



Recuperação de Padrões em Arquivos Postscript para um Sistema de Bibliotecas Digitais

Aluna: Lidiane Vogel Sander


Orientadora: Mariza Andrade S. Bigonha

O Problema

- Aumento do volume de informações disponíveis → organização dessas informações.
- Tentativas existentes: bibliotecas digitais e servidores de publicações.

A Proposta

- Estudo da viabilidade de construção de um sistema web para atuar como uma biblioteca digital.
- Necessidade do laboratório SIAM – compartilhar informações comuns de maneira mais simples, organizada e eficiente.
- Possibilidade de ampliação para atender outras necessidades, em meios acadêmicos ou não, observadas as restrições da proposta.



Desenvolvimento

1. Comparação com sistemas já existentes:
 - 1.1 Koala Document Fingerprinting - Carnegie Mellon University – Sistema para identificar documentos relacionados textualmente.
 - Proposta: documento é passado ao servidor, convertido para .txt e comparado (fingerprinting) aos documentos do banco existente.
 - Ponto comum: submissão e conversão de documentos.

... Desenvolvimento

1.2 Co-Citer – Programa desenvolvido pela Cogitum para capturar textos e citações da Internet.

- Ponto comum: organização da informação – inserção de algumas informações pelo usuário e captação automática de outras.
- Diferenças: armazena informações pré-selecionadas pelo usuário; não envolve documentos como um todo (upload, download).

... Desenvolvimento

1.3 DBLP Computer Science Bibliography – University of Trier, Alemanha.

- Informações bibliográficas sobre grande parte dos periódicos e publicações em Ciência da Computação.
- 400000 artigos e milhares de links para home pages de cientistas da computação.
- Pesquisa por autor, título, assunto ou navegação manual.

... Desenvolvimento

- Diferenças:
 - Servidor de bibliografias, não é serviço de disponibilização de artigos.
 - Submissão de arquivos: via email, para o responsável pela manutenção do serviço.

... Desenvolvimento

- 1.4 BDBComp – Biblioteca Digital Brasileira de Computação
- Acesso à produção científica nacional na área de computação.
- Organização e aquisição de trabalhos científicos
- Três formas de incluir itens na biblioteca:
 - Relação de artigos publicados em eventos nacionais;
 - Cadastramento direto via formulário;
 - Integração com outras bibliotecas digitais ou repositórios.

... Desenvolvimento

- Diferenças:
 - Pesquisa por autor, título, ano, evento.
 - Voltada para produção nacional.
 - Várias formas de inclusão de documentos.
 - Disponibilização no site não-automática.

... Desenvolvimento

2. Estudo da Linguagem PostScript

2.1 Gramática (definição BNF) PostScript para o desenvolvimento de um compilador → reconhecimento de padrões nos documentos.

- Dificuldade: encontrar definição disponível.

... Desenvolvimento

2.2 Testes com o código da linguagem:
desenvolvimento de arquivos .ps “puros” e
comparação com arquivos .ps
“gerados” (ferramentas como o LaTeX) →
complexidade/volume do código.

... Desenvolvimento

- Trecho de um arquivo .ps “gerado”

```
%%Page: 1 1
```

```
1 0 bop -40 -384 a Fi(Eighth)18
```

```
b(International)j(Conference)f(on)d
```

```
(Information)i(and)e(Kno)n(wledge)i(Mana
```

```
gement,)g(CIKM)e(99,)g(Kansas)g
```

```
(City)l(,)h(Missouri,)f(No)o(v)o(ember)h
```

... Desenvolvimento

- Trecho de um arquivo .ps “puro”

```
/Times-Roman findfont % Get the basic font
20 scalefont % Scale the font to 20 points
setfont % Make it the current font
newpath % Start a new path
72 72 moveto % Lower left corner of text at
(72, 72)
(Hello,world!) show % Typeset "Hello, world!"
```

... Desenvolvimento

2.3 Conversão de arquivos .ps para .txt → difícil, susceptível a erros, cara.

- PStoText: aplicativo para extrair textos de arquivos PostScript e PDF.
 - Acoplado ao Ghostscript
 - Heurística para reconhecimento de palavras: strings separados por uma distância inferior à uma média específica pertencem à mesma palavra.
 - Trabalha com codificações segundo convenções da Adobe.

... Desenvolvimento

2.4 Construção do site:


- Definição das linguagens a serem usadas: php e mySQL (Banco de dados).
- Construção dos mecanismos de inserção de arquivos.
- Download de arquivos.

... Desenvolvimento

- Utilização da ferramenta de busca FreeFind:
 - Ferramenta livre
 - Indexação (spidering) externa – percorre links e forma índice (base de dados)
 - htDig “versus” FreeFind
 - Problemas: tempo, anúncios, idioma.

Limitações da Versão

- Não utilização do Banco de Dados – informação redundante.
- Inclusão de arquivos PostScript apenas.
- Mecanismo de indexação e busca.
- Download de arquivos.



Trabalhos Futuros

- Mecanismo de busca específico
- Armazenamento em banco de dados
- Ampliação para inclusão de outros tipos de documentos.



Referências Bibliográficas

- Adobe Systems Inc. *PostScript Language Reference Manual*, Addison Wesley, 1995, 5th printing.
- Adobe Systems Inc. *PostScript Language Tutorial and Cookbook*, Addison Wesley, 1987.
- McGilton, Henry ; Mary Campione. *Postscript by Example*. Reading, MA : Addison-Wesley, c1992.
- <http://www-2.cs.cmu.edu/afs/cs/user/nch/www/koala-info.html>
- <http://www.cogitum.com/co-tracker-text/more.shtml>
- www.informatik.uni-trier.de/~ley/db
- www.cs.indiana.edu/docproject/programming/postscript/postscript.htm
- <http://research.compaq.com/SRC/virtualpaper/pstotext.html>