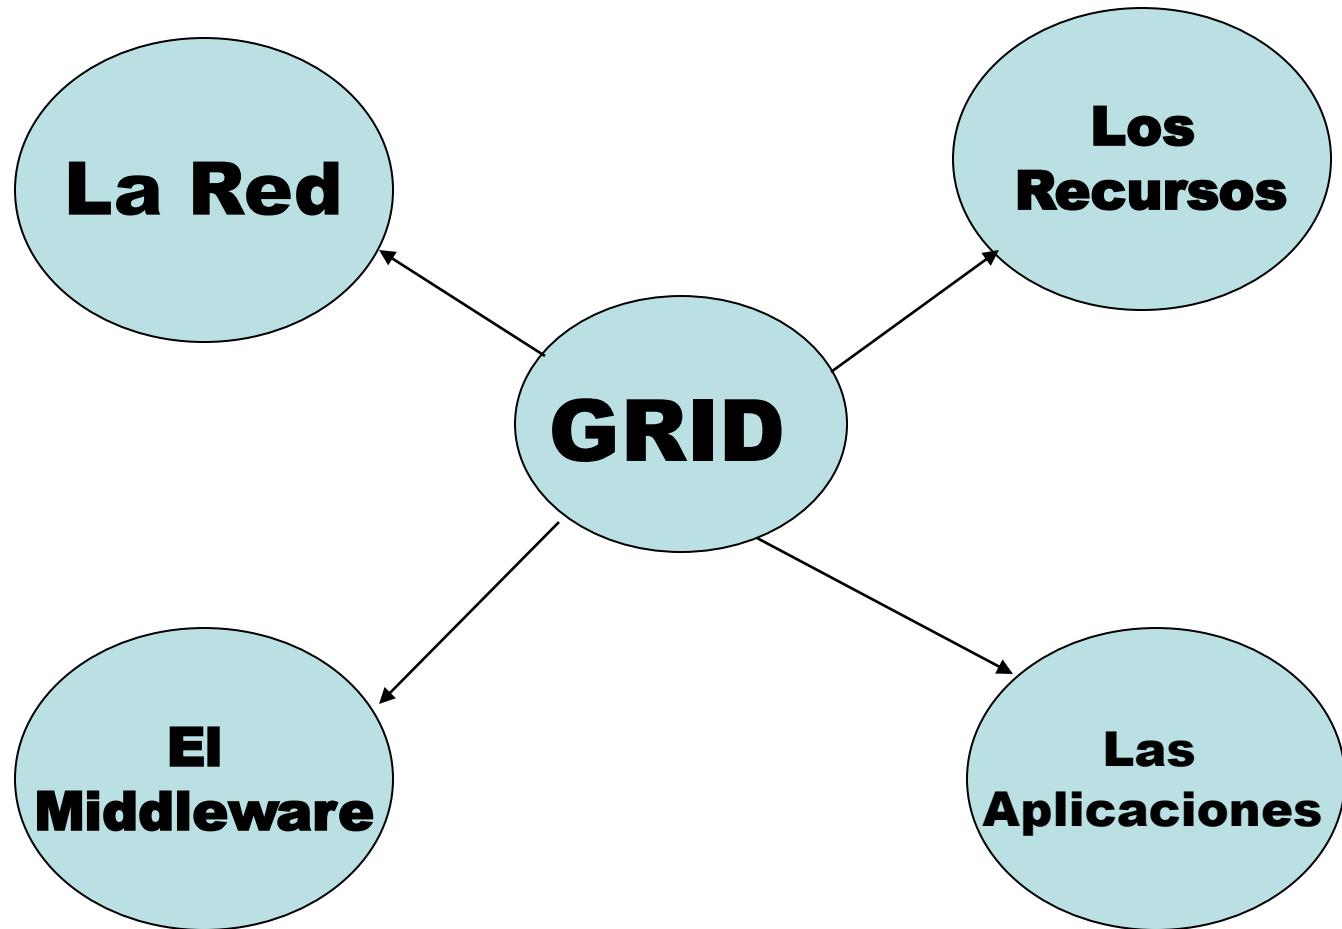


← Ramo de fibras ópticas

- Usuario Final: acceso a las prestaciones informáticas



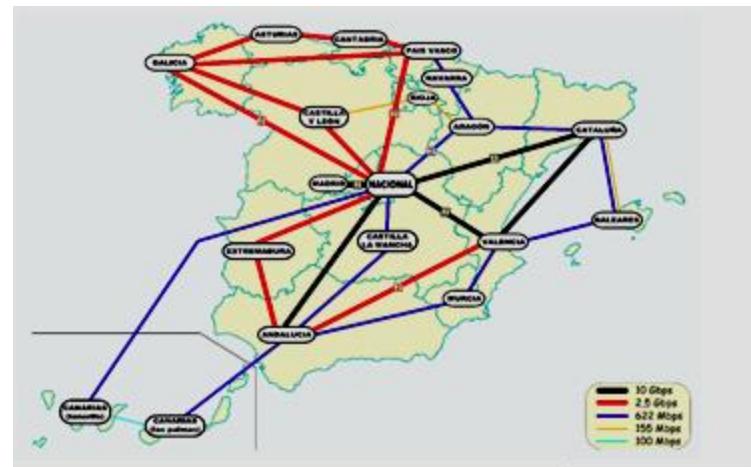
Ingredientes fundamentales del GRID



La Red: las autopistas de la Información

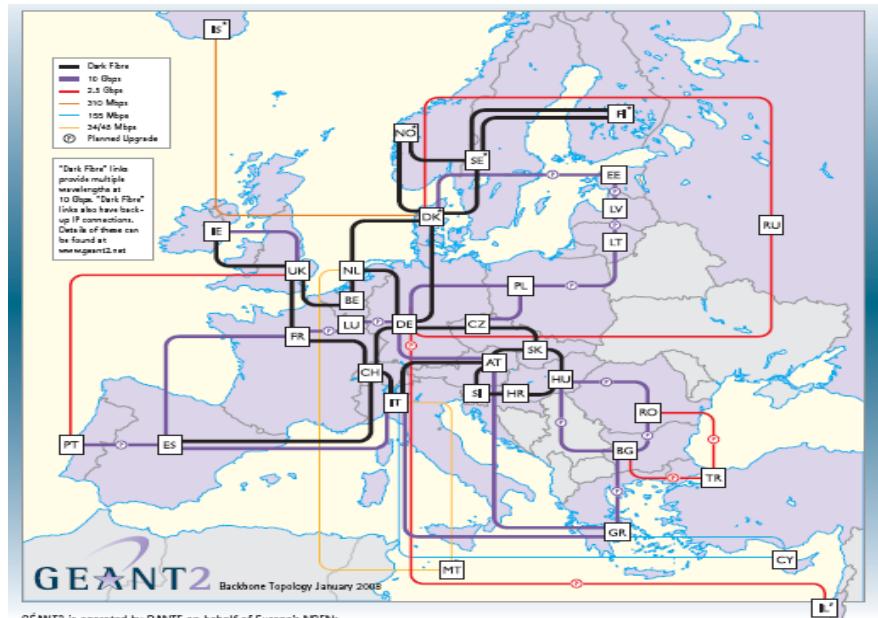


RedIRIS



Mapa de la Infraestructura de la Red en España (RedIRIS)

- El GRID no podría desarrollarse sin una Red apropiada.
- Responsable de asegurar los recursos que forman el GRID
- Comunicación
 - Protocolos de Internet: IP, DNS, routing, etc.
- Gran esfuerzo a nivel Europeo (DANTE y NRENs) y Español (RedIRIS)
- Constituyen **las Autopistas de la Información**

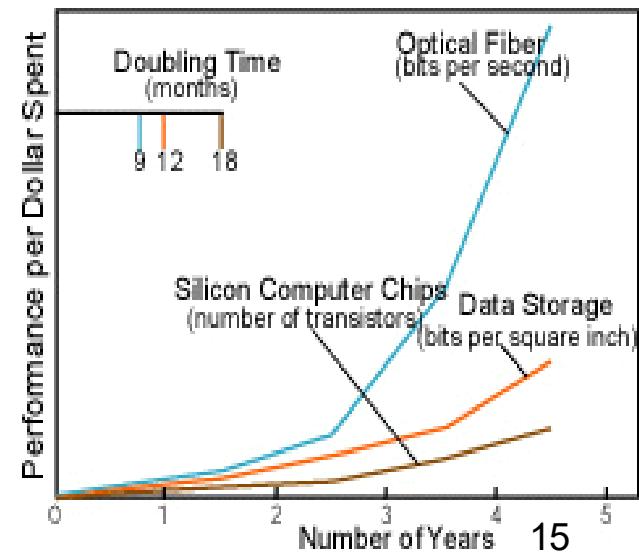


La RED Académica y de Investigación Pan-europea

Los recursos: Las Infraestructuras

Evolución tecnológica

- **Hardware**
 - Procesadores...cumplen la ley de Moore: se **duplica cada 16-18 meses !**
 - Nodos de computación:
 - PCs y portátiles, Estaciones, Servidores, Clusters, Blades
 - Almacenamiento: **se duplica cada 12 meses !!**
- **Mejora de la Red:**
 - la capacidad de la red **se duplica cada 9 meses !!**
 - 10 GB ethernet
- **Coste tiene en cuenta muchos factores:**
 - Espacio, alimentación eléctrica, mantenimiento
- Tendencia al ‘Commodity Computing’ : adquisición de sistemas de diferentes compañías (vendedores), incorporan componentes basados en standards ‘abiertos’

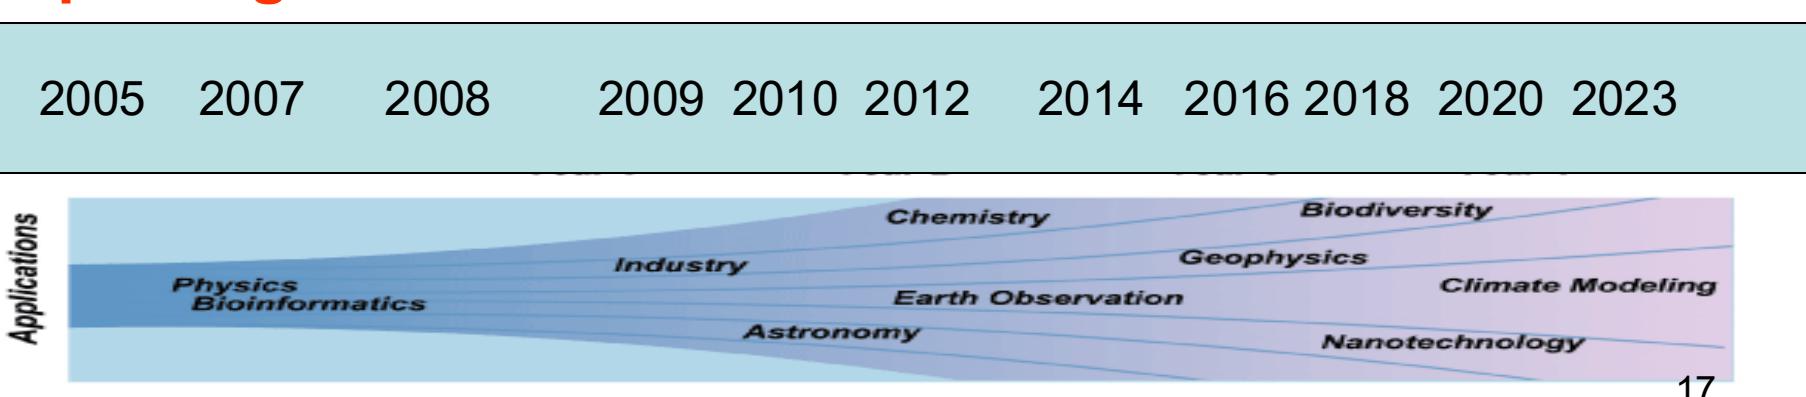


¿Qué es el Middleware?

- **es un software de conectividad que ofrece un conjunto de servicios que hacen posible el funcionamiento de aplicaciones distribuidas sobre plataformas heterogeneas.**
- **nos abstrae de la complejidad y heterogeneidad de las redes de comunicaciones subyacentes, de los sistemas operativos y lenguajes de programación,**
- **Finalidad: ‘virtualizar’ los recursos de computación’**

Las Aplicaciones

- Algunas disciplinas científicas se han organizado durante las décadas pasadas en grandes colaboraciones científicas que agrupan una gran cantidad de científicos al ser la única manera de alcanzar logros de alto nivel que no sería viable con grupos de trabajo reducidos
- resolución de retos tecnológicos importantes (ejemplo: experimentos del LEP, Proyecto Genoma, etc)
- En aspectos computacionales y tecnologías de la información, se ha evolucionado y ha desembocado en el paradigma GRID.

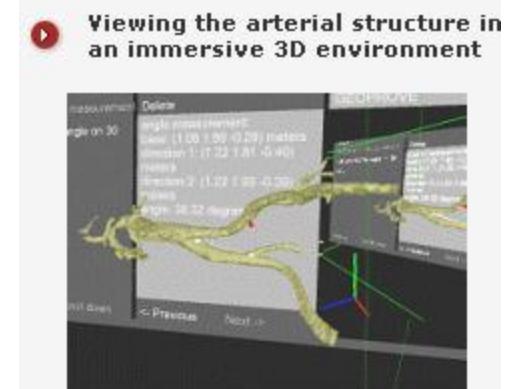
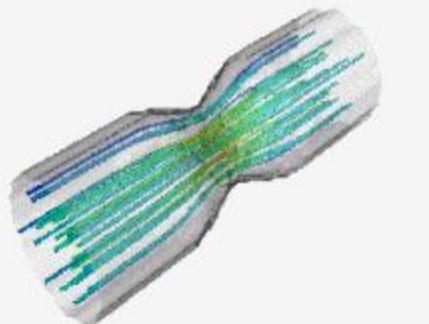


El GRID aplicado a enfermedades vasculares

- Dos procedimientos: stent y bypass
- El cirujano se ayuda con imágenes 3D obtenidas con scanners CT y MRI
- Las simulaciones de una posible intervención ayuda a la toma de decisión por parte del médico



El GRID permite lanzar los cálculos pertinentes. Se utilizan los recursos de los centros que participan en el proyecto (CROSSGRID)



Investigación coordinada por la Universidad de Amsterdam y con la colaboración del CSIC y de todos los centros de CROSSGRID

4.- El Modelo Dinámico de Computación de ATLAS

- El proyecto de Computación GRID para el LHC (WLCG) comenzó en 2002:
 - Fase I (2002-2005): test y desarrollo, construcción y prototipo de servicios
 - Fase II (2006-2010): despliegue inicial de los servicios GRID
 - Fase III (2011-2022): consolidación de servicios, ampliación a otros paradigmas de computación
- Propósito: Suministrar los recursos de computación necesarios para procesar y analizar los datos recolectados por los experimentos del LHC

Enormes volúmenes de datos y capacidad de computación

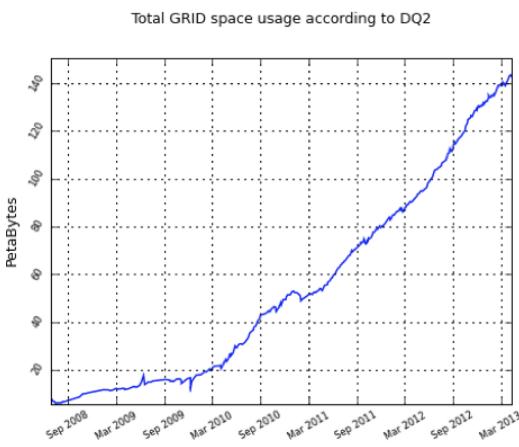
- 15 PB/año (Raw) -> 50 PB/año (overall)
- Vida Util: 10-15 años -> escala del Exabyte

Reto de la Escalabilidad

- Resulta evidente que se necesita una infraestructura distribuida

Logros:

- CMS: ha transferido 100-200 TB/día por el GRID en los últimos dos años
- ATLAS: se han acumulado 140 PB durante el procesado de datos del Run I



Organización de centros de recursos en ATLAS: Tiers

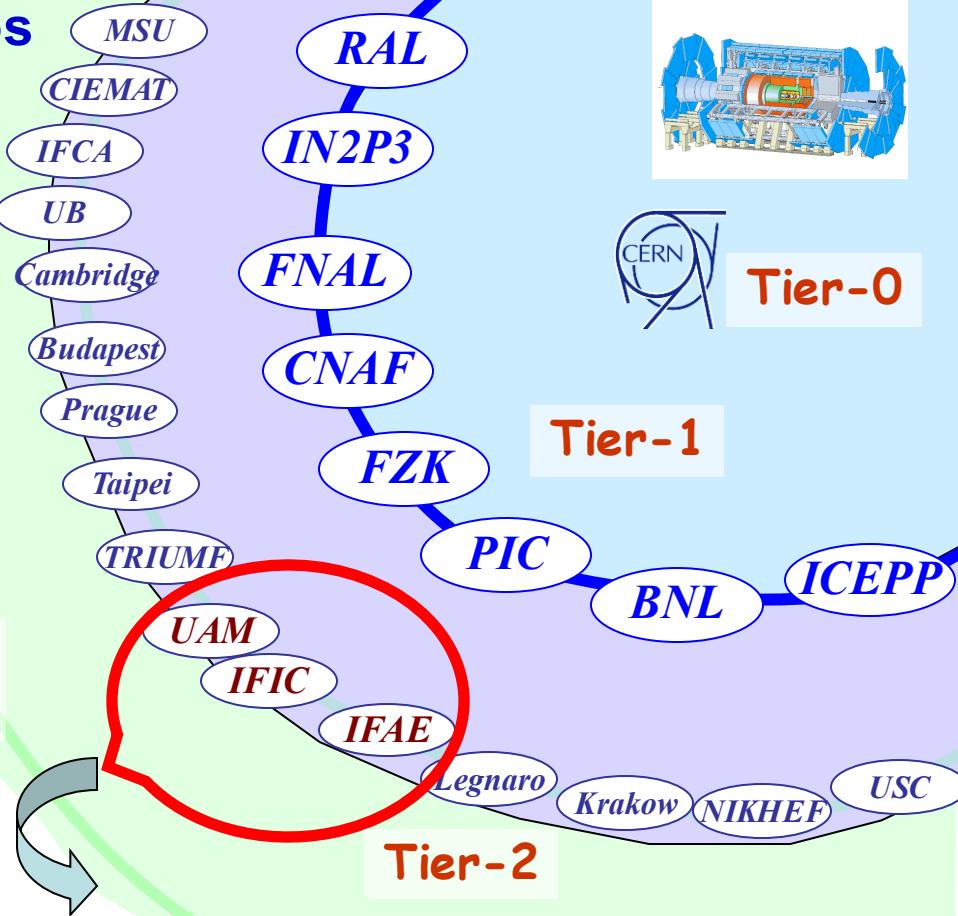


desktops
portables

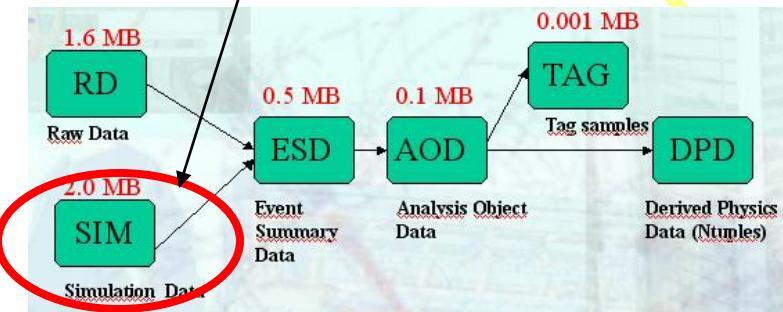
Tier-3

small
centres

Tier-1



asegurar un crecimiento sostenible
de la infraestructura Tier-2 entre
estos centros y su operación de
forma estable



Proceso de transformación de los datos



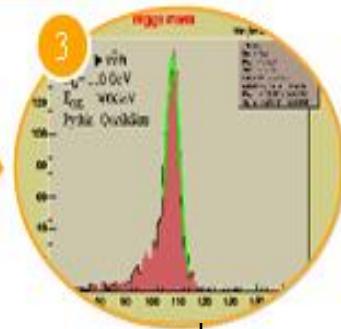
Datos de ATLAS 'brutos'

Proceden directamente del experimento (después del 'trigger') ubicados en el CERN, serán procesados y pasados a los Tier-1 (1.6MB/colisión)



Datos procesados

Proporcionan información clara de trazas y valores de energía registrada por los detectores del experimento ATLAS. (500KB/colisión)



Datos listos para analizar

Provenientes de los datos procesados, servirán para descubrir nuevas partículas por los científicos de ATLAS. (100KB/colisión).



- Los datos sufren transformaciones encaminadas a la reducción en tamaño y la extracción de la información relevante

En el mundo....

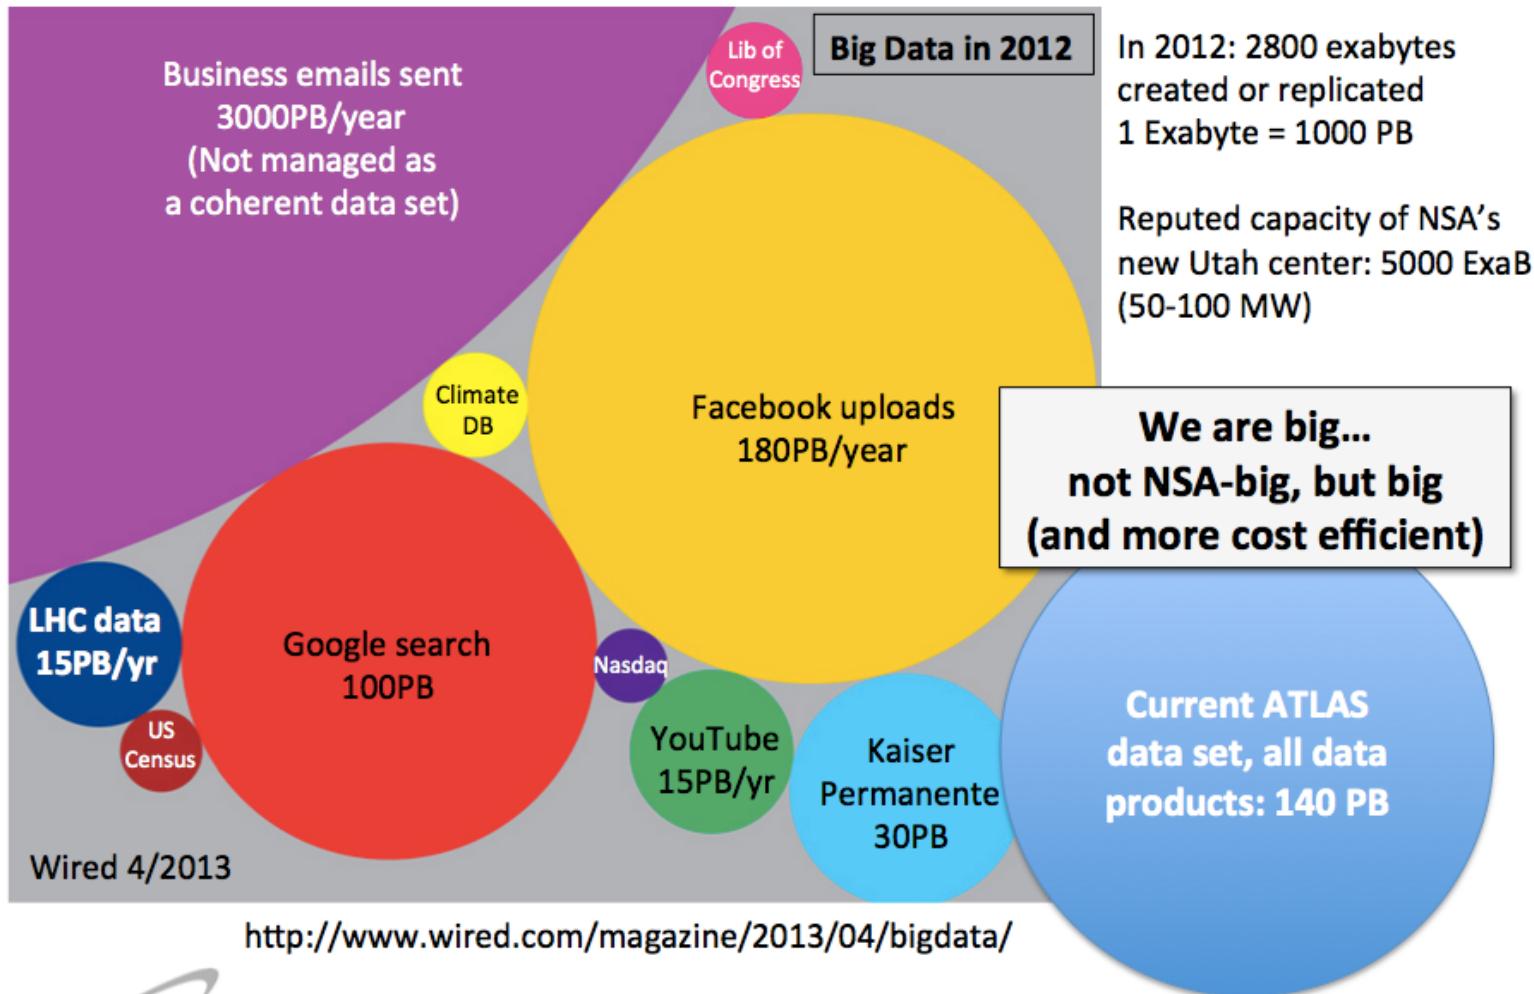


15:

**El GRID: “Un despliegue colaborativo donde no se pone nunca el Sol”
(‘round the clock’: 24 h / 24 h)**

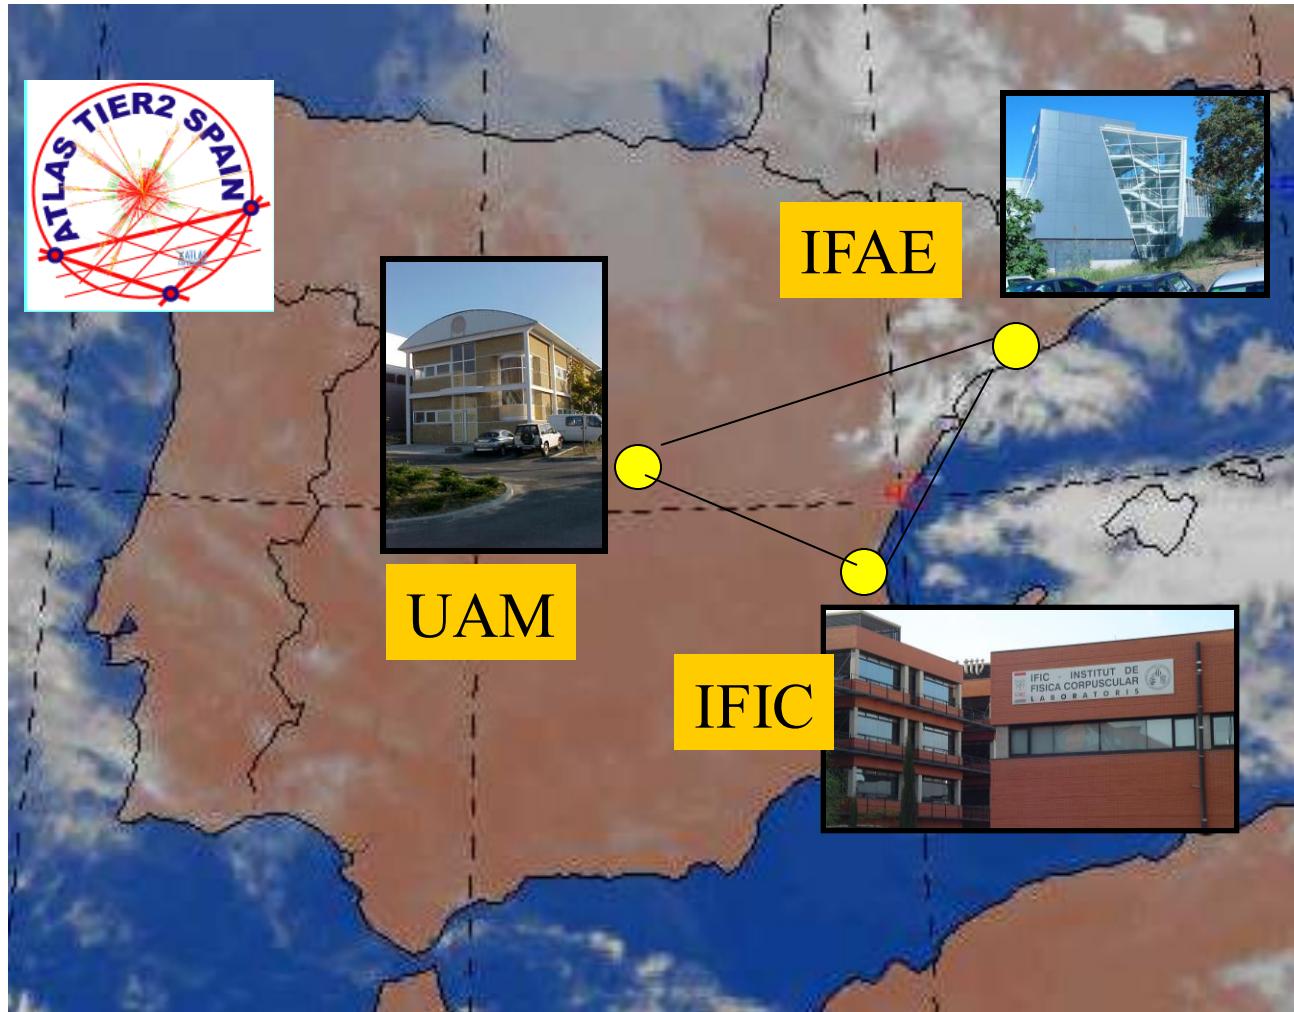
Data Management

Where is HEP in Big Data Terms?



5.- El Tier-2 Español para ATLAS

Proyecto Coordinado del Plan Nacional de FAE de 3 centros:



IFAE (25%)
UAM (15%)
IFIC (60%)
4% del total

Tier-2

Equipamiento:

IFIC
CPU = 41.298. HEPSpec06
Disk = 4.032 TB

Recursos Humanos:

10 FTE

Julio 2023

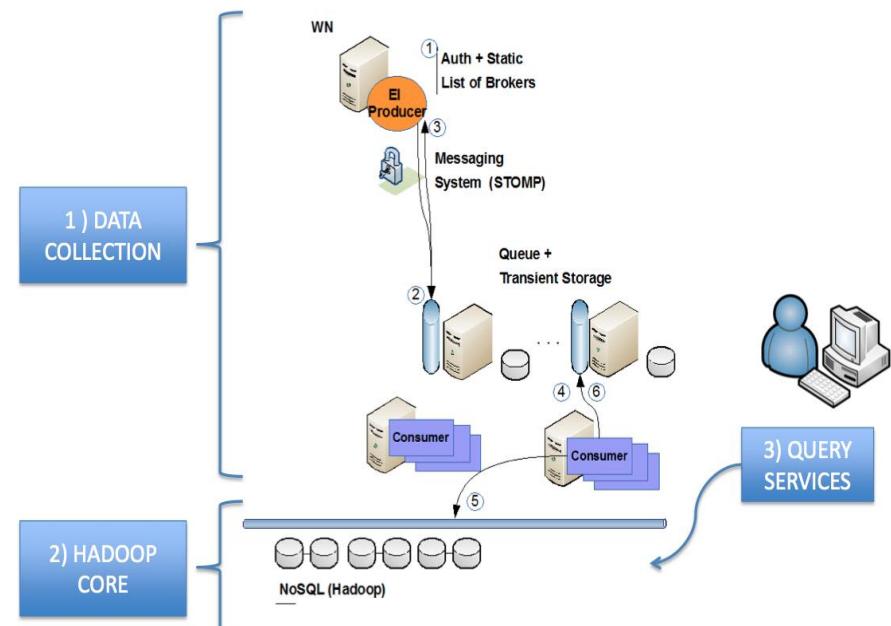
Desarrollo del Event Index de ATLAS

- Desarrollo y despliegue de un catálogo completo de todos los sucesos de física (Real Data y MC) para todas las etapas de procesado

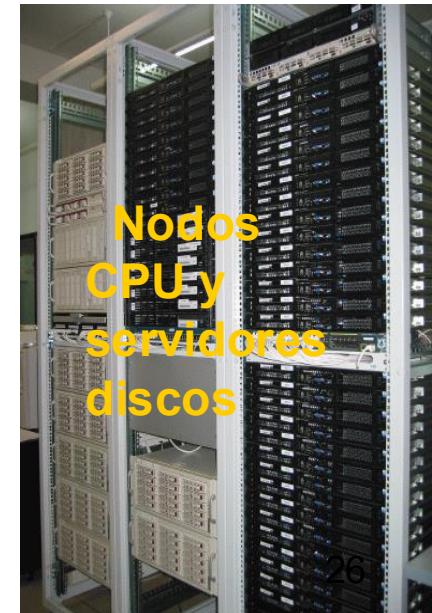
- Uso de nuevas tecnologías de Big Data y NoSQL (Hadoop)

- Alta participación del grupo IFIC:
 - Responsible of Data Collection Task.

- Responsabilidad en la tarea de Data Collection
- Ayuda en las verificaciones de consistencia en la producción global de datos



Evolución del Crecimiento de los recursos de TIER-2 para el experimento ATLAS

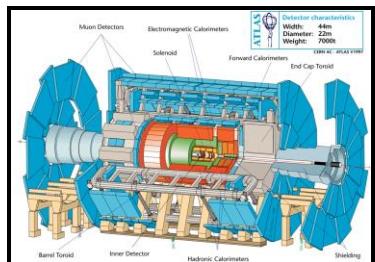


6- El GRID y el Higgs

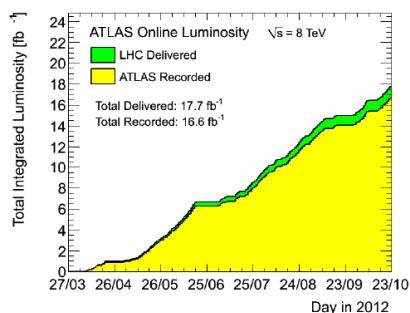
- Los resultados de Física son comparaciones de observables con sus predicciones teóricas/modelo
- Hay un proceso complejo entre la toma de datos y los resultados de física: Trigger/adquisición de datos, reconstrucción , análisis y simulación, grupos de análisis, publicación de resultados.
- Se necesitan algoritmos sofisticados para reconstrucción y análisis
- Uno de los factores más esenciales es disponer de una buena simulación detallada
- Un solo suceso tiene un determinado tamaño y ‘simple’, pero la escala de computación es enorme
- El software y el computing deben funcionar muy bien si se quiere lograr los resultados de primer nivel en el LHC

La computación GRID posibilita la obtención rápida de resultados de física : Un Caso Exitoso

1) Desde el experimento a 100 m bajo tierra...



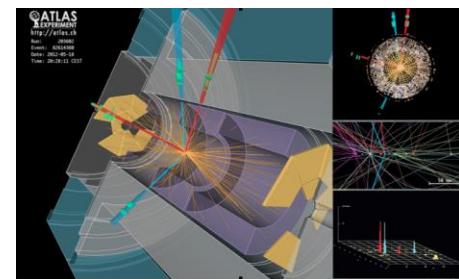
2) ... una ingente cantidad de datos es almacenada, procesada y distribuida...



3) ... por todo el mundo mediante la red y usando el GRID; en aproximadamente 2 horas los sucesos están disponibles en los centros de GRID.



4) ... y el análisis final de los sucesos seleccionados (como el suceso Higgs representado en la figura) se realiza por los grupos de física ...



5) ... y (a veces) ocurre un final feliz de la historia (2012)

Higgs boson-like particle discovery claimed at LHC

COMMENTS (1665)

By Paul Rincon

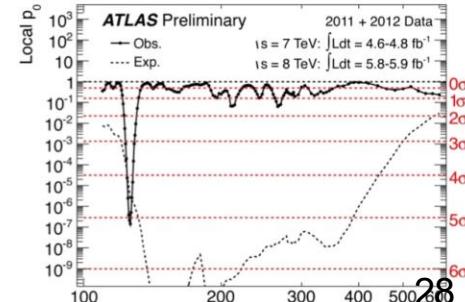
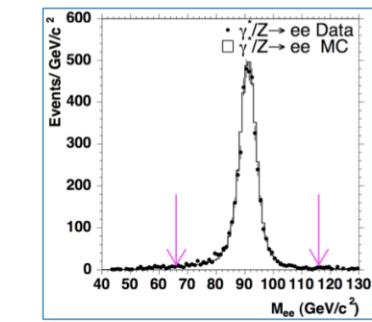
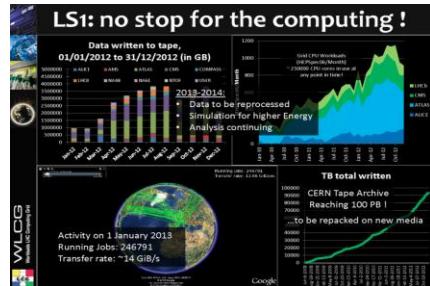
Science editor, BBC News website, Geneva



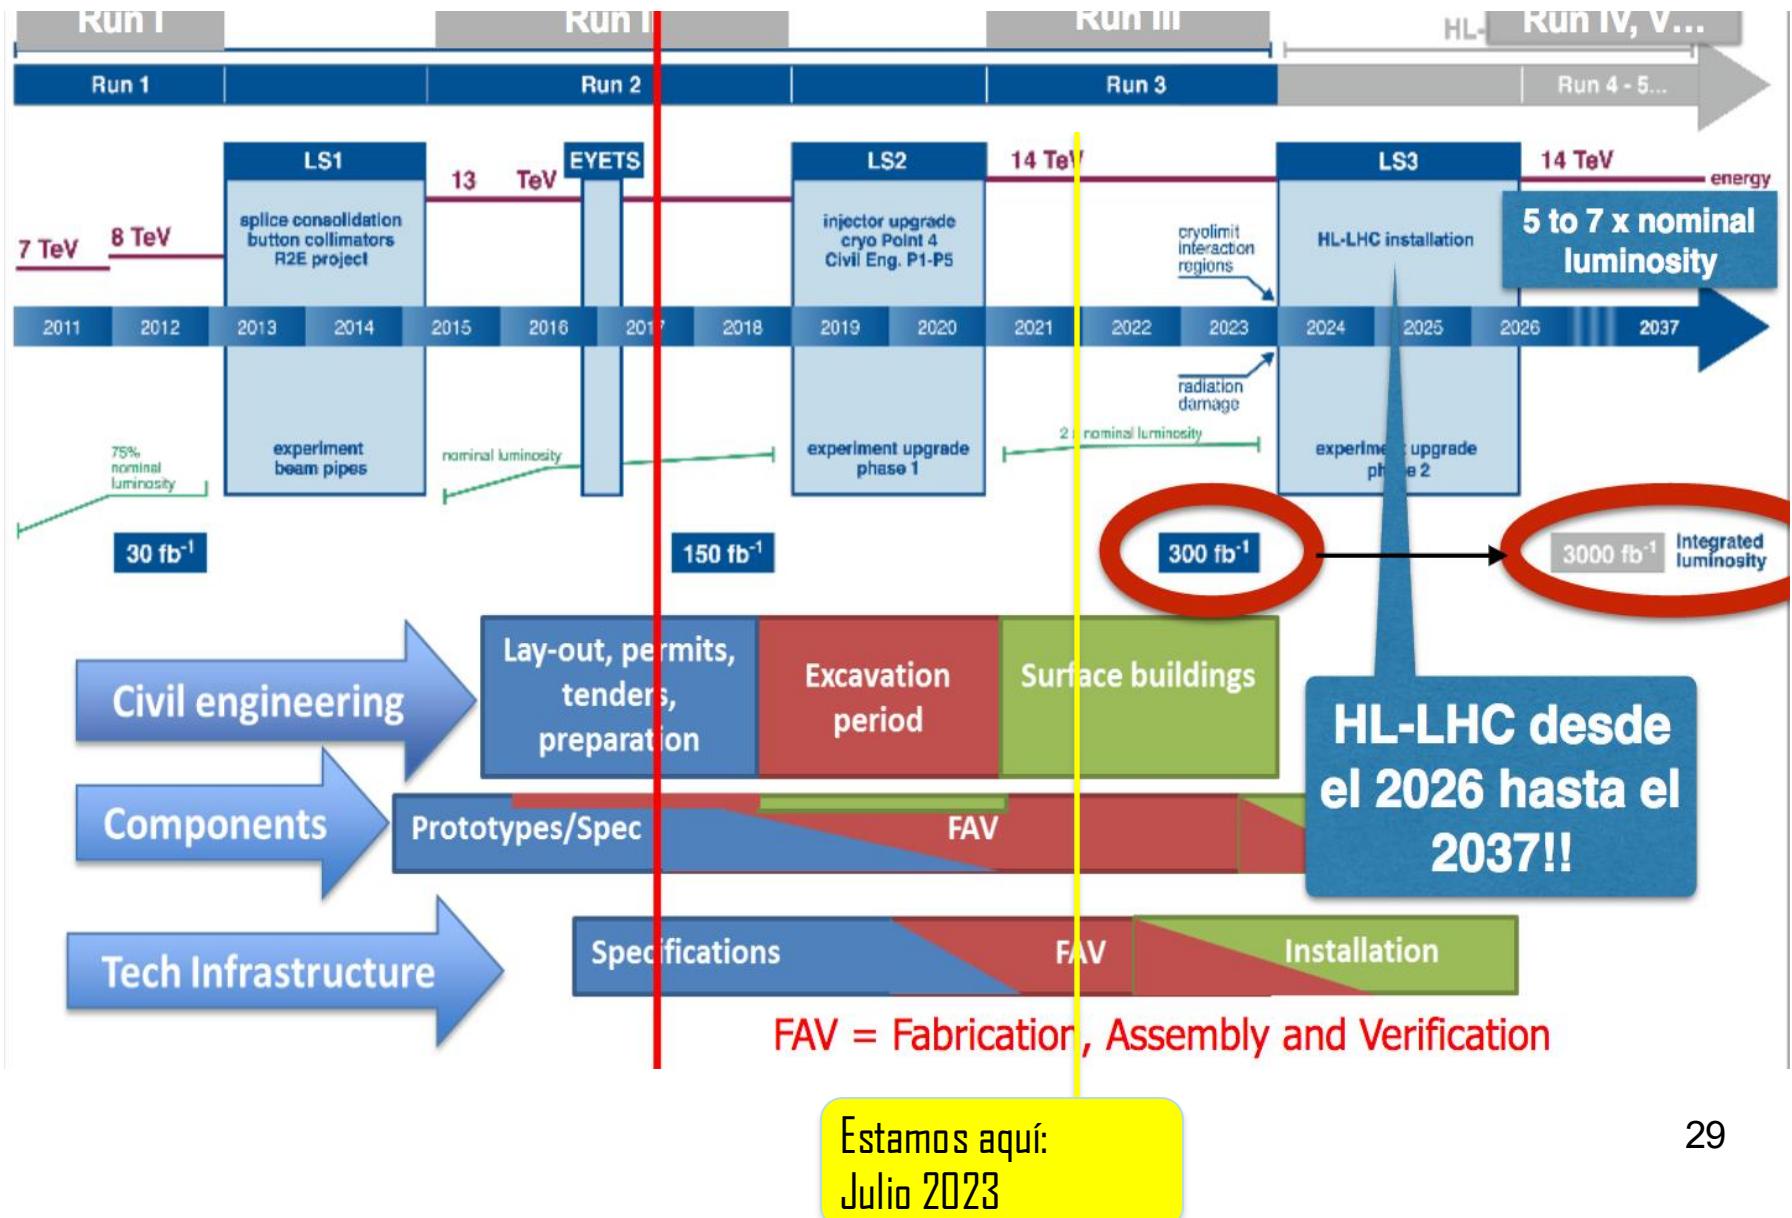
The moment when Cern director Rolf Heuer confirmed the Higgs results

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

6) ...en 2023 nos encontramos inmersos en el Run 3, tras el LS2 con una energía de 13.6 TeV y una cantidad ingente de datos recolectados pero NO hay STOP para el computing



7- Retos de Computación en el futuro



El escenario actual: un ‘ecosistema’ de Computación

Estamos en un nuevo escenario debido a:

- las muy buenas prestaciones de la red en términos de latencia y ancho de banda
- la mejora de la ratio calidad /coste en los equipos de ordenadores
- Los supercomputers (HPC) han seguido una tendencia de crecimiento continuo durante las dos pasadas décadas
- Cloud Computing ha parecido hace unos 8-9 años como otra posible solución para resolver problemas actuales de computación
- Sostenibilidad de la Infraestructura: mayor rendimiento con menos energía, huella de Carbono, green computing

Computer cluster



Cloud Computing

GRID Computing



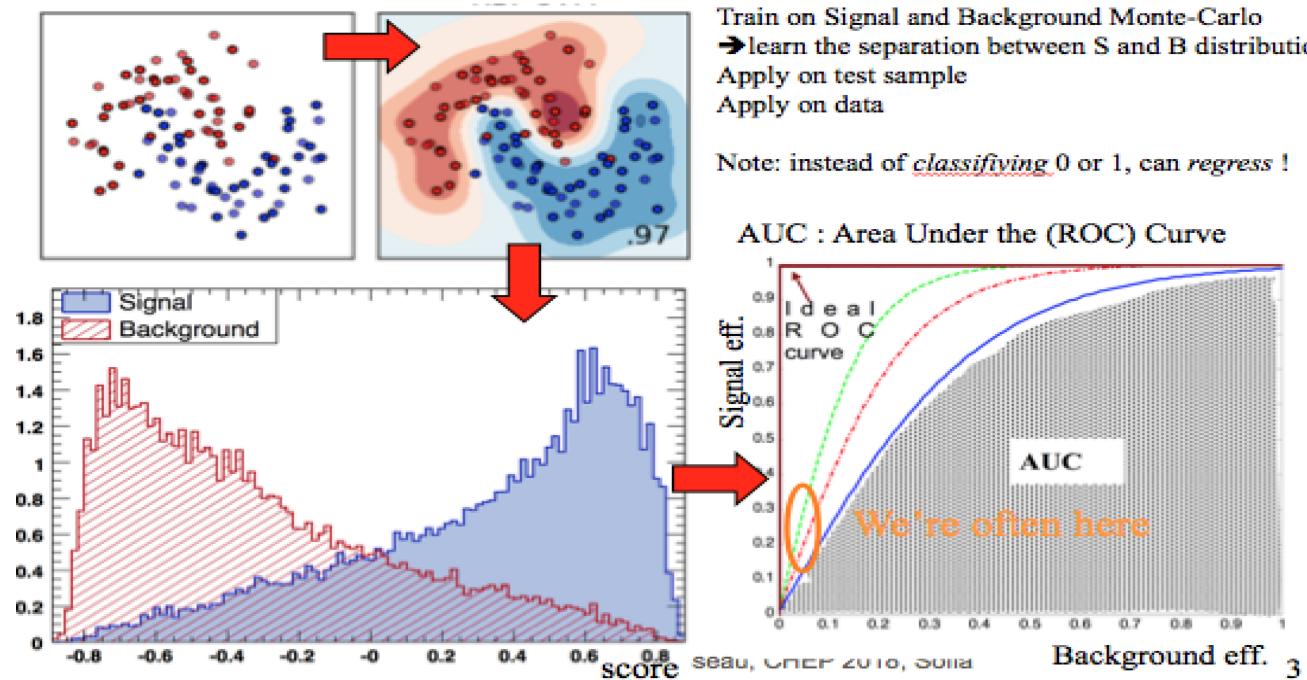
Supercomputers

Machine Learning

- Utilización del Machine Learning en diferentes aspectos:
 - ML en simulación
 - ML en reconstrucción
 - ML en análisis



Clasificación Señal- Background



Salidas Profesionales:

A destacar dos (pero hay más!):

• En Investigación en Física Experimental de Partículas, Nuclear y Astropartículas (estáis viendo qué hacemos):

- trabajando en líneas de investigación que ya estáis
conociendo en el IFIC Summer 2023

• Data Scientist:

- Profesión con muy buenas perspectivas y con una demanda cada vez mayor por parte de empresas y proyectos
- Big Data: Obtención de conocimiento a partir de los datos
 - El experimento ATLAS y otros experimentos (AGATA, DUNE, por ejemplo) son claros ejemplos de Big Data
- Data Mining, Machine learning, Inteligencia Artificial, etc

8.- Mensajes a retener/Conclusiones

- La Física subatómica (HEP & Nuclear & Astroparticle) y Computación están estrechamente relacionadas
- La Computación en la era del LHC se ha desarrollado para resolver problemas originados por las características de los experimentos. La solución inicial ha sido el GRID
- El Computing es como un detector más : colaboración de sites, upgrades, organización de servicios y de 'shifts', R&D , etc
- El I + D + i asociado a estas tecnologías GRID está dando lugar a una 'segunda revolución' del mismo nivel que el que supuso la web hace 20 años
- Esto está generando un Modelo Dinámico de Computación
- Aplicaciones en otras disciplinas científicas. Ya se están obteniendo retornos en Biomedicina, Sector Energético, Química, Biotecnología, etc
- El GRID y otras contribuciones de las Tecnologías de la Información y de la comunicación han dado lugar a la e-Ciencia
- En Investigación es necesario ' Data Scientists' y son también muy apreciados en las empresas en el sector privado y público.

- ChatGPT
- Operación de las infraestructuras con IA

- GRACIAS por vuestra atención
- PREGUNTAS / COMENTARIOS

BACKUP SLIDES

Grupo de Computación GRID y e-Ciencia (G2C2E) *Group of GRID & e-Science*

Personal Permanente:

Álvaro Fernández Casani	Titulado Superior Informática	CSIC
Santiago González de la Hoz	Catedrático Universidad	UV
José Francisco Salt Cairols	Profesor de Investigación	CSIC
Francisco Javier Sánchez Martínez	Titulado Superior Informática	CSIC

Personal Contratado o Vinculado:

Carlos García Montoro	Contratado por Proyecto	CSIC
Javier Aparisi Pozo	Contratado Pre-Doc S8A	CSIC
Esteban Fullana Torregrosa	Contratado Prometeo (postdoc)	CSIC
Miguel Villaplana Torregrosa	Investigador CIDEGENT	UV
Victoria Sánchez Sebastián	Contrato Pre-Doc FPU	CSIC

Farida Fassi Profesora Titular Universidad
De Rabat

Colaboradores Externos/Colaboradores Visitantes:

Julio Lozano Bahilo
Gabriel Amorós Vicente
Mohammed Kaci