

Mineração de Dados em Biologia Molecular

KDD

André C. P. L. F. de Carvalho
Monitor: Valéria Carvalho



Tópicos do Módulo

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

André Ponce de Leon F de Carvalho

2

Introdução

- Avanços recentes nas tecnologias de aquisição, transmissão e armazenamento de dados



Bases de dados cada vez maiores

André Ponce de Leon F de Carvalho

3

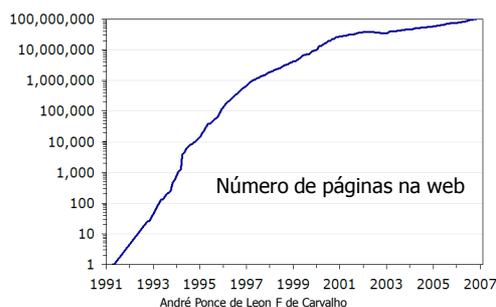
Introdução

- Estima-se que a quantidade de dados em Bases de Dados mundiais dobra a cada 20 meses
 - Transações bancárias
 - Utilização de cartões de crédito
 - Dados governamentais
 - Medições ambientais
 - Dados clínicos
 - Informações disponíveis na web
 - Dados de biologia molecular

André Ponce de Leon F de Carvalho

4

Introdução



André Ponce de Leon F de Carvalho

5

Tamanho Conjunto de Dados

- Tamanhos de conjuntos de dados
 - Pequeno
 - Conjunto de dados pode ser gerenciado pela ferramenta de KDD sozinha, geralmente em um único computador
 - Médio
 - Necessária a integração do ambiente de KDD com Sistemas Gerenciadores de BDs (SGBDs), que gerenciam os dados
 - Grande
 - Quando o volume de dados é grande demais para ser gerenciado pelas ferramentas de um SGBD
 - Necessário sistemas sofisticados capazes de lidar com dados armazenados em arquivos

André Ponce de Leon F de Carvalho

6

Tamanho Conjunto de Dados

Múltiplos de Bytes		
byte	B	10^0
kilobyte	kB	10^3
megabyte	MB	10^6
gigabyte	GB	10^9
terabyte	TB	10^{12}
petabyte	PB	10^{15}
exabyte	EB	10^{18}
zettabyte	ZB	10^{21}
yottabyte	YB	10^{24}

André Ponce de Leon F de Carvalho

7

Armazenamento de Dados

- Computadores atuais já vêm com 1 ou 2 terabyte de memória
- Cabe em 1 petabyte
 - 20 milhões de arquivos de 4 gavetas cheios
 - 500 bilhões de páginas de texto
 - Metade do conteúdo de todas as bibliotecas acadêmicas americanas combinadas
 - 7 bilhões de fotos no *facebook*
 - 200 milhões de músicas

André Ponce de Leon F de Carvalho

8

Grandes Bancos de Dados

- World Data Centre for Climate (WDCC)
 - Max Planck Institute for Meteorology and German Climate Computing Centre
 - 220 TBs de dados disponíveis na web sobre pesquisas e tendências climáticas
 - 110 TBs (24.500 DVDs) com dados de simulações climáticas
 - 6 PBs de informação adicional em fitas magnéticas

André Ponce de Leon F de Carvalho

9

Grandes Bancos de Dados

- Youtube
 - Pelo menos 45 TBs de vídeos
 - 60% de todos os vídeos assistidos online
 - 100 milhões de vídeos assistidos por dia
 - 65.000 novos vídeos adicionados por dia
 - Crescimento esperado de 1.86 TB por mês

André Ponce de Leon F de Carvalho

10

Grandes Bancos de Dados

- Amazon
 - Dois de seus BDs têm juntos mais de 42 TBs de dados
 - Milhões de itens vendidos por ela e por seus associados por ano
 - Equivale a 37 trilhões de posts para fóruns
 - 59 milhões de consumidores cadastrados

André Ponce de Leon F de Carvalho

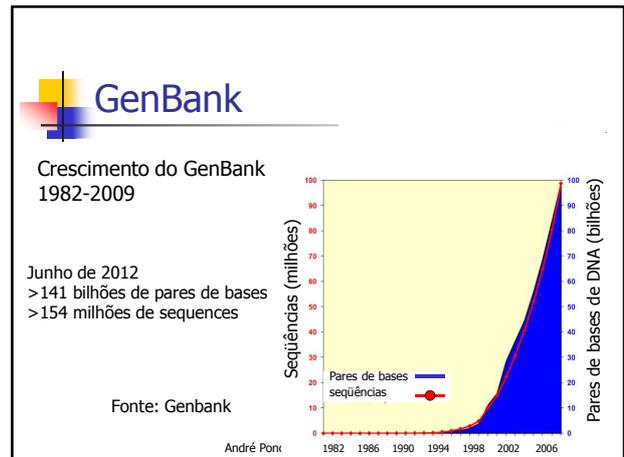
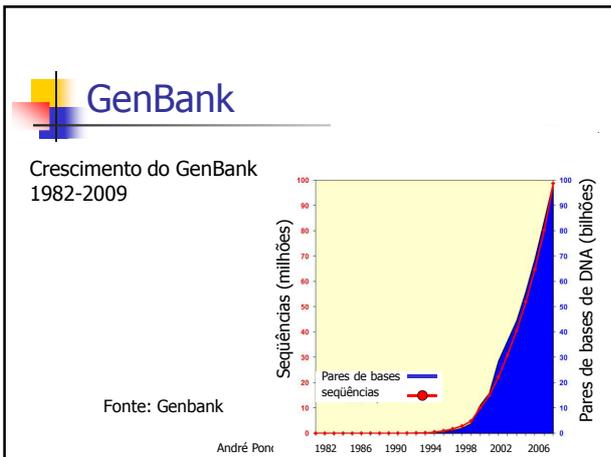
11

Grandes Bases Biologia

- GenBank
 - Banco de dados de sequências genéticas do Instituto Nacional de Saúde (NIH)
 - Todas as sequências de DNA publicamente disponíveis
 - International Nucleotide Sequence Database Collaboration
 - DNA DataBank of Japan (DDBJ)
 - European Molecular Biology Laboratory (EMBL)

André Ponce de Leon F de Carvalho

12



Grandes Bases Biologia

- Worldwide Protein Data Bank (wwPDB) tem mais de 90.000 estruturas
 - RCSB PDB (EUA)
 - PDBe (Europa)
 - PDBj (Japão)
 - BMRB (EUA)
- No passado, crescimento exponencial

2007	7263
2008	7073
2009	7448
2010	7971
2011	8120

André Ponce de Leon F de Carvalho 15

Introdução

- Bases de Dados muito grandes podem conter (esconder) dados preciosos
- Existe um interesse crescente em explorar esses dados armazenados
 - Descobrir conhecimento novo e útil
 - Apoio a decisão

André Ponce de Leon F de Carvalho 16

Exemplo – Carros

vhigh,vhigh,2,2,small,low,unacc
 vhigh,high,3,more,big,low,unacc
 vhigh,low,3,4,big,low,unacc
 med,low,4,2,small,high,unacc
 med,low,3,4,small,med,acc
 high,high,2,4,big,med,acc
 low,low,5more,4,small,med,acc
 low,med,4,4,small,med,acc
 low,med,4,4,big,med,good
 low,low,4,more,big,med,good
 med,low,2,4,small,high,good
 low,med,4,4,big,high,vgood
 med,med,2,4,big,high,vgood
 low,low,5more,more,big,high,vgood

André Ponce de Leon F de Carvalho 17

Exemplo - Carros

- Preço
 - Compra: v-high, high, med, low
 - Manutenção: v-high, high, med, low
- Características técnicas
 - Conforto
 - # portas: 2, 3, 4, 5-more
 - # pessoas: 2, 4, more
 - Espaço porta malas: small, med, big
 - Segurança: low, med, high
- Aval. do carro: unacc, acc, good, vgood

André Ponce de Leon F de Carvalho 18

Exemplo - Carros

vhigh,vhigh,2,2,small,low,unacc
 vhigh,high,3,more,big,low,unacc
 vhigh,low,3,4,big,low,unacc
 med,low,4,2,small,high,unacc
 med,low,3,4,small,med,acc
 high,high,2,4,big,med,acc
 low,low,5more,4,small,med,acc
 low,med,4,4,small,med,acc
 low,med,4,4,big,med,good
 low,low,4,more,big,med,good
 med,low,2,4,small,high,good
 low,med,4,4,big,high,vgood
 med,med,2,4,big,high,vgood
 low,low,5more,more,big,high,vgood

- Preço
 - Compra: v-high, high, med, low
 - Manutenção: v-high, high, med, low
- Características técnicas
 - Conforto
 - # portas: 2, 3, 4, 5-more
 - # pessoas: 2, 4, more
 - Espaço porta malas: small, med, big
 - Segurança: low, med, high
 - Aval. do carro: unacc, acc, good, vgood

André Ponce de Leon F de Carvalho 19

Exemplo - Promotores

```
+S10,
+AMPC,
+AROH,
+DEOP2,
+LEU1_TRNA,
+MALEFG,
-, 296,
-, 648,
-, 230,
-, 1163,
-, 1321,
-, 663,
tactagcaatcgcttcggtcggtgtaagtgtataatgvcgvggcttgcgt
tgctactcctgacagttgacgcgctgattggtgctgtacaatcaacgcatcgccaa
gtactagagaactagtgacgtattgttttttttcatgctaaaccacggcg
aattgtagtgatcgaagtgtgtgtagtagatgtagaatacaacaactc
tcgataattaacttgacgaaagctgaaaaccctagaatgcctcctggtag
agggcaaggaggatgaaagaggttccgtataaagaactagatgccttagg
agggcatgaaacgtctctgtagcgcagtccttctactgtgagtagcaccag
ccgagtagaccctagagagcatgctgacgctcgacaactgcataaatgcttctg
cgctaggacttctgtgatttccatgcggtgttttgcgcaatgtaactcgtt
tatgaccgaaacgagtcactcagaccgcttctgactctggtattactgtgaacatt
agaggggtactccaagaagagagatgaggctagacgtctctgcatggatgta
gagagcatgctcagcacaactgcataaatgcttctttagacgtgcctacg
```

André Ponce de Leon F de Carvalho 20

Introdução

- Técnicas tradicionais de análise de dados permitem apenas consultas simples
 - Quantos itens de um produto em particular foram vendidos em um dado dia?
 - Não conseguem responder consultas do tipo:
 - Dadas características de um carro, ele é bom?
 - Que tecidos podem estar com tumor?
 - Qual a estrutura terciária de uma nova proteína
 - Técnicas mais sofisticadas, capazes de extrair conhecimento de grandes BD são necessárias

André Ponce de Leon F de Carvalho 21

KDD

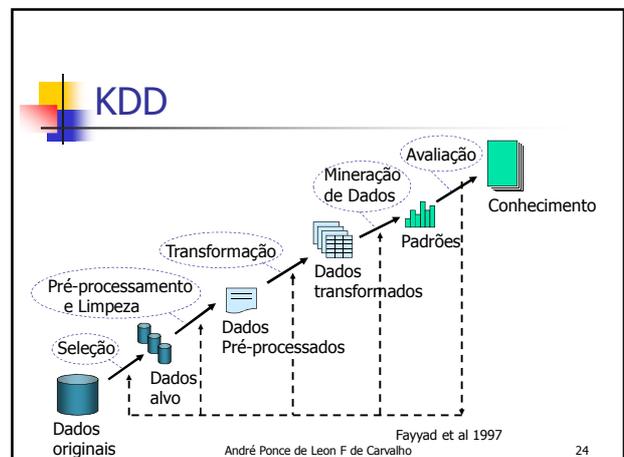
- Descoberta de conhecimento em BD
 - Knowledge Discovery in Databases
- Área de pesquisa em expansão
- Teorias e ferramentas computacionais capazes de extrair informação útil de grandes BD
 - Informação útil = conhecimento

André Ponce de Leon F de Carvalho 22

KDD

- Processo de encontrar em dados padrões
 - Úteis
 - Válidos
 - Novos
 - Potencialmente compreensíveis
- Processo iterativo e iterativo
 - Várias etapas
 - Uma delas é Mineração de Dados

André Ponce de Leon F de Carvalho 23



Seleção

- Entender o domínio de aplicação
 - Determinar o que já é conhecido sobre o problema
 - Identificar claramente os objetivos do usuário
 - Exemplo
 - Diagnosticar um paciente de acordo com um conjunto de sintomas

André Ponce de Leon F de Carvalho 25

Exemplo

- BD de um hospital
 - Composto por conjunto de registros de pacientes
 - Cada registro é composto de atributos
 - Informações pessoais
 - Sintomas

BD com registros de pacientes

André Ponce de Leon F de Carvalho 26

Conjunto de Dados

Atributos de entrada (preditivos)

Nome	Temp.	Idade	Peso	Altura	
João	37	70	94	190	Saudável
Maria	38	65	60	172	Doente
José	39	19	70	185	Doente
Sílvia	38	25	65	160	Saudável
Pedro	37	70	90	168	Doente

Exemplos (objetos, padrões)

Atributo alvo

27

Seleção

- Criação de um conjunto de dados
 - 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 Ponce de Leon F de Carvalho 28

Exemplo

Conjunto com dados clínicos dos pacientes

André Ponce de Leon F de Carvalho 29

Pré-processamento e Limpeza

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

André Ponce de Leon F de Carvalho 30

Transformação

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

André Ponce de Leon F de Carvalho

31

Mineração de Dados

- Principal passo no processo de KDD
 - DM e KDD são freqüentemente utilizados como sinônimos
- Fronteiras da etapa de MD no processo de KDD são de difícil identificação
 - Pré-processamento e transformação de dados são freqüentemente vistos como uma parte de MD

André Ponce de Leon F de Carvalho

32

Mineração de Dados

- Outros termos utilizados para MD e KDD
 - Extração de conhecimento
 - Descoberta de informação
 - Extração de padrões
 - Análise exploratória de dados

André Ponce de Leon F de Carvalho

33

Mineração de Dados



André Ponce de Leon F de Carvalho

34

Interpretação / Avaliação

- Interpretação dos padrões minerados 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 têm um papel de suporte importante

André Ponce de Leon F de Carvalho

35

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

André Ponce de Leon F de Carvalho

36

Aplicações

- Número crescente de aplicações
 - Internet: algoritmos de busca, marketing na web
 - Ciência e Medicina: diagnóstico de pacientes, análise de dados do genoma
 - Indústrias: previsão de falhas, diagnóstico de produtos
 - Marketing: segmentação de mercado
 - Telecomunicações: processamento de alarmes, roteamento de linhas de comunicação
 - Finanças: análise de risco, detecção de fraudes, gerenciamento de carteiras de investimento

André Ponce de Leon F de Carvalho

37

Aplicações Reais

- Cadeias de PUB britânicas utilizam MD para definir mudanças diárias nos preços de algumas bebidas
 - Acessa impacto das ofertas de *happy hour* nas vendas

Se desconto para uma dada bebida aumenta as vendas em um dia, manter o desconto no dia seguinte, senão tentar outra promoção

André Ponce de Leon F de Carvalho

38

Aplicações Reais

- Fast Search & Transfer ASA
 - Software de MD que pode fazer 200 consultas por segundo
 - Utilizado pela Reuters para procurar violações de propriedade intelectual na Web
 - Busca por textos semelhantes aos publicados pela Reuters
 - Envia a Advogados textos suspeitos

André Ponce de Leon F de Carvalho

39

Aplicações Reais

- Seimans Medical
 - Ferramenta de MD para o Tratamento de Ataques cardíacos
 - Combina informações médicas de diversas fontes
 - Inclusive texto
 - Busca automática em registros combinados de 6 milhões de pacientes

André Ponce de Leon F de Carvalho

40

Aplicações Reais

- Seimans Medical
 - Descobriu centenas de casos onde os melhores procedimentos médicos não haviam sido seguidos
 - Mas ainda havia tempo para intervir
 - Identificou pacientes elegíveis para estudos médicos
 - Ganhou o 2005 ICDM Data Mining Practice Prize

André Ponce de Leon F de Carvalho

41

Aplicações Reais

- The Mitre Cooperation
 - Ferramenta de MD para detecção de fraudes no imposto de renda
 - Indivíduos com rendimentos elevados são uma das principais fontes de estimativas não realizadas
 - Renda anual > US\$ 250.000,00
 - Prejuízo (impostos que deveriam ser coletados – impostos coletados)
 - Sistema de MD usa Aprendizado de Máquina e Análise Estatística para descobrir sonegações

André Ponce de Leon F de Carvalho

42

Mitos (Padhraic Smith)

- “Análise de dados pode ser completamente automatizada”
 - Julgamento humano é crítico na maioria das aplicações
 - Entretanto, semi-automação é muito útil
- “Regras de associação são sempre úteis”
 - Regras de associação são essencialmente listas de correlações
 - Nenhuma aplicação bem sucedida documentada
 - Comparar com árvores de decisão (várias aplicações)

André Ponce de Leon F de Carvalho

49

Mitos (Padhraic Smith)

- “Com uma quantidade massiva de dados, não é necessário estatística”
 - Grande volume leva a heterogeneidade
 - Precisa ainda mais de estatística

André Ponce de Leon F de Carvalho

50

Considerações Finais

- Expansão do volume de dados armazenados
- Necessidade de extrair conhecimento dos dados
- KDD é cada vez mais usado
- Cuidado com promessas exageradas
 - Sistemas Especialistas

André Ponce de Leon F de Carvalho

51

Perguntas



André Ponce de Leon F de Carvalho

52