

Universidad Autónoma del Estado de Hidalgo

Escuela Superior Huejutla





Área Académica: Sistemas Computacionales

Tema: Introducción a la Minería de Datos

Profesor: Felipe de Jesús Núñez Cárdenas

Periodo: Agosto Noviembre 2011

Keywords: Minería de Datos, Datawarehouse, OLAP, OLTP





Tema: Introducción a la Minería de Datos

Abstract

Data mining has become a tool that allows companies to predict or describe your current events based on operational data base, all of which has revolutionized the software industry by the growth in storage and speed processing of new computer equipment, data mining supports different algorithms for these events as clustering, classification, etc..

Keywords: Minería de Datos, Datawarehouse, OLAP, OLTP





Finalidad de los Sistemas de Información

La información ***reduce nuestra incertidumbre*** (sobre algún aspecto de la realidad) y, por tanto, nos permite tomar mejores decisiones





Finalidad de los Sistemas de Información


- *Inicialmente* la finalidad de los sistemas de información era recopilar información sobre un parcela del mundo para ayudar en la toma de decisiones:
 - recuentos de cereales en Babilonia, de cacao por los pipiles,
 - censos civiles y militares romanos o chinos,
 - libros contables de árabes o sefardíes,
 - ...
 - *Actualmente*, con la informatización de las organizaciones y la aparición de aplicaciones software operacionales sobre el sistema de información, la finalidad *principal* de los sistemas de información es dar soporte a los procesos básicos de la organización (ventas, producción, personal...).





Interés Renovado por la Finalidad

Una vez satisfecha la necesidad de tener un soporte informático para los procesos básicos de la organización (**sistemas de información para la gestión**).



Las organizaciones exigen nuevas prestaciones de los sistemas de información (**sistemas de información para la toma de decisiones**).





Evolución

- 60's: Informes *batch*:
 - la información es difícil de encontrar y analizar, poco flexible, se necesita reprogramar cada petición.
- 70's: Primeros DSS (*Decision Support Systems*) y EIS (*Executive Information Systems*):
 - basados en terminal, no integrados con el resto de herramientas.
- 80's: Acceso a datos y herramientas de análisis integradas (conocidas como *intelligent business tools*):
 - Herramientas de consultas e informes, hojas de cálculo, interfaces gráficos e integrados, fáciles de usar.
 - Acceden a las bases de datos operacionales ("killer queries").
- 90's: Almacenes de Datos y herramientas OLAP.
- 00's: Herramientas de Minería de Datos y Simulación.





Herramientas para la Toma de Decisiones

Han aparecido diferentes herramientas de negocio o DSS que *coexisten*: EIS, OLAP, consultas & informes, minería de datos, ...

- ¿Cuál es la diferencia entre EIS y OLAP?
- ¿Cuál es la diferencia entre “informes avanzados” y OLAP?
- ¿Cuál es la diferencia entre OLAP y Minería de Datos?
- ¿Qué interrelaciones existen entre todas estas herramientas?





Herramientas para la Toma de Decisiones

¿Cuál es la diferencia entre EIS y OLAP?

Un EIS (*Executive Information System*) es un sistema de información y un conjunto de herramientas asociadas:

Proporciona a los directivos acceso a la información de estado y sus actividades de gestión. Está especializado en analizar el estado diario de la organización (mediante indicadores clave) para informar rápidamente sobre *cambios* a los directivos.

La información solicitada suele ser, en gran medida, numérica (*ventas semanales, nivel de stocks, balances parciales, etc.*) y representada de forma gráfica al estilo de las hojas de cálculo.

Las herramientas OLAP (*On-Line Analytical Processing*) son más genéricas:

Funcionan sobre un sistema de información (transaccional o almacén de datos)

Permiten realizar agregaciones y combinaciones de los datos de maneras mucho más complejas y ambiciosas, con objetivos de análisis más estratégicos.





Herramientas para la Toma de Decisiones

¿Cuál es la diferencia entre “informes avanzados” y OLAP?

Los sistemas de informes o consultas avanzadas:
están basados, generalmente, en sistemas *relacionales u objeto-relacionales*,
utilizan los operadores clásicos: concatenación, proyección, selección, agrupamiento, ... (en SQL y extensiones).
el resultado se presenta de una manera tabular.

Las herramientas OLAP

Están basadas, generalmente, en sistemas o *interfaces multidimensionales*,
Utilizando operadores específicos (además de los clásicos): *drill, roll, pivot, slice & dice, ...*
El resultado se presenta de una manera matricial o híbrida.





Herramientas para la Toma de Decisiones

¿Cuál es la diferencia entre OLAP y minería de datos?

Las herramientas OLAP

proporcionan facilidades para “manejar” y “transformar” los datos.
producen otros “datos” (más agregados, combinados).
ayudan a analizar los datos porque producen *diferentes vistas* de los mismos.

Las herramientas de Minería de Datos:


son muy variadas: permiten “extraer” patrones, modelos, descubrir relaciones, regularidades, tendencias, etc.
producen “reglas” o “patrones” (“conocimiento”).





Herramientas para la Toma de Decisiones

¿Qué interrelaciones existen entre todas estas herramientas?



- La aparición de algunas de ellas han hecho cambiar la manera de trabajar de otras herramientas.





Almacenes de Datos

El almacén de datos es ahora el “**sistema de información central**” en todo este proceso.

Un almacén de datos es una colección de datos:

- orientada a un dominio
- integrada
- no volátil
- variante en el tiempo

para ayudar en la toma de decisiones [Immon 1992, 1996]





Almacenes de Datos

Actualmente,

Los almacenes de datos y las técnicas OLAP son las maneras más efectivas y tecnológicamente más avanzadas para **integrar, transformar y combinar los datos para facilitar** al usuario o a otros sistemas **el análisis de la información.**





Minería de Datos

La Minería de Datos es un conjunto de técnicas de análisis de datos que permiten:

- Extraer patrones, tendencias y regularidades para **describir** y comprender mejor los datos.
- Extraer patrones y tendencias para **predecir** comportamientos futuros.

Debido al gran volumen de datos este análisis ya **no puede ser manual** (ni incluso facilitado por herramientas de almacenes de datos y OLAP) sino que **ha de ser (semi-)automático**.





Minería de Datos

La Minería de Datos se diferencia claramente del resto de herramientas en el sentido de que:

**no transforma y facilita el acceso a la información
*para que el usuario la analice más fácilmente.***

la minería de datos “analiza” los datos





Minería de Datos

La minería de datos es sólo una etapa del **proceso de extracción de *conocimiento* a partir de datos.**

Este proceso consta de varias fases:

Preparación de Datos (selección, limpieza, y transformación), Minería de Datos, Evaluación, Difusión y Uso de Modelos.

incorpora muy diferentes técnicas

árboles de decisión, regresión lineal, redes neuronales artificiales, técnicas bayesianas, máquinas de soporte vectorial, etc.

de campos diversos:

aprendizaje automático e I.A., estadística, bases de datos, ...

aborda una tipología variada de problemas:

clasificación, categorización, estimación/regresión, agrupamiento, ...





Minería de Datos

¿Es necesario tener almacenes de datos para realizar minería de datos?

Los almacenes de datos no son *imprescindibles* para hacer extracción de conocimiento a partir de datos.

Las *ventajas* de organizar un almacén de datos para realizar minería de datos se amortizan sobradamente a medio y largo plazo cuando:

- tenemos grandes volúmenes de datos, o
- éstos aumentan con el tiempo, o
- provienen de fuentes heterogéneas o
- se van a combinar de maneras arbitrarias y no predefinidas.





Bibliografía

- Hand, D.J.; Mannila, H. and Smyth, P. “Principles of Data Mining”, The MIT Press, 2000.
- Hernández, J.; Ramírez, M.J.; Ferri, C. “Introducción a la Minería de Datos” Pearson Prentice Hall, 2004.
- Kosala, R.; Blockeel, H. “Web Mining Research: A Survey” ACM SIGKDD Explorations, Newsletter of the ACM SIG on Knowledge Discovery and Data Mining, June 2000, Vol. 2, nº1, pp. 1-15.
- Mena, Jesus “Data Mining Your Website”, Digital Press, July 1999.
- Mitchell, T.M. “Machine Learning” McGraw-Hill 1997.
- Pyle, D. “Data Preparation for Data Mining” Morgan Kaufmann, Harcourt Intl., 1999.
- Thuraisingham, B. “Data Mining. Technologies, Techniques, Tools, and Trends”, CRC Press, 1999.
- Witten, I.H.; Frank, E. “Tools for Data Mining”, Morgan Kaufmann, 1999.
- Wong, P. C. “Visual Data Mining”, Special Issue of *IEEE Computer Graphics and Applications*, Sep/ Oct 1999, pp. 20- 46.
- Material extraído del Análisis y Extracción de Conocimiento en Sistemas de Información: Datawarehouse y Datamining de **José Hernández Orallo**, **Universidad Politécnica de Valencia**

