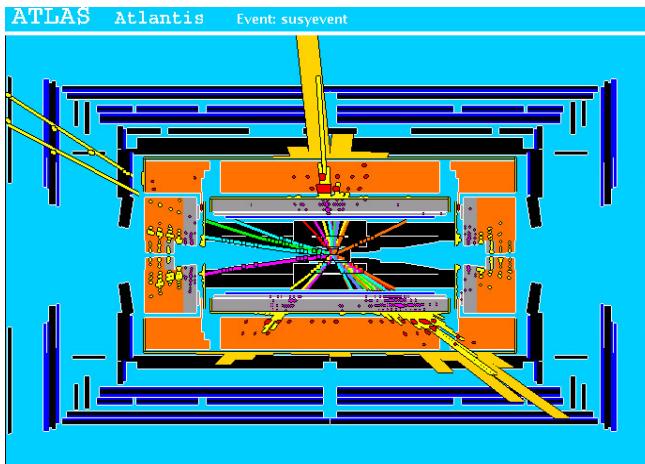
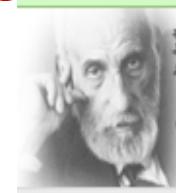


# La Computación en la era del LHC



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

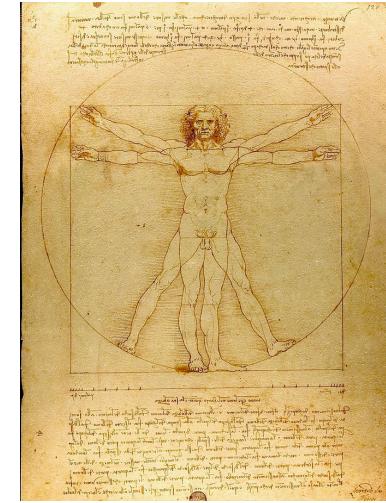


# Contenido

- 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) Conclusiones y perspectivas**

# 1- Introducción: Física y Computing

- Físico Experimental (perfil ‘humanista’-‘renacentista’ de la Física )
  - 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



```
EEuto<U'@x          F_h+= X)ik1B
PaRX0BA>m:          t(g( Vx?t1"
q#xF{22 LF          kcnS@U kNvlg
c 0**v10g 2k          k-5c q0 l# = r-
F #>C]H Z x0 3      ^ f:NE7 ua $/ 9z
q xU3@3 z           N xU2@J uH R0 [ys Jf
xU3@3 z             LHK U = F ZS \X Ex C0 oZ4
xU3@3 z             LHK U = F ZS \X Ex C0 oZ4
)I up\6t             Bt{(+ 000270 ( Rva nvh KHO
)I up\6t             Bt{(+ 000270 ( Rva nvh KHO
-r?h@ = g            n4YI l@ jo6FB@ T gN sI LU
(5tc H             enZ 6s >UEuIZ G h9 g Xi <6
kv+s@ k            ?{, 4B 'ke?ib Z 2^ t j: 3n
vPnpB@ s            +6K P1B sub uu l v u = Bu
L8 n             ZY? n4? 7zp 80 / 7 Mp do
IV X             31= 3:q (P x . : = pI Z b
c 4             8 C2T[s9K uH . q F s L
UC h             qk0dxt sH K )" F g
DB N             1 -TpIT[. E 60 )>E 2
L5 B             T990@c7 p0 E g vR -2
CX 1             ^*xYsd p0 d -L F s
O q             npS0ch+ ^x < 0 & s:
K-             I"5@lU z^ 0 ) nB(
K-             x F6"9s)G. NV . Xz jde
```

# 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



Tim Berners-Lee

Robert Cailliau

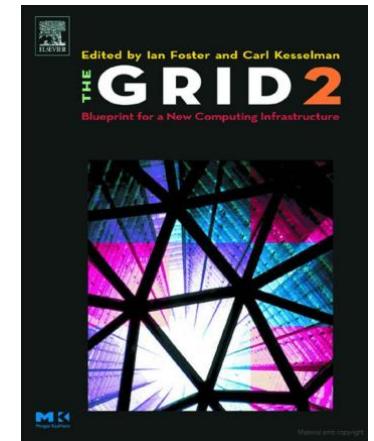


- **1995: Supercomputing '95**

- 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** es suficiente para procesar todos los datos

- Se necesita 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



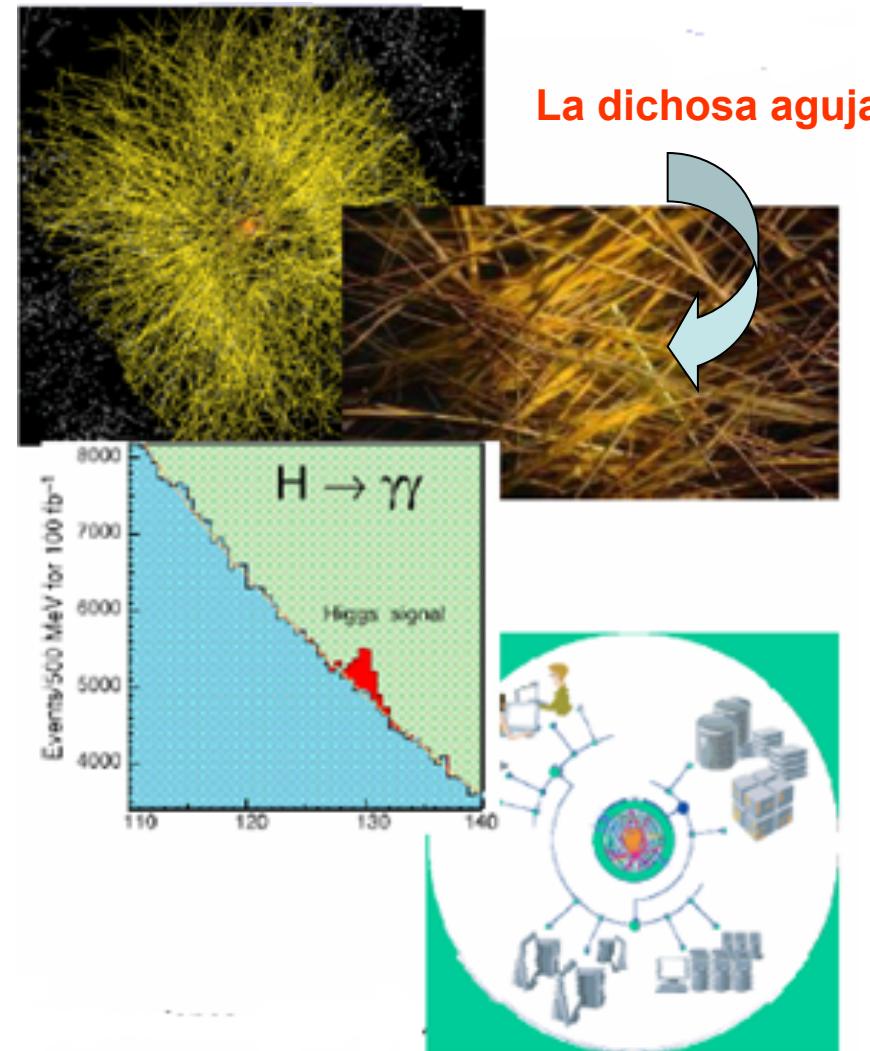
### 3.- La Solución al Problema: las Tecnologías GRID

#### ¿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/Gran Centro de Cálculo)**
- Distribución jerárquica  
**(Centros de cálculo medianos)**



- Red Internet

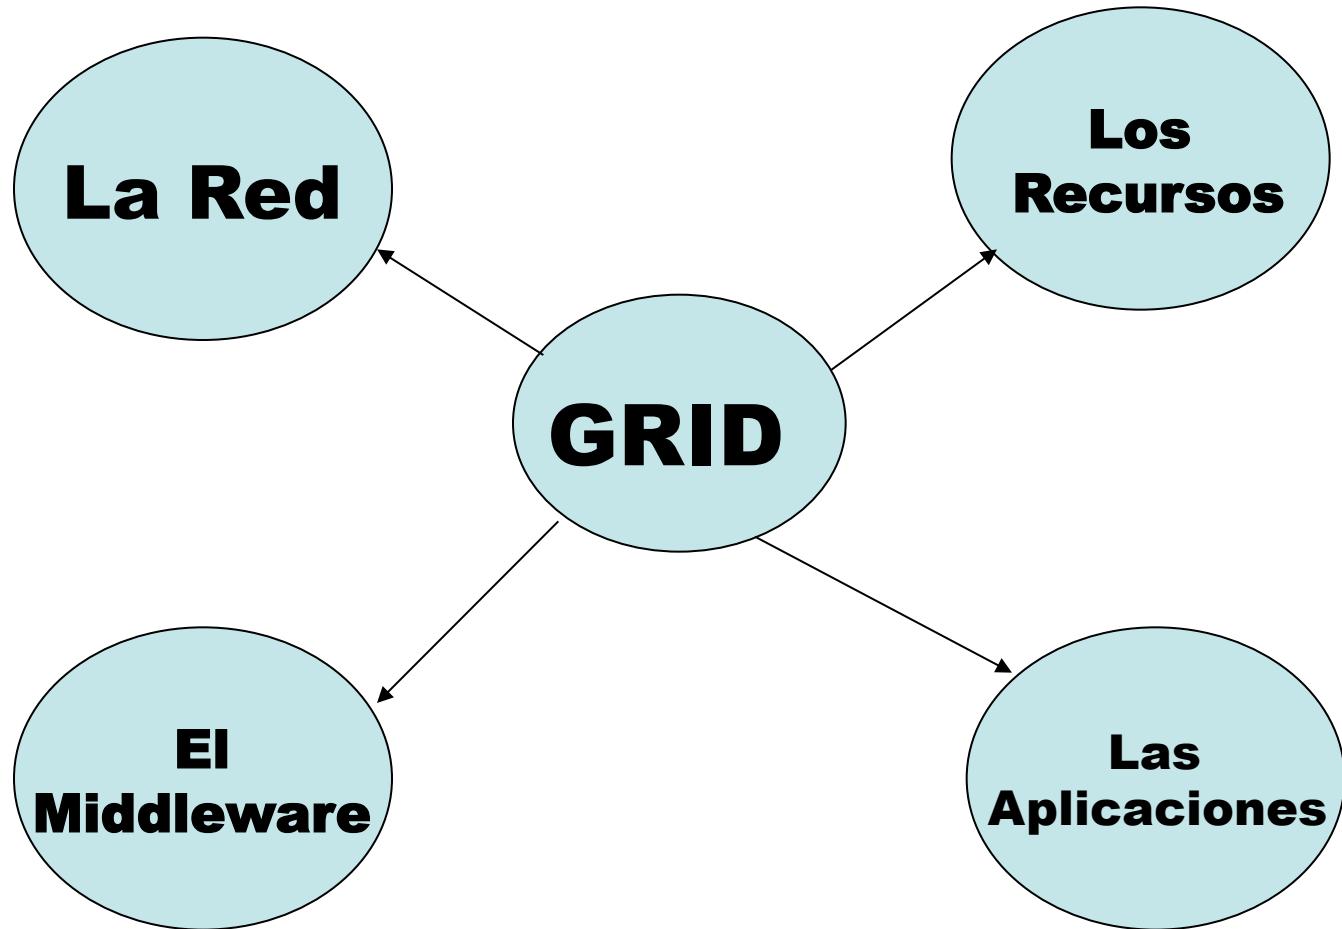


← Ramo de fibras ópticas



- Usuario Final: acceso a las prestaciones informáticas

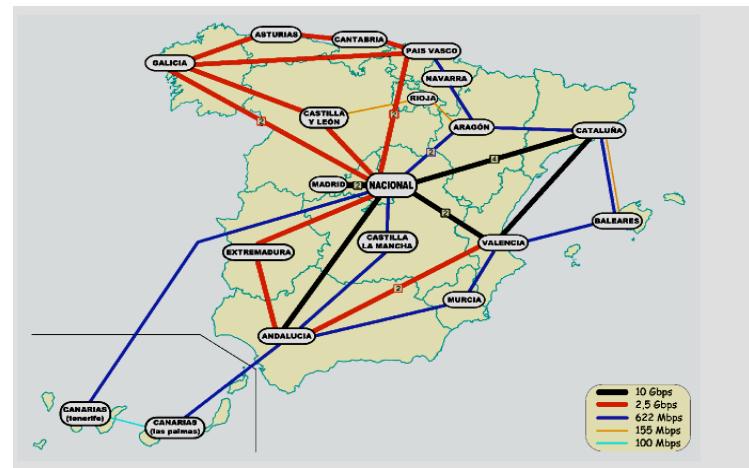
# Ingredientes fundamentales del GRID



# La Red: las autopistas de la Información

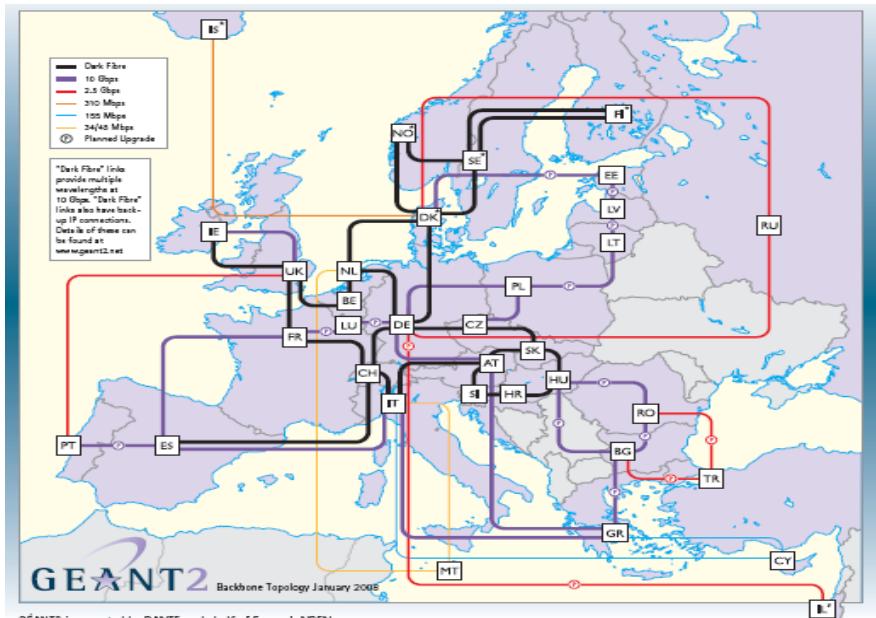


Red IRIS



# **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*

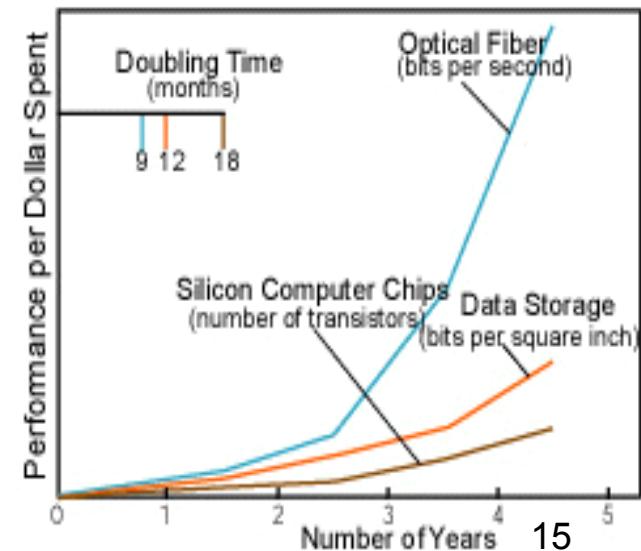
# Los recursos: Las Infraestructuras

## 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’



Gordon Moore

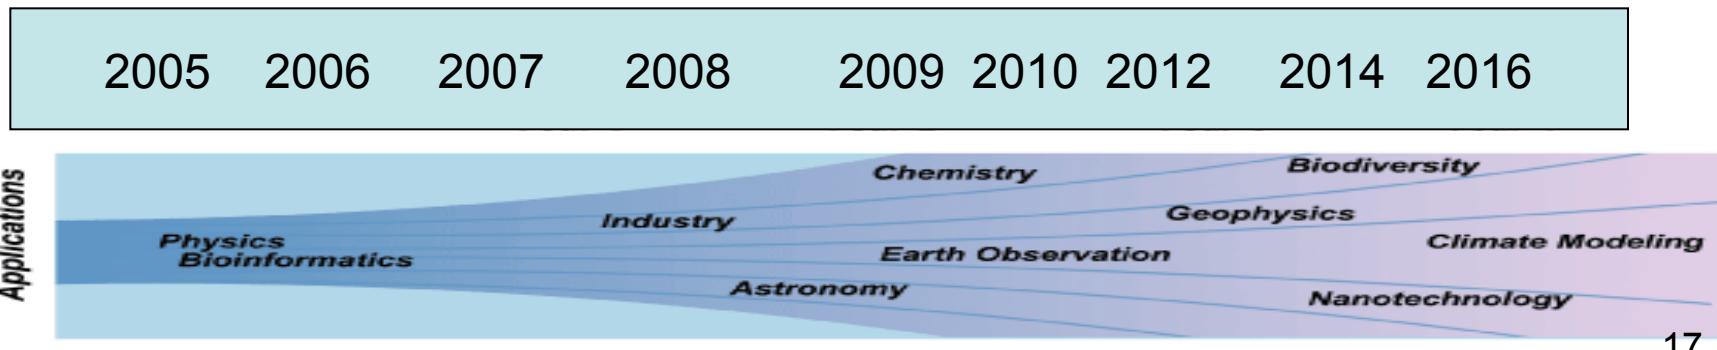


## ¿Qué es el Middleware?

- **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.**



## 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 (2011-2016): 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**

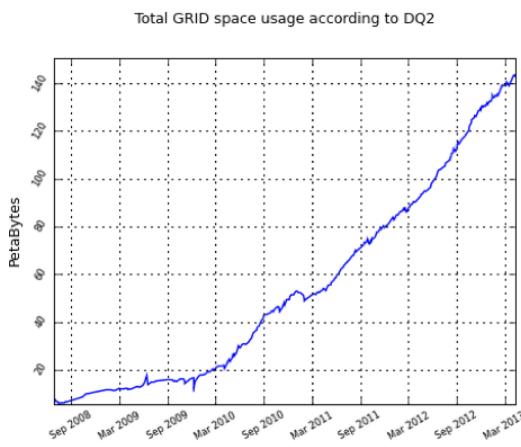
- 15 PB/año (Raw) -> 50 PB/año (overall)
- Vida Util: 10-15 años -> escala del Exabyte

**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

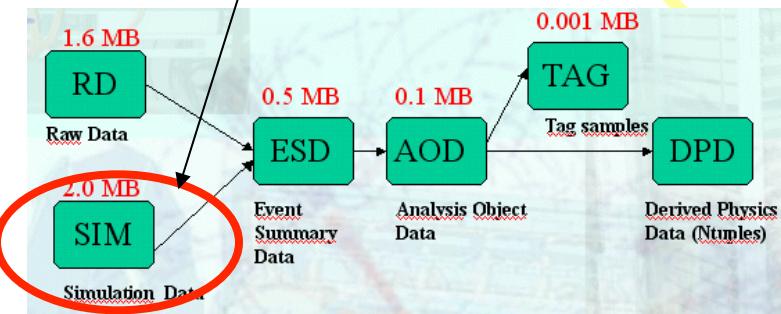
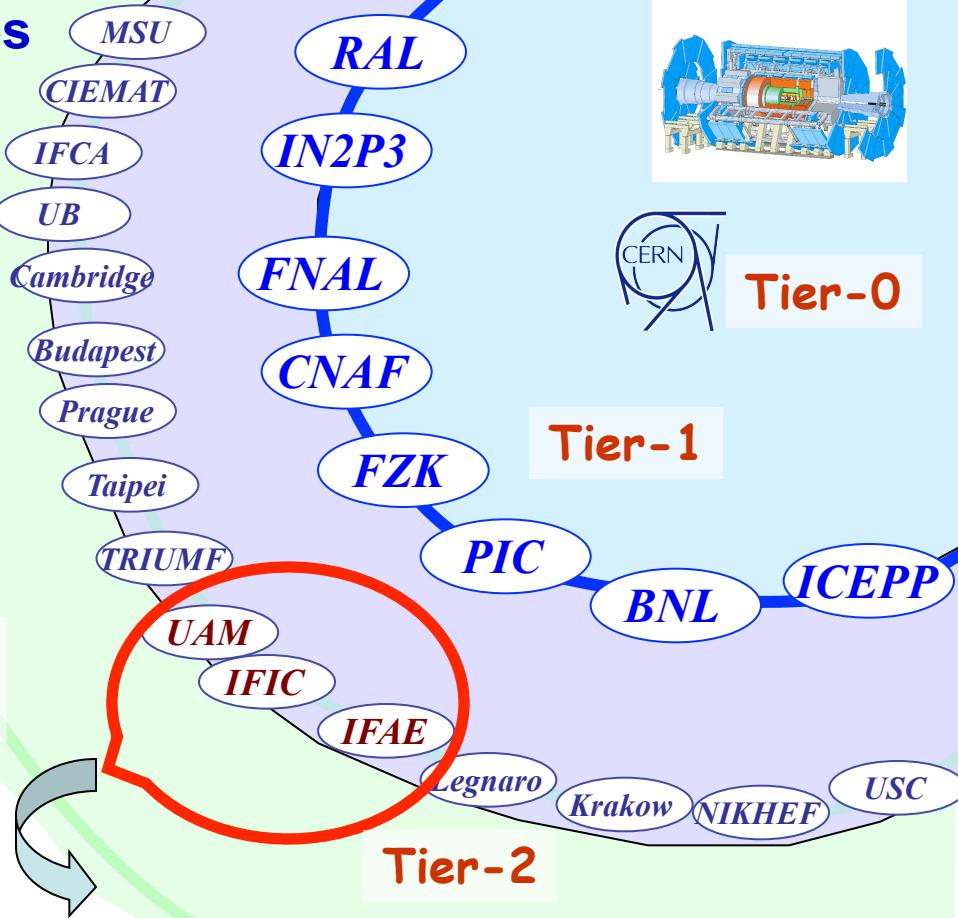


desktops  
portables

Tier-3

small  
centres

Tier-1

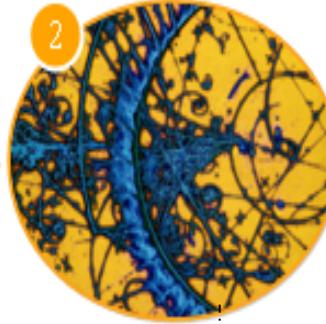


# Proceso de transformación de los datos



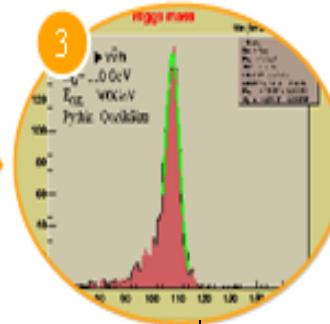
Datos de ATLAS 'brutos'

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....

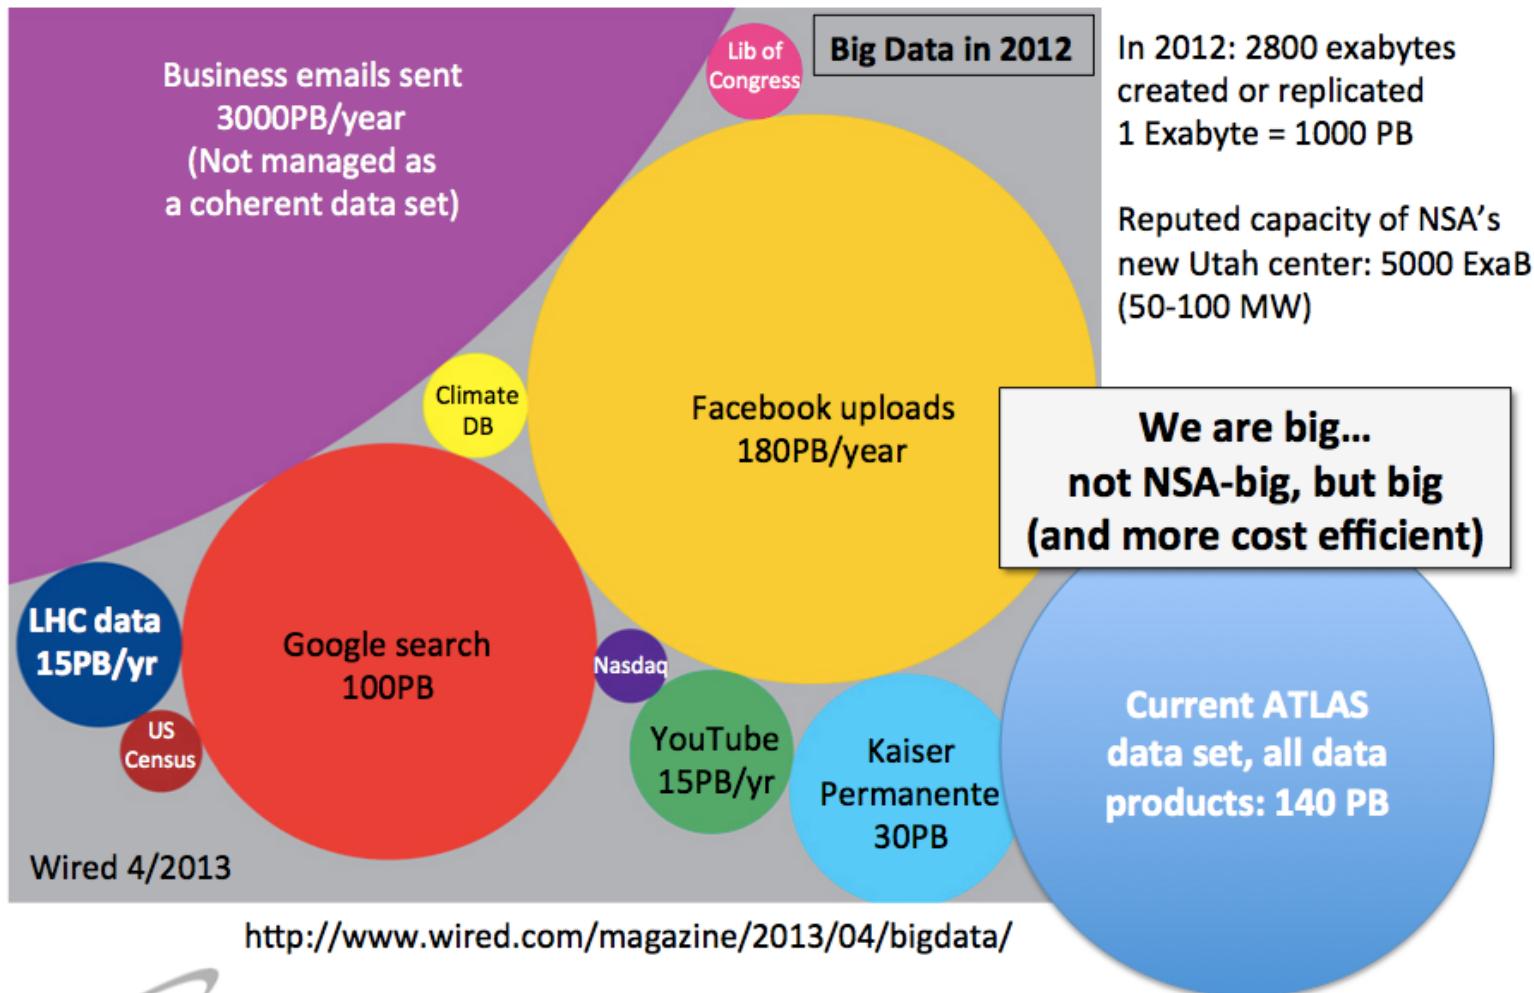


15:

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

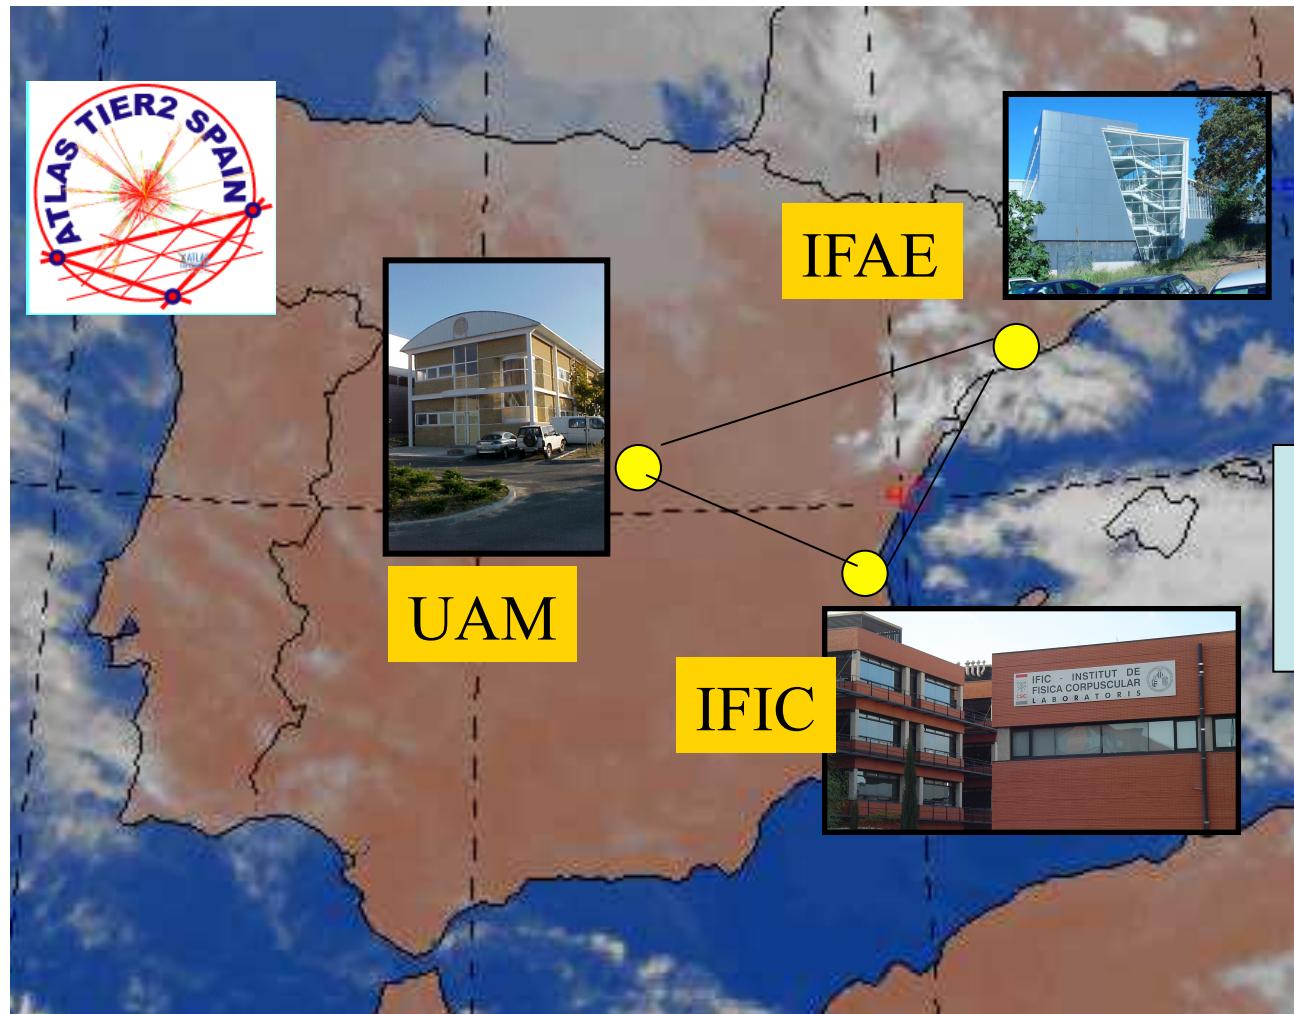
# Data Management

## 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 (25%)

IFIC (50%)

**5% del total**

**Tier-2**

Equipamiento:

CPU = 16.187 KSI2k

Disk = 1.715 TB

Recursos Humanos:

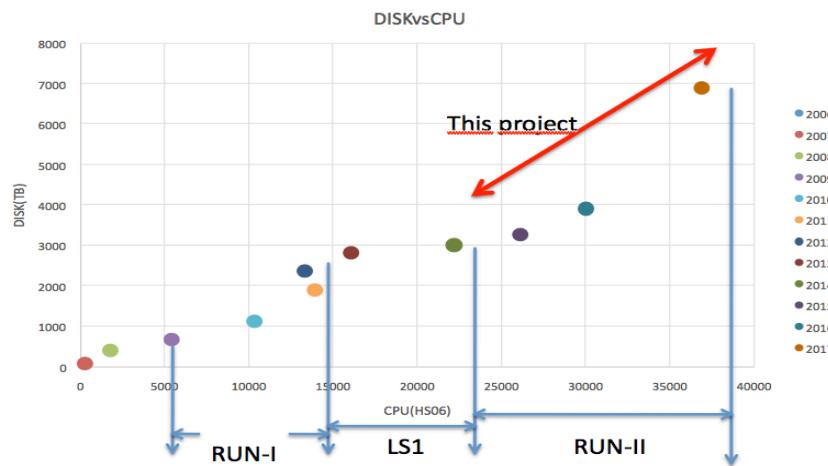
12 FTE

Julio 2016

1 KSI2K: es una unidad de CPU ; Intel D975XB (2 cores) ; Core Extreme X6800 = 3' 041<sup>23</sup> KSI2K

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

Profile resource growth in the period 2006-2017

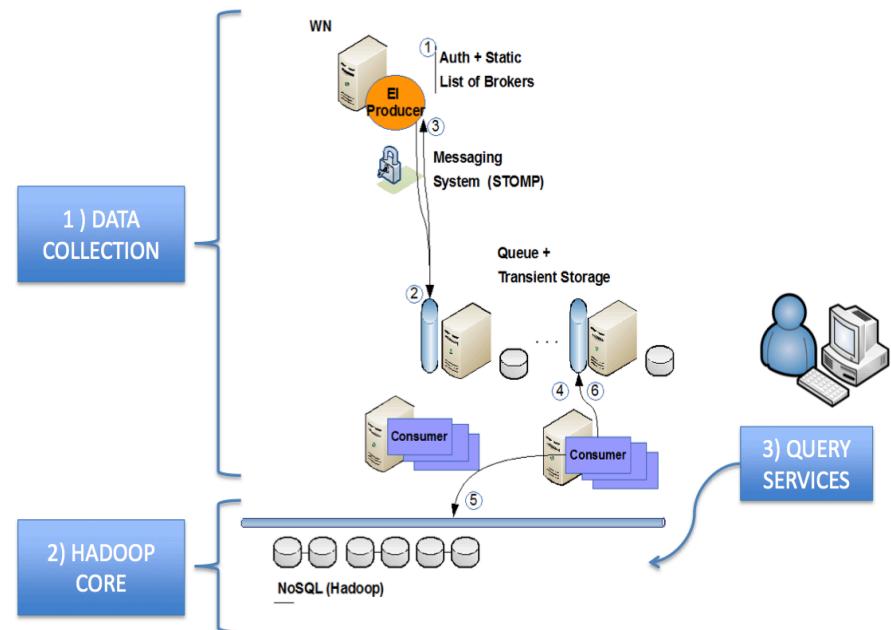


*Fuerte Crecimiento en recursos*



# 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



# Grupo de Computación GRID y e-Ciencia (G2C2E)

## Group of GRID & e-Science

### MIEMBROS



#### Personal Permanente:

- A. Fernández Casani : Titulado Superior Informática- CSIC  
S. González de la Hoz : Profesor Titular – UVEG  
J. F. Salt Cairols, : Profesor Investigación - CSIC  
J. Sánchez Martínez : Titulado Superior Informática- CSIC

#### Personal Contratado ó Vinculado:

- J. Lozano Bahilo                      Contratado Proyecto, CSIC (fin de contrato: Diciembre 2016)
- F. Fassi                                 Doctora Vinculada.  
    Profesora Física Universidad Mohammed V (Rabat)
- C. García Montoro                    Contrato Técnico de Apoyo
- V. Sánchez Martínez:  
Mohammed Kaci:                    Contrato 3 meses Proyecto , CSIC  
    Contrato Proyecto (CSIC)

#### Colaboradores externos/ Colaboradores Visitantes:

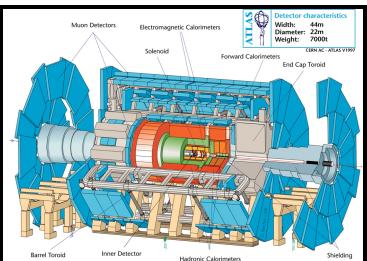
- G. Amorós Vicente:                    Técnico Especialista en la AEMET (Agencia Española de Meteorología)  
    Postdoc en INFN-Milán
- Miguel Villaplana

## 7- El GRID y el Higgs

- Los resultados de Física son comparaciones de observables con sus predicciones teóricas
- Hay un proceso: Trigger/adquisición de datos, reconstrucción , análisis y simulación
- Se necesitan algoritmos sofisticados para reconstrucción y análisis
- Uno de los factores más esenciales es disponer de una buena simulación detallada
- Un solo suceso es pequeño 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...



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

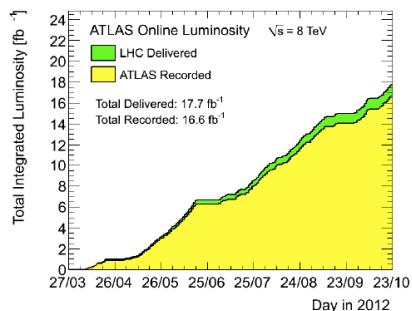
Science editor, BBC News website, Geneva



The moment when Cern director Rolf Heuer confirmed the Higgs results

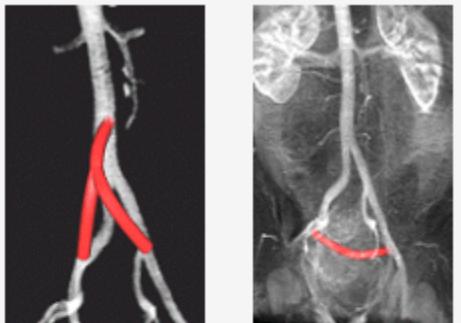
Cern scientists reporting from the Large Hadron Collider (LHC) have claimed the discovery of a new particle consistent with the Higgs boson.

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

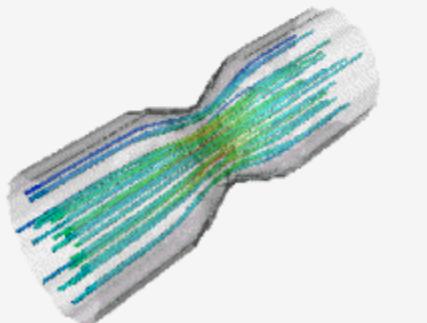


# El GRID aplicado a enfermedades vasculares

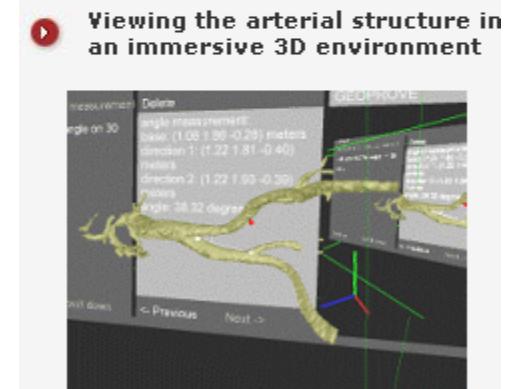
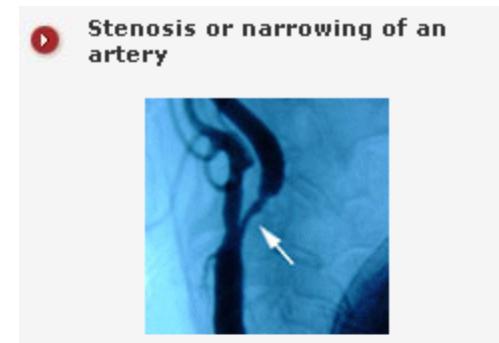
- Dos procedimientos: stent y bypass
- El cirujano se ayuda con imágenes 3D obtenidas con scanners CT y MRI
- Las simulaciones de una posible intervención ayuda a la toma de decisión por parte del médico



Simulated flows



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

# Salidas Profesionales:

A destacar dos:

- En Investigación en Física (estáis viendo qué hacemos):
  - trabajando en líneas de investigación que ya estáis conociendo
- 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

## 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, 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' pero pueden también ser muy apreciados en las empresas

- GRACIAS por vuestra atención
- PREGUNTAS / COMENTARIOS

- *Backup Slides*

# El GRID contra la Malaria

- La malaria es la causa de la muerte de más de 1 millón de personas al año, la mayoría niños que viven en África
- Físicos y Biólogos han compartido sus ordenadores, dentro del contexto del EGEE, con el fin de combatir la enfermedad;
- Con el GRID Internacional se han analizado un promedio de 80.000 posibles compuestos farmacológicos por hora contra la malaria. El total analizado ha ascendido a 140 Millones de compuestos
- Más de 5000 ordenadores se usaron simultáneamente en la campaña obteniendo un total de 2 TB de datos útiles  
(Reto planteado por la colaboración internacional  
**WISDOM: World-wide In Silico Docking On Malaria**)
- El análisis ‘in silico’ agilizó enormemente el docking entre los fármacos testeados y las proteínas blanco de los parásitos de la malaria
- WISDOM usa el docking in silico para calcular la probabilidad de que un molécula se ‘acople’ con una proteína nucleo
- Esto permite a los investigadores rechazar una gran mayoría de fármacos potenciales, y de esta forma , se pueden centrar en compuestos prometedores que se testean en el laboratorio. Se reducen costes

