

Mineração de Dados em Biologia Molecular

Métodos baseados em distância

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



Principais tópicos

- Aprendizado baseado em instâncias
- Conceitos básicos
- KNN
- Raciocínio Baseado em Casos
- Conclusão

27/09/2012

André de Carvalho - ICMC/USP

2

Métodos baseados em distância

- Consideram proximidade entre dados
 - Considera que dados similares tendem a estar em uma mesma região no espaço de entrada
- Aprendizado preguiçoso
 - Só olha os dados de treinamento quando precisa classificar novo objeto
- Exemplos:
 - Algoritmo k-vizinhos mais próximos
 - Raciocínio Baseado em Casos


27/09/2012

André de Carvalho - ICMC/USP

3

Métodos baseados em distância

- Princípio básico
 - Se anda como um cachorro e late como um cachorro, então provavelmente é um ...



27/09/2012

André de Carvalho - ICMC/USP

4

Similaridade x Dissimilaridade

- Similaridade
 - Mede o quanto dois objetos são parecidos
 - Quanto mais parecidos, maior o valor
 - Geralmente valor $\in [0, 1]$
- Dissimilaridade
 - Mede o quanto dois objetos são diferentes
 - Quanto mais diferentes, maior o valor
 - Geralmente valor $\in [0, X]$
- Medida de proximidade pode ser usada nos dois casos

André de Carvalho - ICMC/USP

5

Medida de proximidade

- Várias
 - Euclidiana
 - Quadrática
 - Bloco-cidade

27/09/2012

André de Carvalho - ICMC/USP

6

Distância Euclidiana

- Pode medir dissimilaridade de objetos com mais de um atributo
 - Para atributos com escalas de valores diferentes, pode ser necessário normalizar

$$dist = \sqrt{\sum_{k=1}^m (p_k - q_k)^2}$$

André de Carvalho - ICMC/USP 7

Distância de Minkowski

- Generalização da distância Euclidiana

$$dist = \left(\sum_{k=1}^m |p_k - q_k|^r \right)^{\frac{1}{r}}$$

- Valor de r leva a diferentes distâncias
 - 1 (L₁): Distância bloco cidade (Manhattan)
 - Hamming (valores binários)
 - 2 (L₂): Distância Euclidiana
 - ∞ (L_∞): Distância suprema

André de Carvalho - ICMC/USP 8

Distância quadrada

- Simplificação da distância
 - Menor complexidade
 - Menor exatidão

$$dist = MAX(|p_k - q_k|)$$

André de Carvalho - ICMC/USP 9

Relação entre distâncias

Qualquer ponto que cair na fronteira, dará o mesmo valor de distância do centro

27/09/2012 André de Carvalho - ICMC/USP 10

Exercício

- Calcular a distância entre os exemplos abaixo usando as distâncias
 - Manhattan
 - Euclidiana
 - Quadrada

Ex1 = (3, 1, 10, 2)
Ex2 = (2, 5, 3, 2)

27/09/2012 André de Carvalho - ICMC/USP 11

Exercício

- Encontrar a distância entre os exemplos abaixo utilizando a distância Manhattan
 - 110000, 111001, 000111, 001011, 100111, 101001

27/09/2012 André de Carvalho - ICMC/USP 12

Medidas de distâncias

- Têm, em geral, têm as propriedades:
 - Seja $d(p, q)$ a distância (dissimilaridade) entre dois objetos p e q
 - $d(p, q) \geq 0 \forall p \text{ e } q \text{ e } d(p, q) = 0 \text{ se e só se } p = q$ (definida positiva)
 - $d(p, q) = d(q, p) \forall p \text{ e } q$ (simetria)
 - $d(p, r) \leq d(p, q) + d(q, r) \forall p, q \text{ e } r$ (desigualdade triangular)
- Medidas que satisfazem essas propriedades são denominadas métricas

André de Carvalho - ICMC/USP

13

Medidas de similaridade

- Também têm propriedades bem definidas:
 - Seja $s(p, q)$ a similaridade entre dois objetos p e q
 - $s(p, q) = 1$ (similaridade máxima) apenas se $p = q$
 - $s(p, q) = s(q, p) \forall p \text{ e } q$ (simetria)

André de Carvalho - ICMC/USP

14

Dissimilaridade entre valores

- Sejam a e b dois valores de um atributo
 - Nominal $d(a, b) = \begin{cases} 1, & \text{se } a \neq b \\ 0, & \text{se } a = b \end{cases}$
 - $s = 1 - d$
 - Ordinal $d(a, b) = \frac{|a - b|}{n - 1}$
 - $s = 1 - d$
 - Intervalar ou racional $d(a, b) = |a - b|$
 - $s = -d$ ou $s = 1/(1+d)$

27/09/2012

André de Carvalho - ICMC/USP

15

Exercício

- Qual a distância entre os exemplos da tabela abaixo
- Usar distâncias
 - Euclidiana
 - Bloco cidade
 - Máxima

Estado	Escolaridade	Altura	Salário	Classe
SP	Médio	180	3000	A
RJ	Superior	174	7000	B
RJ	Superior	100	2000	A

27/09/2012

André de Carvalho - ICMC/USP

16

Similaridade entre vetores binários

- Frequentemente, objetos p e q têm apenas valores binários
- Similaridades podem ser computadas usando:
 - M_{01} = número de atributos em que $p = 0$ e $q = 1$
 - M_{10} = número de atributos em que $p = 1$ e $q = 0$
 - M_{00} = número de atributos em que $p = 0$ e $q = 0$
 - M_{11} = número de atributos em que $p = 1$ e $q = 1$

André de Carvalho - ICMC/USP

17

Similaridade entre vetores binários

- Coeficiente de Casamento Simples

$$CCS = \frac{\text{num. de coinc.}}{\text{num. de atributos}} = \frac{(M_{11} + M_{00})}{(M_{01} + M_{10} + M_{11} + M_{00})}$$

- Coeficiente Jaccard

$$J = \frac{\text{num. coinc. 11}}{\text{num. Pelo menos um } \neq 0} = \frac{(M_{11})}{(M_{01} + M_{10} + M_{11})}$$

André de Carvalho - ICMC/USP

18

Exercício

- Calcular dissimilaridade entre p e q usando coeficientes:
 - Casamento Simples
 - Jaccard

$p = 100110101110$
 $q = 010011001011$

Similaridade cosseno

- Muito usado para dados de textos
 - Grande número de atributos
 - Esparsos
- Sejam p e q vetores representando documentos
 - $\cos(p, q) = (p \cdot q) / \|p\| \|q\|$
 - \cdot : vetor produto interno entre vetores
 - $\|p\|$: é o tamanho (norma) do vetor p


Classificação

- Medidas de distância podem ser usadas para classificação de novos dados
 - Classificadores mais simples
 - K-NN
 - Dissimilaridade entre valores
 - Desempenho depende da medida de distância utilizada

1-vizinho mais próximo

- Algoritmos *lazy* (preguiçoso)
 - Olha apenas os dados de treinamento quando precisa classificar novo objeto
 - Não constroem um modelo explicitamente
 - Diferente de classificadores *eager*, como SVMs e DTs
 - Baseados em informações locais
 - ADs, RNs e SVMs são baseados em informações globais


1-vizinho mais próximo



Quantos vizinhos?

- K muito grande
 - Vizinhos podem ser muito diferentes
 - Predição tendenciosa para classe majoritária
 - Custo computacional mais elevado
- K muito pequeno
 - Não usa informação suficiente
 - Previsão pode ser instável
 - Ruído

Quantos vizinhos?




27/09/2012

André de Carvalho - ICMC/USP

25

Quantos vizinhos?



27/09/2012

André de Carvalho - ICMC/USP

26

K-Vizinhos mais próximos

Seja k o número de vizinhos mais próximos a ser considerado
 Para cada novo exemplo x
 Definir a classe dos k exemplos mais próximos
 Classificar x na classe majoritária entre seus vizinhos

27/09/2012

André de Carvalho - ICMC/USP

27

K-vizinhos mais próximos

- Lento para classificar novos objetos
 - Seleção de atributos
 - Eliminação de objetos
 - Armazenar apenas protótipos das classes na memória
 - Algoritmos iterativos
 - Eliminação sequencial
 - Inserção sequencial

27/09/2012

André de Carvalho - ICMC/USP

28

K-vizinhos mais próximos

- Seleção de protótipos
 - Definir um protótipo por classe
 - Eliminação sequencial
 - Começa com todos os objetos
 - Descarta objetos corretamente classificados pelos protótipos
 - Inserção sequencial
 - Conjunto inicial vazio
 - Acrescenta objetos incorretamente classificados pelos protótipos

27/09/2012

André de Carvalho - ICMC/USP

29

K-vizinhos mais próximos

- Normalizar atributos
- Ponderar atributos
- Ponderar voto por distância entre exemplos
- Regressão
- Naturalmente incremental

27/09/2012

André de Carvalho - ICMC/USP

30

Exercício

- Seja o seguinte cadastro de pacientes:

Nome	Febre	Enjôo	Manchas	Dores	Diagnóstico
João	sim	sim	pequenas	sim	doente
Pedro	não	não	grandes	não	saudável
Maria	sim	sim	pequenas	não	saudável
José	sim	não	grandes	sim	doente
Ana	sim	não	pequenas	sim	saudável
Leila	não	não	grandes	sim	doente

27/09/2012 André de Carvalho - ICMC/USP 31

Exercício

- Usar K-NN e os exemplos anteriores para definir as classes dos exemplos de teste
 - Usar $k = 1, 3$ e 5
- Exemplos de teste
 - (Luis, não, não, pequenas, sim)
 - (Laura, sim, sim, grandes, sim)

27/09/2012 André de Carvalho - ICMC/USP 32

Exercício

- Data a tabela abaixo, com $k = 1$ e 3 , definir a classe dos exemplos:
 - (RJ, Médio, 178, 2000)
 - (SP, Superior, 200, 800)

Estado	Escolaridade	Altura	Salário	Classe
SP	Médio	180	3000	A
RJ	Superior	174	7000	B
RS	Médio	180	600	B
RJ	Superior	100	2000	A
SP	Fundam.	178	5000	A
RJ	Fundam.	188	1800	A

27/09/2012 André de Carvalho - ICMC/USP 33

Raciocínio baseado em casos

- Moda no passado: Sistemas Baseados em Regras
 - Dificuldade de especialistas em transformar experiência em regras

27/09/2012 André de Carvalho - ICMC/USP 34

Raciocínio baseado em casos

27/09/2012 André de Carvalho - ICMC/USP 35

Como funciona RBC?

- Resolve novos problemas adaptando soluções de problemas anteriores semelhantes

27/09/2012 André de Carvalho - ICMC/USP 36

Passos

- Apresentar situação atual
- Recuperar casos semelhantes da biblioteca
- Adaptar solução

Que pacote de viagem comprar? Casos semelhantes Adaptação

27/09/2012 André de Carvalho - ICMC/USP 37

O que é um caso?

- Existem dois tipos de casos
 - Casos de entrada:
 - Descrição de características de problemas específicos
 - Casos armazenados:
 - Casos anteriores
 - descrição, solução e resultados

27/09/2012 André de Carvalho - ICMC/USP 38

O que é um caso?

- Um caso armazenado geralmente tem:
 - Uma parte caso
 - Sintomas
 - Usada para identificar o caso
 - Indexação e recuperação
 - Uma parte solução
 - Explica como este caso foi resolvido anteriormente de forma bem (mal) sucedida
 - Adaptada quando o caso é recuperado

27/09/2012 André de Carvalho - ICMC/USP 39

Raciocínio baseado em casos

Novo Caso

Descrição do problema:
Ambiente: praia
Duração: 5 dias
Região: NE
Custo máximo: 2000

Solução do problema:
Local: ???
Transporte: ???
Acomodação: ???
Refeição: ???

Caso 1

Descrição do problema:
Ambiente: praia
Duração: 7 dias
Região: SE
Custo máximo: 1000

Solução do problema:
Local: Ubatuba
Transporte: Ônibus
Acomodação: Hotel Uau
Refeição: Bar do Zé

27/09/2012 André de Carvalho - ICMC/USP 40

Ciclo de um sistema de RBC

Problema → Novo Caso

Novo Caso → Recuperação → Caso recuperado

Novo Caso → Caso novo

Caso recuperado → Reutilização → Caso resolvido

Caso recuperado → Revisão → Caso testado/reparado

Caso resolvido → Retenção → Caso aprendido

Caso testado/reparado → Retenção → Caso aprendido

Caso aprendido → Conhecimento geral

Conhecimento geral → Casos prévios

Casos prévios → Recuperação → Caso recuperado

27/09/2012 André de Carvalho - ICMC/USP 41

Conclusão

- Aprendizado baseado em distância
- Conceitos básicos
- KNN
- Raciocínio Baseado em Casos
- Exemplos

27/09/2012 André de Carvalho - ICMC/USP 42

 Perguntas



27/09/2012 André de Carvalho - ICMC/USP 43