



**João Ribeiro Carrilho Junior**

**Desenvolvimento de uma Metodologia  
para Mineração de Textos**

**Dissertação de Mestrado**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica da PUC-Rio.

Orientador: Prof. Emmanuel Piseces Lopes Passos

Rio de Janeiro  
Dezembro de 2007



**João Ribeiro Carrilho Junior**

**Desenvolvimento de uma Metodologia  
para Mineração de Textos**

Dissertação apresentada como requisito parcial para obtenção do grau Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

**Dr. Emmanuel Piseces Lopes Passos**  
**Orientador**

Departamento de Engenharia Elétrica

**Dra. Marley Maria Bernardes Rebuzzi Vellasco**  
Departamento de Engenharia Elétrica - PUC-RIO

**Dr. Antonio Luz Furtado**  
Departamento de Informática - PUC-RIO

**Dr. Christian Nunes Aranha**  
Cortex Intelligence

**Dr. Ricardo Tanscheit**  
Departamento de Engenharia Elétrica - PUC-RIO

**Prof. José Eugenio Leal**  
Coordenador Setorial do Centro  
Técnico Científico – PUC-Rio

Rio de Janeiro, 18 de dezembro de 2007

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

## João Ribeiro Carrilho Junior

Graduou-se Bacharel em Informática pela PUC-Rio em 2004. Atua como analista de sistemas na Petrobras, principalmente no desenvolvimento de sistemas de apoio à decisão. Tem interesse na pesquisa de novos algoritmos, principalmente na área de Mineração de Textos.

### Ficha Catalográfica

Carrilho Junior, João Ribeiro

Desenvolvimento de uma metodologia para mineração de textos / João Ribeiro Carrilho Junior ; orientador: Emmanuel Piseces Lopes Passos. – 2007.

96 f. ; 30 cm

Dissertação (Mestrado em Engenharia Elétrica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2007.

Inclui bibliografia

1. Engenharia elétrica – Teses. 2. Mineração de textos. 3. Dados não-estruturados. 4. Processamento de linguagem natural. 5. Aprendizado de máquina. 6. Recuperação de informação. I. Passos, Emmanuel Piseces Lopes. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

CDD: 621.3

## Agradecimentos

A Deus, por conceder-me mais esta benção em minha vida.

Aos meus pais, João e Tereza, e minha irmã, Fabiana, que tanto me apoiaram e me incentivaram.

À minha namorada, Beatriz, por ter acreditado em mim e estado ao meu lado em todos os momentos, sendo estes difíceis ou não.

Aos meus avós, Afonso e Sebastiana, que sempre me amaram e estiveram prontos a me ajudar.

Ao professor Emmanuel pelos seus valiosos ensinamentos e pela confiança depositada em meu trabalho.

Aos amigos Roberto e Fábio, que foram companheiros de estudos e que sempre estiveram prontos a colaborar.

Ao CNPq pelo apoio financeiro durante o primeiro ano do mestrado.

## Resumo

Carrilho Junior, João Ribeiro; Passos, Emmanuel Piseces Lopes (Orientador). **Desenvolvimento de uma Metodologia para Mineração de Textos**. Rio de Janeiro, 2007. 96p. Dissertação de Mestrado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

A seguinte dissertação tem como objetivo explorar a Mineração de Textos através de um estudo amplo e completo do que atualmente é considerado “estado da arte”. Esta nova área, considerada por muitos como uma evolução natural da Mineração de Dados, é bastante interdisciplinar e vem obtendo importantes colaborações de estudiosos e pesquisadores de diversas naturezas, como Linguística, Computação, Estatística e Inteligência Artificial. Entretanto, muito se discute sobre como deve ser um processo completo de investigação textual, de forma a tirar máximo proveito das técnicas adotadas nas mais variadas abordagens. Desta forma, através de um encadeamento sistemático de procedimentos, pode-se chegar a uma conclusão do que seria a metodologia ideal para a Mineração de Textos, conforme já se chegou para a de Dados. O presente trabalho explora um modelo de processo, do início ao fim, que sugere as seguintes etapas: coleta de dados, pré-processamento textual, indexação, mineração e análise. Este sequenciamento é uma tendência encontrada em trabalhos recentes, sendo minuciosamente discutido nos capítulos desta dissertação. Finalmente, a fim de se obter enriquecimento prático, foi desenvolvido um sistema de Mineração de Textos que possibilitou a apresentação de resultados reais, obtidos a partir da aplicação de algoritmos em documentos de natureza geral.

## Palavras-chave

Mineração de Textos; Dados Não-Estruturados; Processamento de Linguagem Natural; Aprendizado de Máquina; Recuperação de Informação.

## Abstract

Carrilho Junior, João Ribeiro; Passos, Emmanuel Piseces Lopes (Advisor). **Development of a Methodology for text Mining**. Rio de Janeiro, 2007. 96p. MSc Dissertation - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

The following essay is intended to explore the area of Text Mining, through an extensive and comprehensive study of what is currently considered "state of the art". This new area, considered by many as a natural evolution of the Data Mining, is quite interdisciplinary. Several scholars and researchers from fields like linguistics and computing, for instance, have contributed for its development. Nevertheless, much has been discussed on how complete dossier of textual investigation must be carried out, in order to take maximum advantage of the techniques adopted in various approaches. Thus, through a systematic sequence of procedures, one can come to a conclusion of what would be the ideal method for the Mining of documents, as one has come about Data. This work explores a model of process which suggests the following steps: collecting data, textual pre-processing, indexing, mining and analysis. This sequence is a tendency followed in some recent works and it is thoroughly discussed in the chapters to come. Finally, in order to obtain a practical enrichment, one developed a system of Mining of documents with which became possible the presentation of results, obtained from the application of algorithms in documents of a general nature.

## Keywords

Text Mining; Unstructured Data; Natural Language Processing; Machine Learning; Information Retrieval.

# Sumário

1	Introdução	12
1.1.	Objetivos da Dissertação	13
1.2.	Organização da Dissertação	13
2	Mineração de Textos: Fundamentos e Aplicações	14
2.1.	Áreas de Conhecimento em Mineração de Textos	15
2.1.1.	Processamento de Linguagem Natural	15
2.1.2.	Ciência Cognitiva	16
2.1.3.	Recuperação de Informação	16
2.1.4.	Estatística	18
2.1.5.	Aprendizado de Máquina	18
2.1.6.	Inteligência Computacional	19
2.1.7.	Mineração de Dados	19
2.1.8.	<i>Web Mining</i>	20
2.2.	Aplicações	21
2.2.1.	Negócios	21
2.2.2.	Direito	24
2.2.3.	Medicina	24
3	Etapas da Metodologia de Mineração de Textos	26
3.1.	Coleta	27
3.2.	Pré-processamento	30
3.2.1.	<i>Tokenization</i> (Atomização)	31
3.2.2.	Correção Ortográfica	34
3.2.3.	Redução do Léxico	35
3.2.4.	Identificação do Início e Fim de Sentenças	42
3.2.5.	Etiquetagem POS	45
3.2.6.	Identificação de Entidades Nomeadas	45
3.2.7.	<i>Parsing</i> (Análise Sintática)	46
3.3.	Indexação	48
3.3.1.	Representação de Documentos	48
3.3.2.	Medidas de Similaridade entre Documentos	49
3.3.3.	Listas Invertidas	51
3.3.4.	Processamento de Consultas	52
3.3.5.	Avaliação das Consultas	54
3.4.	Mineração	56
3.5.	Análise da Informação	56
4	Tarefas de Mineração de Textos	58
4.1.	Categorização de Textos	58
4.1.1.	Treinamento e Teste	60
4.1.2.	Avaliação de Performance	62
4.1.3.	<i>Naive Bayes</i>	64
4.2.	<i>Clusterização</i>	67

4.3. Sumarização	69
4.4. Extração de Informação	71
4.5. Sistemas de Busca de Informação	73
5 Implementação e Estudo de Caso	74
5.1. Arquitetura Geral do Sistema	74
5.1.1. Módulo de Coleta	75
5.1.2. Módulo de Pré-processamento	79
5.1.3. Módulo de Indexação	81
5.1.4. Módulo de Mineração	82
5.1.5. Módulo de Análise de Resultados	84
5.2. Estudo de Caso: Identificação de Subjetividade em Pesquisas de Opinião	87
6 Conclusão	91
Referências bibliográficas	92

## Lista de Figuras

Figura 1 – Componentes de um sistema de Recuperação de Informação .....	17
Figura 2 – Abordagens de <i>Web Mining</i> .....	21
Figura 3 - Diagrama que ilustra a metodologia de Mineração de Textos com o “encadeamento” de técnicas proposta por Aranha. ....	26
Figura 4 – “Linha de montagem” de um procedimento de <i>Tokenization</i> . ....	32
Figura 5 – Exemplo de um algoritmo de detecção de início e fim de sentenças... ..	44
Figura 6 - Árvore de Derivação simples para a frase "José comeu o bolo". ....	47
Figura 7 – Exemplificação do modelo “saco de palavras”.....	49
Figura 8 – Documentos “apontando” para seus <i>tokens</i> . ....	51
Figura 9 – Estrutura de Lista Invertida com os <i>tokens</i> “apontando” para os documentos.....	52
Figura 10 - Classificação ternária de documentos.....	59
Figura 11 – Utilização da estratégia <i>holdout</i> para treinamento e validação de classificadores.....	61
Figura 12 –Validação Cruzada com <i>3-folds</i> . ....	62
Figura 13 – Esquema básico da Tarefa de <i>Clusterização</i> . ....	67
Figura 14 – Agrupamento de não-hierárquico aglomerativo de documentos. ....	68
Figura 15 – Extração de Características de um documento.....	71
Figura 16 – Diagrama Hierárquico de Funções do sistema implementado.....	74
Figura 17 – Modelo MVC utilizado no desenvolvimento do sistema. As setas sólidas indicam associações diretas e as tracejadas indicam associações indiretas. ....	75
Figura 18 – Diagrama de classes parcial do sistema com as classes <i>Corpus</i> e <i>Documento</i> . ....	76
Figura 19 – Ciclo contínuo de execução da coleta na Internet através de <i>web crawlers</i> . ....	78

Figura 20 - Diagrama de classes contendo as novas classes introduzidas pela etapa de <i>tokenization</i> do módulo de pré-processamento.....	79
Figura 21 – Parte do diagrama de classes do sistema com a adição das partes envolvidas na indexação.....	81
Figura 22 – Diagrama de classes parcial do sistema com a inclusão das classes que compõem o módulo de mineração.....	83
Figura 23 – Gráfico de barras que mostra a relação entre faixas de frequência e o número total de <i>tokens</i> presentes.....	86

## Lista de Tabelas

Tabela 1 – As duas abordagens para a Análise de Textos e suas principais Áreas de Conhecimento .....	15
Tabela 2 – Principais focos no monitoramento de páginas na <i>web</i> .....	22
Tabela 3 – Resumo das principais coleções de texto usadas pela comunidade científica .....	29
Tabela 4 - Representação atributo-valor obtida à partir da etapa de Pré-processamento .....	30
Tabela 5- Exemplificação do resultado da execução de um subsistema de <i>Tokenization</i> que baseia-se em dicionários pré-estabelecidos e regras de formação. ....	33
Tabela 6 – Identificação e Remoção de <i>Stopwords</i> (os <i>tokens</i> descartados estão tachados).....	39
Tabela 7 – <i>Stoplist</i> obtida automaticamente a partir de um sistema de Mineração de Texto pronto.....	39
Tabela 8 – Matriz de Confusão.....	85
Tabela 9 – Relatório de frequência dos tokens nos corpus envolvidos no treinamento do classificador.....	86
Tabela 10 – Lista de stopwords padrão do Google. ....	88
Tabela 11 – Resultados dos experimentos realizados com o classificador Naive Bayes no problema de subjetividade versus objetividade. ....	89
Tabela 12 – Resultados dos experimentos realizados com o classificador SVM no problema de subjetividade versus objetividade.....	89
Tabela 13 – Categorização obtida para novos exemplos utilizado o classificador <i>Naive Bayes</i> . ....	90