

Mineração de Dados em Biologia Molecular

KDD



Docente: André C. P. L. F. de Carvalho
PAE: Victor Hugo Barella

Tópicos do Módulo

- Introdução
- Descoberta de Conhecimento em Bases de Dados
- Etapas de KDD
- Mineração de Dados
- Aplicações

© André de Carvalho - ICMC/USP

2

Introdução

- Bases de Dados podem conter (esconder) dados preciosos
- Existe um interesse crescente em explorar esses dados armazenados
 - Descobrir conhecimento novo
 - Apoio à tomada de decisão

© André de Carvalho - ICMC/USP

3

O que é um dado?

- Dado
 - Exemplo, objeto, registro
 - Estrutura fundamental sobre a qual um sistema de informação é construído
 - Não tem um significado associado a ele
 - Ex.: 345,43

© André de Carvalho - ICMC/USP

4

Exemplo

muito alto,muito alto,2,2,pequeno,baixo,ruim
 muito alto,alto,3,5 ou mais,grande,baixo,ruim
 muito alto,baixo,3,4,grande,baixo,ruim
 médio,baixo,4,2,pequeno,alto,ruim
 médio,baixo,3,4,pequeno,médio,médio
 alto,alto,2,4,grande,médio,médio
 baixo,baixo,5 ou mais,4,pequeno,médio,médio
 baixo,médio,4,4,pequeno,médio,médio
 baixo,médio,4,4,grande,médio,bom
 baixo,baixo,4,5 ou mais,grande,médio,bom
 médio,baixo,2,4,pequeno,alto,bom
 baixo,médio,4,4,grande,alto,muito bom
 médio,médio,2,4,grande,alto,muito bom
 baixo,baixo,5 ou mais,5 ou mais,grande,alto,muito bom

© André de Carvalho - ICMC/USP

5

Informação

- Dados com um significado associado
 - Tornam os dados úteis em uma tomada de decisão
 - Transformação de dados em informação
 - Geralmente pela apresentação dos dados em uma forma compreensível para o usuário
 - Informação é criada quando é associado um significado a um conjunto de dados

© André de Carvalho - ICMC/USP

6

Exemplo - Carros

- Preço
 - Compra: muito-alto, alto, médio, baixo
 - Manutenção: muito-alto, alto, médio, baixo
- Características técnicas
 - Conforto
 - # portas: 2, 3, 4, 5-5 ou mais
 - # pessoas: 2, 4, 5 ou mais
 - Espaço do porta malas: pequeno, médio, grande
 - Segurança: baixo, médio, alto
- Aval. do carro: ruim, médio, bom, muito bom

© André de Carvalho - ICMC/USP 7

Exemplo - Carros

- Preço
 - Compra: muito-alto, alto, médio, baixo
 - Manutenção: muito-alto, alto, médio, baixo
- Características técnicas
 - Conforto
 - # portas: 2, 3, 4, 5-5 ou mais
 - # pessoas: 2, 4, 5 ou mais
 - Espaço porta malas: pequeno, médio, grande
 - Segurança: baixo, médio, alto
- Aval. do carro: ruim, médio, bom, muito bom

© André de Carvalho - ICMC/USP 8

Exemplo

```
tactagcaatacgttgcggtcggtgtaagtgtataatgacggtgctgtcgt
fgctatcctgacagttgcaagctgattgggtgctgtaacatcaacgcatcgcaa
gtactagagaactagtgacattatctttttttatcatgtagcggcg
aattgtagtgatcgaaagtgtggtgagtagatgtagaatacaaaactc
Tcgataaatactattgacgaaagctgaagactagaatgcctccgtgtag
aggggcaaggaggtggaagaggtgccgtataaagaactagagctcgttagt
agggatgaaactctctgtagcactagctcttctactgtgagtagcggag
ccgagtagcttagagagcatgtagctgacgcaactgcaataatgcttctg
cgctaggacttctgtgatttccatgctggttttgcgcaatgtaactgcttt
tatgggaacgagtcactcagggtctgactctgttactgtgaacattatt
agaggggtgactccaagaaggaagatgaggctagacgtctctgcatggatgga
gagagcatgtagcctcgacaactgcaataatgcttctgtagacgtgcctcag
```

© André de Carvalho - ICMC/USP 9

Exemplo - Promotores

```
+ ,S10,tactagcaatacgttgcggtcggtgtaagtgtataatgacggtgctgtcgt
+ ,AMPc,tgctatcctgacagttgcaagctgattgggtgctgtaacatcaacgcatcgcaa
+ ,AROH,gtactagagaactagtgacattatctttttttatcatgtagcggcg
+ ,DEOP2,aattgtagtgatcgaaagtgtggtgagtagatgtagaatacaaaactc
+ ,LEU1_TRNA,tcgataaatactattgacgaaagctgaagactagaatgcctccgtgtag
+ ,MALEFG,aggggcaaggaggtggaagaggtgccgtataaagaactagagctcgttagt
-, 296,agggatgaaactctctgtagcactagctcttctactgtgagtagcggag
-, 648,ccgagtagcttagagagcatgtagctgacgcaactgcaataatgcttctg
-, 230,cgctaggacttctgtgatttccatgctggttttgcgcaatgtaactgcttt
-, 1163,tatgggaacgagtcactcagggtctgactctgttactgtgaacattatt
-, 1321,agaggggtgactccaagaaggaagatgaggctagacgtctctgcatggatgga
-, 663,gagagcatgtagcctcgacaactgcaataatgcttctgtagacgtgcctcag
```

© André de Carvalho - ICMC/USP 10

KDD

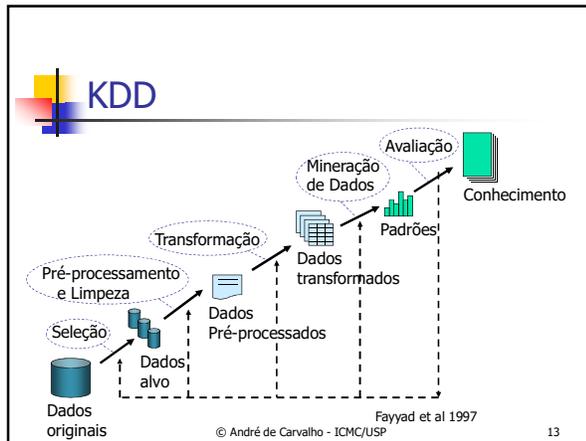
- Descoberta de conhecimento em Bancos de dados (BDs)
 - Knowledge Discovery in Databases
- Área de pesquisa em expansão
- Teorias e ferramentas computacionais para extrair informação útil de BDs
 - Informação útil = conhecimento

© André de Carvalho - ICMC/USP 11

KDD

- Processo de encontrar em dados padrões que são
 - Úteis
 - Novos
 - Válidos
 - Potencialmente compreensíveis
- Processo iterativo e iterativo
 - Várias etapas

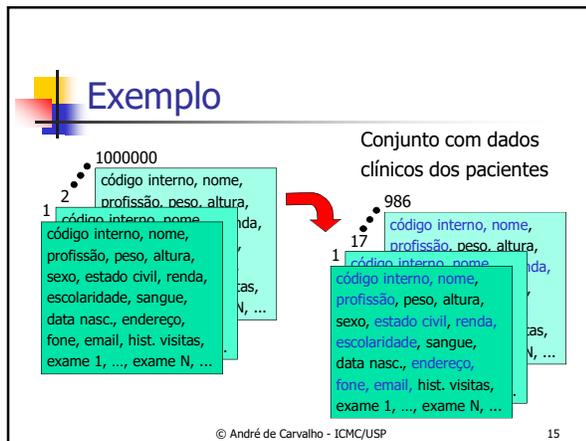
© André de Carvalho - ICMC/USP 12



Seleção

- Cria um conjunto de dados para extração de conhecimento
 - Seleciona "manualmente" um subconjunto dos dados disponíveis
 - Subconjunto de registros (instâncias ou exemplos)
 - Subconjunto de atributos considerados relevantes para o problema
 - Elimina atributos que sejam claramente irrelevantes

© André de Carvalho - ICMC/USP 14



Pré-processamento e Limpeza

- Melhora a qualidade dos dados e facilita sua posterior utilização
- Engloba várias operações
 - Amostragem "automática" de objetos
 - Seleção "automática" de atributos
 - Conversão de valores
 - Lidar com atributos ausentes
 - Eliminar dados duplicados
 - Detectar ruído

© André de Carvalho - ICMC/USP 16

Transformação

- Inclui operações que modificam valores para um dado atributo
 - Cada operação deve ser aplicada a todos os valores do atributo
 - Em todos os objetos
 - Ex.: normalização, valor absoluto, ...

© André de Carvalho - ICMC/USP 17

Mineração de Dados

- Principal passo no processo de KDD
 - Mineração de Dados (DM) e KDD são frequentemente utilizados como sinônimos
- Fronteiras da etapa de MD no processo de KDD são de difícil identificação
 - Pré-processamento e transformação de dados são geralmente vistos como uma parte da MD

© André de Carvalho - ICMC/USP 18

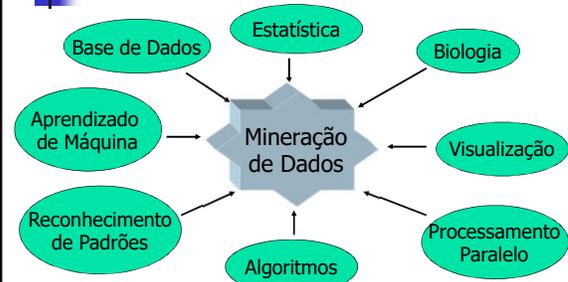
Mineração de Dados

- MD X KDD
 - MD: ferramentas básicas utilizadas para extrair padrões de dados
 - KDD: processo que engloba o uso dessas ferramentas, além de:
 - Pré-processamento, seleção e transformação dos dados
 - Interpretação dos padrões
 - Geração de conhecimento
 - Suporte à tomada de decisão

© André de Carvalho - ICMC/USP

19

Mineração de Dados



© André de Carvalho - ICMC/USP

20

Mineração de Dados

- Outros termos utilizados para MD e KDD
 - Extração de conhecimento
 - Descoberta de informação
 - Extração de padrões
 - Análise exploratória de dados
 - Analítica (Data analytics ou analytics)

© André de Carvalho - ICMC/USP

21

Analítica

- Ciência que analisa dados crus para extrair padrões desses dados
 - Pode englobar coleta e organização dos dados
- Analítica preditiva (predictive analytics)
 - Extraí modelos a partir de dados para fazer previsões futuras
- Analítica descritiva (descriptive analytics)
 - Sumariza ou condensa dados para extrair informações

© André de Carvalho - ICMC/USP

22

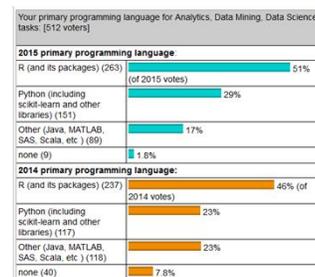
Interpretação / Avaliação

- Interpretação dos padrões encontrados na etapa de MD
 - Possível retorno a qualquer uma das etapas anteriores para iteração adicional
- Valida padrões encontrados
 - Importante consulta a um especialista
- Inclui análise estatística
- Ferramentas de visualização fornecem um suporte importante

© André de Carvalho - ICMC/USP

23

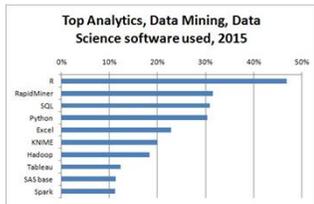
Ferramentas



© André de Carvalho - ICMC/USP

24

Ferramentas



© André de Carvalho - ICMC/USP

25

Custos em MD Preditivo

- 15% - coleta de dados
- 60% - limpeza e pré-processamento de dados
- 15% - construção e análise de modelos
- 5% - aplicação
- 5% - melhorias contínuas

© André de Carvalho - ICMC/USP

26

CRISP-DM

- Projeto CRISP-DM
 - *C*Ross-*I*ndustry *S*tandard *P*rocess for *D*ata *M*ining
 - Concebido em 1996 por:
 - Daimler-Chrysler
 - Aplicava MD em suas operações de negócios
 - SPSS
 - Prestava serviço de MD desde 1990
 - Desenvolveu primeira ferramenta comercial de MD (*Clemetine*)
 - NDR
 - Tinha o propósito de adicionar valor a sua enorme BD

© André de Carvalho - ICMC/USP

27

CRISP-DM

- Projeto CRISP-DM
 - Desenvolveu um novo fluxo de processo para descoberta de conhecimento
 - A partir do processo anterior
 - Fayyad, Piatetsky-Shapiro and Smyth
 - Em resposta a requisitos de usuários
 - Definiu e validou processo de MD utilizado em vários setores industriais

© André de Carvalho - ICMC/USP

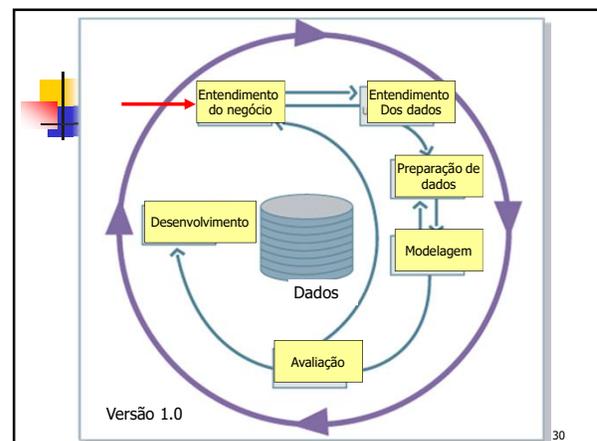
28

CRISP-DM

- Metodologia procura tornar os projetos
 - Mais rápidos
 - Mais baratos
 - Mais confiáveis
 - Mais facilmente gerenciáveis
- Pode ser aplicada a pequenos projetos
- Metodologia padrão da indústria

© André de Carvalho - ICMC/USP

29

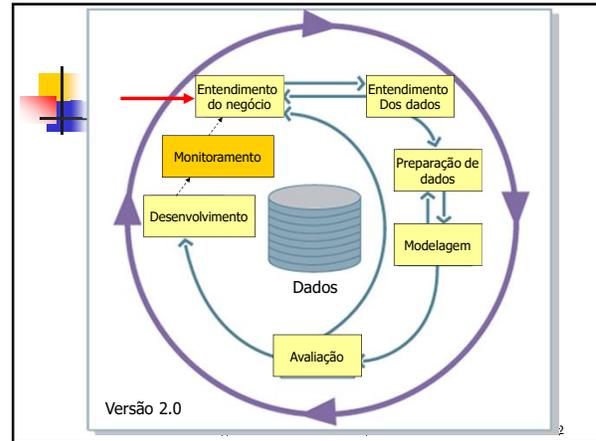


30

CRISP-DM 2.0

- SIG (*special interest group*) formado entre 2006 e 2008
- Mudanças estudadas
 - Divisão da fase de preparação de dados
 - Métodos de avaliação dentro da fase de modelagem
 - Fase de avaliação associada a avaliação na empresa
 - Centro de pesquisa, laboratório, hospital,...
 - Inclusão de fase de monitoramento

© André de Carvalho - ICMC/USP 31



CRISP-DM 2.0

- Não foi lançado até 2005
- SIG foi desfeito
 - Website CRISP-DM.org não esta mais ativo
- IBM criou nova metodologia
 - Refina e estende CRISP-DM
 - Analytics Solutions Unified Method for Data Mining/Predictive Analytics (ASUM-DM)

© André de Carvalho - ICMC/USP 33

Produtos para MD

© André de Carvalho - ICMC/USP 34

Mais Produtos

© André de Carvalho - ICMC/USP 35

Considerações Finais

- Expansão do volume de dados armazenados
 - Necessidade de extrair conhecimento dos dados
- KDD é cada vez mais usado por órgãos privados e públicos
- Cuidado com promessas exageradas
- Leitura
 - Knowledge Discovery and Data Mining: Towards a Unifying Framework, U. Fayyad, P. Smyth, and G. Piatetsky-Shapiro, .2nd International Conference on Knowledge Discovery and Data Mining, 1996

© André de Carvalho - ICMC/USP 36

 Perguntas



© André de Carvalho - ICMC/USP 37