DECSAI

Departamento de Ciencias de la Computación e I.A.

Universidad de Granada

Data Warehousing

© Fernando Berzal, berzal@acm.org

Acceso a los datos

- Bases de datos relacionales: SQL
- O/R Mapping
- Bases de datos distribuidas
- Bases de datos NoSQL
- Bases de datos multidimensionales: Data Warehousing

Data Warehousing

- OLAP vs. OLTP
- Data Warehousing
- El modelo multidimensional
- Implementación de un data warehouse
- Soluciones de data warehousing
- Apéndice: Business Intelligence

OLAP vs. OLTP

OLTP [On-Line Transaction Processing]

Aplicaciones típicas de gestión

- Tareas repetitivas.
- Tareas muy bien estructuradas.
- Transacciones cortas (actualizaciones generalmente).

OLAP vs. OLTP

OLTP [On-Line Transaction Processing]

Prioridad: Gestión de transacciones

- Las transacciones se realizan sobre grandes *bases de datos* a las cuales se puede acceder eficientemente mediante índices, ya que cada operación afecta sólo a unos pocos registros.
- Es de vital importancia garantizar la "acidez" de las transacciones (atomicidad, consistencia, aislamiento y durabilidad).

OLAP vs. OLTP

OLAP [On-Line Analytical Processing]

Sistemas de ayuda a la decisión (DSS)

- Consultas muy complejas (grandes volúmenes de datos y uso de funciones de agregación).
- Actualizaciones poco frecuentes.

OLAP vs. OLTP

OLAP [On-Line Analytical Processing]

Prioridad: Procesamiento de consultas

- Los data warehouses (DW) almacenan datos resumidos de tipo histórico.
- La optimización de las consultas y el tiempo de respuesta son primordiales.

OLAP vs. OLTP

	OLTP	OLAP
Usuarios	Operadores	"Trabajadores del conocimiento"
Función	Operaciones cotidianas	Soporte a la toma de decisiones
Diseño	Orientado a las aplicaciones	Orientado al usuario
Datos	Actuales Actualizados Detallados	Históricos Consolidados Resumidos
Uso	Repetitivo	Ad-hoc
Acceso	Consultas simples y actualizaciones	Consultas complejas
Rendimiento	Transacciones ACID	Consultas: Throughput & tiempo de respuesta
Volumen	GB - TB	TB - PB

Data Warehousing

Problema

Las organizaciones manejan enormes cantidades de datos…

… en distintos formatos.

… que residen en distintas bases de datos.

… organizados utilizando distintos tipos de gestores de bases de datos

Consecuencia

Resulta difícil acceder y utilizar todos los datos en aplicaciones de análisis (las cuales requieren extraer, preparar e integrar los datos)

Data Warehousing

Diseño de procesos e implementación de herramientas que proporcionen información completa, oportuna, correcta y entendible en la toma de decisiones.

"A data warehouse is a subject-oriented, integrated, time-variant, and nonvolatile collection of data in support of management's decision-making process."
— W. H. Inmon

Data Warehousing

Características de un DW

- Orientado a un tema (clientes, productos, ventas): Vista de la BD operativa excluyendo los datos que no son útiles en la toma de decisiones.
- Integrado (ETL) a partir de múltiples fuentes de datos heterogéneas, p.ej. OLTP (RDBMS, NoSQL, ficheros…)
- Perspectiva histórica (mayor horizonte temporal que una base de datos OLTP).
- No volátil (no se realizan actualizaciones, por lo que no se requieren mecanismos de procesamiento de transacciones, control de concurrencia…).

Data Warehousing

- El DW se mantiene separado de las bases de datos operativas.
- El DW consolida datos históricos para su análisis.
- El DW accede a fuentes de datos heterogéneas, para lo que utiliza **herramientas ETL** [extract-transform-load]: limpieza, filtrado y transformación de los datos.
- Únicas operaciones: carga inicial de los datos y realización de consultas.

Data Warehousing

¿Por qué se mantiene separado el DW?

Distintos requisitos operativos:

- DBMS optimizado para OLTP: Métodos de acceso, indexación, control de concurrencia, transacciones…
- DW optimizado para OLAP: Consultas complejas, consolidación de datos, datos históricos…

Data Warehousing

Modelos arquitectónicos

- **Enterprise warehouse**
  (único DW para toda la organización).
- **Data marts**
  (varios DW para grupos específicos de usuarios).
- **Virtual warehouse**
  (vistas sobre las bases de datos operativas,
  de las cuales sólo se materializan algunas de ellas).

Data Warehousing

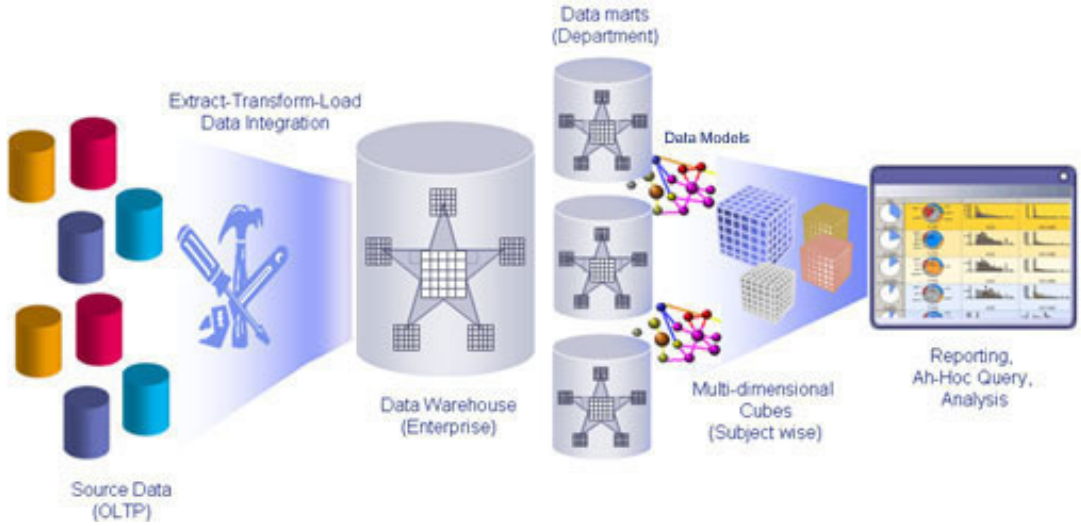

El modelo multidimensional

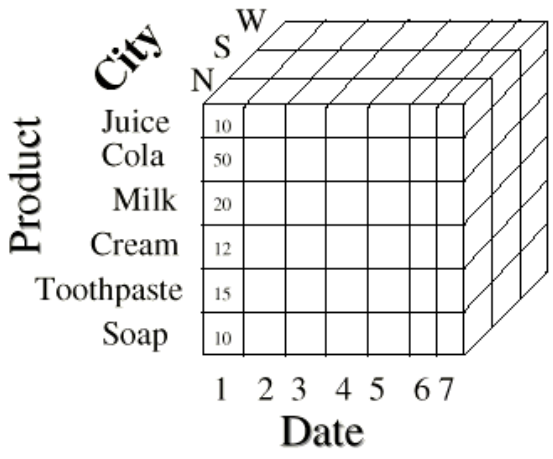

Dimensions: Product, City, Date

Hierarchical summarization paths

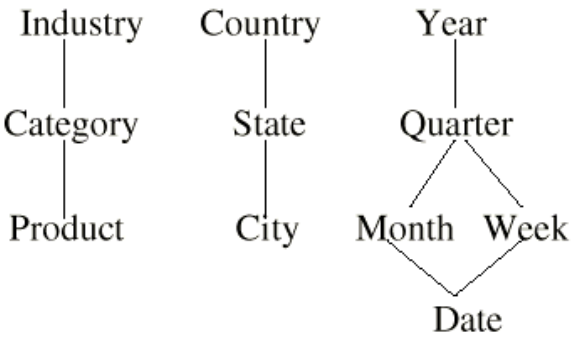

El modelo multidimensional

Los datos en un DW se modelan en cubos de datos [data cubes], estructuras multidimensionales (hipercubos, en concreto) cuyas operaciones más comunes son:

- **Roll up**
  (incremento en el nivel de agregación de los datos).
- **Drill down**
  (incremento en el nivel de detalle, opuesto a roll up).
- **Slice**
  (reducción de dimensionalidad mediante selección).
- **Dice**
  (reducción de dimensionalidad mediante proyección).
- **Pivotaje o rotación** (reorientación de la visión multidimensional de los datos).

El modelo multidimensional

Modelado multidimensional

Modelos de datos
como conjuntos de medidas descritas por dimensiones.

- Adecuado para resumir y organizar datos
  (generalización de las hojas de cálculo).
- Enfocado para trabajar sobre datos de tipo numérico.
- Más simple, más fácil de visualizar
  y de entender que el modelado E/R.

El modelo multidimensional

Dimensiones

Perspectivas o entidades respecto a las cuales una organización quiere mantener sus datos organizados.

Ejemplos:

- Tiempo
- Localización
- Clientes
- Proveedores
- Productos

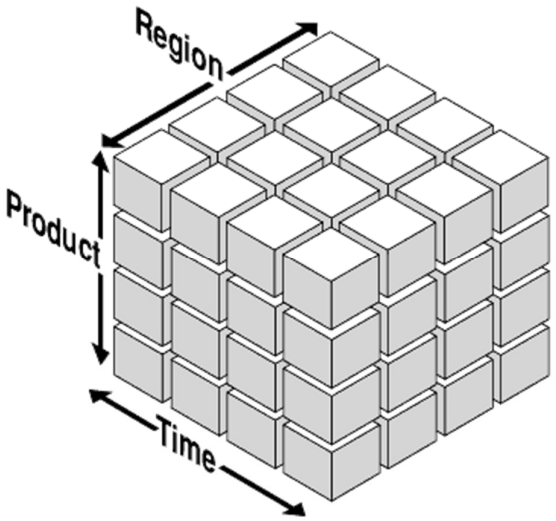

El modelo multidimensional

Miembros

Nombres o identificadores
que marcan una posición dentro de la dimensión.

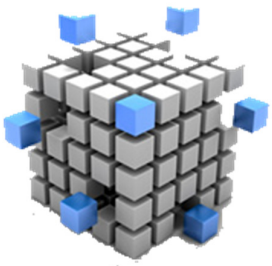

Ejemplos:

- Meses, trimestres y años
  son miembros de la dimensión tiempo.
- Ciudades, regiones y países
  son miembros de la dimensión localización.

El modelo multidimensional

Jerarquías

Los miembros de las distintas dimensiones se suelen organizar en forma de jerarquías.

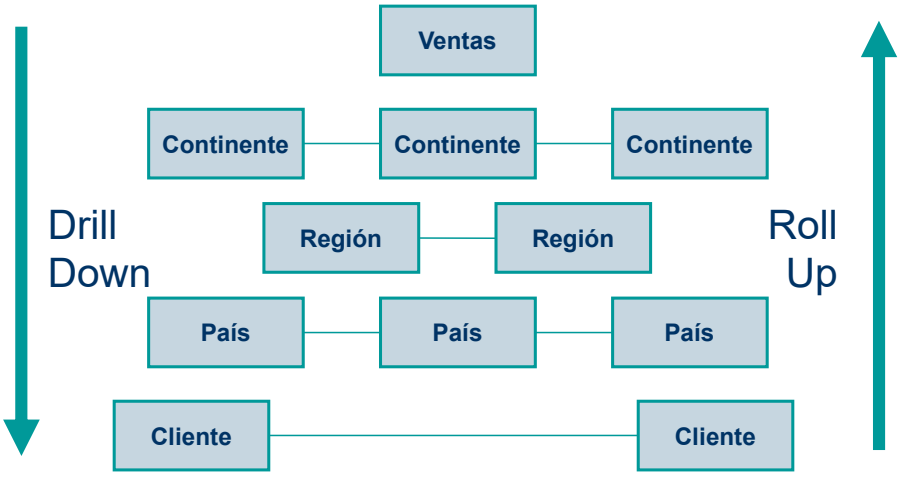

El modelo multidimensional

Hechos

Colecciones de datos relacionados compuestas por medidas y un contexto.

- Las dimensiones determinan el contexto de los hechos.
- Cada hecho particular está asociado a un miembro de cada dimensión.

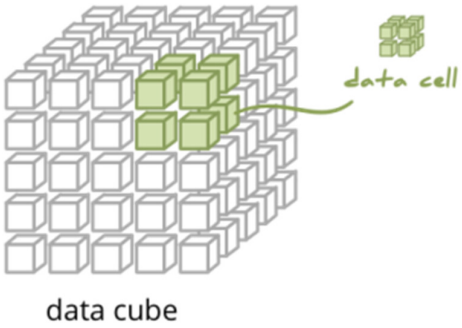

Medidas

Atributos numéricos asociados a los hechos (lo que realmente se mide).

Implementación de un DW

Wrappers

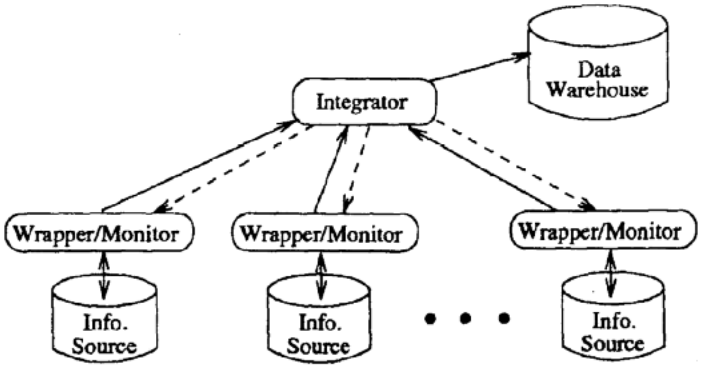

- Los wrappers (encapsuladores) se encargan de extraer los datos de las distintas fuentes y transmitirlos al DW.
- Los monitores están en contacto directo con las fuentes de datos para detectar los cambios que se puedan producir en ellas.
- El integrador es el responsable de filtrar, resumir y unificar los datos de las distintas fuentes.

Implementación de un DW

Metadatos

- Estructura del DW: esquema, vistas, dimensiones, jerarquías, datos derivados, data marts (localización y contenidos)…
- Metadatos operativos: "linaje de los datos" [data lineage], actualidad de los datos (activos, archivados, purgados) e información de monitorización (estadísticas de uso, informes de errores y auditorías).
- Correspondencia entre el entorno operativo y el DW (p.ej. algoritmos utilizados para resumir los datos).
- Datos del negocio [business data]: Términos y definiciones, propiedad de los datos…

Implementación de un DW

Alternativas de implementación

- **MOLAP [Multidimensional OLAP]**
  Datos almacenados en estructuras de datos multidimensionales (matrices multidimensionales sobre las que se realizan directamente las operaciones OLAP).

- **ROLAP [Relational OLAP]**
  DW implementado como una base de datos relacional (las operaciones multidimensionales OLAP se traducen en operaciones relacionales estándar).

Implementación de un DW

ROLAP con esquema en estrella [star]

Una tabla de hechos
y una tabla adicional (denormalizada) por cada dimensión.

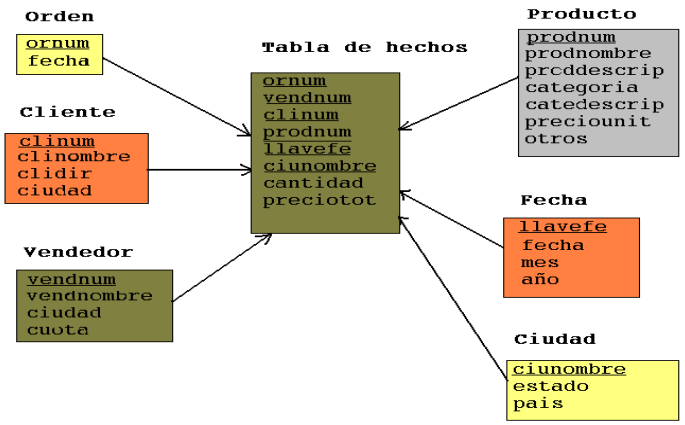

Implementación de un DW

ROLAP con esquema en copo de nieve [snowflake]

Refleja la organización jerárquica de las dimensiones…

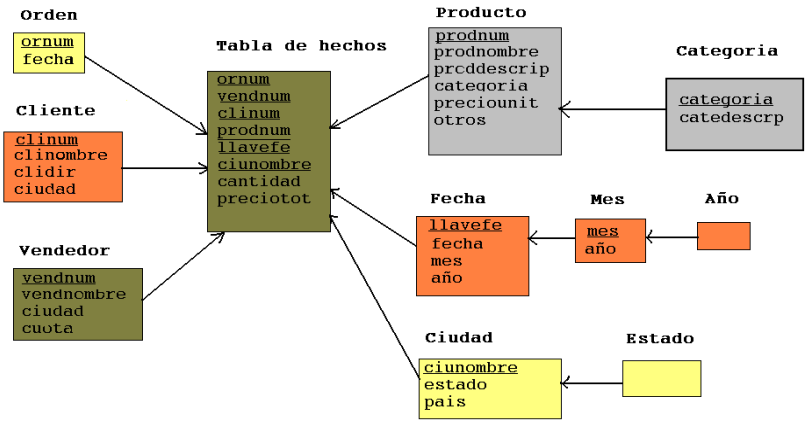

Implementación de un DW

ROLAP con constelaciones de hechos

Múltiples tablas de hechos que comparten dimensiones

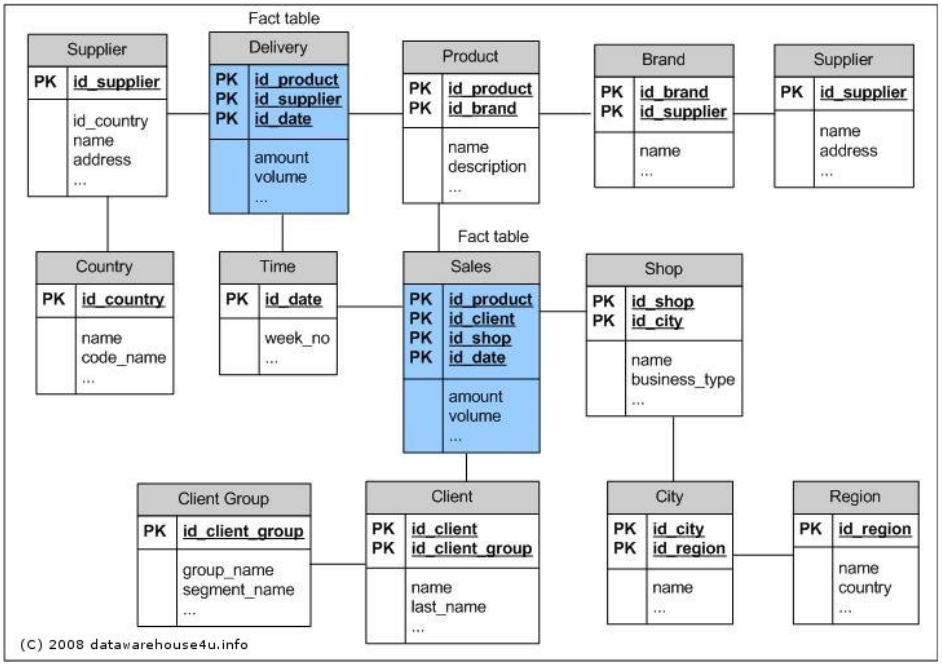

Implementación de un DW

Un cubo de datos como un retículo de cuboides:

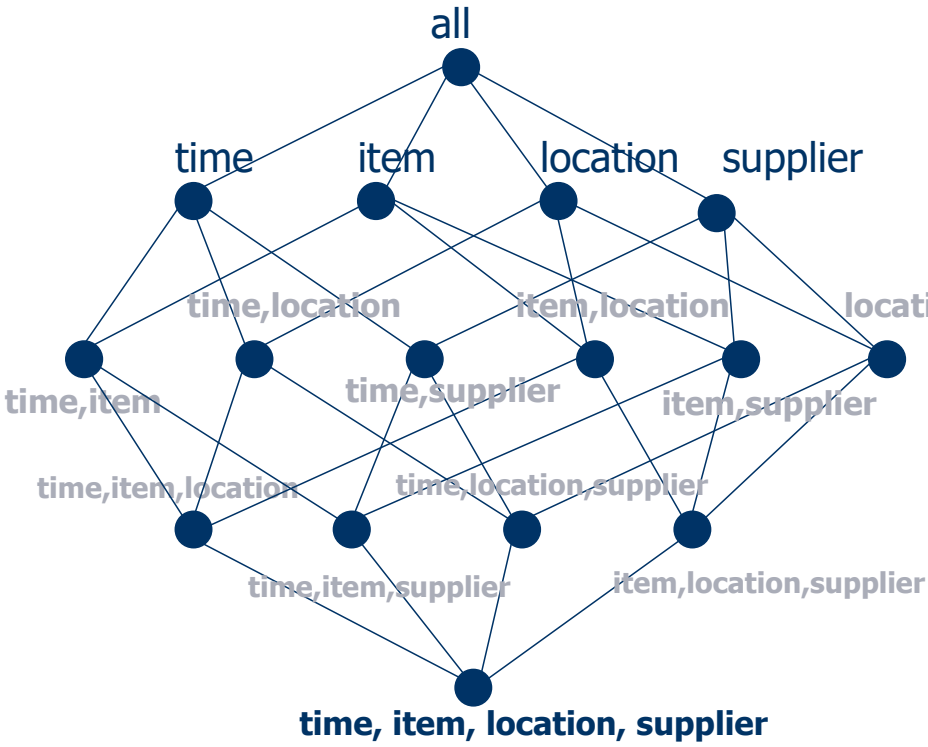

0-D (*apex*) cuboid

1-D cuboids

2-D cuboids

3-D cuboids

4-D (*base*) cuboid

Implementación de un DW

Un cubo de datos como un retículo de cuboides:

- El cuboide base tiene D dimensiones.
- El cuboide ápice tiene 0 dimensiones (1 celda).

Materialización del cubo de datos:

- Completa (todos los cuboides).
- Ninguna (ningún cuboide, i.e. sólo el cuboide base).
- Parcial (algunos cuboides materializados, que se seleccionan en función de su tamaño, uso en distintas consultas, frecuencia de acceso…)

Implementación de un DW

Indexación de datos

- Índice bitmap

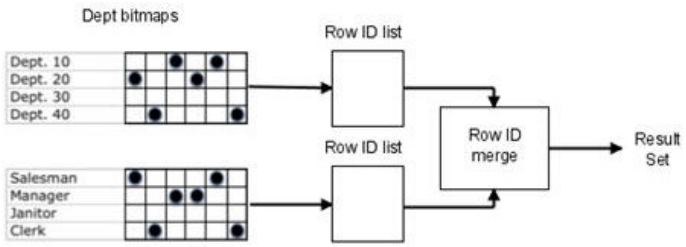

- Índice de reunión [join index], a.k.a. star index

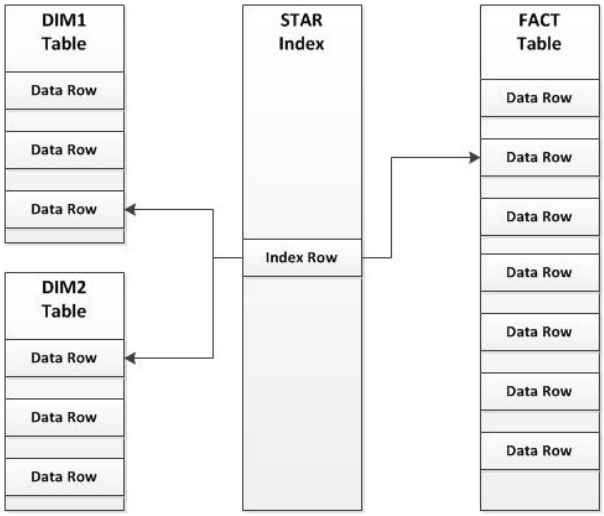

Implementación de un DW

Procesamiento de consultas OLAP

- Se determinan las operaciones que deben realizarse sobre cuboides: se transforman las operaciones sobre cubos de datos (roll up, drill down…) en operaciones relacionales

  p.ej. dice = selección + proyección

- Se determinan los cuboides materializados que pueden utilizarse para resolver mejor la consulta.

Implementación de un DW

Ejemplo: ROLAP sobre Oracle

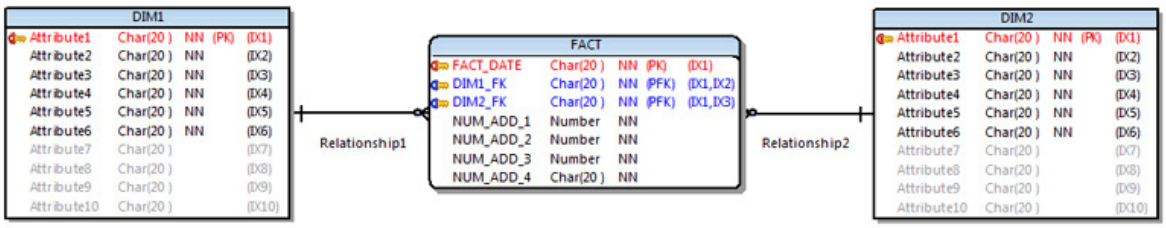

Índice bitmap tradicional

```
CREATE UNIQUE INDEX FACT_PK ON FACT (FACT_DATE,DIM1_FK,DIM2_FK);
CREATE BITMAP INDEX DIM1_FK ON FACT ( DIM1_FK );
CREATE BITMAP INDEX DIM2_FK ON FACT ( DIM2_FK );
```


Implementación de un DW

Ejemplo: ROLAP sobre Oracle

Plan de ejecución de una consulta (bitmap index)

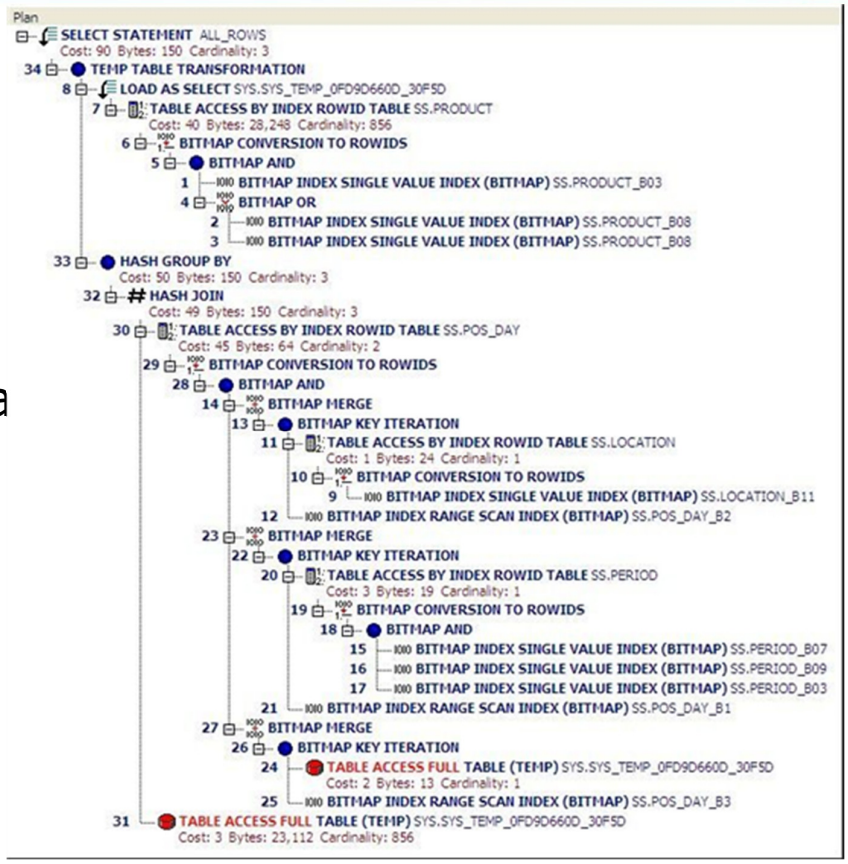

Implementación de un DW

Ejemplo: ROLAP sobre Oracle

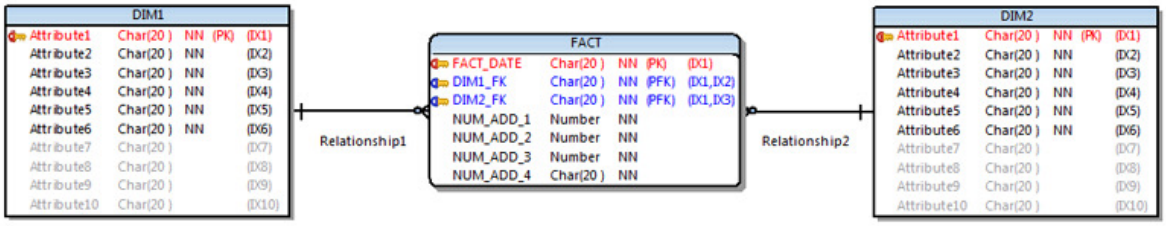

Índice bitmap join (uno por cada dimensión)

```
CREATE UNIQUE INDEX FACT_PK ON FACT (FACT_DATE,DIM1_FK,DIM2_FK);
CREATE BITMAP INDEX FACT_BJ1 ON FACT ( DIM1_FK )
  FROM FACT, DIM1
  WHERE FACT.DIM1_FK = DIM1.ATTRIBUTE1;
CREATE BITMAP INDEX FACT_BJ2 ON FACT ( DIM2_FK )
  FROM FACT, DIM2
  WHERE FACT.DIM2_FK = DIM2.ATTRIBUTE1;
```


Implementación de un DW

Ejemplo: ROLAP sobre Oracle

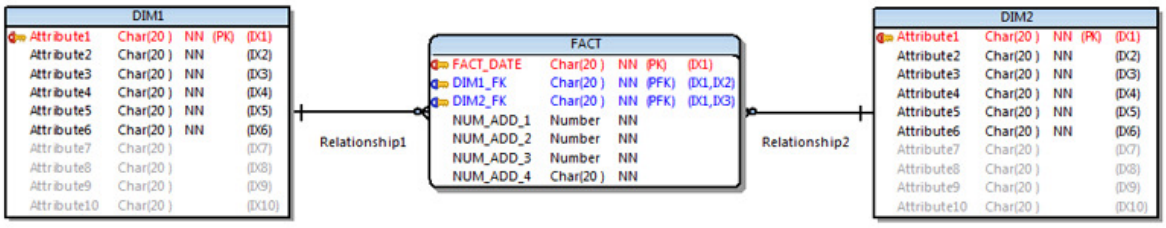

Índice bitmap join (único para las dos dimensiones)

```
CREATE UNIQUE INDEX FACT_PK ON FACT (FACT_DATE,DIM1_FK,DIM2_FK);
CREATE BITMAP INDEX FACT_BJ ON FACT ( DIM1_FK, DIM2_FK )
  FROM FACT, DIM1, DIM2
  WHERE FACT.DIM1_FK = DIM1.ATTRIBUTE1
    AND FACT.DIM2_FK = DIM2.ATTRIBUTE1;
```

Implementación de un DW

Ejemplo: ROLAP sobre Oracle

Plan de ejecución de una consulta (bitmap join)

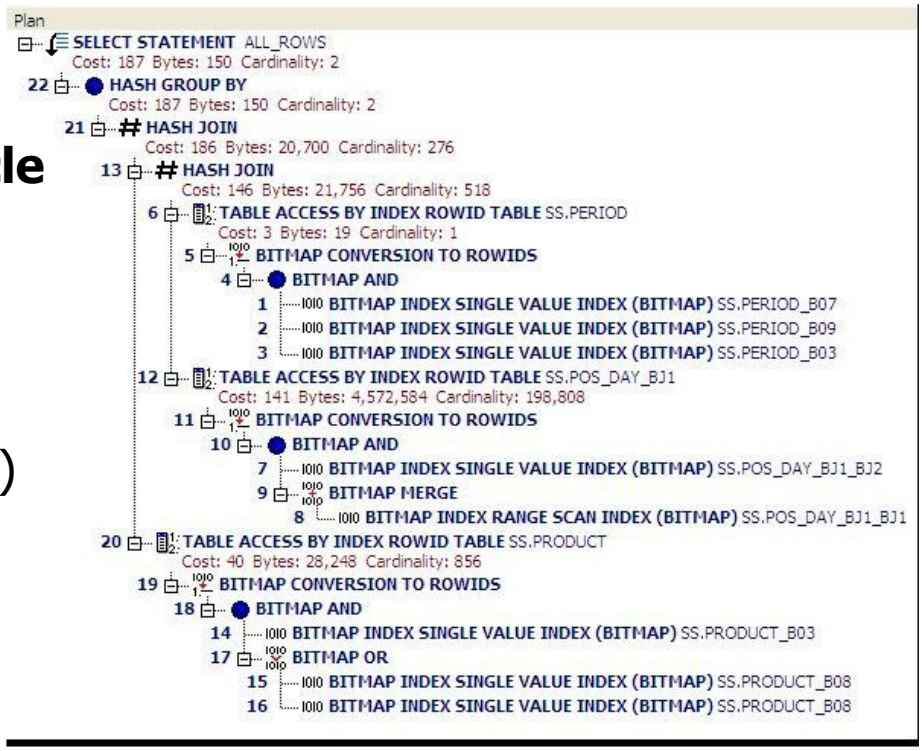

Soluciones DW

MPP [Massive Parallel Processing]

- Shared-nothing architectures vs. SMP [Symmetric Multiprocessing]
- Escalabilidad horizontal (añadiendo nodos).
- Descomposición de consultas (procesamiento paralelo en varios nodos).
- Mayor tasa de ingestión de datos (movimiento de datos en paralelo).

Soluciones DW

Mercado

- Proveedores especializados:
  Teradata, Netezza, Vertica, Greenplum
- Proveedores de gestores de bases de datos:
  Microsoft PDW [Parallel Data Warehouse],
  IBM DB2 UDB with DPF [DB Partitioning Feature]
  Oracle Exadata & Oracle Big Data Appliance
- Soluciones híbridas con Hadoop: Impala, Stinger, Apache Drill, Shark, Hadapt, Teradata SQL-H (Aster Data), EMC HAWK, IBM BigSQL…

Soluciones DW

Costes relativos de distintas plataformas

Teradata	Hardware and licenses the most expensive of all options. Staff costs can be expensive and it takes a great deal of effort to configure and administer.
IBM Netezza	Hardware and licenses used to be much less than Teradata, but prices have been converging. Some of the highest staff cost due to scarcity, but that's tempered by lower effort for configuration and admin of single purpose appliance.
Greenplum	Commodity hardware. Moderately priced licenses. Few Greenplum specialists, but can be staffed by PostgreSQL DBAs and developers.
Vertica	Commodity hardware. Moderately priced licenses, but special purpose orientation limits usefulness. Few specialists, but can be staffed by traditional DBAs and developerss.
Hadoop HBase	Commodity hardware and no license cost, resulting in lowest up-front cost. Likely to buy more hardware for redundancy and load. But requires highly technical staff and implementation is less productive than more mature options.

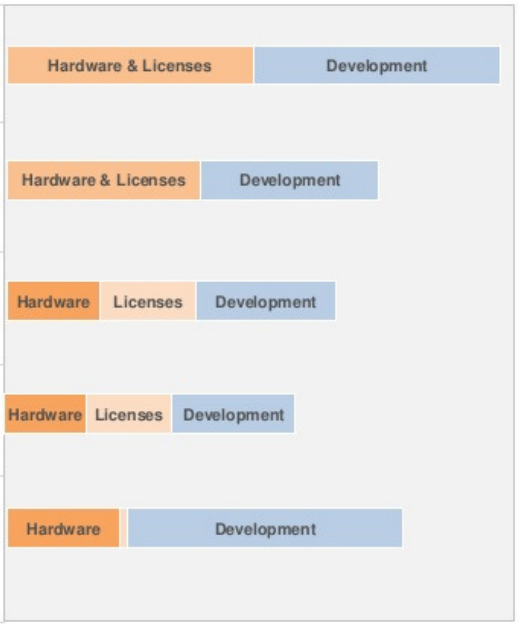

Hardware a medida (p.ej. FPGA)

Open Source

Tendencias

DBMS Market: $80B @ 2021

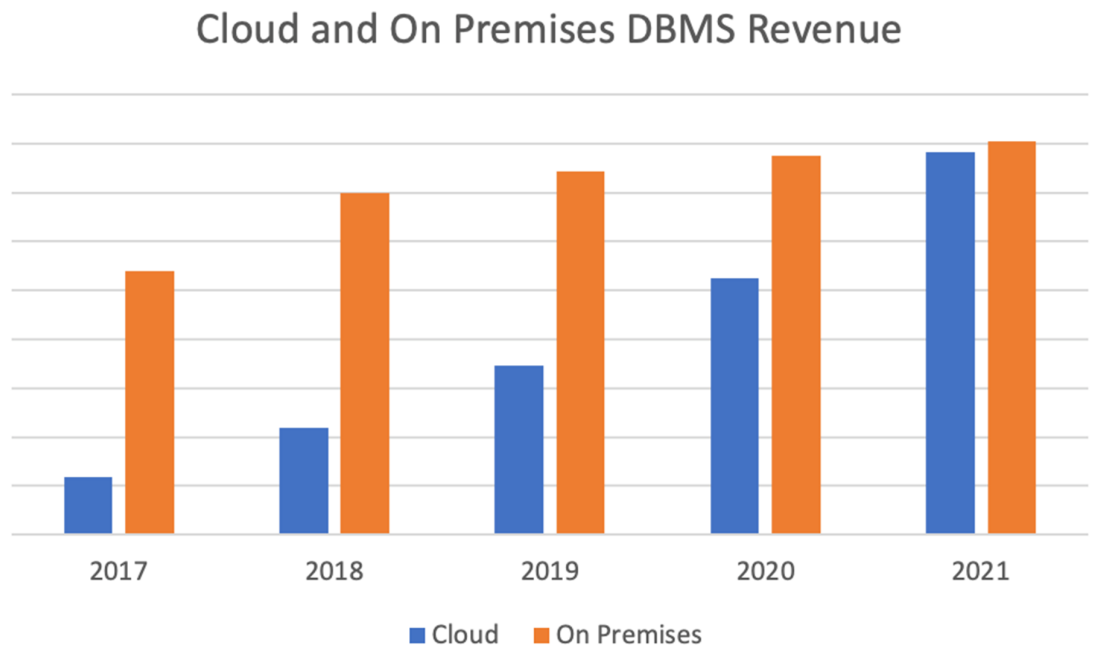

Tendencias

DBMS Market: $80B @ 2021

2017		2018		2019		2020		2021	
Vendor	Share	Vendor	Share	Vendor	Share	Vendor	Share	Vendor	Share
Oracle	36.1%	Oracle	31.1%	Oracle	27.4%	Microsoft	24.3%	Microsoft	24.0%
Microsoft	21.5%	Microsoft	23.6%	Microsoft	24.7%	Oracle	23.8%	AWS	23.9%
IBM	12.7%	AWS	13.5%	AWS	17.1%	AWS	20.6%	Oracle	20.6%
AWS	9.2%	IBM	10.4%	IBM	8.8%	IBM	6.8%	Google	6.5%
SAP	7.4%	SAP	6.9%	SAP	6.5%	SAP	5.6%	IBM	5.6%

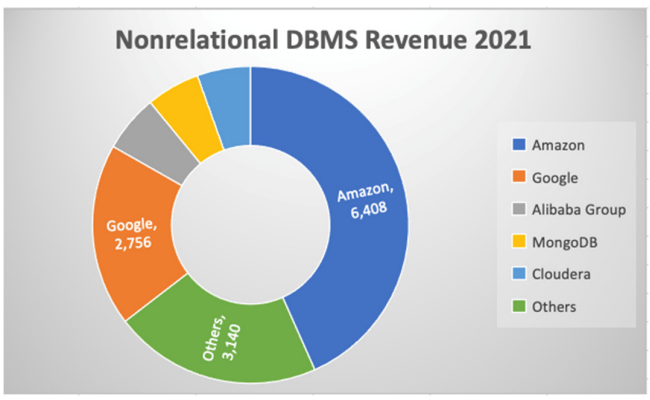

Figure 1: Magic Quadrant for Cloud Database Management Systems

Source: Gartner (December 2022)

Tendencias

In-Memory DBMS

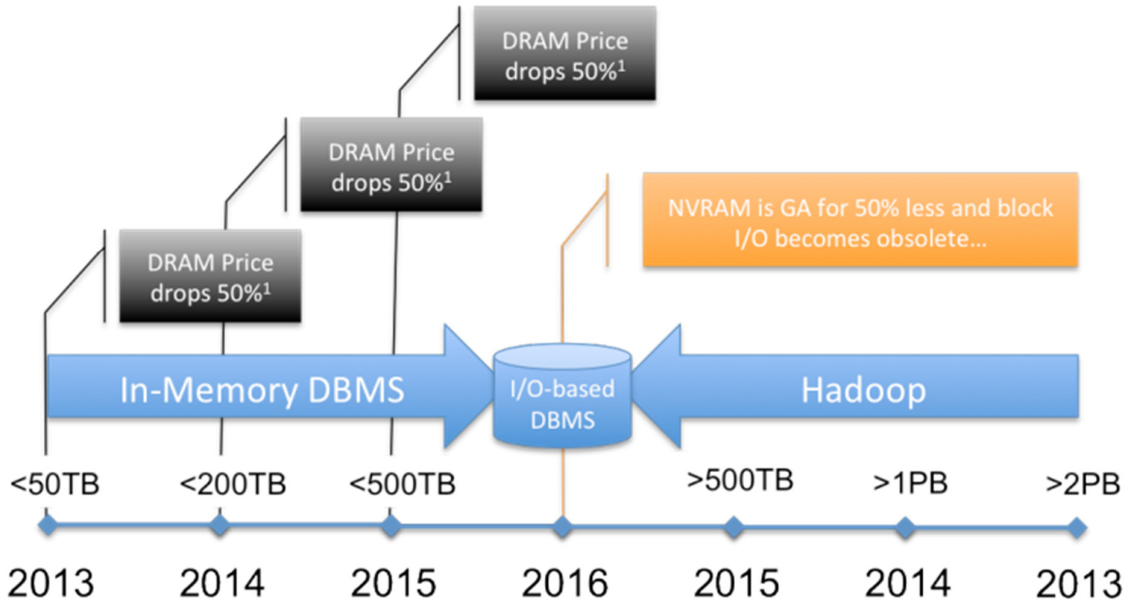

[1] Gartner Forecast: Memory, Worldwide, 2006-2016, 2Q12 Update

Fig. 1 – The Squeeze

En el futuro…

RAMCloud

Stanford University [2009-2017]

"a general-purpose storage system…
which keeps all of its data in DRAM at all times."

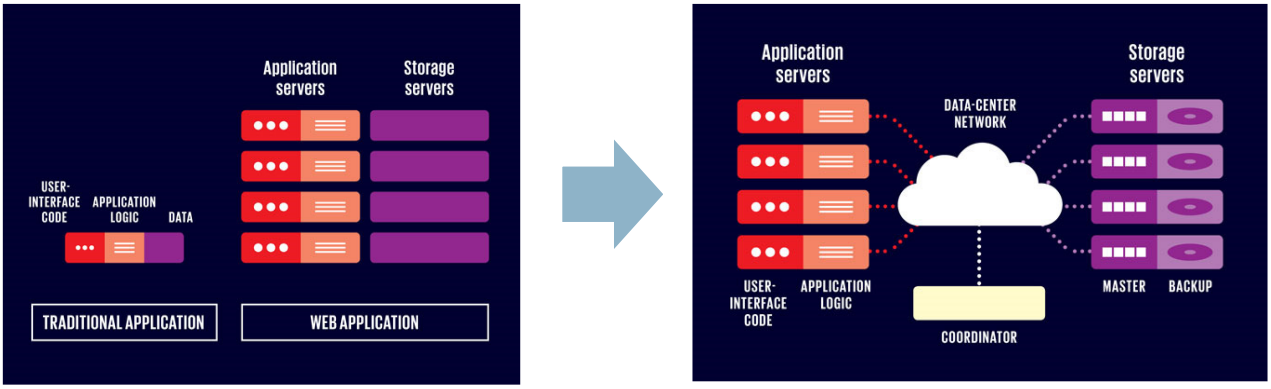

A Radical Proposal: Replace Hard Disks With DRAM
IEEE Spectrum, October 2015
http://spectrum.ieee.org/computing/hardware/a-radical-proposal-replace-hard-disks-with-dram

En el futuro…

"The Machine"

Hewlett-Packard Labs

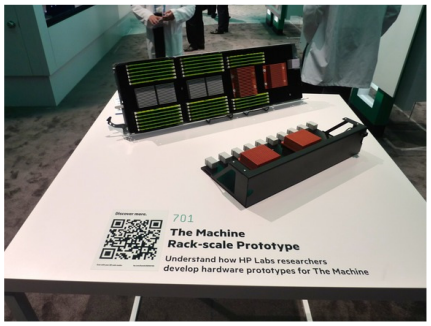

"Universal Memory"
Say goodbye to disk drives

- The goal: "… with this architecture we can ingest, store, manipulate truly massive datasets while simultaneously achieving multiple orders of magnitude less energy per bit."
- The biggest missing piece: "the memristor - a resistor that stores information after losing power and that would allow computers to store and retrieve large datasets far more rapidly than is possible today."

Inside The Machine: Hewlett Packard Labs mission to remake computing
http://www.techrepublic.com/article/inside-the-machine-hewlett-packard-labs-mission-to-remake-computing/

En el futuro…

HPC wire

Since 1987 - Covering the Fastest Computers in the World and the People Who Run Them

- Home
- Topics
- Sectors
- Exascale

HP Removes Memristors from Its 'Machine' Roadmap Until Further Notice
By Tiffany Trader

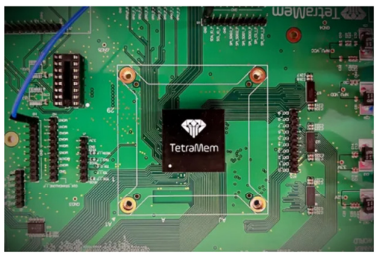

Analog-in-memory AI processor startup uses memristors
Business news | July 22, 2022
By Nick Flaherty

AI · ANALOG · MPUS/MCUS · PLDS/FPGAS/ASICS · ARTIFICIAL INTELLIGENCE

NPU
20 TOPS/W

TECHSPOT

TRENDING · FEATURES · REVIEWS · THE BEST · DOWNLOADS · PRODUCT FINDER · FORUMS · JOBS

HARDWARE · INDUSTRY · RERAM · MEMRISTORS

UK startup wants to turn the RRAM dream into reality

Intrinsic secured funds to build a business around its non-volatile RRAM tech

By Alfonso Maruccia March 14, 2023 at 2:08 PM

En el futuro…

3D XPoint

Intel & Micron

a.k.a.

Intel Optane

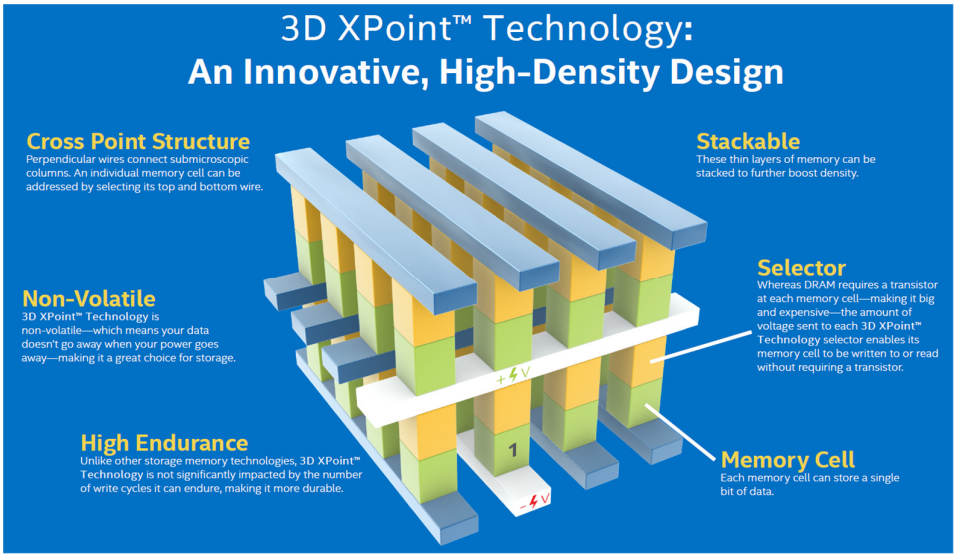

- Memoria no volátil.
- Más rápida que la memoria flash, más lenta que la memoria DRAM.

https://en.wikipedia.org/wiki/3D_XPoint

En el futuro…

TECHSPOT

TRENDING FEATURES REVIEWS THE BEST DOWNLOADS PRODUCT FINDER FORUMS JOBS

Intel and Micron announce 3D XPoint, a new memory technology that's 1,000 times faster than NAND

By Shawn Knight July 28, 2015 at 1:03 PM

De 2015…

… a 2022

TECHSPOT

TRENDING FEATURES REVIEWS THE BEST DOWNLOADS PRODUCT FINDER FORUMS JOBS

Micron is selling its former 3D XPoint fab to Texas Instruments for $900 million

Micron is recouping come of its 3D XPoint investment

By Shawn Knight July 1, 2021 at 10:03 AM

TECHSPOT

TRENDING FEATURES REVIEWS THE BEST DOWNLOADS PRODUCT FINDER FORUMS JOBS

Intel lost half a billion dollars last quarter, confirms price increases, Optane shut down

More expensive CPUs, Optane memory business is going away

By Tudor Cibean July 29, 2022 at 10:19 AM | 41 comments

The Register

Why the end of Optane is bad news for all IT

The biggest new idea in computing for half a century was just scrapped

Liam Proven Mon 1 Aug 2022 // 13:34 UTC

En el futuro…

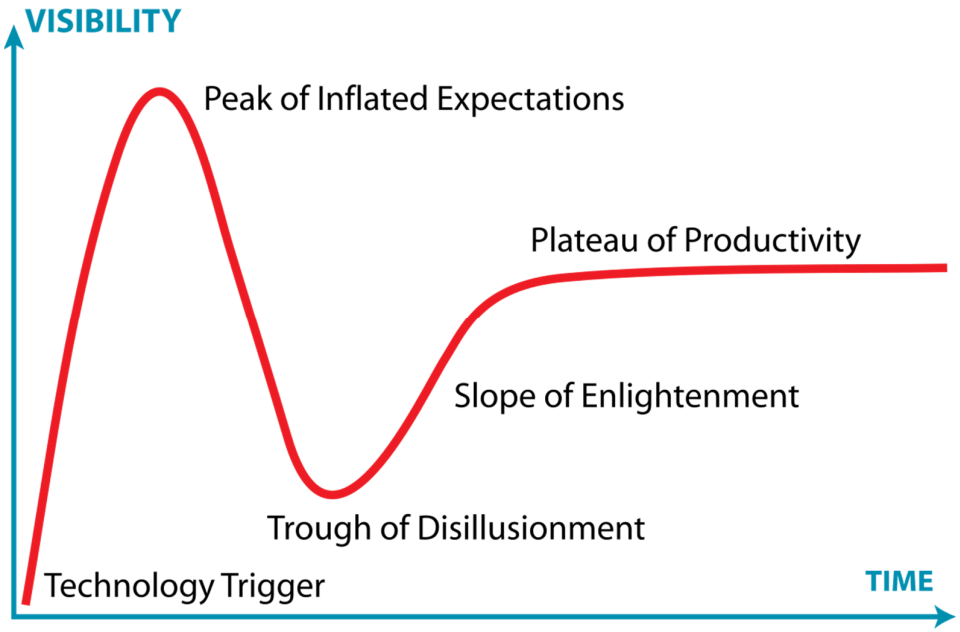

https://en.wikipedia.org/wiki/Gartner_hype_cycle

En el futuro…

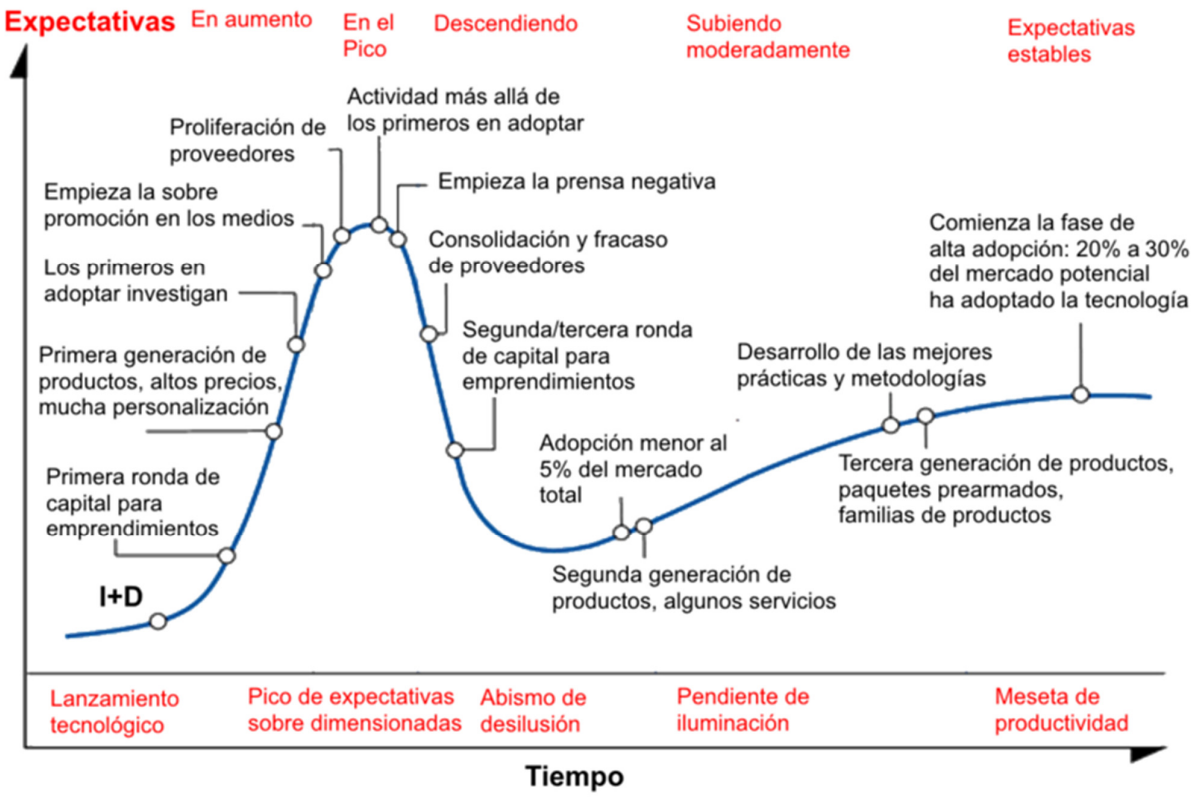

Bibliografía recomendada

- Ralph Kimball & Margy Ross:
  The Data Warehouse Toolkit: The Definitive Guide to Dimensional Modeling.
  Wiley, 3rd edition, 2013.
  ISBN 1118530802

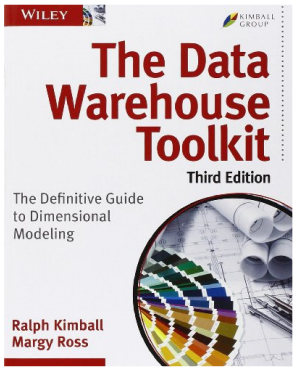

- Ralph Kimball & Joe Caserta:
  The Data Warehouse ETL Toolkit.
  Wiley, 2004.
  ISBN 0764567578

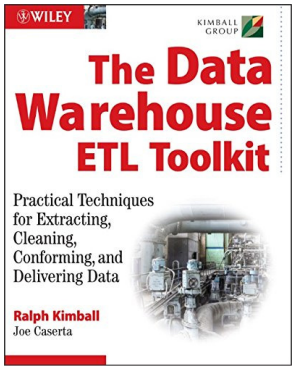

Business Intelligence

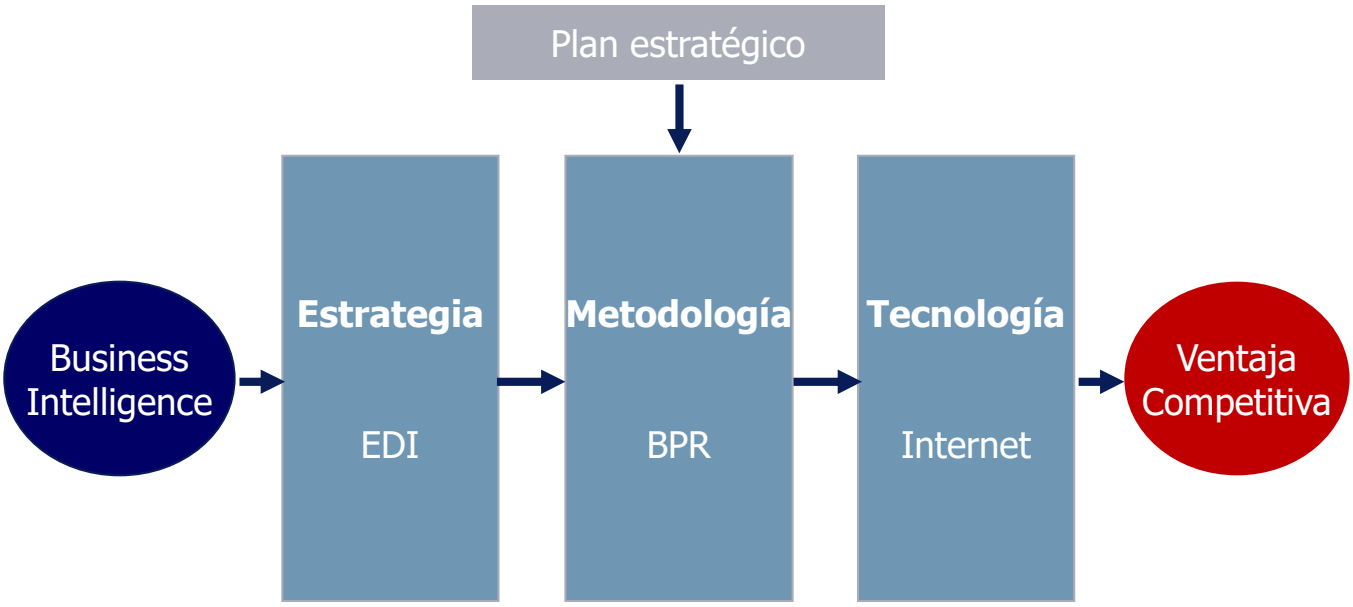

Business Intelligence

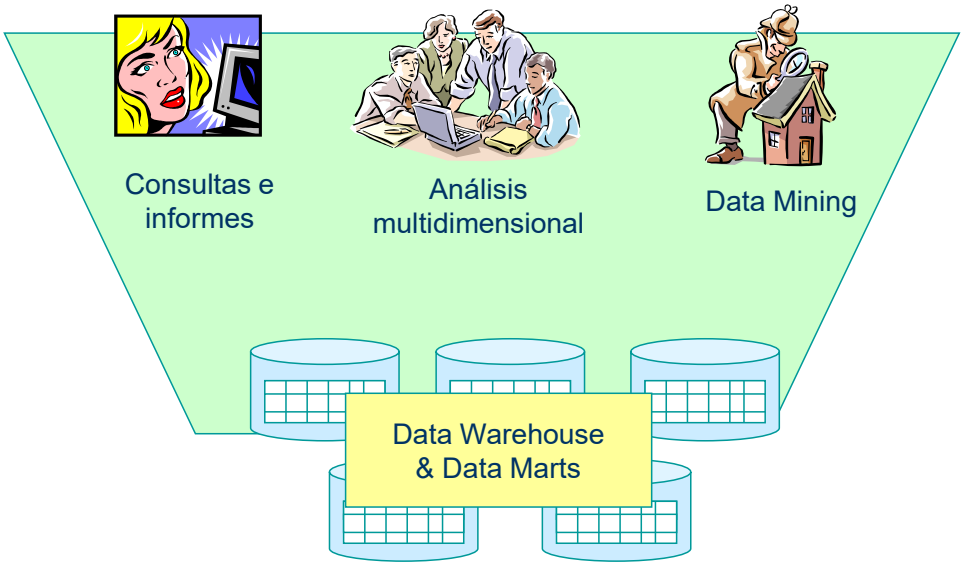

Business Intelligence

BI [Business Intelligence]

- Recopilación de datos: ETL
- Almacenamiento: DW
- Análisis: Data Mining
- Evaluación
- Diseminación: Informes

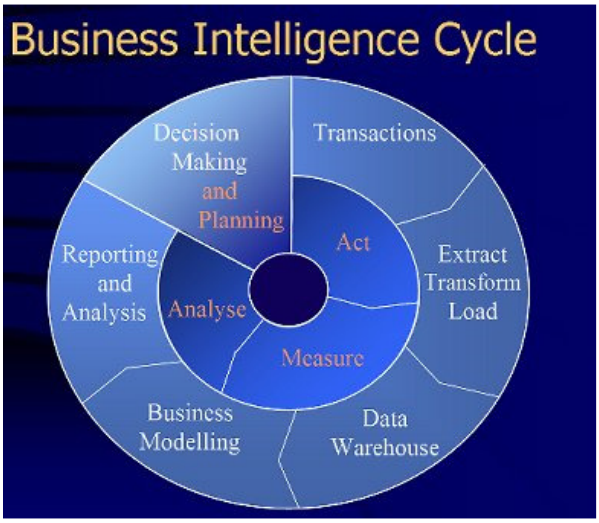

Business Intelligence

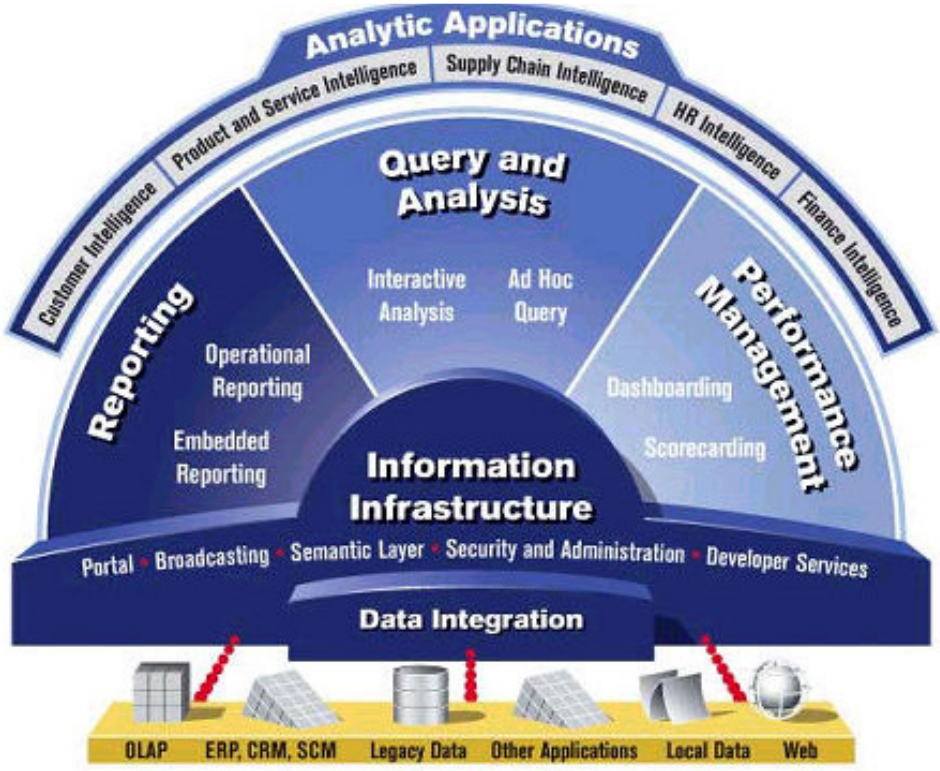

Business Intelligence

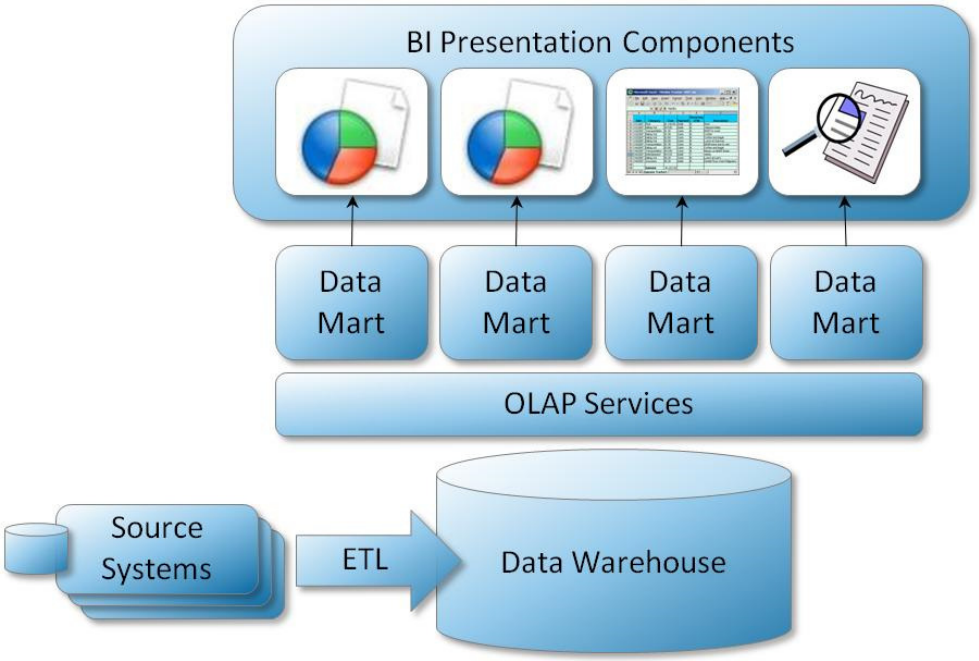

Business Intelligence

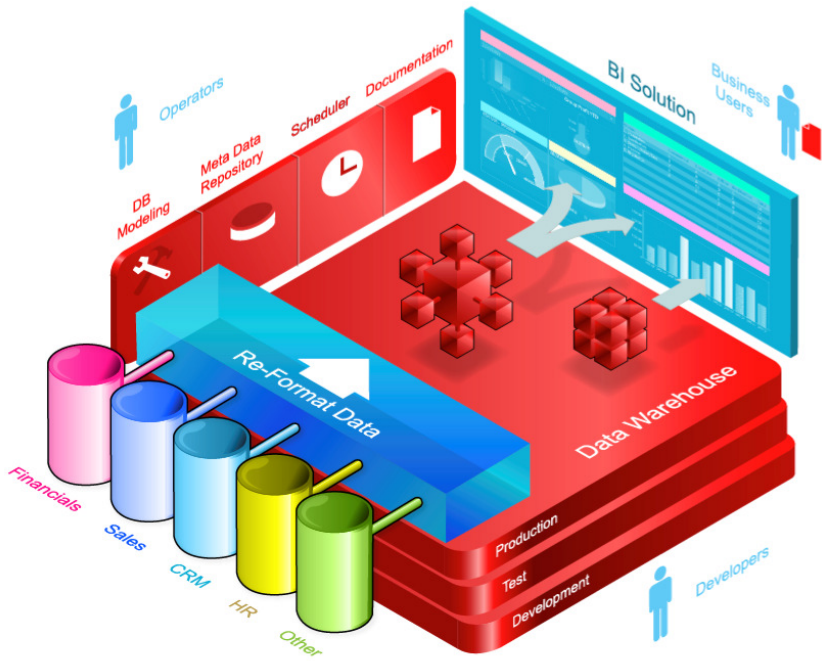

Business Intelligence

Data Analytics

4 types of Data Analytics

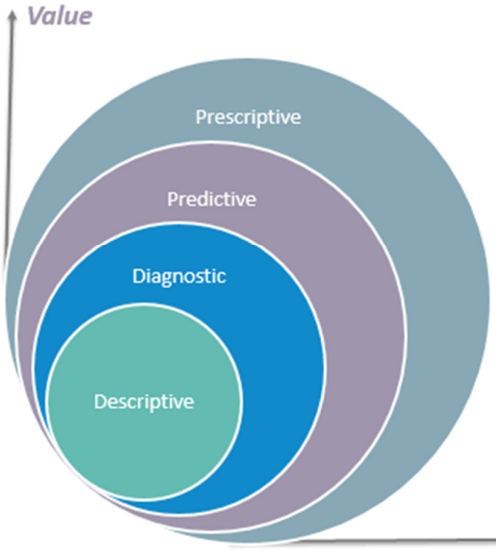

What is the data telling you?

Descriptive: ***What's happening in my business?***

- Comprehensive, accurate and live data
- Effective visualisation

Diagnostic: ***Why is it happening?***

- Ability to drill down to the root-cause
- Ability to isolate all confounding information

Predictive: ***What's likely to happen?***

- Business strategies have remained fairly consistent over time
- Historical patterns being used to predict specific outcomes using algorithms
- Decisions are automated using algorithms and technology

Prescriptive: ***What do I need to do?***

- Recommended actions and strategies based on champion / challenger testing strategy outcomes
- Applying advanced analytical techniques to make specific recommendations

Principa
www.principa.co.za