

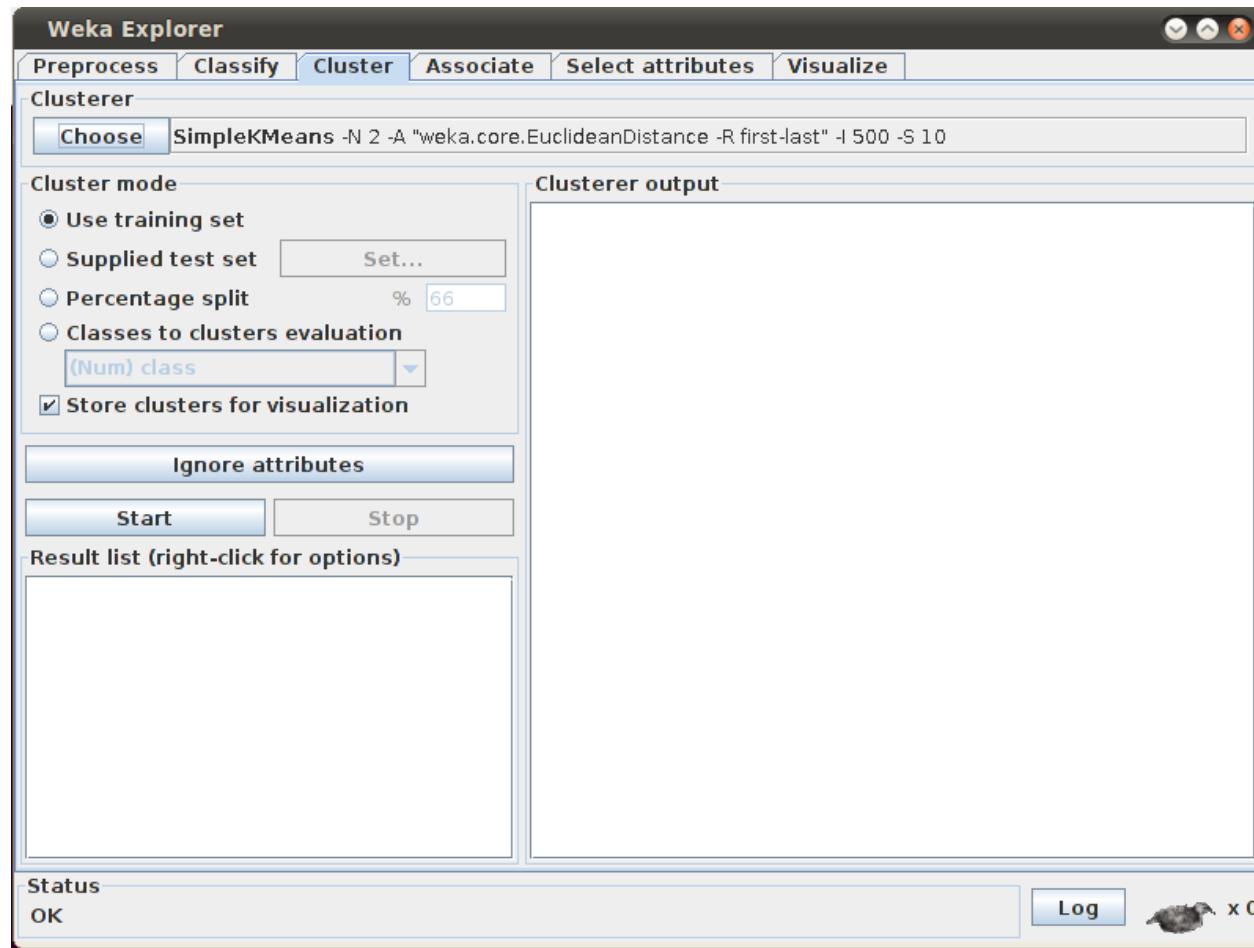
Agrupamento de Dados de Expressão Gênica utilizando WEKA

Estagiário PAE: Pablo Andretta Jaskowiak
Professor: Ricardo J. G. B. Campello

Sumário

- Aplicação de Algoritmos
- Aplicação em Dados de Expressão Gênica
- Outras Ferramentas

Aplicação de Algoritmos



Aplicação de Algoritmos

- Algoritmo *k-means* (*SimpleKMeans*)
 - Presente em praticamente todas as versões
 - Escolha da medida de proximidade
 - Número de grupos
 - Número máximo de iterações
 - Semente

Aplicação de Algoritmos

- Hierárquicos
 - Presentes somente nas versões mais novas
 - Versão 3.7.2
 - Escolha da medida de proximidade
 - Entre objetos
 - Entre grupos
 - Single-Linkage
 - Average-Linkage
 - Complete-Linkage
 - Número de grupos*

Aplicação de Algoritmos

- Utilizando os algoritmos passo a passo
 - Abrir o arquivo *base_1.arff*
 - Aplicar o algoritmo *k-means*
 - Aplicar os algoritmos hierárquicos

Aplicação de Algoritmos

1. Abrir cada uma das bases

base_2.arff

base_3.arff

2. Visualizar as bases

3. Avaliar os resultados

Gerados como sumário

Avaliação visual

Bases de Dados

- Agrupamento de Dados de Expressão Gênica
 - Amostras
 - Provenientes de diferentes tecidos
 - Genes
 - Experimentos de séries temporais
 - Expressão medida ao longo do tempo

Bases de Dados

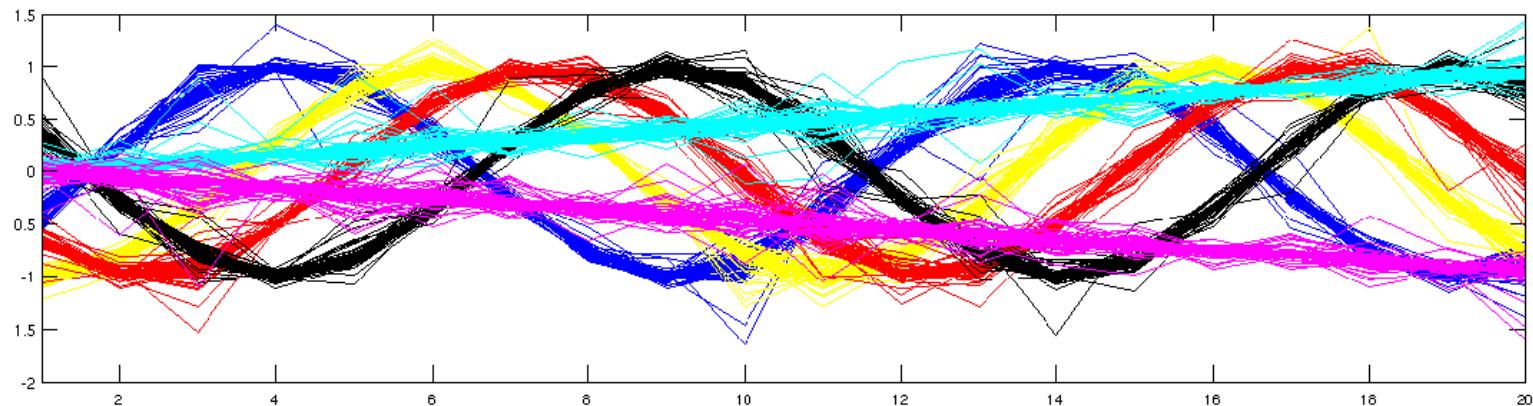
- Agrupamento de Amostras
 - ▣ Golub et al., 1999
 - Descoberta de tipos de leucemia
 - AML (25 amostras)
 - ALL (47 amostras)
 - ▣ Alizadeh et al., 2000
 - Identificação de diferentes tipos de linfomas
 - DLBCL1 (21 amostras)
 - DLBCL2 (21 amostras)

Golub, T. R. et al. Molecular classification of cancer: Class discovery and class prediction by gene expression monitoring. Science, 286(5439):531-537, 1999.

Alizadeh, A. A. et al. Distinct types of diffuse large B-cell lymphoma identified by gene expression profiling. Nature, 403(6769):503-511, 2000.

Bases de Dados

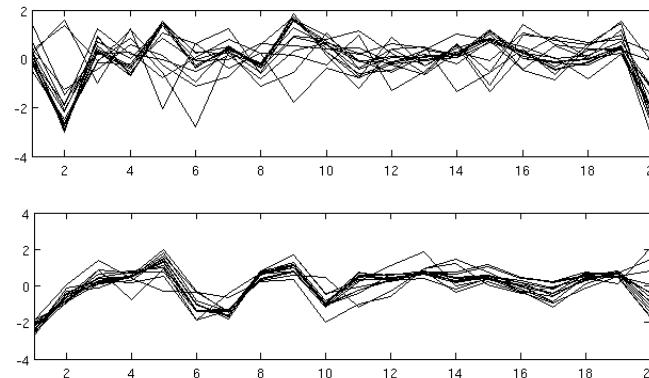
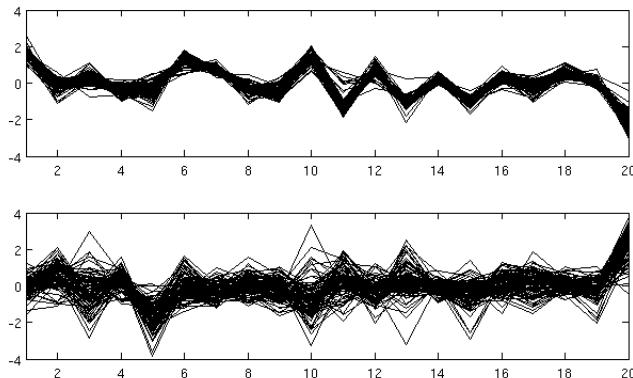
- Agrupamento de Genes
 - Bases sintéticas (Yeung et al., 2003), com 6 grupos
 - Sin2
 - Sin4





Agrupamento de Genes

Base de dados yeast (Cho et al., 1998), com 4 grupos



Outras Ferramentas

- Mayday – Microarray Data Analysis
 - <http://www-ps.informatik.uni-tuebingen.de/mayday/wp/>
- RapidMiner
 - <http://rapid-i.com/content/view/181/190/>
- R Language
 - <http://www.r-project.org/>