

Mineração de Dados em Biologia Molecular

WEKA

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



André Ponce de Leon de Carvalho

2

Tópicos

- Introdução
- Simuladores de MD
- Ambiente WEKA
- Principais módulos

André Ponce de Leon de Carvalho

2

Usando MD

- Implementação e simulação
 - Escrever código do zero
 - Reaproveitar código
 - Utilizar um ambiente dedicado
 - Fornece ferramentas apropriadas para auxiliar o usuário ao longo de toda a simulação
 - Minimiza esforço do usuário
 - Agiliza implementação e realização de experimentos

André Ponce de Leon de Carvalho

3

Ambientes para MD

- Principais tipos
 - Baseados em telas e interfaces gráficas
 - Baseados em biblioteca de funções (lego)
 - Baseados em uma linguagem de programação específica
- Funcionalidades
 - Suporte a pré-processamento e análise de resultados
 - Grande número de algoritmos de AM, técnicas estatísticas e ferramentas de visualização

André Ponce de Leon de Carvalho

4

Ambientes de MD

- Comerciais
 - SAS
 - SPSS
 - Matlab
- Públicos
 - Rapid miner
 - Knime
 - WEKA

André Ponce de Leon de Carvalho

5

WEKA o Pássaro

- Pássaro típico da Nova Zelândia
 - Encontrado apenas lá
 - Não voa
 - Tamanho de uma galinha
 - Alimentam-se de invertebrados e frutas
 - Dócil em extremo
 - Quase foram a extinção

André Ponce de Leon de Carvalho

6

WEKA o Pássaro



Copyright: Martin Kramer (mkramer@vxs.nl)
André Ponce de Leon de Carvalho

7

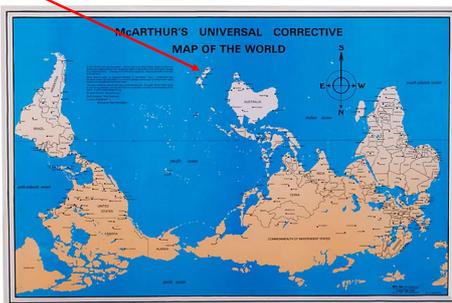
Weka o Ambiente

- Desenvolvido na Universidade de Waikato, NZ
- Mineração de Dados e Aprendizado de Máquina
- Escrito em JAVA
 - Distribuído por meio da licença de software livre da GNU
- Utilizada com diferentes propósitos
 - Ensino, pesquisa, aplicações

André Ponce de Leon de Carvalho

8

Onde fica Waikato?



André Ponce de Leon de Carvalho

9

História do WEKA

- 1992:
 - Submissão do projeto para financiamento pelo governo da NZ por Ian Witten
- 1993:
 - Financiamento aprovado pelo governo
 - Sigla WEKA criada por Geoff Holmes
 - Waikato Environment for Knowledge Analysis
 - Criação do formato ARFF por Andrew Donkin
 - Attribute-Relation File Format
 - Segundo rumores, Andrew's Ridiculous File Format

André Ponce de Leon de Carvalho

10

História do WEKA

- 1994:
 - Primeira versão é disponibilizada
 - Interface TCL/TK e algoritmos de aprendizado escritos principalmente em C
 - Versão beta
- 1996:
 - Primeira versão pública: WEKA 2.1

André Ponce de Leon de Carvalho

11

História do WEKA

- 1997:
 - Decisão de reescrever o código em Java
 - Tese de doutorado de Eibe Frank
 - 1998
 - Disponibilizado WEKA 2.3, última versão baseada em TCL/TK
- 1998:
 - Disponibilizado WEKA 3
 - Primeira versão completamente em Java
 - Inclusão do módulo de desenvolvimento, com GUI
 - Compatível com livro do Witten e Frank

André Ponce de Leon de Carvalho

12

Últimas Versões do WEKA

- Várias versões foram desenvolvidas depois:
 - WEKA 3.2: "versão GUI", adiciona GUI (versão do livro usava linha de comando)
 - WEKA 3.3: "versão de desenvolvimento" com várias melhorias
 - WEKA 3.4: "versão do livro" compatível com segunda edição do livro *Data Mining*
 - WEKA 3.6: última versão estável (3.6.7)
 - WEKA 3.7: finalizada, mas ainda instável

André Ponce de Leon de Carvalho

13

Ambiente WEKA

- Possui vários módulos, que podem ser utilizados para:
 - Pré-processamento de dados
 - Uso de algoritmos de Aprendizado de Máquina
 - Análise de resultados
 - Visualização gráfica de dados e modelos
 - Comparação de modelos (e algoritmos)

André Ponce de Leon de Carvalho

14

Ambiente WEKA

- Com WEKA, é possível
 - Abrir um conjunto de dados em diferentes formatos
 - Pré-processar os dados por meio de filtros
 - Aplicar um algoritmo de AM aos dados
 - Ajustar parâmetros dos algoritmos
 - Analisar os resultados obtidos
 - Utilizar diversas medidas de desempenho

André Ponce de Leon de Carvalho

15

Ambiente WEKA

- 3 formas de usar
 - Aplicar um algoritmo de aprendizado a um conjunto de dados e analisar a saída para saber mais sobre os dados
 - Usar modelos induzidos para gerar previsões para novos dados
 - Comparar desempenho de diferentes algoritmos para selecionar um deles

André Ponce de Leon de Carvalho

16

Ambiente WEKA

- Como usar WEKA?
 - Linhas de comando
 - A partir de programas em Java
 - Chamar métodos do WEKA utilizando suas bibliotecas
 - Permite escrever e testar novos algoritmos
 - Usando GUI do Explorer
 - Mais fácil
 - Uma das opções do WEKA GUI *Chooser*

André Ponce de Leon de Carvalho

17

GUI do WEKA

- *Graphical User Interface*
- Ponto inicial para chamar as principais aplicações e ferramentas de suporte
- Possui quatro opções:
 - *Explorer*
 - *Experimenter*
 - *KnowledgeFlow*
 - *SimpleCLI*

André Ponce de Leon de Carvalho

18

GUI do WEKA



André Ponce de Leon de Carvalho

19

GUI do WEKA

- Funcionalidades são acessadas por
 - Escolha de uma opção de um menu
 - Permite apenas as opções exibidas no momento da simulação
 - Preenchimento de valores em telas
 - Pré-preenchidos com valores *default* para obtenção de resultados com o mínimo de esforço
 - Entender os algoritmos e seu uso é importante para entender os resultados

André Ponce de Leon de Carvalho

20

Principais Opções

- *Explorer*
 - Ambiente para exploração de dados
- *Experimenter*
 - Ambiente para realização de experimentos e testes estatísticos
 - Permite comparar modelos

André Ponce de Leon de Carvalho

21

Principais Aplicações

- *KnowledgeFlow*
 - Suporta mesmas funções que Explorer, além de aprendizado incremental
 - Permite trabalhar com fluxos de dados
 - Inclui interface *drag-and-drop* (arrastar e por)
- *SimpleCLI*
 - Interface para linha de comando
 - Permite que comandos do WEKA sejam executados por sistemas operacionais que não possuem interface GUI

André Ponce de Leon de Carvalho

22

Explorer

- Ferramenta gráfica de fácil uso que mostra as funcionalidades do software
- Cada um dos principais pacotes disponíveis é representado na interface
 - Filtros
 - Algoritmos de classificação
 - Algoritmos de agrupamento
 - Algoritmos de associação
 - Algoritmos de seleção de atributos
 - Ferramenta de visualização

André Ponce de Leon de Carvalho

23

Explorer

- Ferramentas de visualização permitem a análise em duas dimensões de:
 - Dados de um conjunto
 - Predições geradas por:
 - Modelos de classificação
 - Modelos de agrupamento de dados
 - Possui vários painéis

André Ponce de Leon de Carvalho

24

KnowlegdeFlow

- Permite colocar ícones representando algoritmos e fontes de dados na tela
 - E uni-los na configuração desejada
- Permite definir um fluxo de dados
 - Conectando componentes representando
 - Fontes de dados
 - Ferramentas de pré-processamento
 - Algoritmos de aprendizado
 - Métodos de avaliação
 - Módulos de visualização

André Ponce de Leon de Carvalho

25

Experimenter

- Ajuda a definir quando aplicar técnicas de classificação (e de regressão)
 - Que métodos e valores de parâmetros funcionam melhor para um dado problema?
 - Resposta não fácil
- Permite comparar vários algoritmos de aprendizado
 - Pode ser feito interativamente com explorer
 - Módulo *Experimenter* automatiza esse processo

André Ponce de Leon de Carvalho

26

Experimenter

- Como automatiza?
 - Torna mais fácil:
 - Executar algoritmos com:
 - Diferentes valores para seus parâmetros e
 - Vários conjuntos de dados
 - Avaliar desempenho estatístico
 - Realizar testes de significância
- Pode ser usado para distribuir carga em várias máquinas
 - Usando *Java Remote Method Invocation* (RMI)

André Ponce de Leon de Carvalho

27

Documentação

- Documentação *online* gerada automaticamente do código fonte
- Única fonte completa dos algoritmos disponíveis
 - WEKA esta continuamente em crescimento
 - Por ser gerada automaticamente a partir do código fonte, documentação *online* esta sempre atualizada

André Ponce de Leon de Carvalho

28

Prática

- Entrar na ferramenta WEKA
 - Selecionar opção explorer
 - Carregar base de dados iris.arff
 - Opção "Open file"
 - Carregar classificador J48
 - Opção "Classifier"
 - Em *Classifier*, opção "Choose" J48
 - Realizar experimento usando training set
 - Olhar resultados

André Ponce de Leon de Carvalho

29

Perguntas



André Ponce de Leon de Carvalho

30