

# Utilização de Ferramentas de KDD para Integração de Aprendizagem e Tecnologia em Busca da Gestão Estratégica do Conhecimento na Empresa

Alfredo Nazareno Pereira Boente

Fabiano Saldanha Gomes de  
Oliveira

José Luiz Dos Anjos Rosa

Centro Universitário Estadual da Zona Oeste - UEZO

## RESUMO

*Em vista da velocidade das mudanças que ocorrem no mundo o homem está em constante busca de novos meios de conduzir uma organização de modo a garantir seu crescimento e obter vantagens num mercado altamente competitivo. Para isso é necessário que as empresas estejam preocupadas com o seu capital intelectual, pois o conhecimento sempre foi importante para o desenvolvimento econômico de uma organização. O uso de uma ferramenta de KDD – Knowledge Discovery in Databases – vem facilitar e agilizar a obtenção desse conhecimento.*

Palavras-Chave: Gestão. Capital Intelectual. KDD. *Data Mining*.

## 1. INTRODUÇÃO

Quando se ouve falar em integrar tecnologia de informação (TI) e aprendizado para gestão do conhecimento organizacional, um ponto ganha destaque imediato dentre os demais existentes. Estamos nos referindo à descoberta do conhecimento em bases de dados que, talvez seja o tópico de maior relevância prática no contexto da atual gestão estratégica do conhecimento. A tecnologia é algo se desenvolve predominantemente nas empresas por meio de conhecimentos acumulados e desenvolvido sobre tarefas (*know-how*) e pelas suas manifestações físicas decorrentes (Chiavenato, 1987).

A tecnologia trouxe grandes mudanças, constringendo os grupos sociais pela diminuição de distâncias e fazendo com que as inovações fossem rápidas e constantes. Ficou possível entregar informações com precisão em tempo real (Lara, 2001).

O uso de ferramentas para a descoberta de conhecimento em bases de dados vem integrar a tecnologia e a aprendizagem organizacional em busca da gestão estratégica do conhecimento. O processo de KDD não se resume apenas a garimpagem de dados, mas este é considerado o processo elementar para geração do conhecimento gerado a partir de Bases de Dados. Na verdade, além do *Data Mining* existem ainda o pré-processamento e o pós-processamento (Boente, 2006).

De maneira geral, a complexidade do processo de KDD está na dificuldade em perceber e interpretar adequadamente inúmeros fatos observáveis durante o processo e na dificuldade em conjugar dinamicamente tais interpretações de forma a decidir quais ações devem ser realizadas em cada caso (Goldschmidt e Passos, 2005). Assim, é de responsabilidade do chamado “analista humano” a árdua tarefa de orientar a execução do processo de KDD para a gestão estratégica do conhecimento.

## 2. GESTÃO DO CONHECIMENTO

Conhecimento não é dado nem informação, embora esteja relacionado com ambos e as diferenças entre esses termos seja normalmente uma questão de grau (Davenport e Prusak, 2003). Os dados podem ser considerados como sendo uma seqüência de números e palavras, sob nenhum contexto específico. Quando os dados são organizados com a devida contextualização, há a informação. Já o conhecimento é a informação organizada, com o entendimento de seu significado (Santiago Junior, 2004). Assim, a partir de um esclarecimento do que vem a ser dado, informação e conhecimento, já estamos prontos para entender a definição de gestão do conhecimento. Segundo Rossatto (2002):

*“A gestão do conhecimento é um processo estratégico contínuo e dinâmico que visa gerir o capital intangível da empresa e todos os pontos estratégicos a ele relacionados e estimular a conversão do conhecimento”.*

É possível distinguir diversos níveis de interação social por meio dos quais o conhecimento é criado nas organizações, e é importante que a organização seja capaz de integrar aspectos relevantes do conhecimento desenvolvido a partir dessas interações (Fleury e Oliveira Junior, 2001).

Visando uma melhor compreensão sobre a criação do conhecimento e o gerenciamento dessa criação, Nonaka e Takeuchi (1997) propõem um modelo de conversão do conhecimento, que pressupõe quatro formas, a saber: (1) de conhecimento tácito em conhecimento tácito, que denominaram socialização; (2) de conhecimento tácito em conhecimento explícito, que denominaram externalização; (3) de conhecimento explícito em conhecimento explícito, que denominaram combinação e (4) de conhecimento explícito em conhecimento tácito, que denominaram internalização.

Organizações saudáveis geram e usam o conhecimento. À medida que interagem com seus ambientes, elas absorvem informações, transformam-nas em conhecimento e agem com base numa combinação desse conhecimento com suas experiências, valores e regras internas (Davenport e Prusak, 2003).

Esse processo de transformação de informação em conhecimento é agilizado através do emprego de tecnologia da informação. O uso de ferramentas de KDD permite esse tipo de integração de maneira mais fácil e ágil, principalmente pelo fato de que a análise de grandes quantidades de dados pelo homem é inviável sem o auxílio de uma ferramenta computacional apropriada (Goldschmidt e Passos, 2005).

## 3. DESCOBERTA DE CONHECIMENTO EM BASES DE DADOS

A descoberta de conhecimento em bases de dados é um processo computacional que permite extrair conhecimento de informações armazenadas em grandes bases de dados especializadas, geralmente por assunto, como é o caso de *Data Warehouses*, *Data Marts* e *Data Stores*, por meio de uma ferramenta específica de KDD, auxiliando na busca da gestão do conhecimento estratégico organizacional.

### 3.1. UMA VISÃO GERAL DO KDD

A descoberta do conhecimento baseada em computador vem sendo realizada desde a década de 60. No entanto, as técnicas que se tornam possíveis foram ampliadas e aperfeiçoadas com o passar do tempo. Os processos de KDD (*Knowledge Discovery in*

*Databases* – Descoberta de Conhecimento em Bases de Dados) surgiram sobre diversos nomes e apresentaram diferentes características.

A descoberta de conhecimento em bases de dados é caracterizada como um processo composto por três etapas operacionais (a figura 1 mostra as etapas operacionais do processo de KDD) cujas denominações surgidas foram as seguintes: etapa de pré-processamento que compreende as funções que se relacionam a captação, à organização e ao tratamento de dados, cujo objetivo é preparar os dados para os algoritmos da etapa seguinte; etapa de *Data Mining* (Mineração de Dados) que realiza a busca efetiva de conhecimentos úteis no contexto proposto para a aplicação do KDD; etapa de pós-processamento que abrange o tratamento do conhecimento obtido na etapa anterior (Goldschmidt e Passos, 2005).

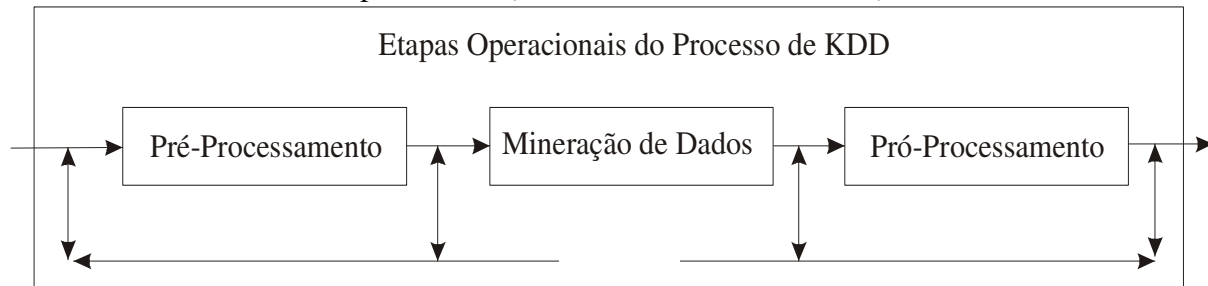


Figura 1 – Etapas operacionais do processo de KDD.

A etapa de pós-processamento nem sempre é necessária embora tenha o objetivo de avaliar a utilidade do conhecimento descoberto. Como se pode observar, de modo geral, a complexidade do processo de KDD está na dificuldade de perceber e interpretar corretamente os inúmeros fatos observados durante um processo e na dificuldade de julgar dinamicamente tais interpretações de forma a decidir quais ações devem ser realizadas em cada caso (Goldschmidt e Passos, 2005).

A expressão padrão válido indica que o conhecimento deve ser verdadeiro e adequado ao contexto da aplicação de KDD. Um novo padrão deve sempre acrescentar novos conhecimentos ao conhecimento existente no contexto da aplicação de KDD. Analisa-se que um conhecimento realmente útil é aquele que pode ser aplicado de forma a proporcionar benefícios reais ao contexto da aplicação de KDD.

A descoberta de conhecimento em bases de dados é multidisciplinar e, historicamente, se origina de diversas áreas, dentre as quais podem ser destacadas a estatística, inteligência computacional, reconhecimento de padrões e banco de dados (Boente, 2006).

As atividades de KDD podem ser organizadas em três grandes grupos, conforme descritos a seguir:

(1) Desenvolvimento Tecnológico: Esse item abrange todas as iniciativas de concepção, aprimoramento e desenvolvimento de algoritmos, ferramentas e tecnologias de apoio que podem ser usados na busca de novos conhecimentos de grandes bases de dados;

(2) Execução de KDD: Refere-se às atividades voltadas à busca efetiva de conhecimentos em bases de dados;

(3) Aplicação de Resultados: As atividades se voltam para aplicação dos resultados no contexto em que foi realizado o processo de KDD.

Em termos históricos, a Mineração de Dados, é usualmente utilizada para referenciar a descoberta de conhecimento em bases de dados. Muitas pessoas costumam se confundir quanto ao conceito de *Data Mining* e KDD. Para melhor esclarecer, a Mineração de Dados representa uma etapa do processo operacional de KDD. O *Data Mining* recebeu esse nome devido às semelhanças entre a pesquisa de informação de valor para o negócio de grandes bancos de dados e a garimpagem em busca de minérios preciosos (Turban et. al, 2004).

O problema a ser submetido ao processo de KDD é caracterizado por três elementos: conjunto de dados, o especialista do domínio da aplicação e pelos objetivos da aplicação. Os recursos obtidos a partir da aplicação dos recursos do problema que compreende o modelo de conhecimento descobertos ao longo da aplicação de KDD e o histórico das ações que foram eventualmente realizadas (Goldschmidt e Passos, 2005).

Conforme já foi mencionado, a Descoberta de Conhecimento em Bases de Dados se caracteriza por apresentar um processo composto por três etapas: Pré-processamento, Mineração de Dados e Pós-processamento. A etapa de Pré-processamento tem o objetivo de preparar os dados para os algoritmos da próxima etapa, Mineração de Dados, e compreende todas as funções relacionadas à captação, à organização e ao tratamento de dados.

As principais funções do Pré-processamento de dados são as seguintes:

(1) Seleção de Dados: Também conhecida como Redução de Dados, identifica de quais informações, dentre as bases de dados existentes, devem ser efetivamente consideradas durante o processo de KDD;

(2) Limpeza de Dados: Envolve qualquer tipo de tratamento referente aos dados selecionados de forma a assegurar a qualidade dos fatos por ele representados;

(3) Codificação dos Dados: Os dados são codificados para que possam ficar numa forma que possam ser efetivamente usados como entrada dos algoritmos de Garimpagem de Dados;

(4) Enriquecimento de Dados: Consiste em conseguir de alguma forma mais informações que possam ser agregadas aos registros existentes, enriquecendo assim, os dados para que sejam capazes de fornecer mais informações para efetivação do processo de descoberta de conhecimento em bases de dados.

Durante a etapa de Mineração de Dados, é realizada a busca efetiva por conhecimentos úteis no contexto da aplicação de KDD. Pode-se considerar a principal etapa do processo de KDD. Na Mineração de Dados, são definidas as técnicas e os algoritmos a serem utilizados no problema em questão, através de Redes Neurais, Algoritmos Genéricos, modelos Estatísticos e probabilísticos (Goldschmidt e Passos, 2005). A escolha da técnica a ser utilizada no processo de Mineração de Dados, depende exclusivamente do tipo de tarefa de KDD a ser efetivamente realizada, de acordo com a seguinte classificação:

(1) Descoberta de Associação: Abrange a busca por itens que frequentemente ocorram de forma simultânea em diversas transações de bases de dados.

(2) Classificação: Consiste em descobrir uma função que mapeie um conjunto de registros em um conjunto de rótulos categóricos predefinidos, denominados classes.

(3) Regressão: Consiste num mapeamento efetivo dos registros de certo banco de dados em busca de valores reais. Essa tarefa é bem próxima à tarefa de classificação, já apresentada anteriormente;

(4) Clusterização: Objetiva separa os registros de uma base de dados em subconjuntos de clusters de modo que os elementos de um cluster compartilhem as propriedades comuns que distingam de elementos de outros clusters.

(5) Sumarização: Busca a identificação de características comuns entre conjuntos de dados.

(6) Detecção de Desvios: Consiste em localizar registros de uma base de dados cujas características não atendem aos padrões considerados normais no contexto atual.

(7) Descoberta de Seqüências: Usada para descobrir que existem possíveis mudanças sazonais de quantidade em remessa de determinadas peças.

A etapa de Pós-processamento abrange o tratamento do conhecimento adquirido através do processo de Mineração de Dados. Muitas vezes se torna desnecessário esse tipo de tratamento, pois essa etapa apresenta como objetivo a facilidade de interpretação e da avaliação, por parte do homem, em relação à utilidade do conhecimento descoberto. Dentre as principais funções da etapa de Pós-processamento estão a elaboração e organização, podendo incluir a simplificação de gráficos, diagramas e outros tipos de relatórios demonstrativos, além da conversão da forma de representação do conhecimento obtido.

Uma aplicação de KDD pode ser classificada quanto à orientação das ações a serem realizadas (Goldschmidt e Passos, 2005). Seguem as seguintes classificações a saber:

(1) Validação de Hipótese Postuladas: O especialista na área em que se deseja realizar o processo de KDD apresenta algumas hipóteses que devem ser comprovadas por meio de uma análise de dados minuciosa;

(2) Descoberta de Conhecimento: Ocorre a busca efetiva por conhecimento a partir da abstração dos dados existentes.

A classificação da aplicação de KDD, quanto ao macro-objetivo desejado pode ser:

(1) Predição: Busca-se um modelo de conhecimento que permita, a partir de um histórico já existente, prevê os valores de determinados atributos em novas situações;

(2) Descrição: Busca-se um modelo que descreva, de forma compreensível pelo homem, o conhecimento existente em um conjunto de dados.

Uma operação de KDD, que se refere a qualquer função das etapas operacionais de KDD, e pertence à etapa de Mineração de Dados, representa a especificação de uma função de KDD. Podem-se citar as seguintes operações: Seleção de Dados, Limpeza de Dados, Codificação, Classificação, Descoberta de associação, Regressão e Simplificação de Modelos de Conhecimento, dentre outras.

Uma operação de KDD pode ser primária, aquela que não pode ser desmembrada em outras operações, ou composta, aquela que pode ser desmembrada em diversas operações primárias.

A expressão técnica de KDD se refere a qualquer teoria que possa fundamentar a implementação de um método de KDD. Elas podem ser as seguintes (Boente, 2006):

(1) A Teoria de Redes Neurais, subsidia o desenvolvimento das Máquinas de Suporte Vetorial, SVM – Support Vector Machines.

(2) O Método Rule Evolver, foi concebido a partir da Teoria de Algoritmos Genéticos e podem ser aplicados em operações de Classificação e Sumarização;

(3) O Método NFHB-Class, baseia-se na combinação de princípios das Teorias de Lógica Fuzzy e Redes Neurais e podem ser aplicado em operações de classificação.

Existem diversos tipos de técnicas e de algoritmos para Mineração de Dados. Estas podem ser subdivididas da seguinte forma (Boente, 2006):

(1) Técnicas Tradicionais: São tecnologias que existem independentes do contexto da Mineração de Dados. São tecnologias tradicionais as Redes Neurais Artificiais (RNA), Lógica Nebulosa (*Fuzzy Logic*), Algoritmos Genéticos (AG) e Estatística.

(2) Técnicas Específicas: São técnicas desenvolvidas especificamente para aplicação de tarefas de KDD, baseadas em algoritmos computacionais, cujo objetivo é descrever passos sequenciais para buscar a solução de um determinado problema.

(3) Técnicas Híbridas: Representa a combinação de diversas técnicas objetivando a geração de um sistema híbrido, que são aqueles que utilizam mais de uma técnica em busca da solução de um problema de modelagem.

As ferramentas de KDD são destacadas no processo de KDD como meio de viabilização dele. A importância de ferramentas de KDD é automaticamente identificada visto que é capaz de auxiliar o homem no controle de aplicação de KDD (Goldschmidt e Passos, 2005).

### 3.2. O PROCESSO DE KDD E SUAS ETAPAS

Não devemos desconsiderar as chamadas variáveis do problema, também denominadas atributos, que são primordiais para as etapas do processo de KDD. Elas podem ser classificadas quanto à representação de seus valores (tipo de dados) e quanto à natureza da informação (tipo de variável). A tabela1 apresenta o enquadramento das variáveis, conforme classificação descrita a seguir:

Atributo	Tipo de Variável	Observações
Nome	Nominal	Não possui uma relação de ordem em seus valores
CPF	Nominal	Não possui uma relação de ordem em seus valores
Data_Nascimento	Discreto	Pode ser representada pelo número de dias transcorridos a partir de um determinado marco temporal. Sendo assim, envolve

		uma relação de ordem entre seus valores.
Renda_Familiar	Contínuo	O conjunto de valores, embora seja limitado, é teoricamente infinito uma vez que sejam admitidas variações no número de casas decimais.
Despesas_Mensais	Contínuo	O conjunto de valores, embora seja limitado, é teoricamente infinito uma vez que sejam admitidas variações no número de casas decimais.
Número_Dependentes	Discreto	Envolve uma relação de ordem entre seus valores pois, o conjunto de valores desta variável é finito.

Tabela 1 – Enquadramento das variáveis.

### 3.2.1. A ETAPA DE PRÉ-PROCESSAMENTO

Essa etapa compreende as funções relacionadas à captação, à organização, ao tratamento e à preparação dos dados para a etapa de *Data Mining*. É indispensável dizer que esta etapa representa fundamental importância no processo de Descoberta de Conhecimento em Bases de Dados.

Para cada função de Pré-processamento apresentada alguns métodos possíveis (seleção de dados, limpeza, codificação, enriquecimento, normalização de dados, construção de atributos e correção de prevalência). Em inteligência computacional denomina-se heurística a todo conhecimento que pode ser utilizado na simplificação de um dado problema (Goldschmidt e Passos, 2005).

### 3.2.2. A ETAPA DE MINERAÇÃO DE DADOS

É considerada a principal etapa do processo de KDD. É aqui onde ocorre a busca efetiva por novos conhecimentos a partir de dados conhecidos. A execução dessa etapa compreende a aplicação de algoritmos sobre os dados procurando abstrair o tão esperado conhecimento (Boente, 2006).

Estratégia	Algoritmos
Classificação	árvores de decisão e redes neurais
Agregação	métodos estatísticos e redes neurais
Associação	métodos estatísticos e teoria de conjuntos
Regressão	métodos de regressão e redes neurais
Predição	métodos estatísticos e redes neurais

Tabela 2 – Estratégia do processo de KDD.

Todo conjunto de dados no processo de KDD corresponde a uma base de fatos ocorridos que podem ser interpretados como um conjunto de pontos em um hiper-espaço de dimensão  $k$ . A dimensão da base de fatos é determinada pelo número de atributos do conjunto de dados em análise.

Todo processo de KDD deve ser norteado por objetivos e estes compreendem a definição da tarefa de KDD a ser executada e da expectativa que os conhecedores do domínio da aplicação tenham com relação ao modelo de conhecimento a ser gerado. A partir dessas definições, o especialista em KDD tem condições de delinear que tipos de padrões devem ser abstraídos a partir dos dados identificados.

A conceituação de medida de interesse é essencial ao processo de KDD por dois motivos principais:

Medidas de interesse podem ser usadas após a etapa de Mineração de Dados a fim de ordenar ou filtrar os padrões descobertos de acordo com o grau de interesse associado a estes padrões;

Medidas de interesse podem ser usadas para guiar ou restringir o espaço de busca de Mineração de Dados, melhorando a eficiência da busca ao eliminar conjuntos de padrões que não satisfaçam a condições predeterminadas.

Atualmente existem dois tipos de medidas de interesse que podem ser associadas aos modelos de conhecimento de Mineração de Dados:

Medidas de Interesse Objetivas: São baseadas na estrutura dos padrões descobertos e nas estatísticas a eles relacionados;

Medidas de Interesse Subjetivas: São aquelas que os especialistas do domínio da aplicação tenham com relação aos dados e aos modelos de conhecimento gerados.

A avaliação envolvendo este tipo de medida depende da visualização e da interpretação dos resultados obtidos, normalmente realizadas na etapa de Pós-processamento. Determinados algoritmos possuem restrições quanto aos tipos de variáveis existentes no conjunto de dados. Neste caso duas alternativas podem ser consideradas:

Elimina-se do conjunto de algoritmos de Mineração de Dados todos aqueles que forem incompatíveis com os tipos de variáveis envolvidas no problema;

Escolhe-se por utilizar um determinado algoritmo de Mineração de Dados a realizar todo o Pré-processamento sobre o conjunto de dados de forma a torná-lo compatível com o algoritmo desejado.

Um conceito muito importante a ser considerado é a similaridade. Uma vez que o conjunto de dados pode ser interpretado com um conjunto de pontos em um espaço  $k$ -dimensional, o conceito de similaridade entre dois pontos pode ser traduzido como a distância entre os pontos. O conceito de distância é formalizado como uma função  $D : E \times E \rightarrow R$  que atende às seguintes restrições:  $D(x, x) = 0$ ,  $D(x, y) = D(y, x)$  e  $D(x, y) \leq D(x, z) + D(z, y)$ .



Diversos algoritmos de Mineração de Dados utilizam o conceito de distância entre as tuplas do banco de dados.

A Mineração de Dados pode ocorrer por meio de diferentes métodos e cada um deles requer diferentes necessidades de Pré-processamento. Portanto, tais necessidades variam de acordo com os aspectos extensional da base de dados em que o método será utilizado.

Os métodos de KDD podem ser considerados operadores definidos a partir de precondições e efeitos. Uma precondição de um método KDD é um predicado que estabelece um requisito que deve ser cumprido antes da execução do método. Um efeito de um método, também referencia um predicado que descreve uma situação gerada após a aplicação do método desejado. Um plano d ação de KDD válido representa toda seqüência de métodos de KDD onde as precondições para a execução de cada um dos métodos da seqüência sejam efetivamente atendidas. Esses métodos podem ser baseados em redes neurais, algoritmos genéticos, instâncias, métodos estatísticos, métodos específicos, indução de árvore de decisão, lógica nebulosa,

### 3.2.3. A ETAPA DE PÓS-PROCESSAMENTO

Esta etapa envolve a visualização, a análise e a interpretação do modelo de conhecimento gerado pela etapa de Mineração de Dados. Será nesta etapa que o especialista em KDD e o especialista de domínio da aplicação avaliam os resultados obtidos e definem novas alternativas de investigação dos dados. Seguem as operações de Pós-processamento: Simplificação do Modelo de Conhecimento, Transformações do Modelo de Conhecimento e Organização e Apresentação dos Resultados.

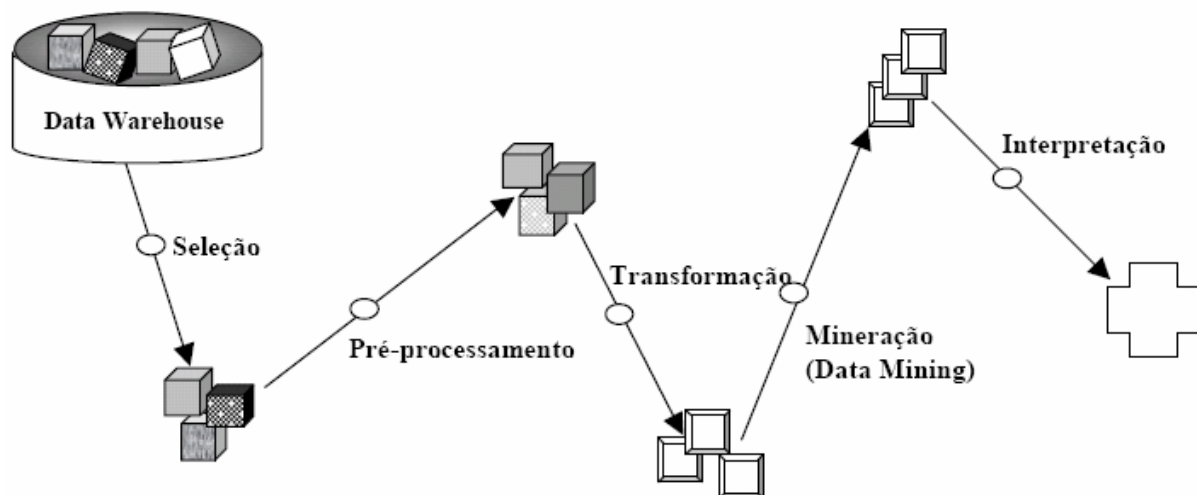


Figura 2 – Processo de KDD.

### 3.3. AS TAREFAS DE KDD

Uma tarefa de KDD corresponde a uma operação de KDD que pertença à etapa de Mineração de Dados. Portanto, de forma análoga às operações de Mineração de Dados, as tarefas de KDD podem ser primárias ou compostas. São elas: Descoberta de associações, Descoberta de associações generalizadas, Descoberta de seqüências, Descoberta de seqüências

generalizadas, Classificação, Regressão, Sumarização, *Clusterização*, Previsão de séries temporais e Detecção de Desvios.

### 3.4. FERRAMENTAS DE KDD

Hoje em dia se pode encontrar diversas ferramentas disponíveis no mercado consumidor que apresentam a característica de implementar ambientes integrados para facilitar a execução das etapas operacionais de KDD, procurando minimizar diversas das dificuldades operacionais existentes.

O modelo descritor de ferramentas operacionais de KDD, além de destacar importantes características observáveis em ferramentas de KDD, pode ainda ser utilizado como instrumento facilitador da comparação entre tais ferramentas. O *SPSS/Clementine*, *PolyAnalyst*, *Weka*, *Simple Client*, *Explorer*, *Experimenter*, *KnowledgeFlow*, *Darwin*, *Intelligent Miner*, *Wiz Rule*, *Bramining*, *SAS Enterprise Miner* e *Oracle Data Mining*. A tabela 3 apresenta um comparativo entre as ferramentas de KDD.

Ferramenta	Tarefa de KDD	Fabricante e Site de Acesso
<i>SPSS/Clementine</i>	Classificação, Regras de Associação, Clusterização, Sequência e Detecção de Desvios.	SPSS Inc. <a href="http://www.spss.com">www.spss.com</a>
<i>PolyAnalyst</i>	Classificação, Regressão, Regras de Associação, Clusterização, Sumarização e Detecção de Desvios.	Megaputer Intelligence <a href="http://www.megaputer.com">www.megaputer.com</a>
<i>Weka</i>	Classificação, Regressão e Regras de Associação.	University of Waikato <a href="http://www.cs.waikato.ac.nz">www.cs.waikato.ac.nz</a>
<i>Darwin</i>	Classificação	Thinking Machines <a href="http://en.wikipedia.org/wiki/thinking_machines">http://en.wikipedia.org/wiki/thinking_machines</a>
<i>Intelligent Miner</i>	Classificação, Regras de Associação, Clusterização e Sumarização.	IBM Corp. <a href="http://www.ibm.com">www.ibm.com</a>
<i>WizRule</i>	Sumarização, Classificação e Detecção de Erros.	WizSoft Inc. <a href="http://www.wizsoft.com">www.wizsoft.com</a>
<i>Bramining</i>	Classificação, Regras de Associação, Regressão e	Graal Corp.

	Clusterização.	<a href="http://www.graal-corp.com.br">www.graal-corp.com.br</a>
<i>SAS Enterprise Miner</i>	Classificação, Regras de Associação, Regressão e Sumarização.	SAS Inc. <a href="http://www.sas.com">www.sas.com</a>
<i>Oracle Data Mining</i>	Classificação, Regressão, Associação, Clusterização e Mineração de Textos.	Oracle <a href="http://www.oracle.com">www.oracle.com</a>

Tabela 3 – Tabela comparativa das ferramentas de KDD.

O modelo comparativo tem por objetivo descrever um determinado modelo que permita a caracterização, de forma resumida, de ambientes integrados para a realização de aplicações de KDD.

O modelo descritor destaca importantes características observadas em ferramentas de KDD, destacando a importância das características observadas por meio das ferramentas de KDD. Pode ainda ser usada como instrumento facilitador da comparação entre as diversas ferramentas existentes.

#### 4. CONCLUSÕES

As empresas buscam valorizar cada vez mais seu capital intelectual. Isso é possível a partir da implementação da gestão estratégica do conhecimento, que retrata um processo estratégico contínuo e dinâmico que visa gerir o capital intangível da empresa assim como todos os pontos estratégicos a ele relacionados, estimulando a conversão do conhecimento.

A adoção de ferramentas de KDD para realizar a descoberta de conhecimento em bases de dados é uma estratégia inteligente que permite agilizar e facilitar todo esse mecanismo de valorização do capital intelectual nas empresas.

#### 5. REFERÊNCIAS

BOENTE, A.N.P. Descoberta de Conhecimento em Bases de Dados. Iowa, Tese de Doutorado – Departamento de Informática, AWU – American World University, 2006.

CHIAVENATO, I. Teoria, Processo e Prática. São Paulo: McGraw Hill, 1997.

DAVENPORT, T.H.; PRUSAK, L. Conhecimento Empresarial: Como as Organizações Gerenciam o seu Capital Intelectual. 11ª Edição. Rio de Janeiro: Elsevier, 2003.

FLEURY, M.T.L.; OLIVEIRA JUNIOR, M.M. (organizadores). Gestão Estratégica do Conhecimento: Integrando Aprendizagem, Conhecimento e Competências. São Paulo: Atlas, 2001.

GOLDSCHMIDT, R.R.; PASSOS, E. Data Mining: Um Guia Prático. Rio de Janeiro: Campus, 2005.

HARVARD BUSINESS REVIEW. Gestão do Conhecimento. Tradução de Afonso Celso da Cunha Serra. 9ª Edição. Rio de Janeiro: Elsevier, 2000.

LAPA, E. Gestão de Conteúdo como apoio à Gestão do Conhecimento. Rio de Janeiro: Brasport, 2004.

LARA, C.R.D. A Atual Gestão do Conhecimento: A Importância de Avaliar e Identificar o Capital Humano nas Organizações. São Paulo: Nobel, 2004.

NONAKA, I.; TAKEUCHI, H. Criação do Conhecimento na Empresa: Como as Empresas Japonesas Geram a Dinâmica da Inovação. Tradução de Ana Beatriz Rodrigues e Priscila Martins Celeste. 16ª Edição. Rio de Janeiro: Campus, 1997.

ROSSATO, M.A. Gestão do Conhecimento: A Busca da Humanização, Transparência, Socialização e Valorização do Intangível. Rio de Janeiro: Interciência, 2002.

SANTIAGO JUNIOR, J.R.S. Gestão do Conhecimento: A Chave para o Sucesso Empresarial. São Paulo: Novatec, 2004.

TURBAN, E.; McLEAN, E.; WETHERBE, J. et. al. Tecnologia da Informação para Gestão: Transformando os negócios na Economia Digital. 3ª Edição. Porto Alegre: Bookman, 2004.

ZABOT, J.B.M.; MELO DA SILVA, L.C. Gestão do Conhecimento: Aprendizagem e Tecnologia Construindo a Inteligência Coletiva. São Paulo: Atlas, 2002.