CAPITULO 3

CONSTRUCCIÓN DEL DATA WAREHOUSE

Transformar los datos en conocimiento es un proceso complejo. Este proceso de transformación e integración de los datos puede sintetizarse a través de las etapas representativas de un método industrial ilustrado por los siguientes pasos:

1. Ensamblar las materias primas (los datos de diferentes fuentes),
2. Según instrucciones específicas (el metamodelo),
3. Para realizar un producto terminado (los datos analíticos),
4. Almacenado en un almacén de datos (el Data Warehouse),
5. Para su disponibilidad fácil de cara a los Clientes (los usuarios finales)

La **Figura No. 10** ilustra el marco general de un Data Warehouse.

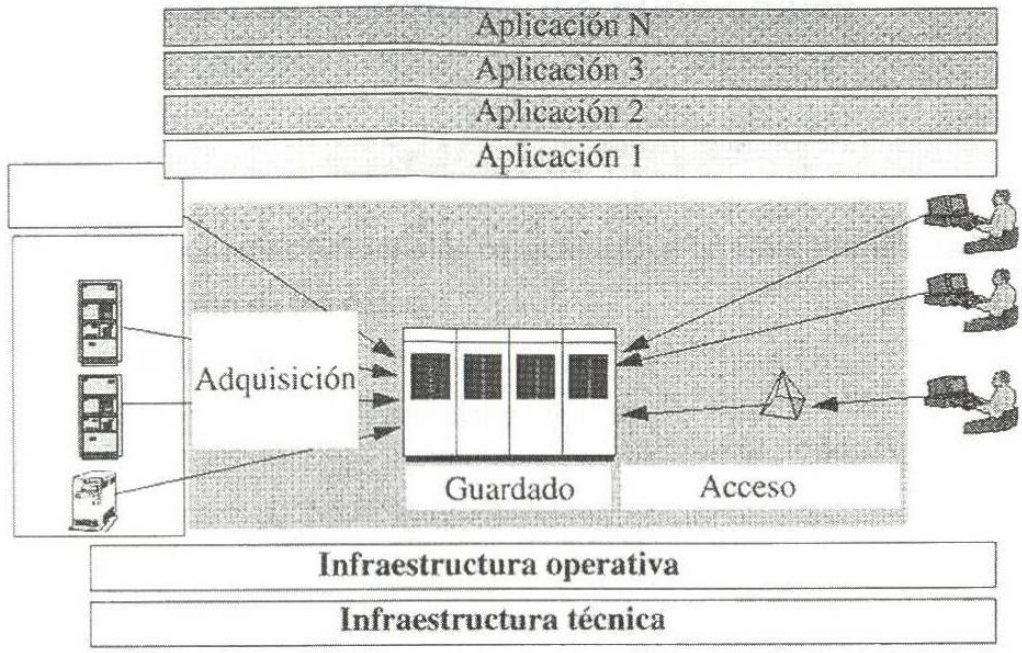

Figura No. 10

Un Data Warehouse no se construye en una sola iteración. Cada tema tratado se descompone en un conjunto de iniciativas (las aplicaciones). El perímetro de cada aplicación debe estar claramente definido (actores afectados, frecuencia y periodicidad de los análisis, objetivos y naturaleza de las vueltas sobre la actividad de la empresa ...). Las aplicaciones deben ser controlables y proporcionar resultados «tangibles» en un plazo de menos de seis meses, que corresponde al plazo medio de realización de una aplicación. Esta descomposición en aplicaciones aporta numerosas ventajas, pero genera dificultades sobre ciertos temas, como los relacionados con la infraestructura técnica y organizativa que necesitan que se imagine una visión más global. Una aplicación puede también ser un programa de decisión. En este caso, conviene asegurarse de que se integra en la infraestructura global.

3.2 Los Componentes Funcionales

Tres componentes funcionales caracterizan a un Data Warehouse:

1. La adquisición de los datos,
2. Su almacenamiento, y
3. El acceso por parte de los usuarios finales.

3.2.1 La adquisición de los datos

La adquisición de los datos se desarrolla en tres etapas:

a) La extracción,
b) La preparación, y
c) La carga.

a) La extracción de los datos consiste en recoger los datos útiles en el sistema de producción. Primero hay que identificar los datos que hayan evolucionado a fin de extraer el mínimo de datos, luego planificar estas extracciones a fin de evitar las saturaciones (red, entradas / salidas y unidad central) del sistema de producción. La integridad de los datos extraídos es obligatoria y precisa en consecuencia la sincronización de los diferentes procesos de extracción. Los problemas relacionados con esta necesaria sincronización pueden ser complejos, ya sea funcionalmente o bien técnicamente en entornos muy heterogéneos.

Para extraer los datos originales, se pueden usar varias tecnologías:

- **Pasarelas**, proporcionadas principalmente por los editores de bases de datos; estas pasarelas son generalmente insuficientes porque están orientadas esencialmente a datos y soportan con dificultad procesos (programas) de transformación complejos;
- **Utilidades de replicación**, utilizables si los sistemas de producción y el sistema de decisión son homogéneos y si la transformación a aplicar a los datos es ligera;
- **Herramientas específicas de extracción**; estas herramientas son sin duda la solución operativa al problema de la extracción, pero su precio elevado limita su uso en las primeras aplicaciones.

b) La preparación de los datos corresponde a la transformación de las características de los datos del sistema operativo en la forma definida del Data Warehouse. Esta preparación incluye la correspondencia de los formatos de datos, la limpieza, la transformación y la agregación. Este proceso de transformación accederá naturalmente a todas las informaciones almacenadas en el diccionario, especialmente la localización de las fuentes de datos y sus estructuras en el sistema de producción, la estructura objeto del Data Warehouse, las reglas de identificación, de asociación, de transformación y de agregación de los datos y las reglas de seguridad. La limpieza de los datos es una etapa sobre la que actualmente trabajan numerosos editores. Además de la calidad de los datos que aportan, las herramientas de limpieza permiten suprimir los duplicados en los archivos. La supresión de los duplicados es un proceso que se justifica rápidamente. Un ejemplo permite ilustrar este punto. Se refiere a una experiencia vivida regularmente por cada uno de nosotros cuando abrimos nuestros buzones y encontramos cartas idénticas que se refieren a la misma promoción o al mismo servicio, con la única diferencia debida al destinatario.

c) La carga es la última etapa de la alimentación del Data Warehouse. Se trata de una etapa delicada especialmente cuando los volúmenes son importantes.

Para obtener buenos rendimientos de carga, es imperativo controlar las estructuras del SGBD (tablas e índices) asociadas a los datos cargados para optimizar al máximo estos procesos. Por ejemplo, en grandes cargas, es preferible indexar las tablas una vez cargados los datos en lugar de indexarlos al mismo tiempo que se cargan. Además, las técnicas de paralelismo optimizan las cargas pesadas.

3.2.2 El almacenamiento de los datos

El componente básico de soporte del almacenamiento es el SGBD. Además del almacenamiento, el SGBD debe proponer extensiones para responder a las características del acceso a la decisión. Estas tecnologías se relacionan principalmente con el paralelismo de las consultas y con diversas optimizaciones propuestas para acelerar las selecciones y las agrupaciones de conjuntos.

Debido a la importancia del historial en un Data Warehouse, la estructuración física de los datos es también muy importante. Una partición física de las tablas en unidades menores según el criterio tiempo aporta rendimientos estables en el tiempo, facilidades para la recuperación, las indexaciones, las reestructuraciones y el archivo. También resulta más fácil almacenar estos datos en soportes menos costosos que los discos.

El último elemento relacionado con el almacenamiento concierne a los tipos de datos. Hoy, sólo el 15% de la información se almacena en formato electrónico y la principal razón de este bajo porcentaje proviene del hecho de que una información debe descomponerse primero en una serie de enteros, de

147975

reales y de textos antes de almacenarse en un SGBD de producción. Los editores realizan muy fuertes evoluciones en lo que algunos denominan la «gesfión de contenido». Aportar una mejor respuesta a ésta pasa por la integración en el SGBD de nuevos tipos de datos que permitan almacenar y manipular estructuras multimedia compuestas de documentos, de imágenes, de sonidos, de vídeos, etc. El avance de Internet acelerará también, sin duda, esta evolución. Una vez que los SGBD sepan gestionar eficientemente estas nuevas estructuras, permitirán el almacenamiento y la manipulación de informaciones nuevas, complementarias a las informaciones tradicionales aportándoles valor en los procesos de toma de decisión.

El SGBD aporta, finalmente, la transparencia a la evolución del hardware (scalability en inglés), la independencia, ya sea en los tipos y el número de procesadores, los discos o la memoria, así como la transparencia ante la evolución de los sistemas operativos. Sin embargo hay que tener cuidado con las afirmaciones de los editores y constructores, porque esto tiene un costo y unos límites.

3.2.3 El acceso a los datos

Definir una arquitectura global que dé soporte a los accesos de decisión impone opciones tecnológicas no estructuradoras. Este método es el mismo que el que ha llevado a las empresas a orientarse hacia la arquitectura cliente/servidor, y mas recientemente a la Web, para sus aplicaciones transaccionales. Una de las bases de esta arquitectura es que permite implementar una infraestructura común a todas las aplicaciones de decisión,

dejando a los usuarios la oportunidad de utilizar las soluciones mejor adaptadas a su problemática: un grupo de usuarios deseará efectuar consultas simples o complejas sobre los datos que les interesen; otro grupo querrá efectuar análisis sobre informaciones muy estructuradas y agregadas; otro servicio necesitará hacer extrapolaciones o simulaciones a partir de la información existente.

La **Figura No. 11** ilustra la lógica de esta arquitectura, que da a los usuarios puntos de vista diferentes según las herramientas utilizadas.

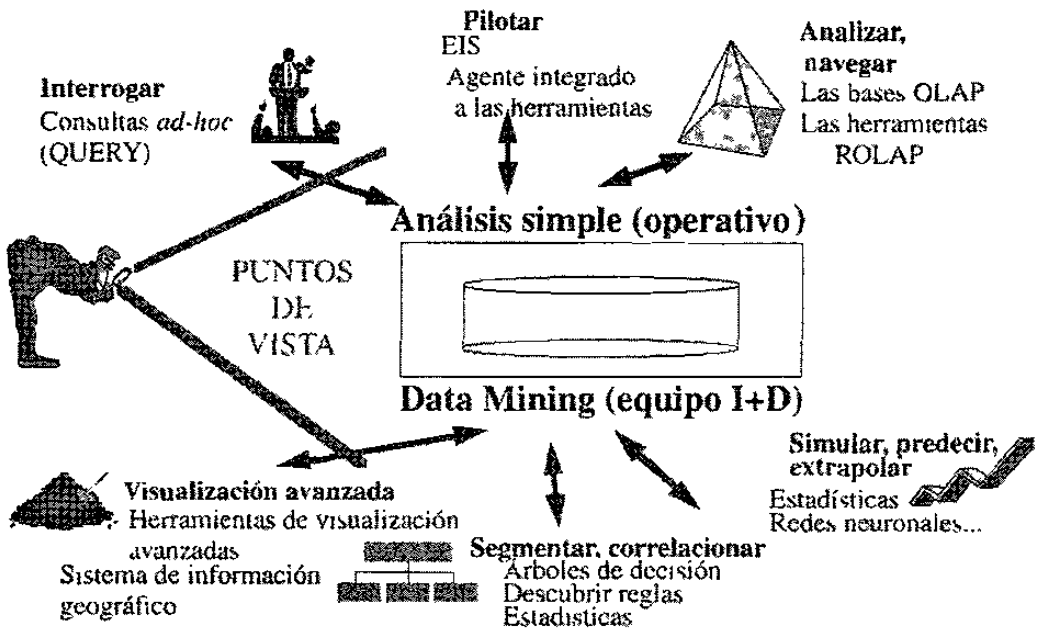

Figura No. 11

Sea cual sea el tipo de la herramienta, tendrá que adaptarse a las exigencias del usuario y a su manera de trabajar. En el mundo de la decisión, el análisis es iterativo y los resultados de la consulta actual influyen a menudo en la consulta siguiente. «Dame lo que te pido, que luego podré decirte lo que quiero realmente» es una fórmula que refleja bien este comportamiento.

3.3 Las Infraestructuras

Para responder a estas necesidades, el nuevo papel de la informática es definir e integrar una arquitectura sobre la que se basarán las aplicaciones de decisión.

Hay que considerar dos niveles de infraestructura en un Data Warehouse:

- La infraestructura técnica, es decir, el conjunto de componentes materiales y programas, y
- La infraestructura operativa, es decir, el conjunto de procedimientos y servicios para administrar los datos, gestionar los usuarios y utilizar el sistema.

3.3.1 La infraestructura técnica

Se compone de productos que implementan las tecnologías elegidas integrados en un conjunto coherente y homogéneo. Estas opciones técnicas afectan a los componentes materiales y programas junto con los componentes funcionales que son la alimentación, el almacenamiento y el acceso.

3.3.2 La infraestructura operativa

Se compone de todos los procesos que permiten, a partir de los datos de producción, crear y gestionar el sistema de decisión. Las grandes funciones de esta infraestructura conciernen a la administración de los datos, la gestión de los usuarios en el sentido de apoyo y administración y el uso del sistema de decisión. Esta última función es muy importante porque afecta a la ordenación y a la gestión de los flujos de datos de los sistemas originales al sistema destinatario (la gestión del rendimiento, de la seguridad, etc.)

CAPITULO 4

ELABORACIÓN DE UN DATA WAREHOUSE

En lugar de pretender proponer un método «llave en mano» para la elaboración de un Data Warehouse, el objetivo de esta guía es proponer un marco, que podrá servir de base para una apropiación en relación con el contexto de una empresa.

Este marco parte de los principios siguientes, puntos comunes a la mayoría de las Organizaciones actuales:

- El objetivo no es construir un sistema de decisión aislado o al margen de otro sistema, sino más bien implementar un sistema de información coherente e integrado.
- Este sistema no se construye en un solo bloque. Se descompone en aplicaciones, integrándose cada una de ellas al marco general del Data Warehouse. Su implementación es pues incremental, constituyendo cada aplicación la unidad de incremento.

Estos dos objetivos son simples de enunciar, pero más complejos de realizar, ya que implican restricciones. Renunciar a hacer frente a estas restricciones podrá llevar el proyecto hacia una deriva clásica en la informática:

construir tantos sistemas como necesidades de decisión haya en la empresa, renunciando a su integración, juzgada demasiado compleja, costosa o difícil de vender, especialmente por razones políticas. Esta deriva entraña, entre otros, dos riesgos principales.

El primero es limitar el valor de la información contenida en el Data Warehouse. Si, por ejemplo, las informaciones respecto a las ventas no son coherentes con las que afectan a las compras, porque se han modelado en dos Data Marts diferentes, el sistema perderá una parte considerable de su valor para la empresa.

El segundo es implicar un costo informático considerable a largo plazo. Para convencerse de este punto, basta con observar las realizaciones de Data Warehouse actuales. Si algunas de ellas son complejas, es precisamente porque la información necesaria para su constitución se encuentra desperdigada en una multitud de sistemas, herencia de la empresa, no integrados entre sí. Cuando los sistemas de información tienen que gestionar informaciones cada vez más diversas y voluminosas, se hace imperativo evitar que se «desintegren» y el Data Warehouse constituye una oportunidad para alcanzar este objetivo.

4.1 Estrategia de elaboración del Data Warehouse

Un proyecto de Data Warehouse puede ser descompuesto en 4 etapas.

La primera etapa, titulada ***«descubrir y definir las iniciativas»***, es a nivel de empresa – esta etapa permitirá definir el porqué del Data Warehouse,

informar sobre el beneficio esperado, sus características, sus aplicaciones para los actores afectados. Finalmente, permitirá determinar las aplicaciones a realizar (o proyectos) en este marco, estimará los beneficios esperados y dará un plan de acción para su implementación y ordenación.

La segunda etapa llamada ***«determinación de la infraestructura»*** permitirá definir la infraestructura técnica y organizativa del Data Warehouse.

La tercera etapa, conocida como ***«implementación de las aplicaciones»*** implementará las aplicaciones, una por una, y las desplegará.

La cuarta y última etapa nombrada ***«evaluación de resultados»*** la cual se refiere a evaluar los resultados obtenidos, en términos de costos y beneficios, por la implementación del Data Warehouse.

4.1.1 El descubrimiento y definición de las iniciativas

El método utilizado por esta primera etapa esta muy bien representada por la **Figura No. 12**. Primero definiremos los objetivos de cada una de las etapas presentadas en ella y posteriormente presentaremos los puntos clave necesarios para su desarrollo.

Figura No. 12

Los tres estadios superiores de la pirámide son fundamentales y afectan más a la empresa y a su estrategia que a la informática propiamente dicha; de ahí el término de «estudio estratégico» utilizado, que se encuentra bajo diferentes terminologías anglosajonas como Strategic Information Analysis ó Business Information Planning.

En nuestro contexto, ***el estudio estratégico***, se trata de :

- Informar y motivar a los actores de la empresa afectados por esta etapa inicial a fin de que se comprometan en el proceso de implementación de los proyectos de decisión: es la función de la etapa de sensibilización, de patrocinio (sponsorship), y de preparación para el cambio;

- Implicar a la dirección, a los equipos operativos y a los equipos informáticos, para que participen en la etapa de identificación y de comprensión de los objetivos de empresa que un Data Warehouse contribuiría a alcanzar; es la etapa de identificación y de comprensión de los desafíos;

- Identificar de manera más precisa los proyectos a realizar para alcanzar los objetivos identificados anteriormente.

A esta etapa le sigue la, **elaboración del plan de acción**, en la que se trata de:

- Asegurar la viabilidad de cada uno de los proyectos. En efecto, un Data Warehouse se basa en datos existentes, por lo que hay que asegurarse de su existencia y de su calidad. También deben tenerse en cuenta las restricciones técnicas (ejemplo: capacidad y voluntad de soportar grandes volúmenes de datos) u organizativas (ejemplo: impactos demasiado importantes o juzgados no realistas, inadecuación de las soluciones propuestas a los modos de trabajo de los equipos implicados por el proyecto).

- Estimar los recursos necesarios para la implementación de cada proyecto (costo de desarrollo, costo de programas y materiales, costo de administración, duración...), así como los recursos necesarios para la implementación de la infraestructura técnica y organizativa. Esta etapa permite también estimar las ganancias aportadas por cada realización, y por tanto evaluar el retorno sobre inversión de cada uno de los proyectos.
- Secuenciar y planificar la realización de los proyectos.

Estas etapas pueden parecer largas de implementar; así mismo, a fin de mejorar el tiempo, es tentador eliminarlas o reducirlas a su mínima expresión. El riesgo es llegar a la construcción de un Data Warehouse sin objetivo claramente definido, como un fin en sí mismo y no como una palanca tecnológica al servicio de los desafíos de la empresa.

Sin embargo, es posible limitar el objetivo de esta etapa a un sector o a un ámbito preciso para la empresa, lo que le quita su carácter transversal. El objetivo buscado puede ser el retorno rápido sobre inversión, o la prueba del concepto para partir hacia metas más ambiciosas. Esto equivale a constituir un prototipo operativo, con retornos sobre inversión medibles.

Los prototipos pueden destinarse a probar los beneficios funcionales del concepto o a demostrar que son tecnológicamente factibles las iniciativas futuras.

4.1.2 La determinación de la infraestructura

Se trata de determinar la infraestructura necesaria para la puesta en marcha del Data Warehouse. Esta etapa necesita evidentemente efectuar un cierto número de opciones tecnológicas, pero va más allá. Se trata también de determinar la infraestructura organizativa para su desarrollo, pero también de gestionar la conducción del cambio necesario para su constitución.

La determinación de la política tecnológica es fundamental. Muchos conceptos o características de las nuevas tecnologías, como la escalabilidad o los sistemas abiertos, son interesantes porque permiten elegir los componentes informáticos mejor adaptados a su contexto de uso. Identificar claramente esto es pues fundamental, más que elegir tal o cual producto.

La Infraestructura técnica. En este punto deben tomarse opciones tecnológicas, evidentemente en sincronía con la política más global de la empresa. Entre éstas, podemos citar :

- La elección del o de los proveedores de tecnologías: ¿hay que orientarse hacia um producto integrado, propuesto por un editor de programas como SAS, un constructor, o hacia ciertos integradores? ¿O mejor inclinarse por ensamblar las mejores ofertas para cada módulo de la arquitectura? Elegir la primera aproximación tiene la ventaja de facilitar considerablemente la definición de la política tecnológica y reducir los costos de integración en la

implementación, pero en este caso es conveniente asegurarse de que la solución elegida responderá a las necesidades actuales y futuras del proyecto. En el segundo caso, la flexibilidad aportada podrá aprovecharse para una adaptación ajustada a las necesidades de cada iniciativa y de cada grupo de usuarios. Habrá que considerar entonces el trabajo de integración necesario.

- La elección de las herramientas: ¿deben construirse, comprarse o aprovechar lo que se tiene? Esta problemática se presenta particularmente en los componentes considerados como opcionales, como son las herramientas de extracción o los referenciales. En efecto, la justificación económica, el cálculo de los riesgos inducidos por su ausencia sobre la perennidad del proyecto y la aportación en términos de mantenimiento de estas herramientas tendrán un eco importante en su elección.
- ¿Cómo se utilizará el Data Warehouse, por qué y cómo se estructurará la organización que lo usará? Las respuestas a estas preguntas permitirán determinar qué arquitectura se utilizará: centralizada (un Data Warehouse), distribuida (varios Data Marts, sin Data Warehouse físico), replicada (un Data Warehouse físico y varios Data Marts)? Asimismo, permitirán determinar si se justifican tecnologías como Internet o la intranet para el sistema, para qué tipos de necesidad y para qué usuarios.
- La elección de la estructura de almacenamiento: ¿debe ser relacional, multidimensional o híbrida (Data Warehouse relacional, Data Marts multidimensionales por ejemplo)? ¿Se dará primacía a la portabilidad o se acepta una fuerte adhesión a una herramienta, a un sistema o a un hardware para centrarse en el rendimiento o las funcionalidades?
- La elección del hardware: según los volúmenes contemplados, la población afectada, la arquitectura pensada y la flexibilidad esperada, pueden estudiarse diferentes gamas de hardware.
- La elección de las infraestructuras destinadas a la administración de sistemas, a la gestión de la seguridad, etc.

Es evidente que será necesario asegurarse de que todas las soluciones elegidas funcionan entre sí. En el mejor de los casos. descrito en los folletos comerciales, todas son compatibles. Pero la realidad aporta su paquete de decepciones: es preferible asegurarse también de que existen referencias comunes entre los editores seleccionados y de que el soporte técnico propuesto sabrá resolver las incompatibilidades eventuales entre herramientas heterogéneas.

La Infraestructura organizativa. Paralelamente a estas elecciones, será necesario determinar la logística y la organización necesarias para la concreción de las iniciativas. El equipo responsable del Data Warehouse deberá diseñar cada iniciativa, desarrollarla y utilizarla. En este estadio, destaquemos que a nivel técnico un Data Warehouse es ante todo una mecánica de gestión de flujos de datos. Los equipos de desarrollo y uso se organizan a menudo respecto a lo siguiente:

- Un primer centro de competencias tiene la responsabilidad del proceso de alimentación de datos de los sistemas de producción hacia el Data Warehouse. Los individuos que constituyen el equipo deberán tener un buen conocimiento de los sistemas afectados, tanto en el plano técnico como funcional.
- El segundo centro de competencias está encargado de la gestión y el soporte del Data Warehouse propiamente dicho. Los administradores de datos y de bases de datos especialmente constituirán este equipo.
- El último centro de competencia es responsable de los flujos de informaciones que transitan entre los usuarios y su puesto de trabajo por un lado, y el Data Warehouse por el otro.

Los implicados podrán formar parte alternativamente de una u otra de las tres celdas. Esto es particularmente válido para quienes se encargan de la administración de sistemas y de la seguridad, pero también para quienes disponen de un buen conocimiento de los ámbitos funcionales.

Conducir el cambio. Según la experiencia de la empresa en el ámbito de la ayuda a la decisión, por una parte, y de las tecnologías y herramientas utilizadas, por otra, será necesario un plan de formación. También será muy importante que los miembros del equipo sean favorables al cambio, debido a las especificidades de los proyectos de decisión. Un desarrollador, por ejemplo, no podrá trabajar ante un informe de programación, sino que deberá tomar iniciativas, saber comunicarse con los usuarios y comprender sus necesidades en términos funcionales. La formación y, más generalmente, la conducción de cambio no deben negligirse, bajo ningún concepto, para todos los actores afectados por el proyecto.

Para un equipo informática, por ejemplo, una de las características de un proyecto de decisión es que es relativamente poco complejo de implementar técnicamente, pero está sembrado de trampas. Por ejemplo, supongamos que un programa de carga mal diseñado necesita horas para su ejecución. Si el equipo controla el entorno, en unos segundos el especialista del ámbito podrá disminuir este tiempo en un factor muy significativo. Si no lo controla, el problema bloquea el proceso y el proyecto encaja un retraso.

La gestión del cambio no afecta únicamente a los informáticos; también es necesario, en esta etapa, preparar el plan de gestión del cambio e identificar el o los promotores (sponsors) cuya función será hacer que lo acepten los actores afectados. Según la dimensión del proyecto global, podrán necesitarse varios promotores. En particular, a menudo es deseable identificar un promotor por iniciativa, y cada uno de ellos se asocia en general a una entidad operativo (mercadotecnia, comercial, logística, finanzas, recursos humanos...etc.)

4.1.3 La implementación de las aplicaciones

Esta etapa se realiza para cada iniciativa que la etapa de identificación de las necesidades ha permitido delimitar. El método propuesto aquí es un método en cinco etapas:

- Una etapa de especificaciones, que define y planifica las etapas siguientes de manera más precisa y detallada que en las etapas precedentes;
- Una etapa de diseño;
- Una etapa de implementación e integración;
- Una etapa de despliegue, integrando la conducción del cambio;
- Una etapa de medidas.

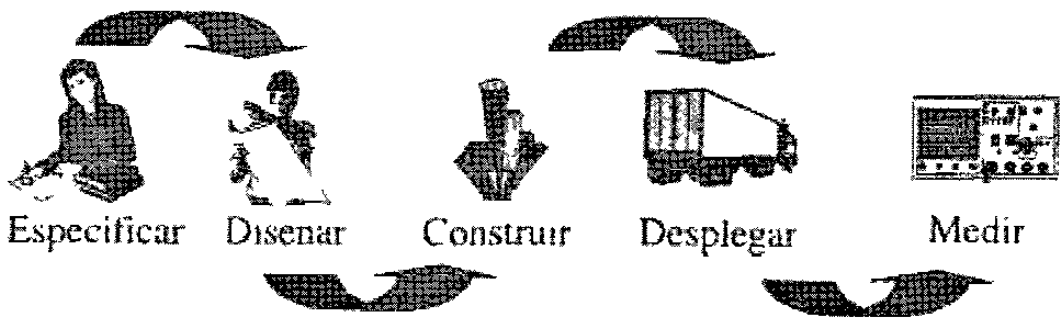

Figura No. 13

Esta división en etapas representada por la **Figura No. 13** resultará familiar a quienes tengan experiencia en la implementación de proyectos informáticos. Pero hay que insistir particularmente en las dos últimas etapas.

Se ha destacado ya la importancia de la conducción del cambio, pero aún no se ha tratado la importancia del control del despliegue. Un Data Warehouse utiliza implícitamente tecnologías cliente/servidor. Si bien hay acuerdo unánime sobre los menores costes del clientelservidor comparados con

los de entornos más tradicionales, todos los estudios demuestran que esta tecnología puede inducir costos ocultos. Si estos costos son ocultos es porque no se controlan, y esta falta de control afecta especialmente a la etapa de despliegue, en general ignorada o insuficientemente industrializada. Cuidado, pues, con caer en esta trampa.

Dos artículos aparecidos en el Journal of Data Warehousing ([SKE96], [LOV96]) presentan esencialmente los éxitos en este ámbito en términos de retorno sobre inversiones, ganancias de partes del mercado, reducción de stocks, etc. Si el balance de la implementación de una aplicación Data Warehouse puede anunciarse en estos términos, es una palanca para los desarrollos siguientes. Esta etapa de medición es la que debe aportar este tipo de información. El Data Warehouse es en sí mismo la herramienta ideal para efectuar estas medidas, siempre que se haya tenido en cuenta este objetivo en su diseño, porque los datos que reúne son fechados y no volátiles.

La etapa de medición permite hacer también balance de la realización y capitalizar los éxitos y fracasos encontrados durante el desarrollo de la aplicación. Idealmente, esta etapa se repite regularmente, para hacer un seguimiento de las mediciones y determinar las necesidades de mejora de la aplicación.

Hasta ahora, la etapa de implementación se ha presentado como una sucesión secuencias de etapas. Evidentemente, también puede desarrollarse de manera iterativa, según una lógica de tipo RAD ([MAR91]).

Puede ser también muy provechoso descomponer esa etapa en 2 subetapas. La primera se destina a desarrollar un prototipo y la segunda al despliegue a una escala mas importante.

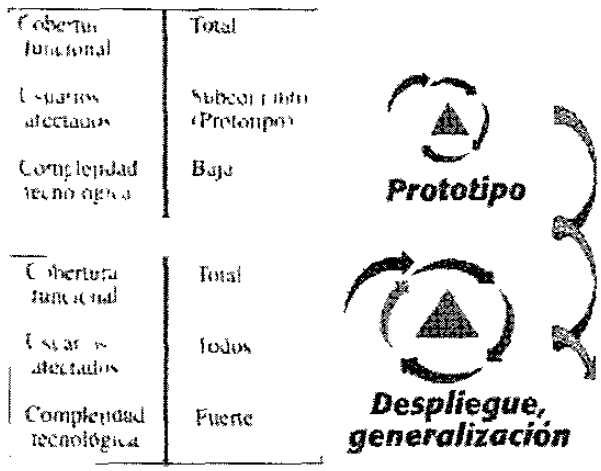

Figura No. 14

Como se muestra en la **Figura No. 14**, el objetivo de este método es empezar por un proyecto de tamaño modesto reduciendo al mínimo su complejidad tecnológica. En la distribución a gran escala, por ejemplo, el prototipo podrá afectar sólo a algunos almacenes cuyos sistemas sea relativamente homogéneos. La complejidad tecnológica se reduce y será más fácil centrarse en el aspecto funcional. Una vez realizado el prototipo, podrá ser probado y utilizado por usuarios piloto, para posteriormente, tras haber satisfecho y probado su valor, el proyecto podrá desplegarse a mayor escala y, en esta etapa, la problemática se expresará esencialmente en términos de implementación técnica y de conducción del cambio para los usuarios afectados por el despliegue.

4.1.4 La Evaluación de los Resultados

En esta etapa se deben evaluar los resultados en términos de costos y beneficios obtenidos por el Data Warehouse. Estos costos y beneficios no se deben de considerar únicamente en relación a los gastos e inversiones realizadas para la construcción del Data Waarehouse, ni tampoco en relación a los beneficios inmediatos en la toma de decisiones que permitirá hacer el Data Warehouse.

Este análisis debe ser amplio y basarse mas bien en escenarios, uno de los cuales será el escenario de tener el Data Warehouse y otro el de no contar con el Data Warehouse. Para ambos casos se debe tomar en cuenta tanto la parte económica como la parte involucrada en la satisfacción y eficiencia obtenida por parte de los usuarios en cada uno de los escenarios, y lo que esto involucra en términos económicos (rotación de personal, retrabajos, horas extras, etc).

La evaluación debe proyectarse a corto, mediano y largo plazo, para de esa manera reforzar el apoyo que se pudiera otorgar a futuros proyectos de Data Warehouse; ya que dichos proyectos necesitarán patrocinadores bien convencidos de los beneficios reales que se pueden obtener al realizarlos.

4.2 Etapa 1: Descubrimiento y definición de las iniciativas

Esta etapa esta mas bien relacionada con la parte de viabilidad del proyecto de Data Warehouse y afecta mas a la empresa que a la informática propiamente dicha. Sin embargo existen en ella aspectos informáticos de gran importancia. Dichos aspectos representarán los temas abordados en esta guía, ya que obviamente serán a los que se les prestará interés en este documento.

4.2.1 Diseño del Data Warehouse

Cuatro características del Data Warehouse tienen efectos determinantes sobre el método de diseño de un proyecto de este tipo.

La primera está vinculada a las evoluciones tecnológicas recientes. El cliente/servidor y los sistemas abiertos, por ejemplo, tecnologías implícitamente utilizadas en los sistemas Data Warehouse, han aportado evoluciones fundamentales: un sistema de información puede construirse por integración de un cierto número de componentes, pudiendo ser elegido cada uno en relación con su contexto de uso. Como las soluciones de software ya no son monolíticas, cada empresa tiene la oportunidad de definir su arquitectura, y no adaptar el problema a tal o cual tecnología del mercado. En este marco, los métodos de implementación también deben adaptarse al contexto del proyecto. En el ámbito de las metodologías y las técnicas de implementación, por

ejemplo, es posible elegir uno o más métodos, por ejemplo Merise, Information Engineering, los métodos orientados a objetos, etc. Esta diversificación puede verse como una oportunidad o como una constatación de fracaso, pero, en cualquier caso, es difícil pretender conocer métodos universales independientes del contexto de uso.

La segunda es que un Data Warehouse está mucho más cerca de la estrategia de una empresa. El Data Warehouse esta muy apegado a la estrategia de la empresa a diferencia de lo que pueden estarlo generalmente las aplicaciones de carácter transaccional. Mientras que éstas permiten a menudo la automatización de procesos existentes, o descritos formalmente por adelantado, el objetivo del Data Warehouse se expresa a menudo en términos puramente de negocio como: mantener la fidelidad de la clientelas. En su desarrollo, habrá que tener en cuenta estos aspectos, implicando al máximo a los usuarios más experimentados en el conocimiento de su empresa y/o de su negocio, pero también integrando esta dimensión en todas las técnicas utilizadas para el diseño y el seguimiento del proyecto.

La tercera se desprende del hecho que un Data Warehouse, una vez construido, debe evolucionar. El Data Warehouse debe evolucionar en función de las peticiones de los usuarios o de los nuevos objetivos de la empresa, y se sitúa, pues, en una lógica de mejora imprevisible y frecuente.

Finalmente, el nivel de madurez de cada empresa ante los sistemas de decisión puede diferir considerablemente. Para algunas empresas, el Data Warehouse está en continuidad con su adquisición de ayuda a la decisión, que les permite disponer ya de una organización y de métodos probados, mientras que para otras se trata de un ámbito aún desconocido.

A pesar que el diseño del Data Warehouse es diferente al usado en los diseños tradicionales, no es menos importante. El hecho que los usuarios finales tengan

dificultad en definir lo que ellos necesitan, no lo hace menos necesario. En la práctica, los diseñadores de Data Warehouse tienen que usar muchos "trucos" para ayudar a sus usuarios a "visualizar" sus requerimientos. Por ello, son esenciales los prototipos de trabajo.

4.2.2 Planificación del Data Warehouse

La planificación es el proceso más importante que determina el tipo de estrategias de Data Warehousing que una organización iniciará.

No existe una fórmula que garantice el éxito de la construcción de un Data Warehouse, pero hay muchos puntos que contribuyen a ese objetivo. Algunos puntos claves que deben considerarse en la planificación de un Data Warehouse son los siguientes :

1. Establecer una asociación de usuarios, gestión y grupos. Es esencial involucrar tanto a los usuarios como a la gestión para asegurar que el Data Warehouse contenga información que satisfaga los requerimientos de la empresa. La gestión puede ayudar a priorizar la etapa de la implementación del Data Warehouse, así como también la selección de herramientas del usuario. Los usuarios y la gestión justifican los costos del Data Warehouse sobre cómo será "su ambiente" y está basado primero en lo esperado y segundo, en el valor comercial real.

2. Seleccionar una aplicación piloto con una alta probabilidad de éxito. Una aplicación piloto de alcance limitado, con un reembolso medible para los

usuarios y la gestión, establecerá el Data Warehouse como una tecnología clave para la empresa. Estos mismos criterios (alcance limitado, reembolso medible y beneficios claros para la empresa) se aplican a cada etapa de la implementación de un Data Warehouse.

3. Trabajar mediante prototipos con cambios rápidos y frecuentes. La mejor manera para asegurar que el Data Warehouse reúna las necesidades de los usuarios, es hacer el prototipo a lo largo del proceso de implementación y aún más allá, así como agregar los nuevos datos y/o los modelos en forma permanente. El trabajo continuo con los usuarios y la gestión es, nuevamente, la clave.

4. Realizar una Implementación de manera incremental. La implementación incremental ayuda a la reducción de riesgos y asegura que el tamaño del proyecto permanezca manejable en cada etapa.

5. Retroalimentar constantemente y publicar los casos exitosos. La retroalimentación de los usuarios ofrece una excelente oportunidad para publicar los hechos exitosos dentro de una organización. La publicidad interna sobre cómo el Data Warehouse ha ayudado a los usuarios a operar más eficientemente puede apoyar la construcción del Data Warehouse a lo largo de una empresa. La retroalimentación del usuario también ayuda a comprender cómo evoluciona la implementación del Data Warehouse a través del tiempo para reunir requerimientos de usuario nuevamente identificados.

4.2.3 Selección del Data Warehouse a construir

Antes de intentar construir un Data Warehouse, es crítico el establecer de una estrategia que sea apropiada para las necesidades y los usuarios.

Las preguntas básicas que deben hacerse son:

- ¿ A quien va dirigido ?
- ¿ Cuál será el alcance ?
- ¿ Qué tipo de Data Warehouse debería construirse ?

Existe varias estrategias mediante las cuales las organizaciones pueden construir sus Data Warehouses, de las cuales se explicarán a continuación las mas comunes.

Estrategia del Data Warehouse virtual. Esta estrategia esta basada en el uso actual. Se crea un Data Warehouse físico para soportar los pedidos de alta frecuencia. Puede ser construido mediante:

1. La Instalación de un conjunto de facilidades para acceso a datos, directorio de datos y gestión de proceso.
2. El entrenamiento de usuarios finales.
3. El control de cómo se usan realmente las configuraciones del Data Warehouse.

Estrategia de la copia de datos operacionales. Esta estrategia se basa en obtener una copia de los datos desde un sistema operacional único y dotar al Data Warehouse de una serie de herramientas de acceso a la información. Esta estrategia tiene la ventaja de ser simple y rápida. Desafortunadamente, si los

datos existentes son de mala calidad y/o el acceso a los datos no ha sido previamente evaluado, el Data Warehouse puede presentar serios problemas.

Estrategia en base a análisis de necesidades y consensos. Esta estrategia se basa en seleccionar un número de usuarios basados en el valor de la empresa y hacer un análisis de sus puntos, preguntas y necesidades de acceso a datos. De acuerdo a estas necesidades, se construyen los prototipos de Data Warehousing y se prueban para que los usuarios finales puedan experimentar y modificar sus requerimientos. Una vez se tenga un consenso general sobre las necesidades, entonces se consiguen los datos provenientes de los sistemas operacionales existentes a través de la empresa y/o desde fuentes externas de datos y se cargan al Data Warehouse. Si se requieren herramientas de acceso a la información, se puede también permitir a los usuarios finales tener acceso a los datos requeridos usando sus herramientas favoritas propias, o facilitar la creación de sistemas de acceso a la información multidimensional de alto desempeño, usando el núcleo del Data Warehouse como base.

En conclusión, no se tiene un enfoque único para elaborar un Data Warehouse que se adapte a las necesidades de las empresas, debido a que las necesidades de cada una de ellas son diferentes, al igual que su contexto. Además, como la tecnología Data Warehousing esta en constante evolución, el enfoque mas práctico para la construcción del Data Warehouse es mantener una evolución constante en la utilización de las técnicas y herramientas que vayan surgiendo, en aras de un mejor desempeño en el almacenamiento y consulta de la información proporcionada por el Data Warehouse.

4.2.4 Administración y gestión del Data Warehouse

Un proyecto de Data Warehouse acarrea inevitablemente un problema de administración de los datos. La administración de los datos (DWA, Data Warehouse Administration) del Data Warehouse es una función que debe declinarse a varios niveles: por ejemplo, empresa, ámbito, proyecto. No hay reglas universales sobre el nombre y la naturaleza de estos niveles para obtener un sistema consolidado y coherente. Detallartemos los diferentes niveles de administración:

DWA centralizada: Las normas deben definirse a nivel de la empresa; el modelo de datos es global a la empresa.

DWA descentralizada: Data Marts Administration (DMA): en este caso, se podrá organizar la administración por ámbitos funcionales (Contabilidad, Mercadotecnia...), por ámbitos de aplicación (Facturación, Surtido ...), por entornos técnicos (Sede central, micros en agencias, IBM, DEC ...) o por sedes geográficas (Data Marts para Alemania, para Estados Unidos ...).

Administración local de proyecto: Se encuentra aquí un caso clásico de gestión de los datos de una aplicación. Los modelos de datos son locales y describen generalmente datos operativos.

Para que un Data Warehouse siga vivo, debe instituirse la función de administración de los datos para todo proyecto encargado de desarrollar una aplicación que deba alimentar el Data Warehouse.

El Data Warehouse requiere una comercialización y gestión muy cuidadosa. Debe considerarse lo siguiente:

- Un Data Warehouse es una inversión buena, sólo si los usuarios finales realmente pueden conseguir información vital más rápida y más barata de lo que obtienen con la tecnología actual. Como consecuencia, la gestión tiene que pensarse seriamente sobre cómo quieren sus depósitos para su eficaz desempeño y cómo conseguirán llegar a los usuarios finales.
- La Administración debe reconocer que el mantenimiento de la estructura de datos del Data Warehouse es tan crítico como el mantenimiento de cualquier otra aplicación de misión crítica. De hecho, la experiencia ha demostrado que el Data Warehouse llegará a ser rápidamente uno de los sistemas más usados en cualquier organización.
- La gestión debe comprender también que si se deciden por un proyecto de Data Warehouse, se crearán nuevas demandas sobre sus sistemas operacionales, como lo son:
    1. Demandas para mejorar datos
    2. Demandas para datos consistentes
    3. Demandas para diferentes tipos de datos, etc.

4.3 Etapa 2: Determinación de la Infraestructura

En esta etapa se trata de seleccionar la infraestructura desde 2 ámbitos principales : el técnico y el organizativo. Los temas que se desarrollarán en este punto están enfocados a ayudar a tomar decisiones respecto a la formación de cada una de las infraestructuras en los ámbitos mencionados.

4.3.1 Alcance del Data Warehouse

El alcance de un Data Warehouse puede ser tan amplio como toda la información estratégica de la empresa desde su inicio, o puede ser tan limitado como un Data Warehouse personal para un solo gerente durante un año.

En la práctica, en la amplitud del alcance, el mayor valor del Data Warehouse es para la empresa y lo más caro y requirente de tiempo es crearlo y mantenerlo. Como consecuencia de ello, la mayoría de las organizaciones comienzan con Data Warehouses funcionales, departamentales o divisionales y luego los expanden como usuarios que proveen retroalimentación.

La **Figura No. 15** muestra un esquema bidimensional para analizar las opciones básicas. La dimensión horizontal indica el alcance del depósito y la vertical muestra la cantidad de datos redundantes que deben almacenarse y mantenerse.

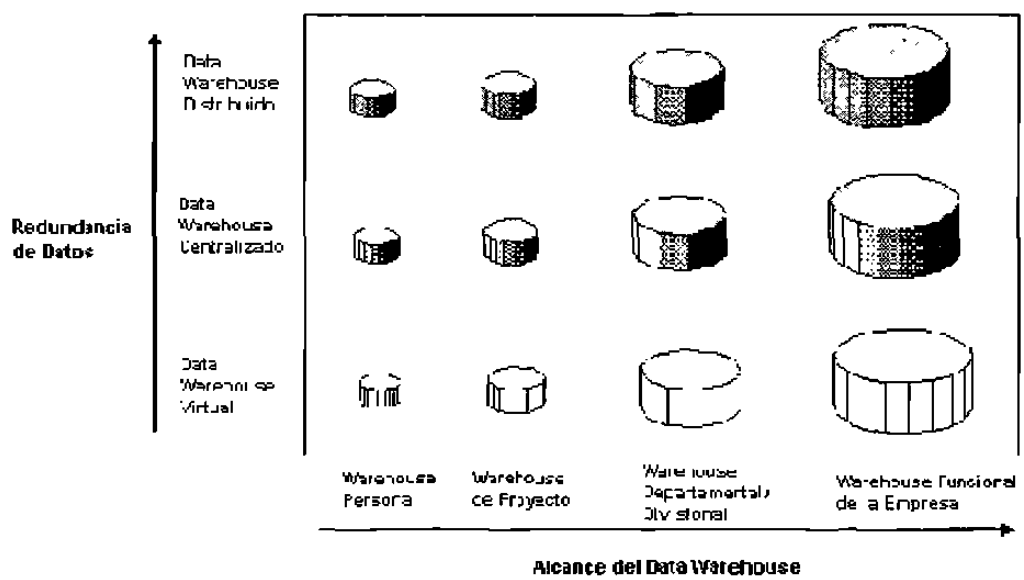

Figura No. 15

4.3.2 Arquitectura del Data Warehouse

Un Data Warehouse está integrado por un servidor de hardware y los DBMS que conforman el depósito. Del lado del hardware, se debe combinar la configuración de plataformas de los servidores, mientras se decide cómo aprovechar los saltos casi constantes de la potencia del procesador. Del lado del software, la complejidad y el alto costo de los DBMSes fuerzan a tomar decisiones drásticas y balances comparativos inevitables, con respecto a la integración, requerimientos de soporte, desempeño, eficiencia y confiabilidad.

Si se escoge incorrectamente, el Data Warehouse se convierte en una gran empresa con problemas difíciles de trabajar en su entorno, costoso para arreglar y difícil de justificar. Para conseguir que la implementación del depósito tenga un inicio exitoso, se necesita enfocar hacia tres bloques claves de construcción:

- Configuración del depósito
- Configuración del servidor
- Sistemas de Gestión de Base de Datos

4.3.3 Configuración del depósito

La elaboración del Data Warehouse comienza con la estructura lógica y física de la base de datos del depósito más los servicios requeridos para operar

y mantenerlo. Esta elección conduce a la selección de otros dos puntos fundamentales: el servidor de hardware y el DBMS.

La plataforma física puede centralizarse en una sola ubicación o distribuirse regional, nacional o internacionalmente. A continuación se dan las siguientes alternativas de arquitectura:

Data Warehouse integrado : Consiste en generar un plan para almacenar los datos de su compañía, que podrían obtenerse desde fuentes múltiples internas y externas, y consolidarlos en una sola base de datos (el Data Warehouse). El enfoque consolidado proporciona eficiencia tanto en la potencia de procesamiento como en los costos de soporte. (**Ver Figura No. 16**).

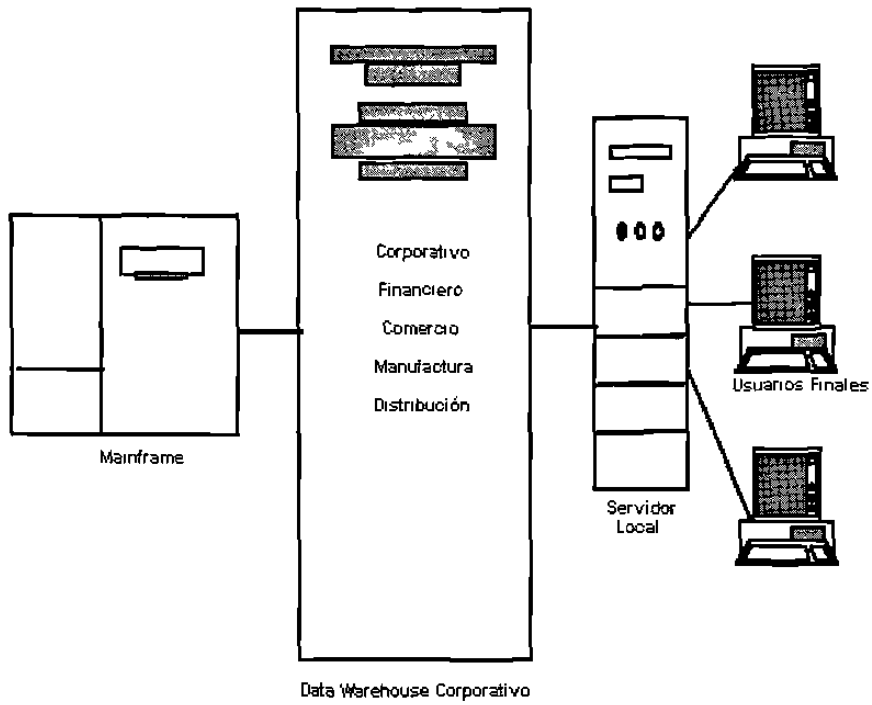

En una arquitectura centralizada, una sola, el data warehouse integrado refle todos los aspectos del negocio. Las bases de datos separadas son todas interrelacionadas y físicamente almacenadas en la misma plataforma.

Figura No. 16

Data Warehouse distribuido: Consiste en distribuir la información por función, con datos financieros sobre un servidor en un sitio, los datos de comercialización en otro y los datos de fabricación en un tercer lugar. (Ver la **Figura No. 17**)

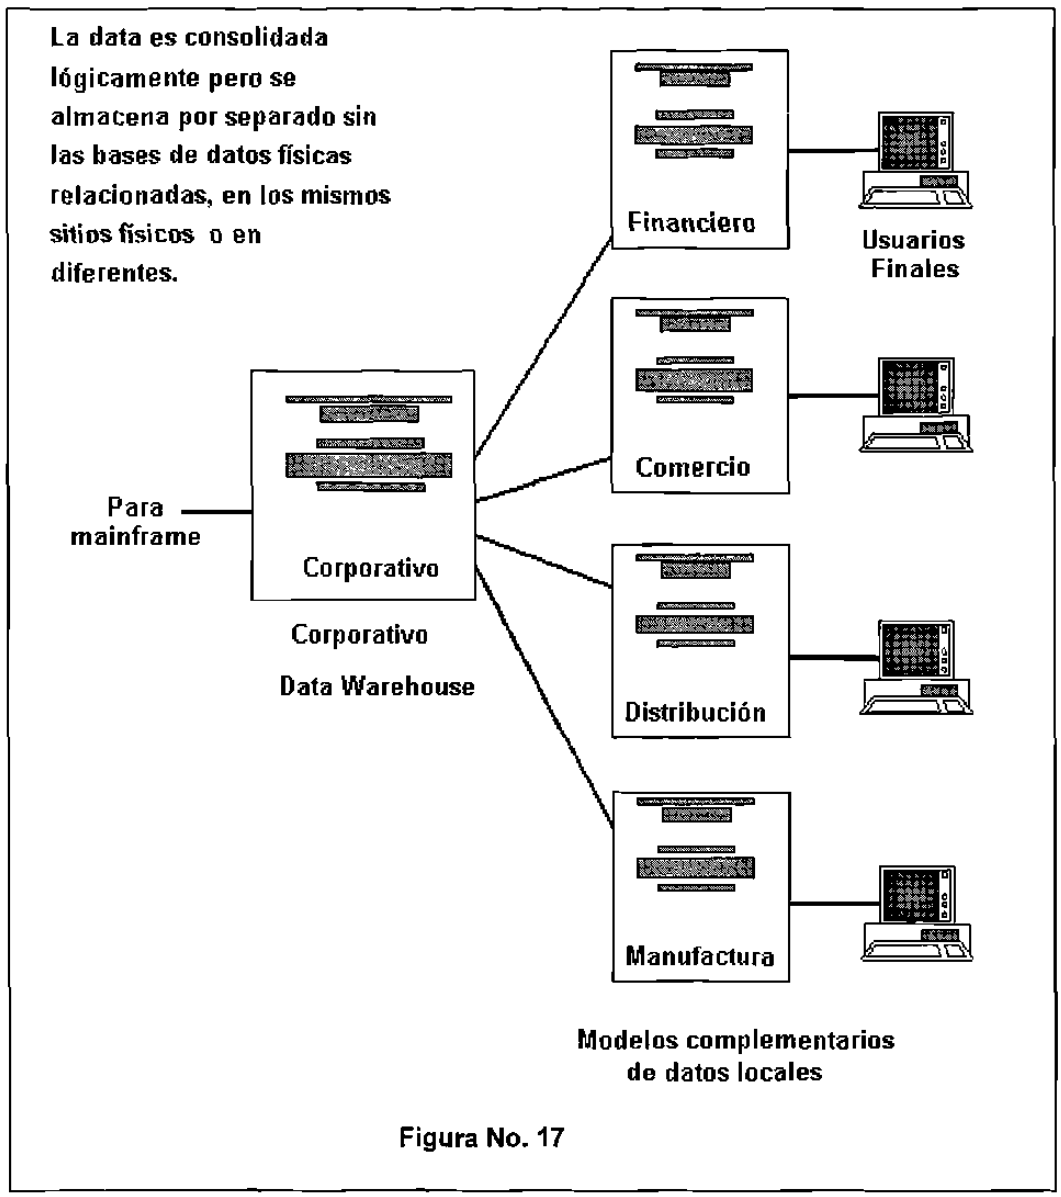

Figura No. 17

Data Warehouse por niveles: Almacena datos altamente resumidos sobre una estación de trabajo del usuario, con resúmenes más detallados en un segundo servidor y la información más detallada en un tercero. La estación de trabajo del primer nivel maneja la mayoría de los pedidos para los datos, con pocos pedidos que pasan sucesivamente a los niveles 2 y 3 para la resolución. Las computadoras en el primer nivel pueden optimizarse para usuarios de carga pesada y volumen bajo de datos, mientras que los servidores de los otros niveles son más adecuados para procesar los volúmenes pesados de datos, pero cargas más livianas de usuario. (Ver la **Figura No. 18**).

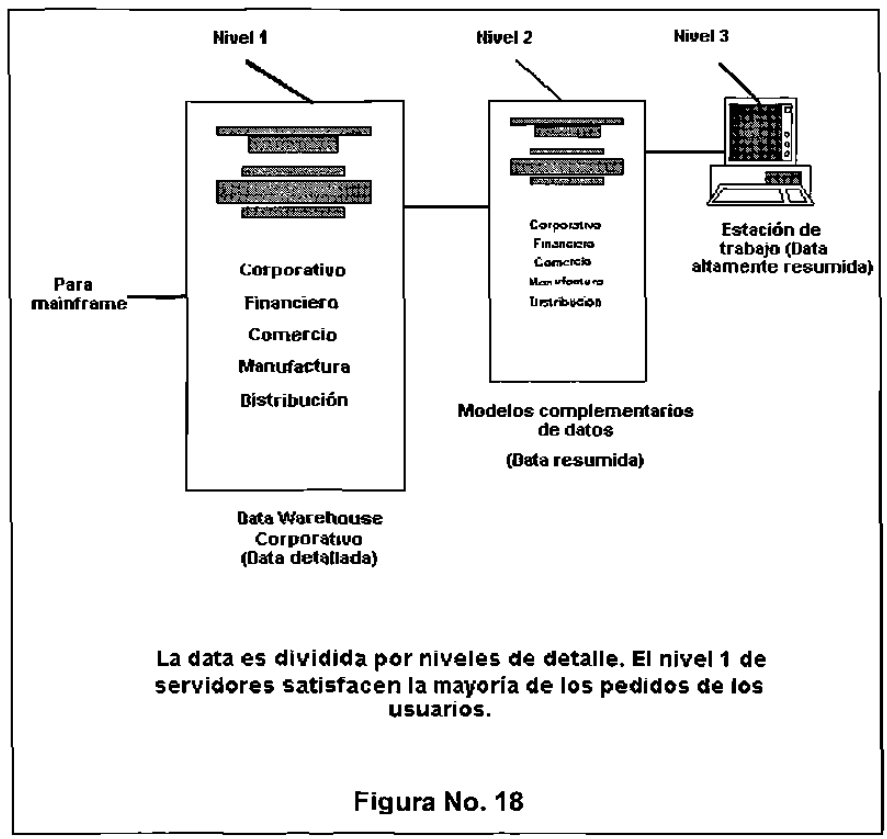

Figura No. 18

4.3.4 Configuración del servidor

Al decidir sobre una configuración de depósito distribuida o centralizada, también se necesita considerar los servidores que retendrán y entregarán los datos. El tamaño de su implementación (y las necesidades de su empresa para escalabilidad, disponibilidad y gestión de sistemas) influirá en la elección de la arquitectura del servidor.

Servidores de un solo procesador : Los servidores de un sólo procesador son los más fáciles de administrar, pero ofrecen limitada potencia de procesamiento y escalabilidad. Además, un servidor sólo presenta un único punto de falla, limitando la disponibilidad garantizada del depósito. Se puede ampliar un solo servidor de redes mediante arquitecturas distribuidas que hacen uso de subproductos, tales como Ambientes de Computación Distribuida (Distributed Computing Environment - DCE) o Arquitectura Broker de Objeto Común (Common Objects Request Broker Architecture - CORBA), para distribuir el tráfico a través de servidores múltiples. Estas arquitecturas aumentan también la disponibilidad, debido a que las operaciones pueden cambiarse al servidor de backup si un servidor falla, pero la gestión de sistemas es más compleja.

Multiprocesamiento simétrico : Las máquinas de multiprocesamiento simétrico (Symmetric MultiProcessing - SMP) aumentan mediante la adición de procesadores que comparten la memoria interna de los servidores y los dispositivos de almacenamiento de disco. Se puede adquirir la mayoría de SMP en configuraciones mínimas (es decir, con dos procesadores) y levantar cuando es necesario, justificando el crecimiento con las necesidades de procesamiento. La escalabilidad de una máquina SMP alcanza su límite en el número máximo de procesadores soportados por los mecanismos de conexión (es decir, el backplane y bus compartido).

Procesamiento en paralelo masivo : Una máquina de procesamiento en paralelo masivo (Massively Parallel Processing - MPP), conecta un conjunto de procesadores por medio de un enlace de banda ancha y de alta velocidad. Cada nodo es un servidor, completo con su propio procesador y memoria interna (posiblemente SMP) para optimizar una arquitectura MPP, las aplicaciones deben ser "paralelizadas" es decir, diseñadas para operar por separado, en partes paralelas. Esta arquitectura es ideal para la búsqueda de grandes bases de datos. Sin embargo, el DBMS que se selecciona debe ser uno que ofrezca una versión paralela. Y aún entonces, se requiere un diseño y afinamiento esenciales para obtener una óptima distribución de los datos y prevenir problemas.

Acceso de memoria no uniforme : La dificultad de mover aplicaciones y los DBMS a agrupaciones o ambientes realmente paralelos ha conducido a nuevas y recientes arquitecturas, tales como el acceso de memoria no uniforme (Non Uniform Memory Access - NUMA). NUMA crea una sola gran máquina, al conectar múltiples nodos en un solo (aunque físicamente distribuida) banco de memoria y un ejemplo único de OS. NUMA crea una sola gran máquina SMP al conectar múltiples nodos SMP en un solo (aunque físicamente distribuida) banco de memoria y un ejemplo único de OS. NUMA facilita el enfoque SMP para obtener los beneficios de performance de las grandes máquinas MPP (con 32 o más procesadores), mientras se mantiene las ventajas de gestión y simplicidad de un ambiente SMP estándar.

Lo más importante de todo, es que existen DBMS y aplicaciones que pueden moverse desde un solo procesador o plataforma SMP a NUMA, sin modificaciones.

4.3.5 Sistemas de Gestión de Base de Datos (SGBD)

Los Data Warehouses (conjuntamente con los sistemas de soporte de decisión [Decision Support Systems - DSS] y las aplicaciones cliente/servidor), fueron los primeros éxitos para el DBMS relacional (Relational Data Base Management Systems - RDBMS).

Mientras la gran parte de los sistemas operacionales fueron resultados de aplicaciones basadas en antiguas estructuras de datos, los depósitos y sistemas de soporte de decisiones aprovecharon el RDBMS por su flexibilidad y capacidad para efectuar consultas con un único objetivo concreto.

Los RDBMS son muy flexibles cuando se usan con una estructura de datos normalizada. En una base de datos normalizada, las estructuras de datos son no redundantes y representan las entidades básicas y las relaciones descritas por los datos (por ejemplo productos, comercio y transacción de ventas). Pero un procesamiento analítico en línea (OLAP) típico de consultas que involucra varias estructuras, requiere varias operaciones de unión para colocar los datos juntos.

El desempeño de los RDBMS tradicionales es mejor para consultas basadas en claves ("Encuentre cuenta de cliente #2014") que para consultas basadas en el contenido ("Encuentre a todos los clientes con un ingreso sobre $ 10,000 que hayan comprado un automóvil en los últimos seis meses").

Para el soporte de depósitos a gran escala y para mejorar el interés hacia las aplicaciones OLAP, los proveedores han añadido nuevas características al RDBMS tradicional. Estas, también llamadas características super relacionales, incluyen el soporte para hardware de base de datos especializada, tales como la máquina de base de datos Teradata.

Los modelos super relacionales también soportan extensiones para almacenar formatos y operaciones relacionales (ofrecidas por proveedores como RedBrick) y diagramas de indexación especializados, tales como aquellos usados por Sybase IQ. Estas técnicas pueden mejorar el rendimiento para las recuperaciones basadas en el contenido, al prejuntar tablas usando índices o mediante el uso de listas de índice totalmente invertidos.

Muchas de las herramientas de acceso a los Data Warehouses explotan la naturaleza multidimensional del Data Warehouse. Por ejemplo, los analistas de marketing necesitan buscar en los volúmenes de ventas por producto, por mercado, por período de tiempo, por promociones y niveles anunciados y por combinaciones de estos diferentes aspectos.

La estructura de los datos en una base de datos relacional tradicional, facilita consultas y análisis a lo largo de dimensiones diferentes que han llegado a ser comunes. Estos esquemas podrían usar tablas múltiples e indicadores para simular una estructura multidimensional. Algunos productos DBMS, tales como Essbase y Gentium, implementan técnicas de almacenamiento y operadores que soportan estructuras de datos multidimensionales.

Mientras las bases de datos multidimensionales (MultiDimensional Databases - MDDBs) ayudan directamente a manipular los objetos de datos multidimensionales (por ejemplo, la rotación fácil de los datos para verlos entre dimensiones diferentes, o las operaciones de drill down que sucesivamente exponen los niveles de datos más detallados), se debe identificar estas dimensiones cuando se construya la estructura de la base de datos. Así, agregar una nueva dimensión o cambiar las vistas deseadas, puede ser engorroso y costoso. Algunos MDDBs requieren un recargue completo de la base de datos cuando ocurre una reestructuración.

4.3.6 Ambiente OLTP vs OLAP

La mayor parte de los informáticos dominan aproximaciones para la implementación de sistemas de informaciones, normalmente centrados en metodologías como Merise o Information Engineering. En sus componentes relacionados con el modelado de datos, estas metodologías son a la vez precisas, potentes y bastante poco cuestionadas. A nivel de los modelos de datos, el modelo entidad-relación es el más utilizado, llevando normalmente a la creación de un modelo lógico de tipo relacional. Tanto si se conocen de manera formal los conceptos como si no, todas las teorías asociadas a estos modelos son utilizadas ampliamente en las empresas. Estas técnicas están actualmente tan ancladas en nuestras mentes que a menudo olvidamos su origen. Aparecieron cuando la informática estaba destinada a la automatización de la producción y se utilizan aún con éxito en contextos de este tipo, por ejemplo para las aplicaciones de carácter transaccional, comúnmente llamadas OLTP. Sin embargo, la informática de decisión, que algunos denominan también OLAP, justifica una revisión de los métodos de diseño de un modelo de datos.

Caracteristicas de un contexto OLTP

En la mayor parte de los sistemas transaccionales, el papel de un modelo es garantizar la persistencia de los datos. De hecho, la base de datos se diseña para conservar el rastro de eventos surgidos en la empresa.

Tomemos el ejemplo de una aplicación de gestión de pedidos. En su interior, para evitar la redundancia de información, será necesario mantener

información sobre los pedidos, los clientes y los productos en entidades distintas, relacionadas entre sí por asociaciones. Conceptos más sofisticados, como las nociones de forma normal, de clave única, de clave foránea o de restricción de integridad referencial, permiten garantizar constantemente la integridad de la base de datos. El origen de este esfuerzo de minimización de redundancias deriva principalmente del hecho que los sistemas transaccionales efectúan sus actualizaciones en tiempo real, eventualmente a través de un conjunto de aplicaciones que comparten el mismo modelo de datos.

En un sistema transaccional, el diseño se orienta a procesos y el modelo de datos interviene como apoyo de éste. Desde el punto de vista del usuario, el modelo de datos es totalmente transparente, sólo accede a él indirectamente a través de aplicaciones «empaquetadas» puestas a su disposición. Por ello, la legibilidad del modelo desde punto de vista del usuario no tiene gran importancia, excepto en ocasiones durante la fase de validación del modelo con el usuario.

Las consultas son siempre previsibles, porque se efectúan a través de una aplicación desarrollada normalmente por el mismo equipo encargado del modelo de datos. Por ello, es posible definir un modelo de datos adaptado a las consultas que el sistema será susceptible de lanzar por anticipación. Así, la mayoría de benchmarks (conjuntos de pruebas) que permiten cualificar el rendimiento de una plataforma transaccional se definen a través de un conjunto de transacciones, en general poco numerosas, que serán los únicos puntos de entrada al sistema.

En este contexto, se accede a los datos generalmente por claves, especialmente claves únicas (acceso de un cliente por su número de cuenta). Una buena indexación permite garantizar tiempos de respuesta dependiendo más del volumen de datos a tratar para realizar la transacción que del volumen global de la base de datos. Los volúmenes de datos como resultado de las

transacciones son limitados. Normalmente, el número de entradas/salidas asociadas a cada transacción es un número finito previsible. En ciertos casos, como para las consultas guiadas, este número es más difícilmente previsible; así, la búsqueda de un cliente por su nombre puede llevar a un volumen más o menos importante de resultados. En todo momento, una aplicación transaccional tiende a la productividad, y presentar a un usuario varios miles de registros en este contexto no tiene ningún sentido.

Para efectuar los tratamientos necesarios para su correcta ejecución, una transacción accederá a un número de estructuras limitado y finito. Es muy raro que una consulta transaccional necesite reunir o agregar informaciones surgidas de un gran número de tablas.

Características de un contexto OLAP

Un Data Warehouse es una base dedicada a la decisión. La información se pone a disposición de los usuarios, pero las actualizaciones no se hacen nunca en tiempo real. Por ello, las únicas actualizaciones efectuadas sobre el Data Warehouse provendrán de los sistemas de producción, en las fases de carga. Una vez efectuado este proceso de adquisición de datos, la integridad de datos del Data Warehouse no podrá volver a cuestionarse. Es posible, pues, introducir redundancias, siempre que se controlen en el proceso de alimentación.

En un contexto de decisión, las consultas manipulan regularmente conjuntos. Por ejemplo, el usuario se interesará por las ventas realizadas en la región Norte. Las consultas efectúan frecuentemente selecciones o restricciones de población, agrupaciones, cálculos, agregados, etc. Para responder a las necesidades de los usuarios, aunque el resultado de las consultas puede estar constituido únicamente por algunas líneas, a menudo será necesario manipular volúmenes importantes. En este caso, obtener

tiempos de respuesta proporcionales al volumen de datos resultado de una consulta es mucho más difícil que en transaccional. Los optimistas relativizan esta constatación, partiendo del principio que la decisión da autonomía al usuario y ello le incita a una mayor indulgencia ante los tiempos de respuesta: el Data Warehouse le permite hacer en unos minutos lo que antes hacía en varios días.

La realidad es más compleja: un usuario difícilmente comprenderá una espera de varias decenas de minutos para obtener las ventas del año pasado por regiones, porque se trata de una consulta básica que se ejecutará frecuentemente. Por el contrario, esperar cierto tiempo para obtener información sobre las «ventas de tal producto en tal almacén el último viernes antes de las vacaciones de agosto» se tolerará mejor.

En este contexto, es necesario intentar optimizar las consultas efectuadas frecuentemente. Ello es posible siempre que se predefinan físicamente los subconjuntos de datos, menos importantes en tamaño que los datos más detallados, pero suficientes para resolver las consultas más habituales.

Otra característica de la decisión es que los usuarios intentan relacionar con frecuencia elementos que a priori no se correlacionan al principio. Desearán por ejemplo relacionar las ventas con los gastos, comparar las ventas de un período respecto a otro... Para conseguirlo, son necesarias consultas complejas, que interrogan un número importante de tablas. Esta característica es tanto más actual cuanto que existen herramientas de ayuda a la decisión cada vez más sofisticadas, permitiendo al usuario formular simplemente lo que habría sido incapaz de formalizar con las herramientas de ayer. Ante esta complejidad, el Data Warehouse debe poder reaccionar en plazos razonables.

Cada vez son más raros los sistemas de decisión empaquetados, es decir, encapsulados en aplicaciones fijas y predefinidas por la informática. Cada

vez más, el usuario desea obtener los medios para su autonomía. A fin de evitar la clásica espera de reactividad relacionada con la puesta en producción, no debe depender de un informático que desarrolle la aplicación adaptada a sus necesidades. Un Data Warehouse intenta responder a las necesidades de los usuarios en términos de informaciones y no en términos de aplicaciones.

La consecuencia de esta constatación es que cuanto más legible sea el modelo, es decir, intuitivo para los usuarios, menos largo y costoso será definir una capa por encima de este sistema destinada a hacerlo comprensible y adaptado a las necesidades de los usuarios. Esta capa es de cualquier forma necesaria para dar al usuario una visión de negocio del modelo de datos y hay numerosas herramientas de ayuda a la decisión en el mercado que proponen su implementación. Pero debe ser ligera, porque cuanto más gruesa sea esta capa complementaria, más larga de definir resultará a los informáticos. Definir un modelo legible se convierte, pues, en una preocupación fundamental.

En un contexto de decisión, desde el punto de vista del administrador de base de datos, una de las mayores dificultades es gestionar lo imprevisible. En efecto, las consultas son normalmente ad hoc, generadas por el usuario a través de una herramienta, y es pues imposible optimizar cada una de ellas caso por caso. Sie embargo existen, técnicas de optimización basadas no ya en las consultas, sino más bien en los caminos de acceso para garantizar tiempos de respuesta convenientes y previsibles en la decisión.

La última característica del mundo Data Warehouse es que permite implementar normalmente un modelo de datos integrado, cuyo objetivo es ser transversal a la empresa. Este modelo se constituye habitualmente de manera incrementar, a medida de las realizaciones sucesivas de los proyectos de decisión de la empresa. Por ejemplo, el primer proyecto permitirá construir el modelo que integra las ventas para tal tipo de producto. Este modelo se enriquece poco a poco ampliando la gama de productos incluidos, integrando la

información relativa a la logística, ete. En este marco, el modelo de datos evolucionará de manera constante y regular.

4.3.7 Elección de los componentes

Una limitación de un RDBMS y un MDDB, es la carencia de soporte para tipos de datos no tradicionales como imágenes, documentos y clips de video/ audio. Si usted necesita estos tipos de objetos en su Data Warehouse, busque un DBMS relacional-objeto (Ejemplo: Ilustra de Informix).

Por su enfoque en los valores de datos codificados, la mayor parte de los sistemas de base de datos pueden acomodar estos tipos de datos, sólo con extensiones basadas en cierta referencias, tales como indicadores de archivos que contienen los objetos. Muchos RDBMS almacenan los datos complejos como objetos grandes binarios (Binary Large Objects - BLOBs). En este formato, los objetos no pueden ser indexados, clasificados, o buscados por el servidor.

Los DBMS relacional-objeto, de otro lado, almacenan los datos complejos como objetos nativos y pueden soportar las grandes estructuras de datos encontradas en un ambiente orientado a objetos. Estos sistemas de base de datos naturalmente acomodan no sólo tipos de datos especiales sino también los métodos de procesamiento que son únicos para cada uno de ellos.

Pero una desventaja del enfoque relacional-objeto, es que la encapsulación de los datos dentro de los tipos especiales de datos (una serie

de precios de stock a través del tiempo en cada registro de una tabla de stock, por ejemplo), requiere de operadores especializados para que hagan búsquedas históricas simples (por ejemplo, "Encontrar todas las existencias que han mostrado una disminución en el precio de Abril a Mayo 1996").

La selección del DBMS está también sujeta al servidor de hardware que se usa. Algunos RDBMS, como el DB2 Paralelo, Informix XPS y el Oracle Paralelo, ofrecen versiones que soportan operaciones paralelas. El software paralelo divide consultas, uniones a través de procesadores múltiples y corre estas operaciones simultáneamente para mejorar el desempeño.

Se requiere el paralelismo para el mejor desempeño en los servidores MPP grandes y SMP agrupados. No es aún una opción con MDDBS o DBMS relacional-objeto. En la tabla "Matriz para la selección de la DBMS" se resumen los pro y los contra de los diferentes tipos de DBMS para operaciones de Data Warehouse.

La tabla "Matriz de Decisión del Data Warehouse" contiene algunos ejemplos de cómo afectan estos criterios de decisión en la elección de una arquitectura de servidor/ Data Warehouse.

MATRIZ PARA LA SELECCIÓN DE LA DBMS					
Características/Función	**Relacional**	**Super Relacional**	**Multi Dimensional (Lógico)**	**Multi dimensional (Físico)**	**Objeto-Relacional**
Estructuras Normalizadas					
Tipos de datos abstractos					
Paralelismo					
Estructuras Multidimensionales					
Drill-Down					
Rotación					
Operaciones dependientes de datos					

MATRIZ DE DECISIÓN PARA EL DATA WAREHOUSE					
Para estos ambientes...			Seleccione...		
Requerimientos comerciales	**Usuarios**	**Soporte de Sistemas**	**Arquitectura**	**Servidor**	**DBMS**
Alcance: departamental **Usos**: análisis de datos	Pequeño – Ubicación única	Local mínimo – Central promedio	Consolidado – Paquete	Procesador único o SMP	MDDB
Alcance: departamental **Usos**: investigación	Pequeño – Pocas ubicaciones	Central fuerte	Centralizado	MPP	RDBMS con soporte paralelo
Alcance: departamental **Usos**: análisis más Informática	Grande – Analistas en una sola ubicación Usuarios informáticos dispersos	Local mínimo Central promedio	Seccionado – detalle en central Resumen en local	Grupos de SMP para central SP o SMP para local	RDBMS para central MDDB para local
Alcance: empresa **Usos**: análisis más informática	Grande – geográficamente disperso	Central fuerte	Centralizado	Grupos de SMP	Objeto relacional soporte Web

4.3.8 Combinación de la Arquitectura y la Gestión de la BD

Para seleccionar la combinación correcta de la arquitectura del servidor y el DBMS, primero es necesario comprender los requerimientos comerciales de su compañía, su población de usuarios y las habilidades del personal de soporte.

Las implementación del Data Warehouse varía apreciablemente de acuerdo al área. Algunos son diseñados para soportar las necesidades de análisis específico para un solo departamento o área funcional de una organización, tales como Finanzas, Ventas o Mercadotecnia. Las otras implementaciones reúnen datos a través de toda la empresa para soportar una variedad de grupos de usuarios y funciones. Por regla general, a mayor área del depósito, se requiere mayor potencia y funcionalidad del servidor y el DBMS.

Los modelos de uso del Data Warehouse es también un factor. Las consultas y vistas de reportes pre-estructuradas frecuentemente satisfacen a los usuarios informáticos, mientras que hay menos demandas sobre el DBMS y la potencia de procesamiento del servidor. El análisis complejo, que es típico de los ambientes de decisión-soporte, requiere más poder y flexibilidad de todos los componentes del servidor. Las búsquedas masivas de grandes Data warehouses favorecen el paralelismo en el DBMS y el servidor.

Los ambientes dinámicos, con sus requerimientos siempre cambiantes, se adaptan mejor a una arquitectura de datos simple, fácilmente cambiable (por ejemplo, una estructura relacional altamente normalizada), antes que una estructura intrincada que requiere una reconstrucción después de cada cambio (por ejemplo, una estructura multidimensional).

El valor de la data fresca requerida indica cuán importante es para el Data Warehouse renovar y cambiar los datos. Los grandes volúmenes de datos que se refrescan a intervalos frecuentes, favorecen una arquitectura físicamente centralizada para soportar una captura de datos eficiente y minimizar el tiempo de transporte de los datos.

Un perfil de usuario debería identificar quiénes son los usuarios de su Data Warehouse, dónde se ubican y cuántos necesita soportar. La información sobre cómo cada grupo espera usar el Data Warehouse, ayudará a analizar los diversos estilos de uso.

Conocer la ubicación física de sus usuarios ayudará a determinar cómo y a qué área necesita distribuir el Data Warehouse. Una arquitectura por niveles podría usar servidores en el lugar de las redes de área local. O puede necesitar un enfoque centralizado para soportar a los trabajadores que se movilizan y que trabajan en el depósito desde sus Lap-tops.

El número total de usuarios y sus modelos de conexión determinan el tamaño de sus servidores de depósito. Los tamaños de memoria y los canales de I/O deben soportar el número previsto de usuarios concurrentes bajo condiciones normales, así como también en las horas pico de su organización.

Finalmente, se debe factorizar la sofisticación del personal de soporte. Los recursos de los sistemas de información (Information System - IS) que están disponibles dentro de su organización, pueden limitar la complejidad o sofisticación de la arquitectura del servidor. Sin el personal especializado interno o consultores externos, es difícil de crear y mantener satisfactoriamente una arquitectura.

4.3.9 Administración de los datos

Los datos "sucios" son peligrosos. Las herramientas de limpieza especializadas y las formas de programar de los clientes proporcionan redes de seguridad.

No importa cómo esté diseñado un programa o cuán hábilmente se use. Si se alimenta mala información, se obtendrá resultados incorrectos o falsos. Desafortunadamente, los datos que se usan satisfactoriamente en las aplicaciones de línea comercial operacionales pueden ser basura en lo que concierne a la aplicación Data Warehouse.

Por lo tanto es de suma importancia tomar en cuanta una serie de conceptos que permitirán aportar la dosis de confiabilidad, oportunidad y eficiencia necesaria al Data Warehouse respecto a los datos que manipulará.

Estos conceptos se explican a continuación, y como ya lo hemos repetido insistentemente durante todo el presente documento, en este tema tampoco hay una formula predefinida a utilizar, sino mas bien algunas reglas que seguir y algunos cuidados a tener en la Administración de los datos.

Metadatos

Los metadatos es la información sobre los datos esencial para una utilización eficaz de un Data Warehouse. Forman un conjunto de información de administración y de seguimiento para el proyecto de decisión. Mas precisamente lo metadatos representan todas las informaciones necesarias para el acceso, la comprensión y la utilización de los datos del Data

Warehouse: semántica, origen, reglas de agregación, almacenamiento, formato, utilización ....

Por ejemplo, a continuación se muestra una manera de calificar este tipo de informaciones designadas con el término *metadatos* :

Tipo de Información	Significado
Semántica	¿Qué significa este dato? ¿Qué significa «cifra de negocio»? ¿Qué significa «cliente»? ¿Para qué sirve, quién la necesita? Esta pregunta se hace únicamente desde un punto de vista funcional.
Origen	¿De dónde proviene? ¿Dónde, por quién y cuándo ha sido creada, actualizada?
Regla de cálculo	¿Cómo se calcula, cómo se calcula la cifra de negocio a partir de¡ montante elemental de cada una de las facturas o de los contratos o eventualmente de los servicios anexos o de subcontrataciones, etc.? Muchos conceptos corresponden a un negocio y una regla de cálculo corresponde a una regla de gestión.
Regla de agregación	¿Cuál es el perímetro de consolidación? Por ejemplo, para el dato «cifra de negocio europeo», ¿qué significa «el conjunto de países europeos»? Esta noción puede cambiar según las empresas o según la organización.
Guardado, Formato	¿Dónde y cómo se guarda, cuál es su formato: «cifra de negocio» en pesetas, en dólares, sin tasas, precio neto, etc. ¿Cuál es su ámbito de valores?
Utilización	¿Cuáles son los programas informáticos que la utilizan? ¿Cómo y en qué máquinas está disponible? ¿Durante cuánto tiempo se conserva?

Hay una regla primordial: todos los datos deben ir documentados por un conjunto de metadatos. Por ejemplo, si interesa la «cifra de negocio consolidada en Europa para tal línea de productos y tal organización», hay que definir exactamente lo que cubre esta expresión, su modo de cálculo, etc. El dato está necesariamente vinculado a otros objetos del sistema de información; por tanto, también es necesario representar, describir y almacenar estas interacciones con otros datos.

Tipo de enlace	Definición
Ámbito, temas	El Data Warehouse se estructura más bien por tema. Por tanto, cada dato se indexará por tema o por ámbito..
Estructura organizativa, Estructura geográfica	El dato se indexará igualmente según la estructura organízativa o geográfica, porque un dato puede tener sentidos ligeramente distintos según la persona que la manipula.
Conceptos genéricos	La noción de producto se declinará en línea de productos, servicios, servicios postventa, etc.
Aplicaciones, programas	El dato será manipulado por una o más aplicaciones o programas.
Tablas, columnas	El dato se sitúa en una o más columnas, tablas y bases de datos
Sedes, máquinas	Esta rúbrica representa la localización física (sede informática y máquina) del dato.

Los metadatos servirán pues para enriquecer el dato almacenado en un Data Warehouse. Existen varias maneras de representar y almacenar estos metadatos. Para facilitar su acceso y manipulación., se podría utilizar una ficha que contenga una descripción del dato y de sus enlaces. Pero, generalmente, se utiliza un simbolismo habitual en informática: los modelos de datos en el sentido Merise del término. Los metadatos se expresan en forma de modelos

conceptuales y de modelos lógicos de datos (MCD y MLD). Así, se obtiene una visión sintética que permite navegar entre los diferentes datos.

Coherencia y fiabilidad

La administración de los datos es la función que permitirá ante todo garantizar la coherencia del modelo global. Esta coherencia no es inmediata y a menudo es necesario implementar una función dedicada a esta tarea. Esta función se encarga por ejemplo de todos los problemas de arbitraje entre los diferentes puntos de vista de la empresa (por ejemplo, la noción de margen puede diferir según los servicios).

Existe ya una función de este tipo en ciertas empresas. Antes de la llegada del Data Warehouse, algunos se dieron cuenta de la diversidad de los sistemas de la empresa: la producción, la investigación, el servicio comercial, la contabilidad, etc., tienen normalmente sus propios sistemas operativos que tienen generalmente muy mala disposición para intercambiar datos. El Data Warehousing, por su aproximación, obliga naturalmente a enfrentarse al problema. Es importante entonces implementar a nivel de grupo o a nivel de empresa funciones de federación, de pilotaje de los diferentes proyectos, para asegurarse de la coherencia de las bases. En el marco de un Data Warehouse, se encuentran los problemas habituales de administración de los datos, ya de por sí complejos de resolver, y son normalmente aún más agudos.
Recordemos ahora cuáles son estos problemas, relacionados tradicionalmente con la administración de los datos:

Redundancias, sinonimias, duplicados. La visión del cliente desde un punto de vista comercial no es la misma que desde el punto de vista de la contabilidad, la gestión administrativa o el servicio postventa. En ocasiones se puede incluso duplicar bases de datos; esto presenta un problema de administración.

Incoherencias según el origen o en el tiempo. La noción de producto puede no ser la misma en todas partes a pesar de una denominación idéntica.

No reutilización de los modelos, las estructuras o los ámbitos de valores.

No capitalización del conocimiento. Conceptos habituales, como producto, contrato o cliente se redefinen regularmente, en ocasiones de manera contradictoria.

No fiabilidad, según el origen del dato. La calidad del dato puede ser aleatoria (por ejemplo, presencia o no de un dato).

En el marco del Data Warehouse encontramos los mismos problemas con el agravante de la necesidad de consolidar y agregar los datos, por lo que será necesario un esfuerzo suplementario.

Un Ejemplo

Los datos "sucios" pueden presentarse al ingresar información en una entrada de datos (por ejemplo, "Sitsemas S. A." en lugar de "Sistemas S. A.") o de otras causas.

Cualquiera que sea, la data sucia daña la credibilidad de la implementación del depósito completo. En la **Figura No. 19** se muestra un ejemplo de formato de ventas en el que se pueden presentar errores. Afortunadamente, las herramientas de limpieza de datos pueden ser de gran ayuda. En algunos casos, puede crearse un programa de limpieza efectivo. En el caso de bases de datos grandes, imprecisas e inconsistentes, el uso de las herramientas comerciales puede ser casi obligatorio.

Decidir qué herramienta usar es importante y no solamente para la integridad de los datos. Si se equivoca, se podría malgastar semanas en

recursos de programación o cientos de miles de dólares en costos de herramientas.

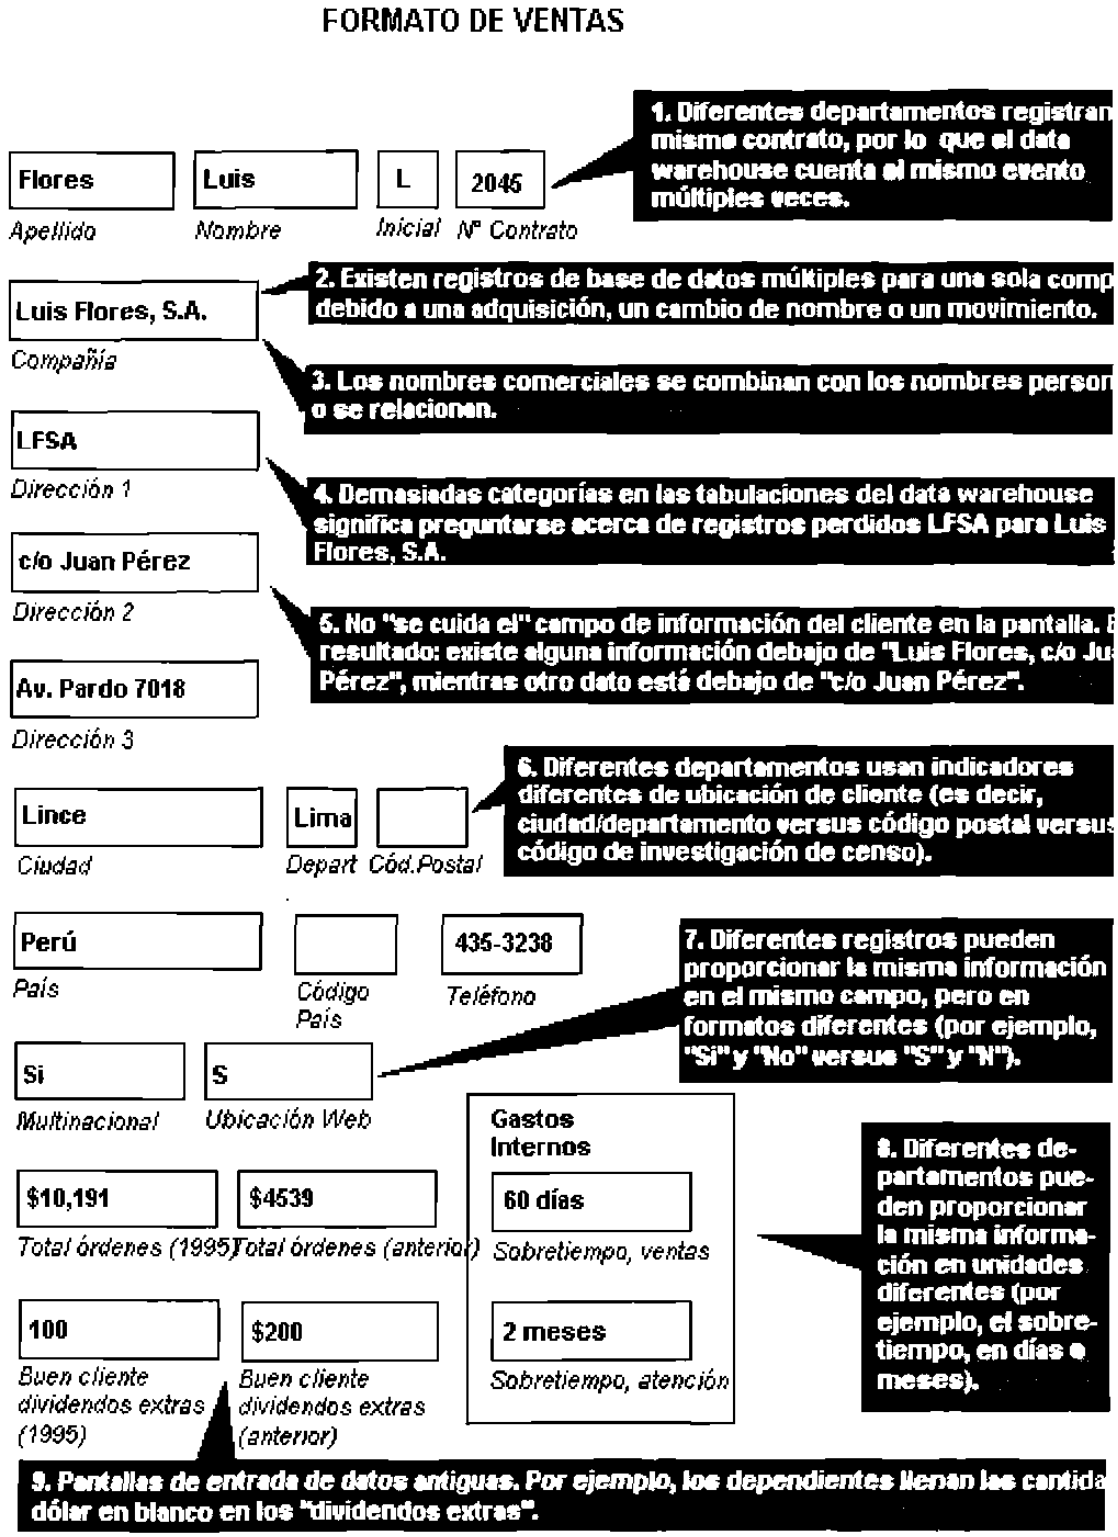

Figura No. 19

4.4 Etapa 3: Implementación de las Aplicaciones

En esta fase, el proyecto de Data Warehouse debe tener asignado el liderazgo adecuado, así como, los recursos humanos, tecnológicos y el presupuesto apropiado.

Sin embargo, deben evaluarse otros aspectos, como desarrollar un proyecto en su totalidad o por fases y además, diferenciar el tipo de proyecto a realizar.

Al llegar a esta etapa deben de coexistir dos visiones del Data Warehouse, tal y como lo muestra la **Figura No. 20** .

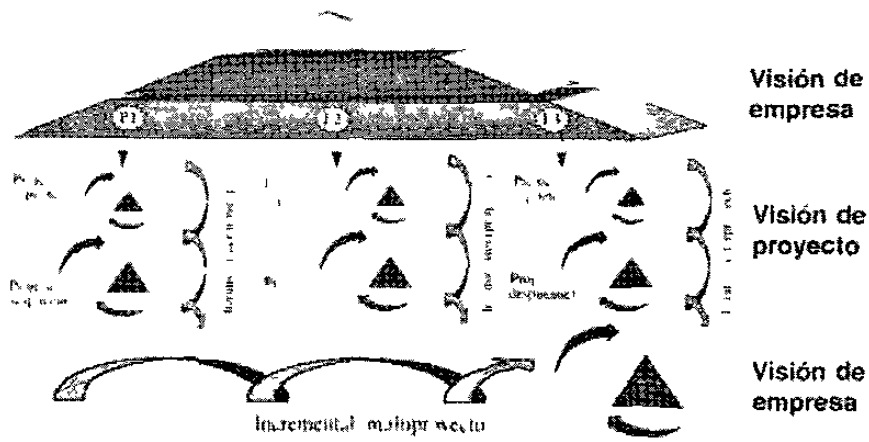

Figura No. 20

Una visión de empresa: los proyectos se identifican en la primera fase. A medida que se implementan, la infraestructura global del Data Warehouse se enriquece: desde este punto de vista, el método propuesto es incrementar. En efecto, cada proyecto es visto de manera independiente y responde a un objetivo de negocio delimitado. Pero participa también en la construcción del Data Warehouse integrándose en él.

Una visión de proyecto: los proyectos identificados en la fase inicial se convierten en aplicaciones, por ejemplo por una descomposición en dos etapas. En primer lugar, la realización del prototipo operativo permite concretar un subconjunto del proyecto identificado y desplegarlo en lugares piloto. Esta fase va seguida por el despliegue propiamente dicho del proyecto para todos los sitios afectados de la empresa.

Es necesario adaptar esta visión a cada contexto de empresa, porque es ilusorio presentar un método completo y universal sobre la implementación del Data Warehouse. Si bien la literatura se enriquece cada día con nuevos puntos de vista sobre este tema, éstos no comparten el mismo punto de vista.

4.4.1 Decisiones importantes al inicio de la implementación

Forma de Implementación del Data Warehouse

Elegir la forma en que se va a implementar un proyecto de Data Warehouse no es una tarea que se pueda determinar con exactitud, depende de muchos factores, entre los que se encuentran el grado de madurez informática de la empresa, factores económicos, de organización, etc.

Sin embargo como una recomendación general para mejorar las posibilidades de éxito al embarcarse en la implementación de un Data Warehouse se puede decir que: Es más viable el desarrollo de un proyecto en fases que produzcan resultados a corto plazo que el desarrollo de un proyecto que entregue resultados al término de varios años. Por ello, el proyecto debe estar centrado en un área o un proceso.

Tipo de Proyecto a implementar

Decidir sobre el tipo de proyecto, es algo complicado, ya que tiene un alto grado de relación con las decisiones estratégicas de la empresa y con cuestiones de carácter económico.

Un proyecto especializado se encarga de soportar directamente un proceso específico, puede ser Retención de Clientes, cobranza, etc. Este tipo de proyectos, por un lado tienen un resultado mas directo y visible respecto a los objetivos buscados, pero por otro lado tienden a ser mas costosos y tardar mas tiempo su implementación.

Un proyecto base entrega capacidades genéricas de análisis a todos los usuarios que tengan acceso al Data Warehouse, pero no tiene, entre sus funcionalidades, la solución de un problema específico o el soporte especializado de un proceso específico.

Un proyecto base es más económico y fácil de acabar que uno especializado.

En base a estas consideraciones el encargado de la implementación debe decidir con cual tipo de proyecto tiene mas posibilidades de obtener logros importantes en la Organización.

4.4.2 Estrategia en la Implementación

Un objetivo importante de la fase de implementación del Data Warehouse es el minimizar los riesgos inherentes a todo proyecto que implica la introducción de nueva tecnología en una organización. Una estrategia recomendable en el proceso de implementación se plantea mediante 10 pasos, los cuales se describen a continuación :

Paso 1. Identificar uno o varios problemas ó áreas de oportunidad actual en la Organización que cumpla con las siguientes características :

- Sea de uso estratégico para el negocio.
- Genere ventaja competitiva a la organización o reduzca costos.
- Pueda ser apoyado o resuelto mediante el Data Warehouse.

De las posibles opciones se deberá seleccionar el proyecto dependiendo de las prioridades del negocio; se deberá optar por el que sea más rentable (justificación económica) y más factible técnicamente. En caso de que los factores de selección no coincidan en un mismo proyecto, se deberá optar por el que mejor siga la línea del negocio.

Paso 2. Definir el modelo lógico de datos a implementar para resolver el problema planteado. Ejemplo: Se puede dar un modelo lógico cuando se presenta al usuario la información en términos de dimensiones (clientes, productos, canales de ventas, promociones, adquirientes, etc) básicas del modelo de datos y hechos que se registrarán para estas dimensiones (medidas de ventas, de costos, de producción, de facturación, de cartera, de calidad, de servicio, etc.).

Paso 3. Reunir los datos para poblar ese modelo lógico de datos. En este punto es importante identificar las formas en que serán administrados los datos, su

alimentación, así como su adecuación a la estructura y semántica del Data Warehouse.

Paso 4. Definir el mejor diseño físico para el modelo de datos. El diseño físico debe estar orientado a generar buen rendimiento en el procesamiento de consultas, a diferencia del modelo lógico que está orientado al usuario y a la facilidad de consulta.

Paso 5. Definir los procesos de extracción, filtro, transformación de información y carga de datos que se deben implementar para poblar ese modelo de datos.

Paso 6. Definir los procesos de administración de la información que permanece en el Data Warehouse.

Paso 7. Definir las formas de consultas a la información del Data Warehouse que se le proporcionará al usuario. Para ello, debe considerarse la necesidad de resolver la necesidad y la potencia de consulta.

Paso 8. Completar el modelo de consulta base, relativo al área seleccionada.

Paso 9. Implementar los procesos estratégicos del área de trabajo, es decir, implementar herramientas especializadas de scoring, herramientas especializadas para inducción de conocimiento (Data Mining), etc.

Paso 10. Completar las áreas de interés, en forma similar a lo descrito anteriormente.

Es importante destacar que estos pasos representan una guía para la implementación y pueden ser modificados y/o agregar pasos dependiendo de las necesidades de la Organización para la que se está construyendo el Data Warehouse.

Además esta guía establece un orden para la ejecución de cada una de las tareas a realizar, pero como ya habrá notado, no establece mecanismos para el seguimiento del proyecto. Estos mecanismos son importantes y en general se refiere al establecimiento de tareas, secuencia de ejecución, responsables, costos asignados, etc.

Se sugiere controlar el proyecto mediante el uso de gráficas de Gant, o cualquier otra técnica ó metodología conocida para el control de proyectos. Para una mayor agilidad y eficiencia puede utilizar software especializado para el control de proyectos.

4.4.3 Capacitación en la Implementación

La capacitación es un proceso que debe estar presente durante todo el proyecto, aun antes de la fase de implementación. Esta función no debe negligirse, ya que el proyecto de Data Warehouse lleva consigo toda una serie de cambios y nuevas tecnologías cuyo éxito depende directamente de su uso y explotación en beneficio de la Organización.

Sin embargo la capacitación toma una importancia aún mayor en la fase de implementación, ya que está íntimamente ligada con los tiempos del proyecto y en términos generales con el éxito del proyecto.

Toda persona involucrada en el proyecto generalmente requiere algún tipo de capacitación, por lo que esta se debe plantear en los diferentes ámbitos de la empresa.

En el ámbito técnico . El área de informática es una de las principales afectadas, ya que debe tiene que adiestrarse en la utilización de metodologías, técnicas, aplicaciones, etc. Pero no solo el informático debe de recibir capacitación técnica, los usuarios finales también deben ser instruidos en el uso de las diferentes herramientas que utilizarán para explotar la información derivada del Data Warehouse.

En el ámbito Organizativo . Aquí los principales involucrados son los usuarios y los mandos ejecutivos. A este nivel la capacitación se debe enfocar a instruirlos respecto a la mejor explotación de la información proporcionada. También es muy importante aclararles todos los conceptos de negocio homologados durante la creación del Data Warehouse, con los cuales trabajaran en adelante.

4.4.4 Uso de herramientas en la Implementación

Existe una gran diversidad de herramientas a utilizar en un Data Warehouse, por lo durante la implementación se dificulta el determinar cual es el uso que se le debe dar a cada una de estas herramientas.

De manera general existen algunas clasificaciones que definen la utilización de las diferentes herramientas de Data Warehouse. Cada herramienta cae en una de estas clasificaciones.

El presente tema tiene como objetivo el definir los usos adecuados para cada una de estas clasificaciones, de forma tal que el problema solo se reduzca a seleccionar la clasificación adecuada para cada caso que se presente.

En los anexos del presente documento se muestran una serie de opciones de Software agrupadas por clasificación. De esta manera una vez seleccionada la clasificación podemos consultar algunas de las herramientas de Software que apoyarían nuestro caso. La tabla "Matriz para selección de herramientas" puede serle de gran utilidad para este propósito.

MATRIZ PARA SELECCIÓN DE HERRAMIENTAS

Tipo de Herramienta	Pregunta básica	Modelo de Salida	Usuario típico
Consulta y Reporte	¿Qué sucedió?	Reportes de ventas mensuales; histórico de inventario	Necesita datos históricos. Puede tener aptitud técnica limitada
Procesamiento analítico en línea (OLAP)	¿Qué sucedió y por qué?	Ventas mensuales vs. Cambios de precio de los competidores	Necesita ir a una visión no estática de los datos. Técnicamente astuto
Sistema de Información Ejecutiva (SIE)	¿Qué necesito conocer ahora?	Libros electrónicos; Centros de comandos	Necesita información resumida o de alto nivel. Puede no ser técnicamente astuto

Herramientas de Consulta y Reporteo

Aunque las capacidades varían de un producto a otro, las herramientas de consulta y reporte son más apropiadas cuando se necesita responder a la pregunta :

- ¿"Qué sucedió"?

Ejemplo:

¿"Cómo comparar las ventas de los productos X,Y y Z del mes pasado con las ventas del presente mes y las ventas del mismo mes del año pasado?"

Existe una gran cantidad de herramientas de consulta y reporte en el mercado. Algunos proveedores ofrecen productos que permiten tener más control sobre qué procesamiento de consulta es hecho en el cliente y qué procesamiento en el servidor.

Las más simples de estas herramientas son productos de reporte y consultas básicas. Ellos proporcionan desde pantallas gráficas a generadores SQL. Más que aprender SQL o escribir un programa para acceder a la información de una base de datos, las herramientas de consulta al igual que la mayoría de herramientas visuales, le permiten apuntar y hacer click a los menús y botones para especificar los elementos de datos, condiciones, criterios de agrupación y otros atributos de una solicitud de información.

La herramienta de consulta genera entonces un llamado a una base de datos, extrae los datos pertinentes, efectúa cálculos adicionales, manipula los datos si es necesario y presenta los resultados en un formato claro. Se pueden almacenar las consultas y los pedidos de reporte para trabajos subsiguientes, como está o con modificaciones.

El procesamiento estadístico se limita comúnmente a promedios, sumas, desviaciones estándar y otras funciones de análisis básicas.

Lo más avanzado de estos productos lo orientará hasta las consultas que tienen sintaxis mala o que devuelven resultados imprevistos. El acceso a los datos han mejorado también con las nuevas versiones de estos productos y los vendedores ya instalan manejadores (drivers) estándares tales como ODBC y 32-bit nativo, hasta fuentes de datos comerciales.

En general, los administradores de data warehouses que usen estos tipos de productos, deben estar dispuestos a ocupar su tiempo para resolver las tareas de estructuración, como administrar bibliotecas y directorios, instalar software de conectividad, establecer nombres similares en Inglés y precalcular "campos de datos virtuales".

Herramientas de Bases de Datos Multidimensionales (OLAP)

Las primeras soluciones OLAP estuvieron basadas en bases de datos multidimensionales (MDDBS). Un cubo estructural (o un arreglo multidimensional) almacenaba los datos para que se pudieran manipular intuitivamente y claramente ver las asociaciones a través de dimensiones múltiples.

Para los usuarios que requieren algo mas que una simple vista estática de los datos, las herramientas del procesamiento analítico en línea (OLAP - On Line Analytical Processing), proveen capacidades que contestaría :

- "¿Qué sucedió? " al analizar el porqué de los resultados en diferentes dimensiones.

Sin embargo las herramientas OLAP aun presentan algunas limitaciones que afectan su utilización, configuración y desempeño. Explicaremos dos de ellas que presentan gran importancia :

- Las nuevas estructuras de almacenamiento de datos requieren bases de datos propietarias. No hay realmente estándares disponibles para accesar a los datos multidimensionales.
- Las compañías generalmente almacenan los datos de la empresa en bases de datos relacionales, lo que significa que alguien tiene que extraer, transformar y cargar estos datos en el hipercubo. Este proceso puede ser complejo y tardado pero, nuevamente, los proveedores están investigando la forma de solucionarlos. Las herramientas de extracción de datos y otras automatizan el proceso, trazando campos relacionales en la estructura multidimensional y desarrollando el MDDB sobre la marcha. Algunos proveedores ofrecen ahora la técnica ROLAP (Relational On Line Analytical Processing), que explora y opera en el Data Warehouse directamente usando llamadas SQL estándares. Las herramientas de pantallas permiten retener los pedidos multidimensionales, pero el motor ROLAP transforma las consultas en rutinas SQL. Entonces se recibe los resultados tabulados como una hoja de cálculo multidimensional.

Los retos administrativos y de desarrollo de OLAP, a diferencia de las encontradas con las herramientas de consulta y reporte, son generalmente más complejos. Definiendo el OLAP y el software de acceso a los datos, se requiere un claro entendimiento de los modelos de datos de la corporación y las funciones analíticas requeridas por ejecutivos, gerentes y otros analistas de datos.

El desarrollo de productos comerciales pueden aminorar los problemas, pero OLAP es raramente una solución clave. La arquitectura debe permitir el soporte a su fuente de datos y requerimientos. Pero una vez que se ha establecido un sistema OLAP, el soporte al usuario final será mínimo.

Sistemas de Información Ejecutivos (SIE)

Un uso típico de un SIE es :

- facilitar al usuario la recuperación y análisis de la métricas, de desempeño de la organización.

Las herramientas de sistemas de información ejecutivos SIE (Executive Information Systems), proporcionan medios sumamente fáciles de usar para consulta y análisis de la información confiable. Generalmente se diseñan para el usuario que necesita conseguir los datos rápidamente, pero quiere utilizar el menor tiempo posible para comprender el uso de la herramienta.

El precio de esta facilidad de uso es que por lo general existen algunas limitaciones sobre las capacidades analíticas disponibles con el sistema de información ejecutivo. Además, muchas de las herramientas de consulta/reporte y OLAP/multidimensional, pueden usarse para desarrollar sistemas de información ejecutivos.

El concepto de sistema de información ejecutivo es simple: los ejecutivos no tienen mucho tiempo, ni la habilidad en muchos casos, para efectuar el análisis de grandes volúmenes de datos. El SIE presenta vistas de los datos simplificados, altamente consolidados y mayormente estáticas.

Los Libros electrónicos: Son una versión en línea, contraparte del papel que muchos ejecutivos usan en reuniones con el personal. Las diapositivas presentan una visión concreta de una iniciativa organizacional o quizás los datos para dar a conocer la situación actual de un proyecto importante.

El centro de comando: Es básicamente una conjunto reducido de puntos en un amplia cantidad de reportes. El newsgroup recupera desde Internet y otros

materiales que proveen conocimientos en la organización. Los reportes del centro de comando pueden ser accedidos diariamente o con más frecuencia, si la información cambia constantemente o sólo cuando se garantiza las excepciones. Algunos productos generan alarmas cuando ocurren las excepciones especificadas.

Cuando sea apropiado, cada diapositiva del Libro electrónico o pantalla del centro de comando, debería permitir al ejecutivo recibir información adicional si lo desea (y si está disponible). A diferencia del modelo OLAP, donde el incremento de niveles de información se dan a conocer tal como el analista manipula los datos, un ejecutivo espera una descripción global. No deberían escudriñar para obtener respuestas.

Por ello, cuando los ejecutivos piden más información desde las diapositivas del libro electrónico o de las pantallas del centro de comandos, la presentación debería ser cuidadosamente elaborada para presentar principalmente información adicional amplificada. El ejecutivo debe ser capaz de pasar cada punto para "más información", sin perder alguna información crítica.

Los sistemas de información ejecutivos, generalmente tienen una programación que variará en complejidad de un producto a otro.

4.5 Etapa 4: Evaluación de los resultados

Para la evaluación económica se deberán cuantificar, mediante cualquier método, el costo de cada uno de los trabajos involucrados en la elaboración del Data Warehouse

- Cuánto cuestan las demoras
- Cuánto cuestan los errores
- Cuánto se gasta en asesorías especializadas

4.5.1 Evaluación de rendimiento de la Inversión (ROI)

Cuando se evalúan los costos, el usuario del Data Warehouse puede no tener el contenido de los costos en mente, pero las preguntas mínimas que puede comenzar a hacerse son las siguientes:

- ¿Qué clases de costos excedieron el presupuesto en más del 10% en cada uno de los 12 meses pasados?
- ¿Se aumentaron los presupuestos en más de 5% para cualquier área dentro de los últimos 18 meses?
- ¿Cómo especificar las clases de gasto entre diferentes departamentos? ¿Entre divisiones? ¿A través de las regiones geográficas?

- ¿Cómo tener márgenes de operación sobre los dos últimos años en cada área de negocio? Donde han disminuido los márgenes, ¿se han incrementado los costos?

Con frecuencia, los aspectos realmente importantes identificados por una gestión mayor, tienen un valor agregado, en el que ellos saben si tuvieron la información que estaban buscando, lo que significaría una mejora de (por ejemplo) las ventas en 0.5% a 1% - que, si su operación estuvo por los billones de dólares en un año, puede resultar en cientos de millones de dólares. En algunos casos, el costo del depósito inicial se ha recobrado en un período de 6 a 8 meses.

Al hacerse preguntas de este tipo, los usuarios comienzan a identificar las áreas en la que los costos han aumentado o disminuido significativamente y pueden evaluar cada una de estas áreas con más detalle.

4.5.2 El ROI en proyectos de Data Warehouse

A un nivel general los grandes gabinetes de análisis se han centrado en las realizaciones más significativas en el ámbito del Data Warehousing, en particular desde el ángulo económico. Así, el gabinete estadounidense Gartner Group presenta algunos ejemplos, que expresa como beneficio sobre inversión en el tiempo. Este beneficio sobre inversión se expresa en multitud de partidas:

	Retorno sobre Inversión	Periodo (en años)
Industria de gran consumo	*58	4
Compañía aérea	*5	2
Banca	*33	2
Gran distribución	*7	5
Telecomunicaciones	*9	4
Banca regional	*70	5

Hay que indicar que todos los ejemplos presentados aquí conciernen a empresas que se sitúan en el marco de un mercado de volumen, disponiendo de hecho de un número muy importante de clientes, pudiendo ser éstos empresas, pero también individuos. No cabe duda de que en este caso concreto es cuando el valor agregado de un Data Warehouse será más destacable. Esto explica que los éxitos más mediáticos afectan a este tipo de empresa, aunque el Data Warehouse es un concepto que afecta potencialmente a todo actor del mundo económico.

Un estudio sobre el mismo tema ha sido realizado por IDC. Su objetivo no era valorar tal o cual experiencia, sino reunir la información para cualificar de manera genérica la aportación de un Data Warehouse a las empresas. Se interrogó a 62 organizaciones americanas y europeas. Éstos son algunos de sus resultados:

- Beneficio sobre inversión en 3 años: la media es del 401 %, la mediana del 167%. El 90% de las empresas consultadas destacaron un beneficio sobre inversión superior al 40%. Para el 13% de las empresas, el beneficio sobre inversión sobrepasó el 1000%.

- El equilibrio sobre inversión (en inglés payback) se alcanza como promedio en 2.31 años, siendo la mediana de 1.67 años. La inversión promedio es de 2.2 millones de dólares.

A pesar de la elocuencia de estas cifras, es difícil describir de manera genérica y cualitativa los beneficios de un Data Warehouse: muy relacionados con la estrategia de la empresa, dependen necesariamente del sector de actividad. Por ejemplo, un estudio llevado a cabo por AT&T Teradata indica que, en la distribución a gran escala, las principales zonas de oportunidad son:

- Un aumento de las ventas a través de una Mercadotecnia mejor orientada;

- Una mejora de las tasas de rotación de los stocks;

- La reducción de los stocks de productos que han quedado obsoletos;

- La reducción de las pérdidas relacionadas con las rebajas,

- Devoluciones y comisiones,

- La disminución de costos de los productos de proveedores relacionados con una mejor negociación de precios.

Globalmente, el estudio indica que, para los grandes distribuidores, el beneficio sobre inversión medio es de 7 veces la inversión y puede llegar hasta 125 veces la inversión inicial.

Un último elemento contabilizado que muestra el valor agregado de un Data Warehouse aparece en un artículo sobre el Data Warehouse en la gran distribución publicado por el Journal of Data Warehousing [SKE96]. Se analiza especialmente el Data Warehouse del distribuidor W.H. Smith, que en cuanto a técnica es una base de 160 gigabytes, utilizada por 300 usuarios y que recoge 150.000 productos, 10.000 proveedores y 300 almacenes. Tras unos meses de producción, las ganancias calculadas son las siguientes:

Mejor decisión sobre la política de tarificación	$ 750,000
Reestructuración de las líneas	$ 450,000
Mejor seguimiento de la gestión de pérdidas imprevistas (robo, pérdida, etc.)	$ 100,000
Optimización del stock para la campaña de Navidad	$ 900,000
Gestión de devoluciones de mercancías	$ 800,000

ANEXOS

Lista de Software

A-1. Herramientas de consulta y Reporte

PRODUCTO	EMPRESA DISTRIBUIDORA
Access	Microsoft
Business Objects	Business Objects, Inc.
Crystal Reports, Crystal Info	Seagate Software
DB Publisher	Xense Technology Inc.
DbPower	Db-Tech Inc.
Esperant	Speedware
FOCUS Six	Information Builders, Inc.
4S-Report	Four Seasons Software, Inc
Freequery	Dimension Software Systems
Front & Center for Reporting, Nomad	Thomson Software Products
HP Information Access	Hewlett-Packard
Impromptu	Cognos Corporation
InfoAssistant	Asymetrix
InfoMaker	Powersoft Corporation
InfoQuery	Platinum Technology, Inc.
Internet DataSpot	DTL Data Technologies Ltd.
Insight	Williams & Partner
Interactive Query	New Generation software
IQ/Objects, IQ/SmartServer	IQ Software Corporation
Oracle Reports, Browser	Oracle Corporation
Paradox	Borland
Platinum Report Facility	Platinum Technology, Inc
R&R Report Writer	Concentric Data Systems
Report Writer	Raima
SAS System	SAS Institute
SQLPRO Agent	Beacon Ware, Inc.
SQR Workbench	MITI
ViewPoint	Soliton Associates
VisPro/Reports	Hock Ware
Visual Cyberquery	Cyberscience Corporation
Visual Dbase	Borland
Visual Express	Computer Associates International
Visual FoxPro	Microsoft Corporation
Visualizer Query, Charts	IBM
Voyant	Brossco Systems
WebSeQueL	InfoSpace Inc.
Xentis	GrayMatter Software Corporation

A-2. Herramientas de Bases de Datos Multidimensionales (OLAP)

PRODUCTO	EMPRESA DISTRIBUIDORA	TIPO
Acuity ES	Acuity Management Systems Ltd.	MDDB
Acumate ES	Kenan Systems Corporation	MDDB
Advance For Windows	Lighten, Inc.	MDDB
AMIS OLAP Server	Hoskyns Group plc	MDDB
BrioQuery	Brio Technology	MDDB
Business Objects	Business Objects, Inc.	Relacional
Commander OLAP, Decision, Prism	Comshare Inc.	MDDB
Control	KCI Computing	Relacional
CrossTarget	Dimensional Insight	MDDB
Cube-It	FICS Group	MDDB
Dataman	SLP Infoware	MDDB
DataTracker	Silvon Software, Inc.	Relacional
DecisionSuite	Information Advantage, Inc.	Relacional
Delta Solutions	MIS AG	MDDB
Demon for Windows	Data Command Limited	MDDB
DSS Agent	MicroStrategy	Relacional
DynamicCube.OCX	Data Dynamics, Ltd.	Relacional
EKS/Empower	Metapraxis, Inc.	MDDB
Essbase Analysis Server	Arbor Software Corporation	MDDB
Essbase/400	ShowCase Corporation	MDDB
Express Server, Objects	Oracle	MDDB
Fiscal	Lingo Computer Design, Inc.	Relacional
Fusion	Information Builders, Inc.	MDDB
FYI Planner	Think Systems	MDDB
Gentia	Planning Sciences	MDDB
Helm	Codeworks	MDDB
Holos	Holistic Systems	MDDB
Hyperion OLAP	Hyperion Software	MDDB
Informer	Reportech	MDDB/Relacional
Intelligent Decision Server	IBM	Relacional
IQ/Vision	IQ Software Corporation	Relacional
Lightship	Pilot Software, Inc.	MDDB
Matryx	Stone, Timber, River	MDDB
MDDB Server	SAS	Relacional
Media	Speedware Corporation	MDDB
Metacube	Informix	Relacional
MIKSolution	MIK	MDDB
MIT/400	SAMAC, Inc	MDDB
OLAP Office	Graphitti Software GmbH	MDDB
OpenOLAP	Inphase Software Limited	Relacional

A-3. Sistemas de Información Ejecutivos (SIE)

PRODUCTO	EMPRESA DISTRIBUIDORA
Acuity/ES	Acuity Management Systems Limited
Applixware	Applix
BusinessMetrics	Valstar Systems Ltd.
BOARD	Pragma Inform
COINS	Russell Consulting Limited
ColumbusEIS	Jitcons YO
Commander EIS	Comshare Inc.
Corporate Management/ Financial Executive Information System	Strategic Information Associates, Inc.
CorVu	CorVu Pty Ltd.
Decision Suite	Softkit
Discovery EIS	Atlantic Information Systems Ltd.
EIS	Inphase Software Limited
Electronic Balanced Scorecard	ASI Financial Services
Enterprise Periscope	Everyware Development Corp.
Eureka	European Management Systems
ExecuSense	TLG Corporation
FOCUS EIS	Information Builders, Inc.
Forest & Trees	Platinum Technologies, Inc.
iMonitor	BayStone Software
InfoManager	Ferguson Information Systems
Iridon Almanac	The Great Elk Company Limited
inSight	Arcplan Information Services
LEADER	Sterling Strategic Solutions
MagnaFORUM	Forum Systems, Inc.
Merit	GIST, s.r.o.
Open EIS Pak	Microsoft
Panorama Business Views	Panorama Business Views Inc.
Perspectives	Syntell
Qbit	Zenia Software, Inc.
Reveal	CSD Software Inc.
SAS System	SAS Institute
Show Business EIS	Show Business Software
Tiler EIS++	Avoca Systems Limited
Track	Track Business Solutions
Traffic Control EIS	Research & Planning, Inc.
VentoMap, VentoSales	Vento Software Inc.
Virtual Headquarters Management System	vHQ LLC
Visual EIS	Synergistic Software
Visual Publisher	KMA Associates International, Inc
VITAL	Braintec Corporation
Wingz	Investment Intelligence Systems Group
Wired for OLAP	AppSource Corporation
Xecutive Pulse EIS	Megatrend Systems, Ltd.

A-4. Bases de datos de Data Warehouse

PRODUCTO	EMPRESA DISTRIBUIDORA
Adabas D	Software AG
Advanced Pick	Pick Systems
DB2	IBM
Fast-Count DBMS	MegaPlex Software
HOPS	HOPS International
Microsoft SQL Server	Microsoft
Model 204	Computer Corporation of America
NonStop SQL	Tandem
Nucleus Server	Sand Technology Systems
OnLine Dynamic Server, Extended Parallel Server	Informix
OpenIngres	Computer Associates
Oracle Server	Oracle
Rdb	Oracle
Red Brick Warehouse	Red Brick Systems
SAS System	SAS
Sybase IQ	Sybase
Sybase SQL Server, SQL Server MPP	Sybase
SymfoWARE	Fujitsu
Teradata DBS	NCR
THOR	Hitachi
Time Machine	Data Management Technologies, Inc.
Titanium	Micro Data Base Systems, Inc.
Unidata	Unidata, Inc.
UniVerse	VMARK
Vision	Innovative Systems Techniques, Inc.
WX9000	White Cross Systems Inc.
XDB Server	XDB Systems, Inc.

Lista de figuras

Figura	Página

1. Orientación al tema del Data Warehouse 16
2. Datos Integrado en el Data Warehouse 19
3. Los de tiempo variante del Data Warehouse 22
4. Datos operacionales VS datos Data Warehouse 24
5. Objetivos del Data Warehouse 26
6. Estructura del Data Warehouse 27
7. Lógica de acceso 30
8. Ejemplo de datos en el Data Warehouse 31
9. Arquitectura del Data Warehouse 36
10. Infraestructura del Data Warehouse 48
11. Vistas del Data Warehouse 53
12. Proyecto Data Warehouse 59
13. Proceso para implementación de las aplicaciones 65
14. Proyecto prototipo de Data Warehouse 67
15. Alcance del Data Warehouse 77
16. Data Warehouse Integrado 79
17. Data Warehouse Distribuido 80
18. Data Warehouse Por Niveles 81
19. Ejemplo de confiabilidad de la información 102
20. Proceso global del Proyecto Data Warehouse 103