

CEFET-MG

PÓS-GRADUAÇÃO LATO SENSU

Curso: Banco de Dados

Disciplina: Data Warehouse e Business Intelligence
Professor: Fernando Zaidan

Unidade 5 – Data Mining
2012



DATA MINING



Fonte: Carlos Barbieri

INTELIGÊNCIA NOS NEGÓCIOS

-TOMADA DE DECISÃO TRANSFORMANDO DADO EM INFORMAÇÃO

-DUAS VERTENTES:

- ANALÍTICAS=>INTERPRETAÇÃO
- GARIMPAGEM=>DESCOBRIMENTO DE TENDÊNCIAS-PADRÕES-CRIANDO MODELOS

BUSINESS INTELLIGENCE

TOMADA DE DECISÃO

INFERÊNCIA-PADRÕES


INFORMAÇÕES ANALÍTICAS

Fonte: Carlos Barbieri

DATA MINING

- DESCOBERTA DE PADRÕES E TENDÊNCIAS EM GRANDES VOLUMES DE DADOS
- VIABILIZADO POR:
 - < CUSTO ARMAZENAMENTO
 - > CUSTO DE PROCESSADORES
 - > COMPETITIVIDADE NEGOCIAL
- DIFERE DE OLAP-ANÁLISE ONDE CERTAS INFLUÊNCIAS SÃO COLOCADAS NA PESQUISA OLAP
- MINING-ANÁLISE DE TODAS AS INTERRELAÇÕES DE INFLUÊNCIA
- CHAMADA DE KD(KNOWLEDGE DISCOVERY)
- USA MODELOS-CRIADO A PARTIR DOS PADRÕES DOS DADOS
- PADRÕES: COMPORTAMENTOS REPETITIVOS QUE PERMITAM PREVISÃO:
 - EX: 13451345134?
- ALGORITMOS ESTADÍSTICOS:
 - MECANISMOS PARA CRIAÇÃO DE MODELOS
 - ÁRVORE DE DECISÃO
 - ASSOCIAÇÃO
 - ANÁLISE DE REGRESSÃO
 - ALGORITMOS GENÉTICOS
 - REDES NEURAIS ARTIFICIAIS

Fonte: Carlos Barbieri



Fonte: Carlos Barbieri

FATORES CRÍTICOS DE PROJETOS DE DATA MINING

- SABE COM DETALHES QUAL É O SEU PROBLEMA?
- VOCÊ SABE EXATAMENTE O QUE NECESSITA?
 - ANÁLISES COMPLEXAS, TENDÊNCIAS ESCONDIDAS, INFERÊNCIAS?
- VOCÊ TEM OS DADOS NECESSÁRIOS, NA GRANULARIDADE NECESSÁRIA, NO DETALHE NECESSÁRIO?
 - PREPARAÇÃO É FUNDAMENTAL
 - DADOS INTERNOS E EXTERNOS
- DATA MINING É SOLUÇÃO?
 - ACERTO DE EXPECTATIVA
- TEM USUÁRIO PATROCINADOR?
- VOCÊ SABE QUE DM É UM PROJETO DE ASPECTO NEGÓCIOS(NÃO SÓ UM PROJETO ISOLADO)
- VOCÊ TEM, OU ESTÁ DISPOSTO A TER:
 - BOA ARQUITETURA TECNOLÓGICA?
 - CUSTO, COERENTE COM AS NECESSIDADES
 - GRANDES VOLUMES DE DADOS E PROCESSAMENTO
- EQUIPE COM TÉCNICAS E TÉCNICOS COM SKILL EM DM E ANALISTAS EM BUSINESS INTELLIGENCE?

Fonte: Carlos Barbieri

DATA MINING ESTRATÉGIAS

- **MINING DIRETO**
- **OS ATRIBUTOS CONHECIDOS (INPUTS) SÃO FORNECIDOS AO ENGINE DE DM PARA PRODUZIR (BASEADO NO MODELO E PADRÕES DEFINIDOS), OS VALORES PREVISTOS (PREDICTED/TARGETS)**




- **MINING INDIRETO**
- **OS ATRIBUTOS CONHECIDOS SÃO FORNECIDOS AO ENGINE DE DM PARA PRODUZIR CONJUNTOS DE COMPORTAMENTO SEMELHANTES. NÃO PRODUZEM VALORES. SERVE PARA FORMAR NUVENS OU COLONIAS DE OBJETOS COM CARACTERÍSTICAS SEMELHANTES**
- **NORMALMENTE SERÃO USADAS COMO PREPARAÇÃO PARA OUTRAS TÉCNICAS. POR EXEMPLO AGRUPA-SE DADOS PARA TRATAMENTO VIA ÁRVORE DE DECISÃO**

Fonte: Carlos Barbieri

Técnicas

- **Árvores de decisão- 1º Exemplo**
 - Representações simples do conhecimento
 - Utilização de regras condicionais
 - A partir de um conjunto de valores decide SIM ou NÃO
 - Mais rápida e mais compreensível que redes neurais
 - Exemplo: Sair ou não de acordo com o tempo



Predicado objetivo:
Sair ou Não Sair

Fonte: Carlos Barbieri

Técnicas

- **Árvores de decisão: 2º Exemplo**
Classificação de um indivíduo com risco de ter ou não crédito




Predicado objetivo:
Crédito ou Não

Fonte: Carlos Barbieri

Técnicas

- **Redes Neurais:**
 - É uma abordagem computacional que envolve desenvolvimento de estruturas matemáticas com a habilidade de aprender. (modelo do sistema nervoso para aprender)
 - Estruturalmente, uma rede neural consiste em um número de elementos interconectados (chamados neurônios/nós), que possuem entrada, saída e processamento.
 - São organizados em camadas que aprendem pela modificação da conexão.
 - Arquitetura:



Fonte: Carlos Barbieri


Técnicas

- **Redes Neurais:**
 - Para construir um modelo neural, nós primeiramente "adestramos" a rede em um dataset de treinamento e então usamos a rede já treinada para fazer previsões.
 - **Problemas:**
 - Não retorna informação a priori
 - Complicação para treinar em uma grande base de dados
 - Entrada não pode ser dados alfa-numéricos (mapear para numérico)
 - Nenhuma explanação dos dados é fornecida (caixa preta)

Fonte: Carlos Barbieri


Técnicas

- **Redes Neurais:**
 - Exemplo prático: risco de câncer



Spread of Activations

Data mining - Clementine User Guide Fonte: Carlos Barbieri



DATA MINING E ESTATÍSTICA

CONCEITOS COMUNS

- **POPULAÇÃO** : GRUPO DE CASOS INCLUIDOS NO MODELO. AS CARACTERÍSTICAS DEVEM SER BEM DEFINIDAS.
- **AMOSTRA**: SE O CONJUNTO DE CASOS INCLUIDOS NÃO É GERENCIÁVEL, CRIA-SE UMA AMOSTRA REPRESENTATIVA DAQUELA POPULAÇÃO. HÁ QUE SE REPRESENTAR O TODO.
- **VALORES ESTATÍSTICOS**:
 - MÉDIA-SOMA DE VALORES / N
 - MODA-VARIÁVEL DE > FREQUÊNCIA
 - MEDIANA-VALOR CENTRAL DE UMA DISTRIBUIÇÃO
 - VARIÂNCIA: SOMA DAS DIFERENÇAS QUADRADAS ENTRE OS VALORES E A MÉDIA
 - DESVIO PADRÃO: RAZA QUADRADA DA VARIÂNCIA

Fonte: Carlos Barbieri

DATA MINING E ESTATÍSTICA

CONCEITOS COMUNS

- **CORRELAÇÃO**: QUANDO UMA VARIÁVEL MUDA EM FUNÇÃO DA MUDANÇA DE OUTRA
- **REGRESSÃO**: MEDE NUMERICAMENTE O VALOR DESTA INFLUÊNCIA/RELAÇÃO. O QUANTO UMA MUDA, MUDANDO X NA OUTRA

Fonte: Carlos Barbieri

DATA MINING

TREINAMENTO DO MODELO

- TREINAR O MODELO SIGNIFICA ANALISAR AS VARIÁVEIS DE INPUT E OBTER OS PADRÕES
- OS PADRÕES SÃO COLOCADOS EM MODELOS CONSTRUÍDOS
- O MODELO TREINADO FAZ PARTE DO "LEARNING MACHINE", ONDE OS ALGORÍTMOS SÃO AUTOMATICAMENTE ADAPTADOS PARA MELHORAR BASEADO NA EXPERIÊNCIA DE ANÁLISE DE DADOS HISTÓRICOS, CRIAÇÃO DE PADRÕES E SUA VALIDAÇÃO CONTRA NOVOS DADOS

Fonte: Carlos Barbieri

DATA MINING

CUIDADOS NA OBTENÇÃO SIGNIFICÂNCIA DOS MODELOS

- MINING OBJETIVA DESCOBRIR PADRÕES ESCONDIDOS
- POIS BEM: ALGUMAS ANÁLISES PODEM LEVAR A INFERÊNCIAS INCONSISTENTES. POR EX:
- UM BANCO FRANCÊS DEFINIU QUE DONOS DE CARROS VERMELHOS ERAM MELHORES PAGADORES DE EMPRÉSTIMOS.
- ISSO É CHAMADO "**OVERFITTING**"
- TÉCNICAS ESTATÍSTICAS EXISTEM PARA ABALISAR A RELEVÂNCIA DE CERTAS VARIÁVEIS NUM MODELO ESTATÍSTICO:
 - ANÁLISE DE CHI-QUADRADO
 - PRUNNING (PODA-CASO DE ÁRVORES DE DECISÃO)
 - CROSS VALIDATION

Fonte: Carlos Barbieri

- Exemplo (1) - Fraldas X cervejas
 - O que as cervejas tem a ver com as fraldas ?
 - homens casados, entre 25 e 30 anos;
 - compravam fraldas e/ou cervejas às sextas-feiras à tarde no caminho do trabalho para casa;
 - Wal-Mart otimizou as gôndolas nos pontos de vendas, colocando as fraldas ao lado das cervejas;

Resultado: o consumo cresceu 30%

Fonte: Carlos Barbieri

- Exemplo (2) - Lojas de Departamento

- Aplicou 1 milhão de dólares em técnicas de data mining
- Reduziu de 51000 produtos para 14000 produtos oferecidos em suas lojas.
- Exemplo de anomalias detectadas:
 - Roupas de inverno e guarda chuvas encalhadas no nordeste
 - Batedeiras 110v a venda em SC onde a corrente é 220v

Fonte: Carlos Barbieri

Exemplos

- Exemplo (3) - Banco

- Selecionou entre seus 36 milhões de clientes
 - Aqueles com menor risco de dar calotes
 - Tinham filhos com idades entre 18 e 21 anos
 - Resultado em três anos o banco lucrou 30 milhões de dólares com a carteira de empréstimos.



Fonte: Carlos Barbieri

Obrigado e Bons Estudos!

Zaidan

A persistência é o caminho do êxito.

Charles Chaplin