

Introdução à Mineração de Dados

Luciana M. Abud

Instituto de Matemática e Estatística
Universidade de São Paulo

Introdução

- ▶ Exploração e análise de grande quantidade de dados
- ▶ Padrões e regras significativos



Data mining

Dados

- ▶ Em geral:
 - ▶ Grande volume
 - ▶ Dados estruturados
 - ▶ Pré processamento



Tarefas

- ▶ Classificação: categorizar dados não classificados
- ▶ Regressão: definir valor para variável contínua desconhecida
- ▶ Associação: determinar coocorrências
- ▶ Segmentação (*Clustering*): partição dos dados em subgrupos mais homogêneos
- ▶ Sumarização: encontrar descrição compacta para um subconjunto de dados

Aplicações

- ▶ Detecção de fraude (cartão de crédito, telecomunicação, sistemas de computadores, etc.)
- ▶ Diagnóstico médico
- ▶ Análise de sentimento em textos
- ▶ Segmentação de clientes

Mineração de Opinião

Introdução

- ▶ Redes sociais, fóruns, *tweets*, sites para avaliação de produtos e serviços, sites de notícias, etc.
- ▶ Fonte de opinião para organizações e empresas

Etapas

- ▶ Pré processamento
- ▶ Identificação
- ▶ Classificação da polaridade
- ▶ Sumarização

Pré processamento

- ▶ Representação do texto

T1: “@VirginAmerica everything was fine until you lost my bag”

T2: “@united Either is fine. However, plundering my hard-earned dollars is not fine.”

- ▶ Vetor binário

	bag	dollars	either	everything	fine	hard-earned	however	is	lost	my	not	plundering	until	was	you
T1	1	0	0	1	1	0	0	1	1	1	0	0	1	1	1
T2	0	1	1	0	1	1	1	1	0	1	1	1	0	0	0

- ▶ Vetor de contagem de termos

	bag	dollars	either	everything	fine	hard-earned	however	is	lost	my	not	plundering	until	was	you
T1	1	0	0	1	?	0	0	1	1	?	0	0	1	1	1
T2	0	1	1	0	?	1	1	?	0	1	1	1	0	0	0

Pré processamento

- ▶ *Stop words*
- ▶ Lematização
 - ▶ am, are, is → be
 - ▶ better → good
- ▶ Stemização
 - ▶ follow, followed, follows → follow
 - ▶ university, universe, universal → univers

Identificação

- ▶ Alvo da opinião (produto, empresa, pessoa, etc.)
- ▶ Aspectos do alvo (preço, qualidade do serviço, roupa, etc.)

Classificação da polaridade

- ▶ Classificação entre positivo e negativo (ou também neutro)
- ▶ Limitações com ironias, sarcasmos, subjetividades, entre outros

Sumarização

- ▶ Criação de métricas para representar a diversidade de opiniões encontradas
- ▶ Representação em tabelas e gráficos

Classificação

- ▶ Aprendizagem de máquina
 - ▶ conjuntos de treino e de teste
- ▶ Análise sintática: dicionário de sentimentos
 - ▶ *good, excellent* → positivo
 - ▶ *bad, terrible* → negativo
- ▶ Análise estatística: avaliação de coocorrência de termos
 - ▶ ocorrência frequente junto a palavras positivas → provavelmente positivo
 - ▶ ocorrência frequente junto a palavras negativas → provavelmente negativo

Ferramentas

- ▶ Pandas: Python Data Analysis Library.
<http://pandas.pydata.org/>
- ▶ Scikit-Learn: Machine Learning in Python
<http://scikit-learn.org/>
- ▶ WEKA: Machine learning software to solve data mining problems.
<https://sourceforge.net/projects/weka/>
- ▶ R: The R Project for Statistical Computing
<https://www.r-project.org/>
<http://www.rdatamining.com/home>

Referências

- ▶ CAMILO, Cássio Oliveira; SILVA, João Carlos da. Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas. Goiânia: Universidade Federal de Goiás, 2009.
- ▶ Michael J. Berry and Gordon Linoff. 1997. Data Mining Techniques: For Marketing, Sales, and Customer Support. John Wiley & Sons, Inc., New York, NY, USA.
- ▶ S. Sumathi and S. N. Sivanandam. 2006. Introduction to Data Mining and its Applications (Studies in Computational Intelligence). Springer-Verlag New York, Inc., Secaucus, NJ, USA.
- ▶ Introdução à Mineração de Opiniões: Conceitos, Aplicações e Desafios. K Becker, D Tumitan. Simpósio Brasileiro de Banco de Dados, 27-52, 2013. 12, 2013.
- ▶ Christopher D. Manning, Prabhakar Raghavan, and Hinrich Schütze. 2008. Introduction to Information Retrieval. Cambridge University Press, New York, NY, USA.