

Historial Editorial

Recepción: 17-01-12

Revisión: 13-02-12

Aceptación: 26-04-13

**La Inteligencia Analítica y la Competitividad
en las Empresas**

Silvia Edith Albarrán Trujillo

Universidad Autónoma del Estado de México, Facultad
de Ingeniería, México
seat@fi.uaemex.mx

Mireya Salgado Gallegos

Universidad Autónoma del Estado de México, Facultad
de Ingeniería, México
msalgadog@uaemex.mx

La Inteligencia Analítica y la Competitividad en las Empresas

*“Si conoces a los demás y te conoces a ti mismo,
Ni en cien batallas correrás peligro;
Si no conoces a los demás, pero te conoces a ti mismo,
Perderás una batalla y ganarás otra;
Si no conoces a los demás ni te conoces a ti mismo,
Correrás peligro en cada batalla”
Sun Tzu, “El Arte de la Guerra”*

Resumen

En las empresas de hoy no es suficiente tener la mejor maquinaria, el personal mejor calificado o la tecnología actualizada si ello no apoya para que las empresas tengan una ventaja competitiva; en la actualidad no sólo compiten por segmentos de mercado ahora compiten por ser un mejor competidor analítico. La inteligencia analítica implica ir más allá de la obtención del conocimiento de los datos aplicando herramientas como la minería de datos que apoya entre otras cosas, para una mejor toma de decisiones.

Abstract

Inside current enterprises it is not enough to have the best machines, the most qualified people or the most recent technology. It is necessary that all those sources help to have a competitive advantage, nowadays the organizations compete against each other not only for the market segments but for a better analytic competitor. The analytic intelligence extends the value of data through its transforming into knowledge applying tools like data mining which helps to take better decisions.

Palabras Clave

Inteligencia analítica, competitividad, minería de datos

Introducción

El cambio en la forma de competir entre las empresas basadas en el uso extensivo de la analítica, datos y toma de decisiones, ha permitido la proliferación de diferentes modelos para analizar los problemas de negocios. La toma de decisiones en las empresas se basa en información generada mediante la analítica, considerada como una fase posterior a la inteligencia de negocios (Davenport & Harris, 2007; Ruelas, 2007) en la cadena de valor de conocimiento, como se muestra en la figura 1 (SAS, 2002).




Figura 1. Cadena de valor de conocimiento (SAS, 2002)

Para completar la cadena de valor del conocimiento se debe considerar un plan soportado por modelos analíticos de datos; en la etapa de ETL se considera la pre-construcción, capacidad de rendimiento para manipulación de datos, análisis, calidad de datos e integración de datos, transformación y carga de procesos de datos; en el almacenamiento inteligente se determina y especifica la plataforma de almacenamiento de datos, en la fase de inteligencia de negocios la empresa debe adquirir herramientas de reporte y búsquedas logrando una inteligencia competitiva, finalmente la inteligencia analítica, permite realizar un análisis profundo de la información que incluye un modelado predictivo y/o descriptivo, optimización, simulación, diseño experimental, entre otros, con el objetivo de aportar información inteligente para la toma de decisiones en las empresas.

Con base en lo anterior, el presente artículo pretende dar a conocer la importancia de integrar a la inteligencia analítica como herramienta de apoyo en la toma de decisiones dentro del marco de competitividad en las empresas. Para lograr esto, el esquema de presentación está basado en una breve descripción de los antecedentes de esta disciplina, los conceptos relacionados a ésta, las metodologías que la implementan y los modelos y técnicas que ocupa para la obtención de conocimiento.

Competitividad

La AECA (Asociación Española de Contabilidad y Administración de Empresas) define competitividad como *“la capacidad de una organización para obtener y mantener sistemáticamente ventajas comparativas que le permiten alcanzar, sostener y mejorar una determinada posición en el entorno socioeconómico en que actúa”* (AECA, 2011).

La competitividad mundial ha aumentado, produciendo en cada una de las organizaciones un elevado interés en la creación de elementos internos que permitan vencer a la competencia, produciendo dentro de éstos un enfoque dinámico basado en el estudio de la innovación, cuyo componente principal es el conocimiento (Mathison, Gándara, Primera, & García, 2009), de aquí que surja el término inteligencia competitiva (IC).

La inteligencia competitiva es definida por la Sociedad de Profesionales de Inteligencia Competitiva (SCIP) en Estados Unidos como *“un proceso ético y sistemático de recolección de información, análisis y diseminación pertinente, precisa, específica, oportuna, predecible y activa, acerca del ambiente de negocios, de los competidores y de la propia organización”* (Masson, 2005).

La competitividad de las organizaciones depende cada vez más de cómo explotan el recurso *información* (Cardona, 2010; Kuna, García-Martínez, & Machuca, 2009), especialmente cuando se toma conciencia que el recurso “información” es valioso o que el “conocimiento es poder” (Stigler, 1961). En este sentido Gilad (1992) define a la inteligencia competitiva como *“el acceso a tiempo al conocimiento e información relevantes en las distintas fases de la toma de decisiones”*.

Desde 1985 Porter (1985) predijo que la información y la tecnología formarían parte de un proceso revolucionario y que ninguna empresa se escaparía de los efectos de esta revolución; sugería que para hacer frente a esta revolución, los gerentes tenían que evaluar la intensidad de información en sus empresas, evaluar las TIC's en la industria e identificar formas para que éstas desarrollen ventajas competitivas, convirtiéndose en organizaciones intensivas en información (Cardona, 2010).

La unión entre tecnología y negocio se está configurando como una de las grandes fuentes de generación de innovación y valor en las empresas (Moraleta, 2004), haciendo que la tecnología pasara de ser una simple herramienta de apoyo y se transformara en un arma estratégica (V. Berberena, 2006).

Actualmente las empresas han realizado grandes inversiones en tecnología de la información (ERP, DSSI, CRM) (Masson, 2005). Estas herramientas en la mayoría de los casos no rinden a las organizaciones el valor que esperan, el error está en el hecho de que esperan que estas plataformas generen inteligencia y sólo generan información, y en el mejor de los casos, conocimiento (V. Berberena, 2006; Cardona, 2010).

Con base en lo anterior, el desarrollo acelerado de herramientas, técnicas y métodos informáticos para el almacenamiento y explotación de los datos ha traído como consecuencia que la información se esté convirtiendo en la columna vertebral de las organizaciones principalmente en el proceso de toma de decisiones.

La inteligencia analítica

Los rápidos avances de la tecnología de almacenamiento y colección de datos han contribuido en el aumento del volumen y variedad de información que se encuentra en las bases de datos, esto ha hecho que el análisis de un gran volumen de información se haya convertido en una tarea rutinaria (Aluja, 2001), compleja (Bissantz & Hagedorn, 2009; Kamath, 2006) y difícil de realizar manualmente (Goebel & Gruenwald, 1999), lo que afirma que el almacenamiento de información ha crecido más rápidamente que la capacidad de analizarla (U. Fayyad, G. Piatetsky-Shapiro, & P. Smyth, 1996; Kamath, 2006; O. Maimon & L. Rokach, 2005; Thompson, Hopf, & Geiselman, 1984).

La relevante importancia que ha tomado la información en el proceso de toma de decisiones ha hecho que los datos pasen de ser un producto a ser una materia prima que hay que explotar para obtener el verdadero “producto elaborado”: *el conocimiento* (Hernández, Ramírez, & Ferri, 2004), lo cual implica que el verdadero valor no es el almacenamiento de los datos sino la habilidad de extraer conocimiento (U. Fayyad, G. Piatetsky-Shapiro, & P. Smyth, 1996).

La obtención de conocimiento sigue un proceso de transformación de datos: los datos se transforman en información, la información en conocimiento (Kuonen, 2004) y más allá del conocimiento, éste se transforma en inteligencia, este proceso es conocido como “La cadena del valor de la inteligencia” (V. Berberena, 2009a) y representado en la figura 2.




Figura 2: La cadena del valor de la inteligencia (V. Berberena, 2009a)

La cadena del valor de la inteligencia está formada por cuatro componentes esenciales (V. Berberena, 2006):

1. Los datos.
2. La información.
3. El conocimiento.
4. La inteligencia.

Los *datos* son representaciones alfanuméricas de determinadas variables, que identifican los procesos de negocio. Si éstos se extraen, se transforman y se almacenan a un nivel más comprensivo, entonces se convierten en *información*; si a ésta se le aplican técnicas de análisis estadístico, entonces se genera *conocimiento*, una vez obtenido el conocimiento se llega a la última etapa de la cadena del valor de la inteligencia que es quizá la más compleja y valiosa –*la inteligencia o inteligencia analítica*– relacionándose con la extracción de complejos patrones de comportamiento del negocio usados como modelos de soporte, y que permiten a las empresas y organizaciones crear una ventaja competitiva sostenible.

Generar *inteligencia* del conocimiento es hablar de inteligencia analítica, la cual es definida como el proceso de utilización de la analítica aplicada (estadística aplicada, tecnologías de información, análisis de procesos, comunicaciones) para la extracción de complejos patrones de comportamiento en un conjunto de datos. En su aplicación práctica incluye técnicas de análisis y minería de datos.

Con el uso de la inteligencia analítica (IA) las empresas no sólo conocen indicadores tradicionales sino también determinan información que ayuda a estas empresas a estudiar el comportamiento del mercado y averiguar, no sólo los gustos de sus clientes sino lo que harán en el futuro (Sixtina, 2007), de esta manera IA es lo más aproximado a las predicciones (Lamont, 2007; Sixtina, 2007) ya que permite predecir escenarios, es decir, establecer “que pasaría si” (Lamont, 2007), lo cual tiene por objeto crear una ventaja competitiva sostenible en los negocios.

Sixtina Consulting Group (2007) define que la analítica es “el uso intensivo y sofisticado de la información para conocer, evaluar y predecir conductas y comportamientos de todos los participantes de la organización, ya sean clientes, proveedores, personal, etc.”.

Basado en lo anterior, la inteligencia analítica es considerada como la combinación de técnicas de explotación de información, aplicaciones analíticas y herramientas de inteligencia de negocios (análisis de datos cuantitativos e información) para facilitar la toma de decisiones (Kohavi, Rothleder, & Simoudis, 2002; McDonough & Vesset, 2007).

De esta manera, surge un cambio en la forma de competir entre las empresas (Davenport, 2006; Ruelas, 2007) basadas con el uso extensivo de la analítica, datos y toma de decisiones basadas en hechos que han permitido la proliferación de diferentes modelos para analizar los problemas de negocios (V. Berberena, 2009b; Ruelas, 2007), de aquí que surjan “nuevas” empresas denominadas competidores analíticos.

El competidor analítico

En la última década, la masificación de las tecnologías de la información, el aumento en la capacidad de procesamiento y almacenamiento de datos, el crecimiento de las redes sociales y el desarrollo de nuevas metodologías de análisis y visualización de datos, han permitido la aparición de un nuevo tipo de competidor: el competidor analítico (Microsystem, 2009).

Al respecto Davenport (Davenport, 2006) dice: “En una época en la que en muchos sectores las empresas ofrecen productos similares y utilizan tecnologías comparables, los procesos de negocios son uno de los pocos espacios restantes de diferenciación y los competidores analíticos expresen hasta la última gota de valor de esos procesos”.

El competidor analítico tiene un alto nivel de éxito y crecimiento basando su estrategia en el uso superior de la información disponible aplicando en tiempo real métodos de análisis cuantitativos, descriptivos y predictivos de mayor potencia (V. Berberena, 2009b; Microsystem, 2009).

Existen un sinnúmero de empresas que aplican la IA en todos su procesos, entre las que destacan: American Airlines con sus “reservaciones electrónicas”, Otis Elevator con su “mantenimiento predictivo” y American Hospital Supply con sus “pedidos en línea”, “Amazon”, “Harrah’s”, “Capital One” y los “Red Sox de Boston”, dominan en sus respectivos sectores, mediante el uso profundo y sistemático de las técnicas analíticas. Entre otras están las presentadas en la tabla 1.

Con base en lo anterior, las empresas tuvieron y tienen la necesidad de desarrollar nuevas técnicas y herramientas que automática e inteligentemente exploten y transformen los simples datos en conocimiento y más aún en inteligencia (S. Chen, J. Han, & P. Yu, 1996; U. Fayyad et al., 1996; Frawley, Piatetsky-Shapiro, & Matheus, 1992; Goebel & Gruenwald, 1999; Servente, 2002).

Tabla 1. Empresas con IA (Sixtina, 2007)

FUNCIÓN	DESCRIPCIÓN	EJEMPLOS
Compras	Simulación y optimización de cadena de aprovisionamiento, reducción de inventarios y de situaciones de falta de stocks	Dell, Wal-Mart, Amazon
Selección de clientes, fidelización, servicio	Identificación de grupos de clientes con alto potencial de rentabilidad, aumento de la probabilidad de que necesiten el producto/servicio de la empresa, mantener una alta fidelidad	Harrah's, Capital One, Barclays
Precios	Identificar el precio que maximizará el rendimiento o la ganancia. Establecer el precio que el cliente pagará	Progressive, Marriot
Recursos humanos	Elección de los empleados con mayores cualidades para determinadas funciones, estímulos compensatorios, etc.	Boston Red Sox (Club Deportivo)
Calidad	Detección de problemas de calidad, tratamiento preventivo	Honda, Intel
Financiera	Mejor comprensión de los inductores de comportamientos financieros y sus efectos en sectores no financieros	MCI, Verizon
Investigación & desarrollo	Mejoras en calidad, productividad y seguridad en productos y servicios	Novartis, Amazon, Yahoo

Estas técnicas y herramientas han sido el objeto del surgimiento del *Knowledge Discovery in Databases* (KDD) y de la minería de datos (MD o DM por sus siglas en inglés *Data Mining*) (U. Fayyad et al., 1996); esta última ha alcanzado gran importancia en los últimos años. La revista de noticias ZDNET (Konrad, 2001) informó que la MD sería uno de los desarrollos más revolucionarios de esa década, siendo una de las 10 nuevas tecnologías que cambiarían al mundo (MIT, 2001).

La minería de datos (MD)

MD no sólo aparece por el desarrollo de tecnologías, sino por el reconocimiento de un nuevo potencial: el valor, hasta ahora generalmente infrautilizado, de la cantidad de datos almacenados informáticamente en las organizaciones (Hernández et al., 2004), valor que se transforma en conocimiento aportando gran apoyo a la toma de decisiones (Martínez de Pisón, 2003; Méndez & Rodríguez, 2009; Riquelme, Ruiz, & Gilbert, 2006).

La traducción literal del término *Mining (to mine)* al español es extraer, generalmente orientado a la acción de extraer de la tierra recursos preciosos, lo cual traspolado a la aplicación de los datos significaría encontrar información valiosa y adicional de un conjunto de datos (Giudici, 2003a), derivando la expresión “picar piedra para encontrar rubíes, picar datos para encontrar conocimiento”.

Bajo este concepto, un sinnúmero de definiciones de Minería de Datos se encuentran en diferentes fuentes bibliográficas, por hacer referencia a algunas, se mencionan a continuación:

“DM se define como un proceso de descubrimiento de nuevas y significativas relaciones, patrones y tendencias al examinar grandes cantidades de datos”. (Pérez & Santín, 2006)

“Es el proceso de extraer conocimiento útil y comprensible, previamente desconocido, desde grandes cantidades de datos almacenados en distintos formatos, es encontrar modelos inteligentes a partir de los datos...”. (Hernández et al., 2004)

Con base en las definiciones anteriores, se puede decir que la minería de datos es un proceso de explotación de datos y extracción de información que transforma ésta en conocimiento útil para la ayuda de toma de decisiones de una organización a través de la determinación de patrones y modelos.

Los dos retos principales para la aplicación de minería de datos son: primero que el individuo no plantea exactamente qué información necesita; y el segundo, que dada la complejidad de los datos almacenados y de sus correlaciones, la explotación de ellos resulta inadecuada en muchos ámbitos para tomar decisiones, lo cual lleva a que la interpretación de los resultados sea así limitada a su verdadera calidad (Pérez López & Santín Gonzalez, 2006).

La MD y la IA se basan principalmente en que la mayor parte de la información a explotar es histórica, lo que permite explicar el pasado, entender el presente y predecir la información futura (Giudici, 2003a; Glymour, Madigan, Pregibon, & Smyth, 1997; Gramatikov, 2003b; Hernández et al., 2004; O. Maimon & L. Rokach, 2005; Ruiz, Diaz, Chang, Briones, & Fabricio, 2009); para lograr esto, los autores han propuesto fases para la extracción de conocimiento las cuales se esquematizan en la figura 3.




Figura 3: Fases típicas de un proceso de *data mining* (Martínez de Pisón, 2003)

La fase de selección consiste en identificar las fuentes de datos para soportar la resolución de objetivos y el análisis preliminar de la calidad de los datos; la de preprocesado define las estructuras que alimentarán la construcción del modelo; en la transformación, se preparan los datos para aplicar la técnica de minería que mejor se adapte a los datos y al problema; en el uso de algoritmos de minería de datos, se construye un modelo, y finalmente la interpretación y evaluación pretende la validación de dicho modelo; todas estas fases constituyen el proceso de minería de datos.

El Instituto SAS® define el concepto de minería de datos como el proceso de seleccionar (*selecting*), explorar (*exploring*), modificar (*modifying*), modelar (*modeling*) y valorar (*assessment*) grandes cantidades de datos con el objetivo de descubrir patrones desconocidos que puedan ser utilizados

como una ventaja competitiva respecto a los competidores. Este proceso es resumido con la siglas SEMMA (Pérez Lopez & Santín Gonzalez, 2006).

Metodologías para explotación de información

Existen varias metodologías para explotación de datos como SEMMA que se centra en aspectos técnicos del proyecto, CRISP-DM de carácter genérico (Mendez & Rodríguez, 2009), SolEuNet para minería de soporte de decisiones o P³TQ, CIM-OSA son utilizadas principalmente para el modelado e integración empresarial.

SEMMA (*sample, explore, modify, model, assess*) y CRISP-DM (*cross industry standar process for data mining*) han crecido como estándares, ambos definen un conjunto de pasos secuenciales que pretenden ser guía en la implementación de aplicaciones de minería de datos. Semma fue desarrollado por el Instituto SAS®, CRISP-DM fue desarrollado inicialmente por un consorcio formado por Daimler Chrysler, SPSS y NRC. A continuación se describen ambas metodologías.

SEMMA

Considera cinco etapas en su proceso (SAS Institute, 1998), el cual se muestra en la figura 4:

1. Muestrear (*sample*). Consiste en obtener un extracto suficiente de los datos totales que pueda contener información significativa y pueda manipularse de forma rápida.
2. Exploración (*explore*). Es la búsqueda de tendencias no previstas y anomalías para entender el contenido y las ideas.
3. Modificación (*modify*). Consiste en la modificación de los datos mediante la creación, selección y transformación de variables que se adapten al proceso de selección del modelo.
4. Modelado (*model*). Modela los datos permitiendo que el software busque automáticamente la combinación de datos que permitan predecir de manera confiable la información requerida.
5. Evaluación (*assess*). Valora los datos mediante la evaluación de la utilidad y confiabilidad de los hallazgos del proceso de minería de datos.




Figura 4. Proceso de la metodología SEMMA (Martínez de Pisón Ascacibar & Javier, 2003).

Estas etapas permiten un fácil entendimiento del problema, tiene una estructura que permite la concepción, creación y evolución, ayudando a presentar soluciones a los problemas planteados así como metas a encontrar mediante la minería de datos (Azevedo & Santos, 2008).

CRISP-DM

Es un ciclo de seis etapas como se muestra en la figura 5 (Britos, 2008):

1. Comprensión de negocio (*business understanding*). Fase inicial enfocada a entender los objetivos del proyecto y requerimientos desde la perspectiva del negocio, transformar este conocimiento a una definición del problema de DM y el diseño de un plan para alcanzar objetivos.
2. Entendimiento de los datos (*data understanding*). Empieza con una colección inicial de los datos y procede con actividades para conocer los datos, identificar problemas de calidad, detectar subconjuntos marcados; con el propósito de construir hipótesis de la información oculta.

3. Preparación de datos (*data preparation*). Define las actividades requeridas para preparar un conjunto de datos finales resultado de datos iniciales.
4. Modelado (*modeling*). Varias técnicas de modelado deben aplicarse y se evalúan con valores óptimos.
5. Evaluación (*evaluation*). Revisión de la técnicas utilizadas en la etapa anterior para verificar cuales permitirían alcanzar el objetivo.
6. Puesta en marcha o implementación (*deployment*). Creación del modelo, que no es el final del proyecto. Su propósito es aumentar el conocimiento de los datos. Este conocimiento debe organizarse y presentarse al usuario para utilizarse.




Figura 5. Metodología CRISP-DM (Britos, 2008).

Es una metodología completa. Sus etapas están bien organizadas, estructuradas y definidas; permiten que un proyecto sea entendible y fácilmente revisable (Azevedo & Santos, 2008).

Modelos, técnicas y algoritmos de minería de datos

Las técnicas de minería de datos han ofrecido soporte en la optimización del proceso de toma de decisiones en una organización y en la resolución de problemas científicos que involucran análisis de una gran cantidad de datos, pasando a la acción inteligente de éstos sobre su explotación (Pechenizkiy, Puuronen, & Tsymbal, 2008) y extracción del conocimiento en datos históricos (Giudici, 2003a; Gramatikov, 2003b; Hernández et al., 2004), uno de los objetivos de la minería de datos y de la inteligencia analítica.

Existen diversas clasificaciones de métodos y técnicas de minería de datos, de manera general, la taxonomía de minería de datos se muestra la figura 6 (O. Z. Maimon & L. Rokach, 2005), donde se puede apreciar que la minería de datos se emplea para dos grandes tareas: la verificación y el descubrimiento. La mayoría de los autores basan sus clasificaciones en el descubrimiento, donde dividen las técnicas en descripción y predicción y sus respectivas subclasificaciones (Gramatikov, 2003a; Pérez Lopez & Santín Gonzalez, 2006), las cuales se describen a continuación:




Figura 6. Taxonomía de minería de datos (Hernández et al., 2004).

- **Predicción**

- **Clasificación** : quizás el más utilizado. Su objetivo es predecir la clase de nuevas instancias de las que se desconoce la clase; es maximizar la razón de precisión de la clasificación de las nuevas instancias, la cual se calcula como el cociente entre las predicciones correctas y el número total de predicciones (correctas e incorrectas).
- **Regresión**: consiste en aprender una función real que asigna a cada instancia un valor real, el valor a predecir es numérico. El objetivo es minimizar el error entre el valor predicho y el valor real.

- **Descripción:**

- **Clustering**: tarea descriptiva por excelencia, consiste en obtener grupos “naturales” a partir de los datos. A diferencia de la clasificación, en lugar de analizar datos etiquetados con una clase, los analiza para generar esta etiqueta, basándose en el principio de maximizar la similitud entre los elementos.
- **Reglas de asociación**: tienen como objetivo identificar relaciones no explícitas entre atributos categóricos.
- **Correlaciones**: se usa para determinar el grado de similitud de los valores de dos variables numéricas.

La minería de datos utiliza complejos algoritmos estadísticos, el tipo de algoritmo y de técnica a aplicar dependerá del problema a resolver y del objetivo que se quiere alcanzar.

Los algoritmos más utilizados actualmente en minería de datos son los que se muestran en la tabla 2 (Wu et al., 2008).

Tabla 2. Algoritmos más utilizados.

NOMBRE	DESCRIPCIÓN
CLS ID3 C4.5 See5/C5.0	Generan clasificaciones basadas en árboles de decisión. Entre las investigaciones que se generan alrededor del tema están los árboles estables y la descomposición de árboles complejos.
k-means	Utilizados para clasificación de datos basadas en <i>clusters</i> .
<i>Support Vector Machines</i>	Utilizado en las <i>machine learning</i> . Utilizan la clasificación y la regresión.
Algoritmo <i>a priori</i>	Utilizado para encontrar patrones frecuentes y generación de reglas de asociación confiables.
Algoritmo EM	Utilizado para el modelado y <i>clustering</i> usa distribuciones de mezcla (<i>mixture distributions</i>) especialmente distribuciones normales.
<i>PageRank</i>	Es un algoritmo de búsqueda jerarquizado. Constituyó inicialmente la máquina de búsqueda de Google.
<i>AdaBoost</i>	Utiliza el aprendizaje conjunto (<i>ensemble learning</i>) que es un método en el cual se utilizan varios métodos de aprendizaje para resolver un problema. Se utiliza principalmente para mejorar la ejecución de un modelo o disminuir la selección desafortunada.
kNN: <i>k-nearest neighbor classification</i>	Uno de los algoritmos más simples para realizar clasificaciones es el <i>rote</i> , que realiza las clasificaciones mediante coincidencias completas de atributos.
<i>Naive Bayes</i>	Para la solución de problemas de clasificación supervisada, donde una serie de objetos que pertenece a una clase con una serie de variables construye una regla que le permita asignar más objetos a esa clase
CART	Árboles de clasificación y regresión. Procedimiento binario recursivo para procesar atributos nominales.

Aplicaciones de minería de datos

La tendencia en investigación en el área de minería de datos es:

- Estandarización de proyectos, existen ya algunos estándares de minería de datos como: Predictive Model Markup Lenguaje (PMML) es un estándar abierto del grupo Data Mining Group (DMG), basado en especificaciones XML para intercambio de modelos entre diferentes plataformas; otro más es el Common Warehouse Metamodel (CWM) que es una especificación basado en UML/XML del Object Management Group (OMG) (Cios & Kurgan, 2002).
- Modelado empresarial (Neaga & Harding, 2005) que permite la identificación y definición de modelos de conocimiento empresariales.
- Formular políticas ambientales, al analizar grandes cantidades de información y obtener resultados más confiables y convincentes (Lee, Chang, Hong, & Liao, 2006). Las aplicaciones de la minería de datos en los negocios es amplia, desde la identificación de segmentos de clientes, obtención de relaciones de costo-beneficio, análisis de rendimiento de procesos operativos, comprensión de necesidades de clientes, realización de presupuestos, proyecciones, control de gestión, evaluación de valor de los segmentos, obtención de parámetros que afectan a un departamento en específico, entre otros.
- Minería de textos, voz e imágenes; *fuzzy mining* uso de minería de datos con objetos simbólicos (Aluja, 2001).
- De manera general, cualquier problema para el que existan datos históricos almacenados, por ejemplo búsqueda de lo inesperado por descripción de la realidad multivariante, búsqueda de asociaciones, definición de tipologías, detección de ciclos temporales, predicción (Aluja, 2001).

La minería de datos es un soporte en la toma de decisiones, en los negocios permite elevar los niveles de competencia, con base en los rápidos procesamiento y extracción de información relevante del mismo,, descubriendo conocimiento y patrones en las bases de datos. Se puede aplicar a cualquier área de conocimiento, entre las limitaciones cabe mencionar la dificultad para

establecer medidas de evaluación, así como la experiencia que se requiere para analizar los resultados cambiantes con el tiempo (Marcano Aular & Talavera Pereira, 2006).

Conclusiones

La inteligencia analítica permite a las empresas la obtención de conocimiento a partir de sus datos y apoya en la toma de decisiones tácticas y estratégicas en las empresas.

El éxito de las empresas y su actual competitividad dependen de la toma de decisiones rápida y precisa, que basada en el conocimiento que tienen disponible.

El uso de técnicas de explotación de datos, como la minería de datos, permite a las empresas explorar y comprender los datos, identificar patrones, relaciones y dependencias así como realizar predicciones que impactan en la competitividad de la misma.

Todas las empresas se enfrentan a grandes cantidades de datos que deben procesar, para lo cual la inteligencia analítica tiene una ventaja sobre su competencia.

REFERENCIAS

AECA. (2011). La competitividad en la empresa. *Estrategia Empresarial* Retrieved 08 de Junio de 2011, from <http://www.aeca.es/>

Aluja, T. (2001). La minería de datos, entre la estadística y la inteligencia artificial. *Questiío*, 25(3), 479-498.

Azevedo, A., & Santos, M. F. (2008). KDD, SEMMA AND CRISP-DM: A PARALLEL OVERVIEW, *IADIS European Conference Data Mining*.

Berberena, V. (2006). La inteligencia analítica en los negocios. *Datos, diagnósticos, tendencias, Revista AMAI*, 9.

Berberena, V. (2009a). *El papel de la minería de datos y la analítica aplicada en la competitividad*. Paper presented at the 5° Simposio Anáhuac de Investigación.

Berberena, V. (2009b). Los competidores analíticos. *PEARSON Market & Opinion Intelligence*, 17, 33-36.

Bissantz, N., & Hagedorn, J. (2009). Data Mining. *Business & Information Systems Engineering*, 1(1), 118-122.

Britos, P. (2008). *Procesos de explotación de información basados en sistemas inteligentes*. Universidad Nacional de la Plata, La Plata, Buenos Aires, Argentina.

Cardona, D. F. (2010). Economía o sociedad de la información. *Sotavento*(6).

Cios, K. J., & Kurgan, L. A. (2002). Trends in data mining and knowledge discovery. *Pal NR, Jain, LC and Teoderesku, N.(Eds.), Knowledge Discovery in Advanced Information Systems*, 200-202.

Chen, M. S., Han, J., & Yu, P. S. (1996). Data mining: An overview from a database perspective. *IEEE Transactions on Knowledge and data Engineering*, 8(6), 866-883.

Chen, S., Han, J., & Yu, P. (1996). Data mining: an overview from a database perspective. *IEEE Transactions on Knowledge and Data Engineering*, 8(6), 866-883.

- Davenport, T. H. (2006). Competir mediante el análisis. *Harvard business review*, 84(1), 84-94.
- Davenport, T. H., & Harris, J. G. (2007). *Competing on analytics*. Harvard Business School Press.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). Data mining and knowledge discovery in databases. *Communications of the ACM*, 39(11), 24-26.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). The KDD process for extracting useful knowledge from volumes of data. *Communications of the ACM*, 39(11), 27-34.
- Frawley, W., Piatetsky-Shapiro, G., & Matheus, C. (1992). Knowledge discovery in databases: an overview. *AI Magazine, The American Association for Artificial Intelligence*, 57-70.
- Giudici, P. (2003a). *Applied data mining*. Italia: J. Wiley.
- Giudici, P. (2003b). *Applied data mining: statistical methods for business and industry*. John Wiley & Sons, Inc.
- Glymour, C., Madigan, D., Pregibon, D., & Smyth, P. (1997). Statistical themes and lessons for data mining. *Data mining and knowledge discovery*, 1(1), 11-28.
- Goebel, M., & Gruenwald, L. (1999). A survey of data mining and knowledge discovery software tools. *ACM SIGKDD Explorations Newsletter*, 1(1), 20-33.
- Gramatikov, M. (2003a). Data mining techniques and the decision making process in the bulgarian public administration. *NISP Acee Concerence, Bucharest, Romania*.
- Gramatikov, M. (2003b). *Data mining techniques and the decision making process in the bulgarian public administration*. Paper presented at the NISP ACEE Conference, Bucharest, Romania.
- Hernández, J., Ramírez, J., & Ferri, C. (2004). *Introducción a la minería de datos*. Madrid: Pearson Educación, S. A.
- Kamath, C. (2006). *Mining science data*.

Kohavi, R., Rothleder, N. J., & Simoudis, E. (2002). Emerging trends in business analytics. *Communications of the ACM*, 45(8), 45-48.

Konrad, R. (2001). Data Mining: digging user info for gold. Retrieved 14 de Febrero de 2010, from http://news.zdnet.com/2100-9595_22-114240.html?legacy=zdn.

Kuna, H., García-Martínez, R., & Machuca, F. (2009). *Procedimientos de la explotación de información para la identificación de datos faltantes, con ruido e inconsistentes*. Paper presented at the XI Workshop de Investigadores en Ciencias de la Computación.

Kuonen, D. (2004). Data Mining and Statistics: what is the connection? *The Data Administrative Newsletter*.

Lamont, J. (2007). Text analytics: on the trail of business intelligence. *KM World*, 16(10), 12-24.

Lee, I. N., Chang, W. C., Hong, Y. J., & Liao, S. C. (2006). Discovering meaningful information from large amounts of environment and health data to reduce uncertainties in formulating environmental policies. *Journal of Environmental Management*, 81(4), 434-440.

Maimon, O., & Rokach, L. (2005). *Data mining and knowledge discovery handbook*. New York: Springer. Repetido con el siguiente...

Maimon, O. Z., & Rokach, L. (2005). *Data mining and knowledge discovery handbook*: Springer-Verlag New York Inc.

Marcano Aular, Y. J., & Talavera Pereira, R. (2006). Minería de datos como soporte a la toma de decisiones empresariales. *Opcion*(52), 104-118.

Martínez de Pisón Ascacíbar, & Javier, F. (2003). *Optimización mediante técnicas de minería de datos del ciclo de recocido de una línea de galvanizado*. Universidad de la Rioja, España.

Martínez de Pisón, F. (2003). *Optimización mediante técnicas de minería de datos del ciclo de recocido de una línea de galvanizado*. Universidad de La Rioja, España.

Masson, J. L. (2005). *Inteligencia competitiva, bases teóricas y revisión de literatura*. Ensayo. Doctorado en Creación, Gestión y Estrategias de Empresa. Barcelona, Universidad Autónoma de Barcelona.

Mathison, L., Gándara, J., Primera, C., & García, L. (2009). Innovación: factor clave para lograr ventajas competitivas. *Revista Negotium*, 3(7).

McDonough, B., & Vesset, D. (2007). Business analytics--a market in transition. *KM World*, 16(1), 8-24.

Méndez, P., & Rodríguez, A. (2009). *Herramienta de estudio de viabilidad para proyectos que utilizan la metodología P³TQ*. Universidad de Buenos Aires, Buenos Aires, Argentina.

Mendez, P. D., & Rodríguez, A. D. (2009). *Herramienta de estudio de viabilidad para proyectos que utilizan la metodología P3TQ*. Universidad de Buenos Aires, Buenos Aires, Argentina.

Microsystem. (2009). ¿Qué es un competidor analítico? *Información y Procesos Inteligentes* Retrieved 08 de Junio de 2011, from <http://www.microsystem.cl/meshcms/servicios/queescompetidoranalitico.html>

MIT (2001). Ten emerging technologies that will change the world. *Journal*. Retrieved from <http://www.technologyreview.com/Infotech/12265/>

Moraleda, A. (2004). La innovación, clave para la competitividad empresarial. *Universia Business Review*, 128-136.

Neaga, E. I., & Harding, J. A. (2005). An enterprise modeling and integration framework based on knowledge discovery and data mining. *International Journal of Production Research*, 43(6), 1089-1108.

Pechenizkiy, M., Puuronen, S., & Tsymbal, A. (2008). Towards more relevance-oriented data mining research. *Intelligent Data Analysis*, 12(2), 237-249.

Pérez, C., & Santín, D. (2006). *Data Mining, soluciones con Enterprise Miner*. Madrid, España: Alfaomega Ra-Ma.

Pérez Lopez, C., & Santín Gonzalez, D. (2006). *Data sining, soluciones con Enterprise Miner con 1 CD* (1a. edición. ed.). México: Alfaomega Grupo Editor S.A de C.V.

Riquelme, J., Ruiz, R., & Gilbert, K. (2006). Minería de datos: conceptos y tendencias. *Inteligencia Artificial, Revista Iberoamericana de Inteligencia Artificial*, 11-18.

Ruelas, M. (2007). Inteligencia analítica: más allá del BI tradicional. *Journal*. Retrieved from <http://www.sg.com.mx/>

Ruiz, F., Diaz, A., Chang, H., Briones, E., & Fabricio, P. (2009). Sistema de predicción y recomendación personalizada basada en ranqueo de ítems homogéneos usando filtrado colaborati.

The SAS Intelligence Value Chain, (2002). En línea: http://www.sas.com/offices/europe/switzerland/pdf/solutions/SAS_Intelligence_Value_Chain_Analytic_Intelligence_White_Paper.pdf. Ultima Consulta 22 mayo 2013

SAS Institute. (1998). *Methodology Data Mining Projects*.

Servente, M. (2002). *Algoritmos TDIDT aplicados a la minería de datos inteligente*. Universidad de Buenos Aires, Buenos Aires.

Sixtina, C. G. (2007). Analytics la nueva ciencia de la competencia. Retrieved 08 de junio de 2011, from <http://www.gestiopolis.com/canales8/ger/analytics-nueva-ciencia-competencia.htm>

Stigler, G. J. (1961). The economics of information. *The Journal of Political Economy*, 69(3), 213-225.

Thompson, R., Hopf, R., & Geiselman, E. (1984). *Cognitive bases of intelligence analysis*. Ed. U.S. Army Research Institute for the Behavioral and Social Sciences, En google Books: http://books.google.com.mx/books/about/The_Cognitive_Bases_of_Intelligence_Anal.html?id=K4ulGwAACAAJ&redir_esc=y Ultima consulta 22 de Mayo 2013

Wu, X., Kumar, V., Ross Quinlan, J., Ghosh, J., Yang, Q., Motoda, H., et al. (2008). Top 10 algorithms in data mining. *Knowledge and Information Systems*, 14(1), 1-37.

Zhou, Z. H. (2003). Three perspectives of data mining. *Artificial Intelligence*, 143(1), 139-146.