

Técnicas de Seleção de Atributos utilizando Paradigmas de Algoritmos

Theo Silva Lins

Orientador: Luiz Henrique de Campos Merschmann

Programa de Pós-Graduação em Ciência da Computação
Universidade Federal de Ouro Preto

14 de julho de 2011



Universidade Federal
de Ouro Preto

1 Introdução

- Mineração de Dados
- Técnicas de Seleção de atributos
- Motivação
- Desenvolvimento do Problema

2 Seleção de atributos baseado em consistência

- Exemplo Base de dados
- Métrica de Consistência
- Cálculo das taxas de inconsistência.
- Exemplo de Cálculo de Consistência
- Algoritmo
- Heurísticas
- Espaço de Soluções 1
- Espaço de Soluções 2

3 Métodos Utilizados



Mineração de Dados

- Mineração de Dados
- Importância
- Aplicações
- Classificação



Técnicas de Seleção de atributos

- Técnicas de Seleção de atributos
- Tipos
 - Embedded
 - Wrappers
 - Filtros
- Métricas
 - Ganho de Informação
 - Dependência
 - Correlação
 - Consistência



Técnicas de Seleção de atributos

- Técnicas de Seleção de atributos
- Tipos
 - Embedded
 - Wrappers
 - Filtros
- Métricas
 - Ganho de Informação
 - Dependência
 - Correlação
 - Consistência



Técnicas de Seleção de atributos

- Técnicas de Seleção de atributos
- Tipos
 - Embedded
 - Wrappers
 - Filtros
- Métricas
 - Ganho de Informação
 - Dependência
 - Correlação
 - Consistência



Motivação e Objetivos

- Motivação
- Objetivos



Desenvolvimento do Problema

- Fazer um estudo das técnicas de seleção de atributos.
- Encontrar quais técnicas utilizam os paradigmas de algoritmos.
- Selecionar e implementar uma dessas técnicas, utilizando paradigmas diferentes.
- Fazer experimentos e analisar os resultados.
- Obter um comparativo entre as abordagens utilizadas.



1 Introdução

- Mineração de Dados
- Técnicas de Seleção de atributos
- Motivação
- Desenvolvimento do Problema

2 Seleção de atributos baseado em consistência

- Exemplo Base de dados
- Métrica de Consistência
- Cálculo das taxas de inconsistência.
- Exemplo de Cálculo de Consistência
- Algoritmo
- Heurísticas
- Espaço de Soluções 1
- Espaço de Soluções 2

3 Métodos Utilizados



Base de dados - Golf

Outlook	Temperature	Humidity	Windy	Play
sunny	hot	high	FALSE	no
sunny	hot	high	FALSE	yes
overcast	hot	high	FALSE	yes
rainy	mild	high	FALSE	yes
rainy	cool	normal	FALSE	yes
rainy	cool	normal	TRUE	no
overcast	cool	normal	TRUE	yes
sunny	mild	high	FALSE	no
sunny	cool	normal	FALSE	yes
rainy	mild	normal	FALSE	yes
sunny	mild	normal	TRUE	yes
overcast	mild	high	TRUE	yes
overcast	hot	normal	FALSE	yes
rainy	mild	high	TRUE	no

Métrica de Consistência

- Duas instâncias são consideradas inconsistentes se elas possuírem os mesmos valores de atributos e pertencerem a diferentes classes.

Cálculo das taxas de inconsistência.

- A inconsistência é medida com a seguinte formula:
- $TI(S, D) = \frac{\sum_{i=1}^m TI(S_i)}{\text{numero de instancias}}$ onde m é o número de conjuntos de instâncias padrões.
- Logo a consistência será: $C(S) = 1 - TI(S, D)$



Exemplo de Cálculo de Consistência

i	Padrão S_i Outlook, Temperature, Windy	Classe (Freq.)	Taxa de inconsistência de S_i
1	sunny, hot, FALSE	no(1), yes(1)	$2 - 1 = 1$
2	overcast, hot, FALSE	yes(2)	$2 - 2 = 0$
3	rainy, mild, FALSE	yes(2)	$2 - 2 = 0$
4	rainy, cool, FALSE	yes(1)	$1 - 1 = 0$
5	rainy, cool, TRUE	no(1)	$1 - 1 = 0$
6	overcast, cool, TRUE	yes(1)	$1 - 1 = 0$
7	sunny, mild, FALSE	no(1)	$1 - 1 = 0$
8	sunny, cool, FALSE	yes(1)	$1 - 1 = 0$
9	sunny, mild, TRUE	yes(1)	$1 - 1 = 0$
10	overcast, mild, TRUE	yes(1)	$1 - 1 = 0$
11	rainy, mild, TRUE	no(1)	$1 - 1 = 0$

Portanto, teremos a seguinte taxa de inconsistência ($TI(S, D)$):

$$TI(S, D) = \frac{1 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0}{14} = 0,0714.$$

Por fim, a consistência desse subconjunto S será:

$$C(S) = 1 - TI(S, D) = 1 - 0,0714 = 0,929.$$



Algoritmo

- Menor inconsistência e o menor tamanho.
- A base de dados com n atributos, tem-se 2^n subconjuntos de atributos possíveis.
- Métodos heurísticos.



Algoritmo

- Menor inconsistência e o menor tamanho.
- A base de dados com n atributos, tem-se 2^n subconjuntos de atributos possíveis.
- Métodos heurísticos.



Algoritmo

- Menor inconsistência e o menor tamanho.
- A base de dados com n atributos, tem-se 2^n subconjuntos de atributos possíveis.
- Métodos heurísticos.




Heurísticas


- Ponto de partida.
- A estratégia que será utilizada para percorrer o espaço de soluções.
- A forma de avaliação dos subconjuntos de atributos.
- Critério de parada.



Espaço de Soluções - Exemplo 1



Espaço de Soluções - Exemplo 2



1 Introdução

- Mineração de Dados
- Técnicas de Seleção de atributos
- Motivação
- Desenvolvimento do Problema

2 Seleção de atributos baseado em consistência

- Exemplo Base de dados
- Métrica de Consistência
- Cálculo das taxas de inconsistência.
- Exemplo de Cálculo de Consistência
- Algoritmo
- Heurísticas
- Espaço de Soluções 1
- Espaço de Soluções 2

3 Métodos Utilizados



Backtracking

- Método impraticável para datasets com muitos atributos.
- Realiza uma busca completa.



Max Tries

- A idéia desse algoritmo é, por um número máximo de tentativas (max tries), e gerar subconjuntos de atributos.
- O algoritmo para quando o número de tentativas acabar
- Realiza uma busca não-determinística.



Hill Climbing

- Gera os subconjuntos de soluções vizinhas
- Escolher a melhor solução entre vizinhas
- O algoritmo para quando não encontrar nenhum subconjunto melhor entre os vizinhos.
- Realiza uma busca heurística



Hill Climbing

- Gera os subconjuntos de soluções vizinhas
- Escolher a melhor solução entre vizinhas
- O algoritmo para quando não encontrar nenhum subconjunto melhor entre os vizinhos.
- Realiza uma busca heurística



Hill Climbing

- Gera os subconjuntos de soluções vizinhas
- Escolher a melhor solução entre vizinhas
- O algoritmo para quando não encontrar nenhum subconjunto melhor entre os vizinhos.
- Realiza uma busca heurística



Hill Climbing

- Gera os subconjuntos de soluções vizinhas
- Escolher a melhor solução entre vizinhas
- O algoritmo para quando não encontrar nenhum subconjunto melhor entre os vizinhos.
- Realiza uma busca heurística



1 Introdução

- Mineração de Dados
- Técnicas de Seleção de atributos
- Motivação
- Desenvolvimento do Problema

2 Seleção de atributos baseado em consistência

- Exemplo Base de dados
- Métrica de Consistência
- Cálculo das taxas de inconsistência.
- Exemplo de Cálculo de Consistência
- Algoritmo
- Heurísticas
- Espaço de Soluções 1
- Espaço de Soluções 2

3 Métodos Utilizados



- Complexidade $f(n) = O(2^n)$
 - Onde n é o número de atributos.



- Complexidade $f(n) = O(2^n)$
 - Onde n é o número de atributos.



- Complexidade $f(n) = O(m)$
 - Onde m é o número tentativas.



- Complexidade $f(n) = O(m)$
 - Onde m é o número tentativas.



- Complexidade $f(n) = O(n^2)$
 - Onde n é o número de atributos.



- Complexidade $f(n) = O(n^2)$
 - Onde n é o número de atributos.



1 Introdução

- Mineração de Dados
- Técnicas de Seleção de atributos
- Motivação
- Desenvolvimento do Problema

2 Seleção de atributos baseado em consistência

- Exemplo Base de dados
- Métrica de Consistência
- Cálculo das taxas de inconsistência.
- Exemplo de Cálculo de Consistência
- Algoritmo
- Heurísticas
- Espaço de Soluções 1
- Espaço de Soluções 2

3 Métodos Utilizados



Informações

- Consistência.
- Tempo de Execução
- Atributos Selecionados.



Base de Dados

- Golf Data set
- Breast Cancer Wisconsin Data Set
- SPECTF Heart Data Set
- Congressional Voting Records Data Set



Algoritmos

- Max-Tries
 - Tentativas = 1000;
 - Consistência Mínima = 0.8;
- Backtracking



1 Introdução

- Mineração de Dados
- Técnicas de Seleção de atributos
- Motivação
- Desenvolvimento do Problema

2 Seleção de atributos baseado em consistência

- Exemplo Base de dados
- Métrica de Consistência
- Cálculo das taxas de inconsistência.
- Exemplo de Cálculo de Consistência
- Algoritmo
- Heurísticas
- Espaço de Soluções 1
- Espaço de Soluções 2

3 Métodos Utilizados



Conclusão

- Importância das Técnicas de Seleção de atributos
- Experimentos realizados



Trabalhos Futuros

- Implementação de outros algoritmos.
- Estudo e implementação com outras Técnicas de Seleção de Atributos

