

Business Intelligence: Inteligência nos Negócios

Iris Fabiana de Barcelos Tronto, Ana Cláudia Araujo, José Demiso Simões da Silva, Nilson Sant'anna*
Ministério da Ciência e Tecnologia – MCT
Instituto Nacional de Pesquisas Espaciais – INPE
Laboratório Associado de Computação e Matemática Aplicada – LAC/CAP
E-mail: iris_barcelos@lac.inpe.br

Resumo

Este artigo apresenta os principais conceitos de BI- Business Intelligence e sua aplicação para a solução de problemas práticos de uma corporação. Neste contexto, é dada ênfase ao conceito de Data Mining, uma das ferramentas utilizadas por BI que utiliza, dentre outras técnicas, Árvores de Decisão e técnicas de Inteligência Artificial, tais como Algoritmos Genéticos e Redes Neurais em sua implementação.

Abstract

This paper presents the main concepts of BI- Business Intelligence and its application to solve enterprise practical problems. In this context, focalize the concept of Data Mining, which is one tool used at BI. Data Mining uses Answer Trees and techniques of Artificial Intelligence, for example, Genetic Algorithms and Neural Works in its implementation.

1. Introdução

O acelerado crescimento tecnológico e conseqüente informatização das empresas possibilitou avanços operacionais nos negócios. À medida que o *Hardware* ficou mais barato e de melhor desempenho, grandes sistemas foram criados, possibilitando transações rápidas e eficientes, resultando na geração de grandes volumes de dados. Estes são armazenados em repositórios, que possuem uma característica comum: a dificuldade de extração de informação. Importantes informações ficam armazenadas dentro da própria empresa, sendo seu acesso muito difícil. A partir disso não é difícil de se concluir que este processo gradativo de implantação de sistemas informatizados produziu múltiplos estoques de dados, com lógicas próprias e dificuldades de consolidação.

O conceito de Business Intelligence (BI) surgiu para resolver estes problemas e consiste de uma vasta categoria de tecnologias e programas aplicativos utilizados para extrair, armazenar, analisar e transformar grandes volumes de dados, produzindo um ambiente de conhecimento, onde

há produção sistemática de informação gerencial, veloz e consistente, capaz de auxiliar empresas a tomarem as melhores decisões nos negócios, baseado em fatos reais, com profundidade suficiente para descobrir as causas de uma tendência ou de um problema.

Business Intelligence tem como principais características:

- A capacidade de extrair e integrar dados de múltiplas fontes.
- A transformação dos registros obtidos em informação útil para o conhecimento empresarial.
- A valorização da experiência.
- A análise de dados contextualizados.
- A procura de relações de causa e efeito, trabalhando com hipóteses e desenvolvendo estratégias e ações competitivas.

A construção de um ambiente de Business Intelligence requer dados dos vários sistemas informatizados operacionais existentes na empresa. O conjunto de dados coletados é matéria-prima para uma série de transformações, cujo produto final é carregado no *Data Warehouse* (depósito de dados). São criadas visualizações gerenciais que possibilitam que as decisões gerenciais sejam tomadas em tempo real. As aplicações de Business Intelligence, que utilizam as informações armazenadas em um *Data Warehouse*, podem incluir consultas e relatórios, análises OLAP (On-Line Analytical Processing), análises estatísticas, previsões, Balanced Scorecard e *Data Mining*.

O conceito de *Data Mining* surgiu com objetivo de melhorar o uso das informações armazenadas em um *Data Warehouse*, utilizando algoritmos inteligentes que possam selecionar os padrões mais relevantes para certas aplicações. Dentro deste contexto algumas técnicas como *Árvore de Decisão*, *Algoritmos Genéticos* e *Redes Neurais* são utilizados.

Este trabalho está organizado em cinco seções. A Seção 2 apresenta os principais conceitos relacionados a *Business Intelligence*. Visto que o objetivo principal deste trabalho é explorar a aplicação de Inteligência Artificial em *Business Intelligence*, será enfocada a ferramenta de *Data Mining*, cujos conceitos fundamentais são apresentados na Seção 3. Na Seção 4 é abordado um exemplo de aplicação de *Business Intelligence*. Finalmente, a Seção 5 apresenta as conclusões deste trabalho.

2. Business Intelligence

Chegou a era da fidelização, da customização, da sedução do cliente e da Inteligência aplicada aos negócios. Assim sendo, os grandes bancos de dados corporativos começaram a produzir variantes, como os Depósitos de Dados (*Data Warehouse*), com o objetivo de entregar aos tomadores de decisão, a informação na forma mais precisa e utilizável possível. Os dados que até então eram simples representantes de fatos comuns como nome, endereço, telefone, dentre outros, hoje se sofisticam na representação de imagens, vídeos, sons, dados temporais, indicadores econômicos, planilhas, páginas HTML e estruturas XML, acompanhando as mudanças solicitadas por uma sociedade agora alavancada por outras indústrias, como entretenimento, comunicação e comércio eletrônico.

A informática fez os dados, depois os transformou em informação. Agora o objetivo é usinar conhecimentos, a partir daquelas matérias-primas. BI representa a habilidade de se estruturar, acessar e explorar informações, normalmente guardadas em DW/DM (*Data Warehouse*, *Data Marts*) com o objetivo de desenvolver percepções, entendimentos e conhecimentos, os quais podem produzir um melhor processo de tomada de decisão.

É o conceito de *Data Mining* (garimpagem de dados) que objetiva melhorar o uso desses gigantescos arsenais de informação através da identificação de padrões de correlação normalmente invisíveis em análises convencionais. Indicadores de produtos comprados em conjunto ou de padrões de fraudes praticadas ajudarão os gerentes de empresas, no seu cotidiano, a descobrir sinuosas correlações que certamente o levarão a melhor dispor a gôndola do seu mercadinho, ou modificar os critérios de análise de riscos de uma proposta de empréstimo.

Vive-se a era do BI-Business Intelligence, com a informação usinada a partir dos dados sendo diretamente aplicada aos negócios [1]. Assim como a área de gerência de conhecimento (KMS-Knowledge Management System), BI visa criar estoques de dados e fatos que suportem processos decisórios fundamentais.

Enquanto as duas abordagens acima visam olhar para dentro da empresa, existe uma terceira que visa observar o mundo exterior da empresa. É o conceito de CI-Competitive Intelligence. Pode-se entender CI como um BI aplicado ao mundo fora das fronteiras empresariais, focado primariamente em informações textuais e factuais que dizem respeito aos movimentos do mercado e dos concorrentes. A estratégia de CI passa pelas vizinhanças dos conceitos de KMS e se acopla aos de *Mining*.

A proposta de BI acopladas com as de CRM (*Customer Relationship Management*) e SCM (*Supply Chain Management*) de se concentrar em prol dos clientes é algo que parece definitivo. SCM representa os processos de

produção e entrega do produto final, do fornecedor para o cliente. CRM são os sistemas, aplicativos e as tecnologias devotadas ao tratamento com o cliente da empresa, com o objetivo de melhorar as ações de marketing, vendas e serviços.

Um novo conceito emerge na indústria da informática: EAI (*Enterprise Application Integration*), que pode ser traduzido como a integração de aplicações corporativas.

Neste trabalho, o conceito de Business Intelligence é apresentado segundo os conceitos de *Data Warehouse*[7], *Data Mart*[1] e *Data Mining*[5], cobertos na próxima seção.

2.1. Data Warehouse, Data Mart e Data Mining

Os dados que habitam os tradicionais sistemas legados recentemente implementados, ERP (*Enterprise Resource Planning*), ou pacotes integrados de gestão, que constituem a base dos processos de negócios das empresas, estão formatados e estruturados da forma transacional, dificultando, dessa maneira, o seu tratamento informacional. Assim, BI deve ser entendido como o processo de desenvolvimento de:

- Estruturas especiais de armazenamento de informações como *Data Warehouse* (DW), *Data Mart*(DM) e ODS (*Operational Data Store*), com o objetivo de se montar uma base de recursos informacionais, capaz de sustentar a camada de inteligência da empresa e possível de ser aplicada aos seus negócios, como elementos diferenciais e competitivos. Juntamente com o conceito de DM, DW, OSD, o conceito de BI contempla também o conjunto de ferramentas ETC - Extração, Tratamento e Carga, fundamentais para a transformação do recurso de dados transacional em informacional. Enquanto DW e DM se referem à estruturas dimensionais de dados, remodeladas com o objetivo de prover análises diferenciais, o conceito de OSD, por sua vez, está relacionado ao armazenamento e tratamento de dados operacionais, de forma também consolidada, porém sem as características dimensionais. O ODS além de representar a metade do caminho entre o legado e o DW, também oferece informações importantes do ponto de vista decisório, devido a sua característica de consolidação e integração de várias fontes de dados.
- Aplicações especiais de tratamento de dados, como OLAP e *Data Mining*. O termo OLAP (*On-Line Analytical Processing*), hoje muito difundido, traduzido para processamento analítico on-line, representa essa característica de se trabalhar os dados, com operadores dimensionais, possibilitando uma forma múltipla e combinada de análise. O conceito de *Data Mining* por outro lado, está mais relacionado com os processos de análise de inferência do que com os de análise dimensional de dados e representa uma forma de busca de informação baseada em algoritmos que objetivam o

reconhecimento de padrões escondidos nos dados e não necessariamente revelados pelas outras abordagens analíticas, como OLAP.

A Figura 1 mostra esquematicamente os componentes de *Data Warehouse*, *Data Mart*, ODS e Ferramentas (entre as quais as de *Mining*), compondo o mosaico de BI. Além dos depósitos de dados na forma consolidada de *Data Warehouse* ou por assuntos/negócios (como *Data Marts*) e o ODS, aparece também a camada fundamental de ETC-Extração, Transformação e Carga, responsável pelas ações de coleta, limpeza, preparação e carga desses depósitos de informações. Os processos de *Mining* trabalharão sobre um extrato de dados especialmente preparado para esta forma de tratamento.

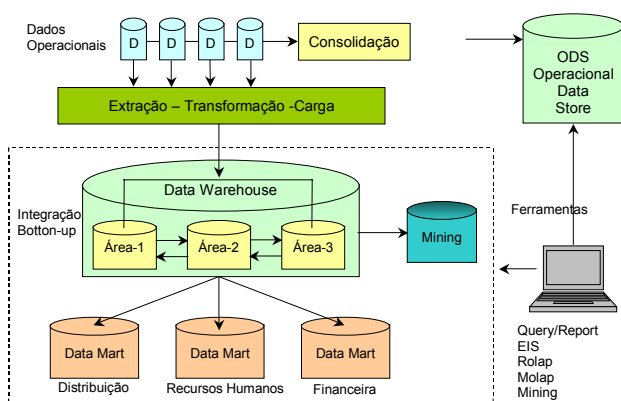


Figura 1 – Componentes de um ambiente de *BI- Business Intelligence* [1]

2.2. Mercado e Ferramentas de BI

As ferramentas para um ambiente de *BI-Business Intelligence* podem ser classificadas como de Construção, Gerência, Uso e Armazenamento.

As ferramentas de construção têm o objetivo de auxiliar no processo de Extração de dados das fontes diversas, seu tratamento de preparação, transformação e sua carga nas estruturas finais do DW/DM.

As ferramentas de Gerência objetivam auxiliar o processo de armazenamento e utilização dos DW/DM e do repositório, onde residem as informações de meta-dados, responsáveis pela definição das estruturas e dos processos de transformação desejados.

As ferramentas de uso são, na essência, os mecanismos, através dos quais os usuários manipulam os dados nos DW/DM e obtêm as informações requeridas. Oferecem um arsenal de operadores, dentre outros *drill-down, up, cross, through* e trabalham em interfaces *Web*. O conceito de *Data Mining* está presente neste tipo de ferramenta.

O mercado de BI aponta para valores bastante significativos para os primeiros anos do novo milênio. Com o crescimento vertiginoso do conceito de BI e com a

forte tendência de fusões e aquisições, o mercado de BI será bastante disputado nos próximos anos. A *Computer Associates* fortaleceu o seu arsenal de BI com as aquisições da *Platinum* e da *Sterling* que, por sua vez, já haviam comprado outras empresas menores. Agora, a *Computer Associates* deverá integrá-las em um mosaico de BI [1]. A *Oracle* desenvolveu um poderoso conjunto de Ferramentas BI, iniciando com a aquisição da *Oracle Express*, seguido de outras ferramentas na área de *Mining* (*Darwin* da *Thinking Machines*).

No cenário de produtos que estarão brigando pelo mercado emergente de BI, certamente dois produtos irão catalisar a atenção dos desenvolvedores de DW e DM, e influenciarão diretamente nos processos de análise e escolha de soluções OLAP para as empresas: o *BW-Business Information Warehouse*, da *SAP* e o *MS-SQL Server Analysis Services*, da *Microsoft*.

3. Data Mining

Um dos grandes problemas dos especialistas em análise de informação é a transformação de dados em informação. Como fazer isso de uma forma automatizada, e no menor tempo possível? Uma das respostas para isso é a combinação de estatística convencional e técnicas de inteligência artificial, que resulta em uma técnica muito comentada nos dias de hoje, o *Data Mining*.

Os processos de *Data Mining* são extremamente complexos, além de ser um trabalho que dificilmente será resolvido apenas por um especialista em *Data Mining*. Em qualquer projeto de *Data Mining* é obrigatório a existência de um profissional com o conhecimento do negócio, pois ele possui domínio total do assunto. Para evitar que a resultado da modelagem não tenha a menor utilidade para apoiar uma decisão.

Segundo Naliato [9], o conceito de *Data Mining* flutua entre uma forma de estatística e um conceito revolucionário, agora aplicado ao mercado. Na verdade, o objetivo desta técnica é encontrar padrões, ainda não descobertos nos dados, que possam gerar respostas corretas para novos casos. Este processo de busca e interpretação de padrões é tipicamente iterativo e iterativo, envolvendo a aplicação repetitiva de métodos específicos de mineração de dados ou algoritmos e interpretações dos padrões gerados como resultado destes algoritmos.

A Figura 2 mostra, numa visão geral, os passos principais de um projeto de *Data Mining*. No esquema estão os grandes blocos do projeto, com as fases de Preparação, Mineração, Análise e Aplicação.

A fase de preparação consiste de atividades que vai desde a construção de um banco de dados, separado, para os dados sujeitos ao *Mining* até a atividade de carregar o banco de dados para o processo de *Mining*. A preparação dos dados a serem utilizados num projeto vai variar de acordo com o algoritmo de *Mining* escolhido. Dependendo

deste algoritmo, os dados serão formatados de maneiras diferentes. Este processo de preparação dos dados é determinante no sucesso do *Data Mining* e costuma consumir muito tempo e recurso.

A fase de mineração é responsável por criar os modelos de *Data Mining*, definir amostras ou população e selecionar dados para treinar o modelo. Além disso, aqui deverá ser definida a formatação requerida pelas ferramentas. Por exemplo, redes neurais exigem dados na forma dicotômica (sim/não) e árvore de decisão demanda agrupamentos, como bom, médio e ruim. Por fim, cria os previsores ou atributos-chave para a análise do negócio.

Alguns modelos básicos de garimpagem de dados podem ser utilizados na fase de análise tais como:

- Regras de associação: São regras que são formadas com informações existentes na base de dados. São relacionamentos que na grande parte das vezes não são conhecidos pelo detentor do negócio.
- Classificação: são processos utilizados para se definir grupos ou classes de elementos, baseado em certos parâmetros pré-estabelecidos. Várias abordagens são usadas para definir modelos de referência (redes neurais, árvores de decisão, baseados em regras), sendo que algumas permitem a definição explícita da classe (árvore de decisão) e outras o seu modelo implícito (redes neurais).
- Padrões Sequenciais: são processos que visam a identificação de fatos que implicam em outros fatos, em momentos diferentes de tempo.
- Agregação: tem como objetivo a obtenção de agrupamentos baseados na similaridade apresentada pelos dados.

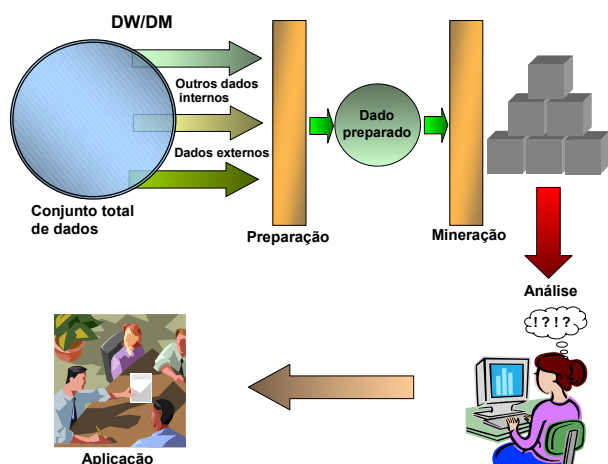


Figura 2 – Visão geral do processo de *Data Mining* [1].

Estes modelos de garimpagem de dados podem ser usados de forma integrada, realizando análises em cascata, com operadores aplicados sobre resultados de outros. Isso pode ser visto em [2].

Depois de definido e testado o modelo, ocorre a fase de aplicação, que se dá pela utilização daqueles algoritmos ajustados em situações reais de sistemas. Alguns produtos permitem que seja produzido um código fonte, resultante dos modelos e algoritmos definidos e compilados, que poderá ser incorporado em sistemas tradicionais e invocado para a execução das análises requeridas. As Seções 3.1, 3.2 e 3.3 abordam algumas aplicações de *Data Mining*.

Existem várias técnicas de *Data Mining* que podem ajudar as empresas a encontrar informações para fomentar a sua tomada de decisão. Heinrichs & Lim [6] utilizam a técnica de Análise de Regressão em seu trabalho sobre ferramenta de *Data Mining* baseado na *Web*. Outras técnicas como Análise de Conglomerados, Métodos Preditivos com Séries Temporais, Árvore de Decisão, Redes Neurais e Algoritmos Genéticos são importantes. Essas três últimas são apresentadas a seguir. Resta aos especialistas identificar a melhor técnica para o seu problema.

3.1. Árvore de Decisão

A árvore de decisão é uma técnica que, a partir de uma massa de dados, cria e organiza regras de classificação e decisão em formato de diagrama de árvores, que irão classificar suas observações ou prever resultados futuros. Se seus dados estiverem divididos em classes dicotômicas, por exemplo, infectados contra não-infectados, um árvore de decisão pode ser construída para criar regras que classifiquem casos já existentes ou casos novos, com precisão.

Começa com um único grupo que reúne todos os casos em estudo. Na medida em que a árvore vai se expandindo, esta base é dividida em módulos que representam categorias das variáveis analisadas. Cada galho da árvore é formado por esses nódulos que vão se abrindo em subgrupos mutuamente exclusivos. Cada nódulo e cada galho apresentam uma proporção de obtenção da resposta em estudo.

O emprego de Árvore de Decisão é abrangente e se dá nas seguintes abordagens:

- a) Segmentação: Identificação de grupos baseando-se na identificação de características em comum apresentadas pelos elementos. Por exemplo, em segmentação de mercado.
- b) Estratificação: Determinação de regras para que se possa designar cada caso a uma dentre várias categorias existentes, como por exemplo classificar um cliente tomador de crédito em grupo de risco elevado, risco médio, risco baixo.
- c) Predição: Criação de regras para aplicação em eventos futuros. Podendo ser usada também para identificar relações entre atributos preditivos e valores de uma variável contínua. Por exemplo, a identificação de

quais ações de *marketing* poderão levar a um aumento significativo nas vendas.

- d) Redução de dados e filtro de variáveis: podem ser utilizadas para identificar quais variáveis têm mais influência sobre a resposta, diminuindo assim o volume de variáveis em estudo.
- e) Identificação de Interações: identificação de interações pertinentes somente em determinados subgrupos e especificações destas em modelos paramétricos formais.
- f) Merção de categorias e discretização de variáveis contínuas: significa a possibilidade de recodificação de variáveis categóricas e contínuas com perda mínima de informação.

Árvores de Decisão podem ser aplicadas em várias áreas. Alguns exemplos típicos de sua aplicação são apresentados em [1]. Dentre eles, se destacam: Mala Direta; *Credit Scoring* (também conhecida como escoragem de crédito); Análise de Mercado; Controle de Qualidade; Recursos Humanos; Pesquisas Médicas e Estudos de Políticas Internas.

3.2. Redes Neurais

As Redes Neurais são uma tecnologia cada vez mais usada em *Data Mining*. Sua grande vantagem está basicamente em sua habilidade de aprendizagem a partir das experiências, não ficando restritas a uma ordem seqüencial pré-fixada. Elas consistem em algoritmos e procedimentos computacionais que imitam a capacidade de aprendizagem do cérebro. Esta técnica é formada de nódulos cujo processamento se assemelha ao dos neurônios, daí seu nome. Não é considerada uma técnica estatística por não apresentar a robustez de uma. Não oferece estimadores definidos e o comportamento de uma rede neural, com certa massa de dados, nem sempre se repetirá com outra.

Os nódulos são conectados como uma rede e funcionam paralelamente. A primeira fase de nódulos é composta pelos nódulos de entrada. Eles recebem o *input* das variáveis fornecidas pelo banco de dados, transformam-no de acordo com uma função (chamada função de ativação), produzindo informação de saída que será enviada à próxima fase de nódulos. Esta, por sua vez, receberá diversas informações dos nódulos de entrada como seu *input*. Esta fase é formada pelos nódulos ocultos, que, em redes neurais mais complexas, podem formar diversas camadas. Por fim, tem-se os nódulos de saída. Estes processam as informações recebidas e produzem uma resposta, mas não a enviam para outro nódulo, pois já é o resultado final da rede. Se a rede é de classificação, o nódulo de saída já é o final. Para o caso de modelos de previsão, o nódulo de saída já representa um valor preditivo.

É importante salientar que não existe uma técnica universalmente melhor que todas. O sucesso do *Data Mining* depende muito da experiência e sensibilidade do pesquisador, o qual terá que identificar qual a melhor ferramenta a ser utilizada, de acordo com o tipo de resposta procurada e com o modo em que se encontram seus dados. Por isso, os exemplos de aplicações dos métodos relacionados neste trabalho podem se repetir.

A técnica de Redes Neurais pode ser aplicada em *Data Mining* para resolver problemas relacionados a: *Marketing*; Modelos Preditivos; Vendas; Finanças; Energia e; Produção. Exemplos dessas aplicações são apresentados em [1].

3.3. Algoritmos Genéticos

Algoritmos genéticos, AGs, são métodos de otimização e busca inspirados nos mecanismos de evolução de populações de seres vivos [8]. Esses algoritmos seguem o princípio da seleção natural e sobrevivência do mais apto, declarado em 1859 pelo naturalista e fisiologista inglês Charles Darwin em seu livro *A Origem das Espécies*.

Otimização é a busca da melhor solução para um dado problema, visando economizar os recursos despendidos, sejam eles financeiros, tempo, etc. Consiste em tentar várias soluções e utilizar informação obtida neste processo de forma a encontrar soluções cada vez melhores.

O primeiro passo de um Algoritmo Genético típico é a geração de uma população inicial de cromossomos. Esta população é formada por um conjunto aleatório de cromossomos, que representam possíveis soluções do problema a ser resolvido. Durante o processo evolutivo, esta população é avaliada e cada cromossomo recebe uma nota (denominada de aptidão), refletindo a qualidade da solução que ele representa. Em geral, os cromossomos mais aptos são selecionados e os menos aptos são descartados (darwinismo). Os membros selecionados podem sofrer modificações em suas características fundamentais através dos operadores de *crossover* e mutação, gerando descendentes para a próxima geração. Este processo é repetido até que uma solução satisfatória seja encontrada.

Pesquisas mais recentes apontam para uma tendência de utilização de Algoritmos Genéticos Híbridos, em que algoritmos Genéticos são combinados com outras técnicas como, por exemplo, Árvore de Decisão, *Data Mining*. Debora [3];[4] propõe uma solução para o problema de desbalanceamento de classes em uma base de dados, baseada no uso de um método híbrido com Algoritmos Genéticos e Árvore de Decisão. Neste caso, o Algoritmo Genético age como um *Wrapper* usando a saída do algoritmo de Árvore de Decisão, para a obtenção da função objetivo das populações de indivíduos.

4. Aplicações de Business Intelligence

A SPSS é uma empresa que lidera tecnologias em *Data Mining* e aplicações analíticas para melhorar a tomada de decisões. Tais aplicações atendem os objetivos do conceito de *Business Intelligence*, que tem como premissa auxiliar organizações no gerenciamento do futuro, através de um aprendizado do passado, do entendimento do presente e prevendo potenciais problemas e possibilidade. A empresa fornece todas as aplicações necessárias para um processo analítico, desde o planejamento, gerenciamento dos dados, análise e distribuição dos resultados.

Algumas dessas aplicações analisam informações históricas para determinar com confiabilidade o que acontecerá no futuro. Árvore de Decisão são úteis em *Data Mining* conforme abordado na Seção 3.1.. Elas criam uma estrutura de árvore na qual cada ramo é separado em subconjuntos mutuamente exclusivos. Cada ramo da árvore corresponde a uma regra para separar os dados em subconjuntos que produzem pre-condições para os dados atuais e para os novos dados. Os componentes de árvore de decisão são úteis, por exemplo, em segmentação de marketing para identificar grupos distintos em um banco de dados de clientes; em análise de riscos para descobrir fatores que determinam se uma aplicação particular é um risco de crédito bom ou ruim e; em gerenciamento de relacionamento de clientes (CRM) para descobrir padrões em como clientes interagem com uma determinada companhia.

Um dos produtos oferecidos pela empresa é a ferramenta *AnswerTree*, que é um software para *Data Mining* que capacita usuários de negócios analisar dados com uma maior precisão. Ela utiliza a técnica de Árvore de Decisão (<http://www.spss.com/spssetd/tools.htm>).

Um exemplo de sua aplicação é quando uma organização deseja determinar quais clientes, ou grupo de cidadãos que melhor combinam com suas promoções e programas, marcando precisamente as pessoas e eliminando as conjecturas que levam a enviar ofertas a grupos arbitrários de pessoas em suas listas de e-mail. Neste caso, *AnswerTree* permite que a organização atinja mais eficientemente o grupo certo de pessoas .

Ela usa Árvores de Decisão escaláveis, que revelam segmentos e prevê como grupos responderão a promoções e programas. *AnswerTree* oferece quatro componentes de árvore de decisão poderosos, (podendo escolher o que melhor se aplica aos dados do usuário), mostra modelos gráficos permitindo visualizar os grupos daquele assunto. Os gráficos são importantes no sentido de permitir agir sobre os resultados rapidamente.

Chen [5] fornece uma visão detalhada sobre os algoritmos e sobre as técnicas que podem ser utilizadas no contexto de *Data Mining*.

5. Conclusões

Atualmente, não é difícil de se perceber que os sistemas de BI da empresa são essenciais para a tomada de decisões. Neste contexto, pode-se dizer que DW (*Data Warehouse*) tornou-se a ferramenta principal para o trabalho do departamento de marketing e que a maioria das informações para tomada de decisão são extraídas dos sistemas de apoio à tomada de decisão. Entre as diversas utilizações dos sistemas de BI, se destacam a análise de tráfego, o acompanhamento da receita e sua tendência, análise de *churn* e de retenção de clientes.

Várias técnicas, ferramentas e conceitos existem no mercado. Porém, quando uma empresa busca implementar uma solução de BI-Business Intelligence, primeiro ela deverá identificar qual é seu problema, como atacá-lo e principalmente como resolvê-lo. Estas questões são fundamentais para que se efetue uma boa escolha da ferramenta ou técnica a ser utilizada.

Uma vez que identificamos a necessidade de se dar apoio à tomada de decisão quando se trata do desenvolvimento de software, pretende-se em trabalhos futuros investigar a aplicabilidade de BI no processo de desenvolvimento de software.

Referências Bibliográficas

- [1] C.Barbieri, “ BI- Business Intelligence: Modelagem & Tecnologia”, Ed. *Axcel Books*, Rio de Janeiro, 2001.
- [2] D. R. Carvalho, “A hybrid decision tree/genetic algorithm for coping with the problem of small disjuncts in *Data Mining*”, In: *2000 Genetic and Evolutionary Computation Conference*, Las Vegas. 2000.
- [3] D. R. Carvalho, “Data Mining através de indução de Regras e Algoritmos Genéticos”, *Dissertação de Mestrado em Informática Aplicada*, PUCPR, PR, 1999.
- [4] D. R. Carvalho, “A hybrid genetic algorithm decision tree approach for coping with unbalanced classes”, In: *The Second International Conference on Pratical Application of Knowledge Management*, London. 1998.
- [5] Z.Chen, “Data Mining and Uncertain Reasoning: An Integrated Approach”, John Wiley & Sons, Canada, 2001.
- [6] H.Heinrichs, Jeen-Su Lim, “Integrating web-based data mining tools with business models for knowledge managment”. *Decision Support System*, vol.35, 2003, p. 103-112.
- [8] E.G.M. Lacerda, A.C.P.L.F. Carvalho, “Introdução aos Algoritmos Genéticos”. In: *Anais do XIX Congresso Nacional da Sociedade Brasileira de Computação*. vol.II, 1999, p.51-126.