

SCC5836 - Visualização Computacional
Profa. Dra. Rosane Minghim

Visualization-based cancer microarray data classification analysis

Minca Mramor , Gregor Leban , Janez Demšar e Blaž Zupan

Tamires Brito da Silva
8124382



Motivação

Motivação

- © Métodos para analisar dados de *microarray* de câncer frequentemente enfrentam dois desafios distintos
 - Classificar novas amostras de tecido
 - Fornecer uma visão dos padrões e interações de genes escondidos nos dados

Motivação

- © A visualização de dados pode fornecer uma excelente abordagem para a descoberta de conhecimento e análise de dados com rótulo de classe
- © **VizRank**
 - Pontua e classifica visualizações baseadas em pontos de acordo com o grau de separação de instâncias de dados de diferentes classes

Proposta do Artigo

- © Extensão do VizRank
 - Técnicas para descobrir *outliers*
 - Ranquear *features* (características) (genes)
 - Executar classificação
- © Demonstrar que a abordagem proposta é bem adequada para a análise de *microarrays* de câncer

Contextualização


Contextualização

- © Distinguir e classificar malignidades humanas dependem de uma variedade de aspectos clínicos, moleculares e parâmetros morfológicos
- © O diagnóstico preciso do câncer continua a ser uma tarefa desafiadora
- © *Microarrays* de DNA

Contextualização

Microarray de DNA

- © Determinar se o DNA contém mutação de genes



FONTE: <https://www.genome.gov/10000533/dna-microarray-technology/>

Contextualização

- © Muitas pesquisas foram feitas para diagnóstico de câncer (Golub et al., 1999; Bhattacharjee et al., 2001; Khan et al., 2001; Shipp et al., 2002)
- © Vários métodos estatísticos e de mineração de dados para *microarray* análise de dados evoluíram (Allison et al., 2006; Asyali et al., 2006; Pham et al., 2006)

Contextualização

- © Inicialmente eram usado métodos sem supervisão
 - Cluster e análise de componentes principais
- © Modelos de dados de câncer são problemas de mineração de dados supervisionado
 - Máquinas de vetores de suporte (*support vector machines SVMs*) (Statnikov et al., 2005)
 - Redes neurais artificiais (*artificial neural networks ANN*) (Khan et al., 2001)
 - *k-nearest neighbors* (k-NN)(Golub et al., 1999)

Contextualização

- © Os dois aspectos mais importantes de mineração de dados preditivos
 - Precisão nas previsões
 - Ganho de *insight* (visão)
- © Nem todos os métodos cobrem esses dois aspectos igualmente bem
- © Visualização de dados oferece meios para expor graficamente padrões interessantes

Visualização

Visualização

© Radviz (Hoffman et al., 1997)

- Método de visualização não linear
- *Features* são visualizadas como ponto-âncora igualmente espaçados ao redor do perímetro de um círculo unitário
- Os valores das *features* são normalizados entre 0 e 1
- As instâncias de dados são mostradas como pontos dentro do círculo


Visualização

© Radviz (Hoffman et al., 1997)

- Abstração física
 - Cada ponto é mantido no lugar com molas presas na outra extremidade dos ponto-âncoras da *feature*
 - A rigidez de cada mola é proporcional ao valor da *feature* correspondente
 - Ponto termina na posição em que as forças da mola estão em equilíbrio
- As instâncias de dados que estão mais próximas de um conjunto de *features* tem maior valor para essas *features* do que as outras

Visualização - Exemplo 1

- © Radviz (Hoffman et al., 1997)
- © *Dataset* de câncer de pulmão (Bhattacharjee et al., 2001)
 - 5 classes
 - 203 amostras de tecido (pontos)
- © Posição de cada ponto depende do valor da sua *feature* (expressões genéticas)
- © 7 genes é o suficiente para separar esse *dataset*




- adenocarcinoma (AD)
- pulmão normal (NL)
- câncer de pulmão de pequenas células (SMCL)
- carcinoma de células escamosas (SQ)
- carcinóide pulmonar (COID)

Visualização - Exemplo 2


© (McCarthy et al., 2004)

- Seleção de características através da aprendizagem de redes neurais para reduzir o número de genes na visualização
- *Cluster de features (cluster de âncoras de features correlacionados)*


Visualização - Exemplo 2



Visualização - Exemplo 2






Visualização - Exemplo 2



Visualização - Exemplo 3

- © (Khan, et al., 2001) resumiu os resultados da análise em uma visualização planar que mostra uma clara separação dos casos diagnósticos
 - Dados não podem ser rastreados até os genes originais
 - Plotagem obtida por escalonamento multidimensional
 - Várias etapas de pré-processamento de dados





Visualização

- ◎ Não é trivial achar uma projeção limpa e que separe as classes
 - Existem milhões de projeções possíveis no Radviz
- ◎ VizRank (Leban et al., 2006)
 - Método para ordenar projeções visuais de dados com classificação de classe por seu potencial de interesse
 - Se concentra em um pequeno subconjunto de visualizações que são mais prováveis fornecer a melhor visão sobre os dados
- ◎ Análise de dados não procura aleatoriamente entre milhões de possíveis projeções

Visualização - Exemplo 4

© VizRank (Leban et al., 2006)

- Define o interesse da projeção estimando o quanto as instâncias de dados da mesma classe são agrupadas e separadas das instâncias de outras




Visualização - Extensão VizRank

© Classificação

- As projeções achadas pelo VizRank podem ser usadas para classificar novas amostras
- A posição da amostra na projeção é determinada por sua expressão dos genes utilizadas na projeção
- A amostra é então classificada para a classe predominante de amostras k-mais próximas da visualização original
- O algoritmo de classificação é, portanto, o mesmo que o utilizado no ranking das projeções

Visualização - Extensão VizRank

© Classificação




Visualização

© Ranqueamento de *features*

- Espera-se que os genes que aparecem nas projeções mais bem classificadas sejam aqueles que detêm mais informações para discriminação de classe
- Pontuação utilidade genética
 - Número de aparições do gene em P melhores projeções ranqueadas

Visualização

© Ranqueamento de *features*



Visualização - Extensão VizRank

© Detecção de *outliers*

- A identificação e análise dos outliers nas melhores projeções podem revelar características interessantes dos dados
 - Casos especiais de uma doença específica
 - Amostras diagnosticadas erroneamente
- Técnica automática que suporta análise exploratória de dados e examina um único caso selecionado
 - Relata suas probabilidades de classe previstas usando um conjunto de visualização mais bem classificadas

Conclusão

Conclusão

- ◎ Método para analisar dados de expressão gênica
 - Fornece um modelo de classificação confiável
 - Fornece uma visão valiosa dos dados na forma de visualizações informativas
- ◎ O método proposto de ranqueamento e classificação de projeções
 - Pode encontrar visualizações simples de conjuntos de dados de expressão gênica de câncer que usam um subconjunto muito pequeno

Conclusão

- © Devido ao potencial na análise exploratória de dados, tempos de execução curtos e interface interativa
 - Visualização de dados suportada com técnicas eficientes de pesquisa de projeção deve complementar outras técnicas estabelecidas na análise de *microarrays* de câncer e se tornar parte das ferramentas de análise padrão

Conclusão

- © VizRank e Radviz são implementados como parte do Orange data mining suite. Disponível em <http://www.ailab.si/orange>
- © Os dados utilizados estão disponíveis em <http://www.ailab.si/supp/bi-cancer>
- © Citado por 74 artigos no Google Scholar e 37 no Web of Science
 - A maioria em conferências/jornais de Bioinformática/ Biomedicina
 - Mas também foi citado em conferências de visualização

Perguntas

Perguntas

1. O que é um microarray de DNA?
2. Como a visualização pode ajudar no diagnóstico de câncer?
3. Como é a procura de projeções do VizRank?

Obrigada!

Perguntas?

tamiresbs@usp.br