Universidade de São Paulo - USP
Universidade Federal de São Carlos - UFSCar
Universidade Estadual Paulista - UNESP

Avaliação de ambientes de suporte à montagem automática de córpus a partir de textos da Web e extração automática de termos

Luiz Carlos Genovês Jr.

Sandra Maria Aluisio

NILC-TR-05-15

Outubro 2005

Série de Relatórios do Núcleo Interinstitucional de Lingüística Computacional
NILC - ICMC-USP, Caixa Postal 668, 13560-970 São Carlos, SP, Brasil

Conteúdo

Índice de Figuras

Índice de Tabelas

Resumo

A utilização de córpus está se generalizando progressivamente nas áreas da Lingüística, do Processamento de Língua Natural (PLN), Tradução e Terminologia, para citar algumas. Embora já exista um número razoável de córpus genéricos (ou de referência, como são chamados) para várias línguas, o número de córpus específicos disponíveis para suporte à pesquisa terminológica, atividades de tradução e avaliação de recursos de PLN ainda é deficiente. Enquanto é possível construir tais córpus por meio de busca manual na Web esse processo consome muito tempo se levarmos em conta os benefícios para pesquisas únicas. Para atender essa necessidade específica de criação e de pesquisa nesses tipos de córpus existem vários projetos que se propõem a disponibilizar ambientes para criação rápida de córpus e posterior pesquisa com eles. Um desses projetos é o Corpógrafo e outro o BootCaT. Os objetivos desta pesquisa foram o estudo e a avaliação dos dois ambientes acima mencionados para gerenciamento de córpus especializados, para serem utilizados, sejam suas próprias ferramentas ou a funcionalidade delas, no projeto *Portal da Rede de Nanotecnologia da USP* e no projeto *Extração automática de termos e elaboração colaborativa de terminologias para o intercâmbio de conhecimento especializado,* ambos sendo desenvolvidos no Núcleo Interinstitucional de Lingüística Computacional.

1. Introdução

1.1. Contextualização, Motivação e Domínio de Aplicação

A utilização de córpus[1] está se generalizando progressivamente nas áreas da Lingüística, do Processamento de Língua Natural (PLN), Tradução e Terminologia, para citar algumas. Segundo Garside, Leech & MacEnery [1], o termo córpus designa um conjunto de dados lingüísticos autênticos que pode consistir de textos escritos, fala transcrita ou ambos. Nos últimos 35 anos, o conceito de córpus tem sido usado como sinônimo de "córpus computadorizado", isto é, os dados estão em formato eletrônico, podendo ser processados por computador e servir a vários propósitos tais como a pesquisa lingüística ou o processamento de língua natural. É possível enriquecer um córpus com o uso de anotação lingüística em vários níveis: morfossintático, sintático, semântico e retórico, por exemplo. Essas anotações agregam valor ao córpus e permitem que várias outras pesquisas sejam feitas nesses dados. Por exemplo, em um córpus com anotação morfossintática pode-se procurar por padrões de termos, como "substantivo–adjetivo" e "substantivo–preposição–substantivo".

Nos últimos anos, tem havido um grande esforço na criação de grandes córpus, constituídos por vários milhões de palavras, para fins genéricos de pesquisa, e na sua posterior disponibilização, tanto em formato CD-ROM como por meio de ambientes de acesso via Web. Por exemplo, temos o BNC[2] e o ANC[3] para a língua inglesa nas variantes britânica e americana, respectivamente, e o CETEMPúblico[4] e o Lácio-Web[5], para a língua portuguesa nas variantes européia e brasileira, respectivamente. Esse último foi desenvolvido num consórcio entre o NILC[6]/ICMC-USP, FFLCH-USP, IME-USP e disponibilizado em julho de 2004.

[1] Neste trabalho, utilizamos o aportuguesamento da palavra *corpus* (plural *corpora*) tendo a mesma ortografia para o plural e singular.
[2] http://www.natcorp.ox.ac.uk/
[3] http://americannationalcorpus.org/
[4] http://www.linguateca.pt/
[5] http://www.nilc.icmc.usp.br/lacioweb/
[6] http://www.nilc.icmc.usp.br/nilc/index.html

Embora já exista um número razoável de córpus genéricos (ou de referência, como são chamados) para várias línguas, o número de córpus específicos disponíveis para suporte à pesquisa terminológica, atividades de tradução e avaliação de recursos de PLN ainda é deficiente. Essa deficiência dá-se pela própria especificidade de tais córpus que são muitas vezes construídos para serem utilizados por um período curto de tempo e por isso se questiona o investimento de grandes esforços na sua compilação e anotação, seja essa de cabeçalho (informações bibliográficas e outras sobre os textos) e lingüística. Além disso, pode acontecer de tais córpus específicos serem utilizados somente em um projeto o que representa uma perda dos recursos dispensados em sua compilação.

Enquanto é possível construir tais córpus pela busca manual na Web, esse processo consome muito tempo se levarmos em conta os benefícios para pesquisas únicas. Para atender essa necessidade específica de criação e de pesquisa nesses tipos de córpus, existem vários projetos que se propõem a disponibilizar ambientes para criação rápida de córpus e posterior pesquisa, tratamento e disponibilização dos resultados do trabalho, por exemplo uma lista de candidatos a termos em pesquisas terminológicas. Um desses projetos é o Corpógrafo [2,3] e outro o BootCaT [4].

O Corpógrafo é um ambiente Web integrado que dá suporte a várias tarefas: montagem da coleção de textos da Web (que podem estar em vários formatos: PDF, HTML, Word, PS), limpeza dos textos, busca utilizando expressão regular, concordância, extração de colocações e contagem de n-gramas[7], extração de candidatos a termos e relações semânticas, compilação de produtos terminológicos, como glossários e tesauros, e exportação desses para outros formatos e aplicações. Já o BootCaT é um conjunto de ferramentas perl implementando um procedimento iterativo para a construção de córpus especializados e candidatos a termos da Web e requer somente uma lista pequena de candidatos (termos típicos do domínio) como entrada. Atualmente, permite somente a inclusão de textos no formato em HTML, mas essa restrição pode ser contornada com a inclusão de rotinas para tratamento dos formatos mais comuns de textos da Web.

Além desses dois ambientes, existe um projeto aprovado pela FAPESP em novembro de 2003 para a construção de um outro ambiente. O projeto é intitulado *Extração automática de termos e elaboração colaborativa de terminologias para o intercâmbio de conhecimento*

[7] termos com *n* de gramas. Exemplo: para n = 2, bigramas; para n =1, unigramas.

especializado (processo nº. 2003/06569-3), e está sendo desenvolvido com a coordenação da Profa. Dra. Gladis Maria de Barcellos Almeida do Departamento de Letras (DL) da Universidade Federal de São Carlos (UFSCar) e Profa Sandra Maria Aluísio do ICMC-USP (ambas são coordenadoras do NILC - Núcleo Interinstitucional de Lingüística Computacional). Ele visa propor soluções para a pesquisa terminológica por meio de ferramentas computacionais baseadas na Web e compartilha da mesma motivação dos ambientes acima, mas possui particularidades quanto aos algoritmos de extração, visualização e edição de produtos terminológicos e formato de exportação dos resultados. Para a criação desse ambiente de apoio à criação de produtos terminológicos a partir de córpus, existe um projeto de doutorado no ICMC orientado pela mesma orientadora deste projeto de graduação. Entretanto, o projeto original não previa a criação do córpus de pesquisa a partir de textos da Web suportada por ferramentas nos mesmos moldes das do BootCaT. No projeto Fapesp original e também no de doutorado que o encampou partia-se de um córpus já construído.

Existe também outro projeto sendo desenvolvido no ICMC, especificamente no NILC, relacionado com o *Portal da Rede de Nanotecnologia da USP*[8]. Esse projeto prevê um estudo sobre terminologia para estabelecer uma estrutura conceitual (ontologia[9]) para a nanotecnologia, que possa não apenas fornecer subsídios para produzir um Portal abrangente e de alta qualidade, mas também guiar a busca de oportunidades de mercado e oferta de tecnologias. Para a construção da ontologia, o projeto previa o uso de métodos automáticos de extração de termos a partir de córpus específicos de uma área do conhecimento. Esse cenário permitiu avaliação de vários métodos de extração a partir de um grande córpus criado com textos da área de nanociência e nanotecnologia.

O domínio de aplicação deste projeto de graduação se insere nas áreas de pesquisa em Lingüística de Córpus e Terminologia e prevê a utilização de ferramentas para construção de córpus a partir de textos da Web e de métodos automáticos de extração de termos (tanto os termos aqueles formados por palavras únicas como por multi-palavras). Ele colabora com os dois projetos citados acima da seguinte forma: para o projeto FAPESP, ele prevê a criação de um módulo extra que auxilia na criação de textos a partir da Web, e para o Portal da Rede de

[8] http://www.usp.br/prp/nanotecnologia/
[9] Neste trabalho, ontologia é entendida como uma estrutura hierárquica com as relações de inclusão de classes (*é um tipo de*) e instanciação que permite a inclusão dos termos do domínio.

Nanotecnologia, prevê a avaliação de um método de extração automática de termos que é disponibilizado no toolkit BootCaT com outros dois métodos sendo utilizados no projeto.

1.2. Objetivos do Trabalho

Os objetivos desta pesquisa foram: o estudo e avaliação dos dois ambientes acima mencionados para gerenciamento de córpus especializados (BootCaT e Corpógrafo) para serem utilizados, sejam suas próprias ferramentas ou a funcionalidade delas, no projeto *Portal da Rede de Nanotecnologia da USP* e no projeto *Extração automática de termos e elaboração colaborativa de terminologias para o intercâmbio de conhecimento especializado.* Especificamente, o projeto de graduação avaliou o método de extração automática de termos do BootCaT com um córpus criado no âmbito do projeto e o comparou com outros dois métodos utilizados por outros membros, usando as medidas de precisão e revocação contra uma ontologia (parcial) composta de termos advindos do córpus. Também, projetou o módulo de criação de textos a partir da Web, com ferramentas do BootCaT, o qual foi implementado por outro membro do projeto.

1.3. Organização da Monografia

O restante da monografia está organizado como segue. No Capítulo 2 são apresentadas as funcionalidades do Corpógrafo e do toolkit BootCat, além de uma descrição breve da API (Interface para Programação de Aplicativos) do Google, pois embasaram o trabalho no projeto *Extração automática de termos e elaboração colaborativa de terminologias para o intercâmbio de conhecimento especializado.* Também apresentamos a metodologia utilizada para construção da ontologia para a área de nanotecnologia e a metodologia utilizada na comparação entre os métodos de extração de termos, juntamente com uma breve descrição destes métodos. Finalmente, explicamos porque este cenário motivou o presente projeto. No Capítulo 3, o projeto é descrito mais detalhadamente, bem como a equipe dos projetos maiores que colaboraram e são apoiadas por este trabalho. Todas as atividades feitas estão reportadas neste capítulo, assim como os resultados aferidos e as dificuldades encontradas no

trajeto. No quarto e último capítulo, descrevemos as conclusões deste trabalho, explicitando suas limitações e os trabalhos futuros.

2. Revisão Bibliográfica

2.1. Síntese das Tecnologias Envolvidas

2.1.1. O Ambiente Corpógrafo

Desenvolvido pela Faculdade de Letras da Universidade do Porto (FLUP), o Corpógrafo[10] é um gestor de córpus que se encontra, atualmente, direcionado para pesquisas terminológicas, isto é, a extração de termos e organização deles em bases de dados. Fornece um ambiente Web integrado para o manejo de córpus, disponibilizando ferramentas para processamento de córpus. Dentre as ferramentas que possui, estão concordanceadores, contadores de freqüência, e também ferramentas de pré-processamento de córpus, como as de limpeza de córpus e sentenciadores. Toda funcionalidade do Corpógrafo está associada a um dos quatro ambientes de trabalho ou módulos: gestor de ficheiros, pesquisa de corpora, centro de conhecimento, centro de documentação, diminuindo a sobrecarga ao trabalhar no ambiente (Figura 1).

Dos quatro módulos contidos no Corpógrafo, o que mais interessou no estudo feito neste projeto foi o "Gestor de ficheiros" (Figura 2), que trata especificamente da montagem de córpus. Para construir um córpus no Corpógrafo, primeiramente é necessário selecionar os textos que comporão o córpus, que podem ser fornecidos de duas maneiras: ou enviando o próprio arquivo (*upload*) ou informando a URL onde o arquivo pode ser encontrado. O Corpógrafo aceita textos do tipo PDF, HTML, DOC, PS e RTF, além do TXT, formato para o qual todos os outros tipos de texto são transformados. O Corpógrafo oferece ferramentas para o pré-processamento desses textos, tais como sentenciadores (denominados "fraseadores" em português de Portugal) e um ambiente de edição que permite fazer a "limpeza" de textos (retirar lixo provindo da conversão de

[10] http://www.linguateca.pt/Corpografo/

tipos de texto, remoção de cabeçalhos, tabelas, referências ou agradecimentos). Após pré-processar os textos, pode-se selecionar aqueles que farão parte do córpus.

Tendo um córpus montado seguindo os passos anteriores, o Corpógrafo oferece ferramentas de busca e extração de conhecimento de córpus, como um concordanciador com suporte para pesquisas utilizando expressões regulares, gerador de n-grama (sendo 5 o tamanho máximo possível para o n-grama), extratores de terminologia, relações semânticas e mapas conceituais, dentre outras.

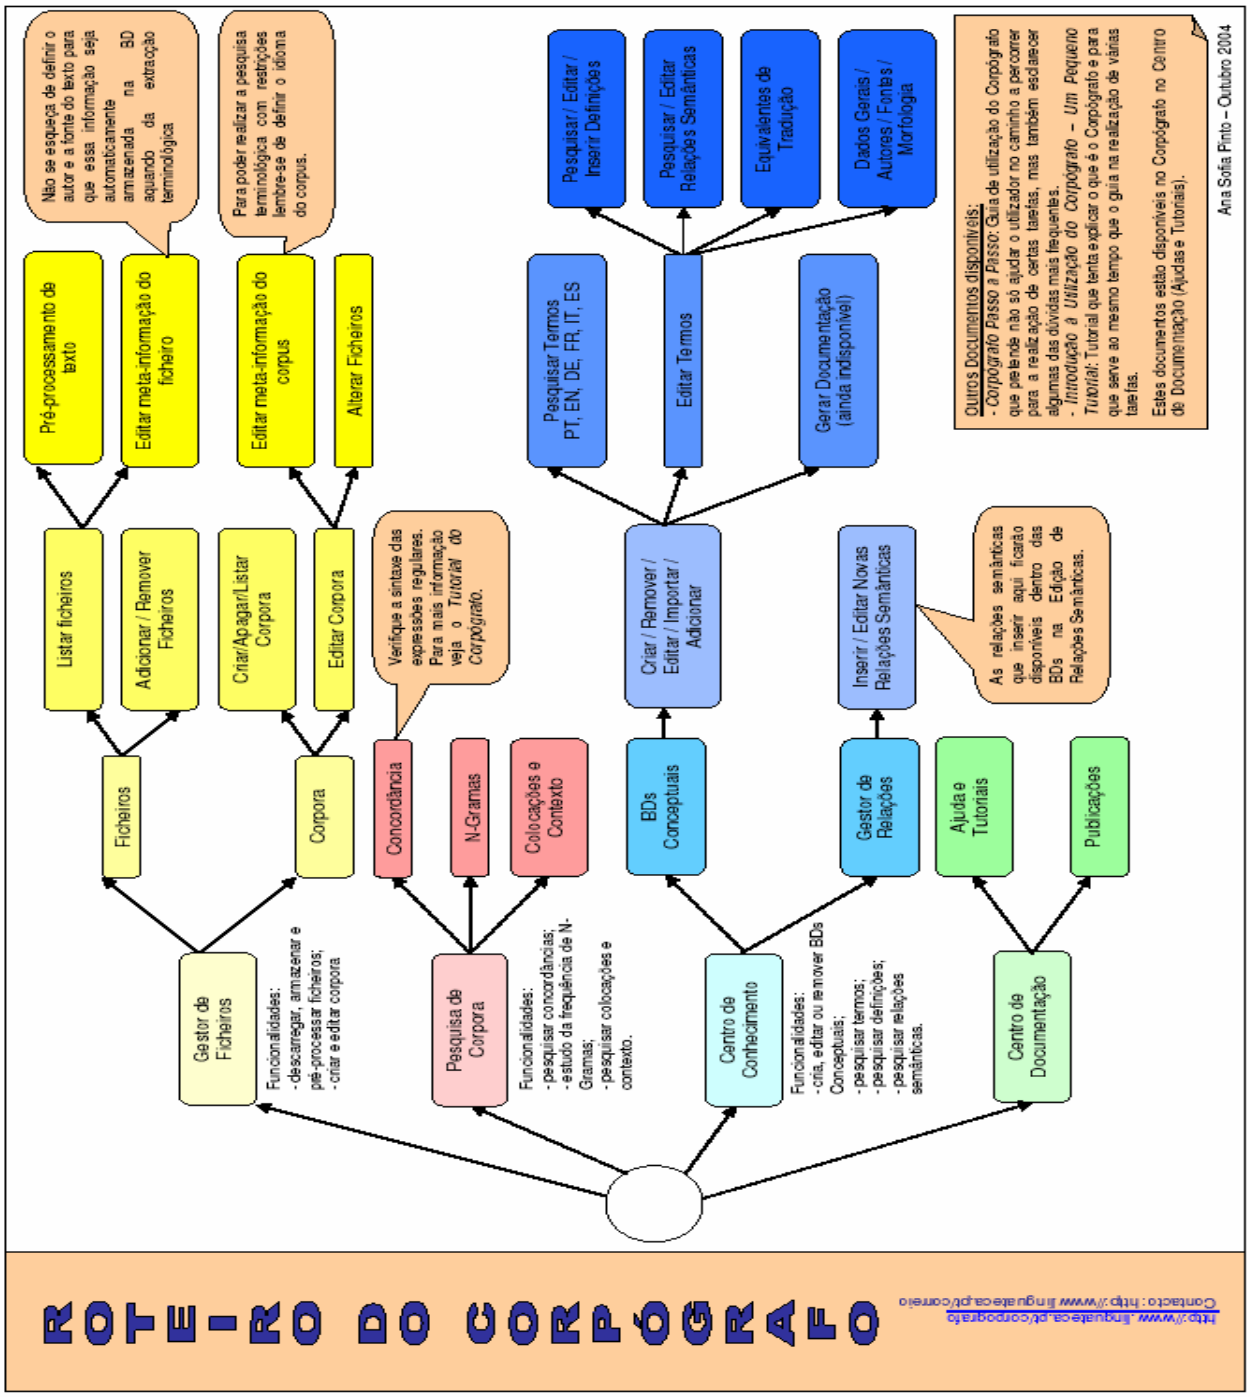

Figura 1: Roteiro completo do Corpógrafo

(http://poloclup.linguateca.pt/corpografo/docs/roteiro.pdf)

CORPÓGRAFO PASSO A PASSO

Gestor de Ficheiros: O *Gestor de Ficheiros* é a base do Corpógrafo. Aqui encontrará as ferramentas necessárias para carregar, armazenar e pré-processar Ficheiros, assim como para criar e preparar os seus corpora de forma a torná-los pesquisáveis.

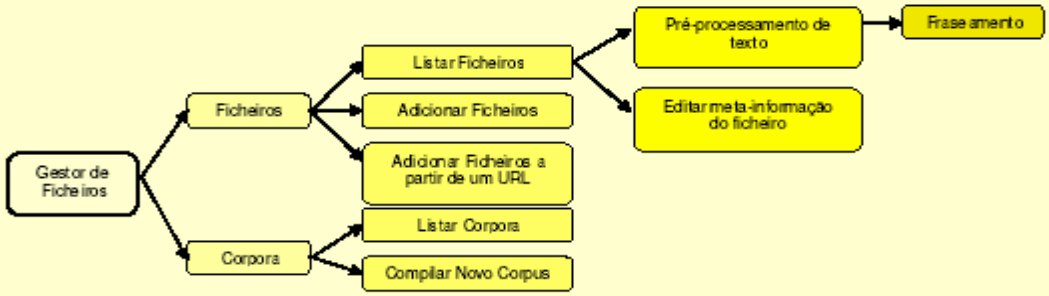

Como carregar Ficheiros para o Corpógrafo?	Como carregar um Ficheiro a partir de um URL?	Ao abrir o Ficheiro, o texto não aparece ou está todo numa só linha.
No *Gestor de Ficheiros*, clique em "Adicionar Ficheiros". Em seguida clique em "*Browse*" para seleccionar o Ficheiro que pretende carregar. Depois de seleccionar o Ficheiro, clique em "Carregar" para que ele seja armazenado no Corpógrafo. Logo que o ficheiro tenha sido carregado, será direccionado para a área de *Edição de Meta-dados* do ficheiro.	No *Gestor de Ficheiros*, clique em "Adicionar Ficheiros". Em seguida, no menu "Adicionar Ficheiro" do lado direito, clique em "A partir de um URL". Indique o URL do ficheiro que pretende carregar sem o prefixo http://, uma vez que este já se encontra digitado. Por fim clique em "Adicionar" para que o ficheiro seja armazenado no Corpógrafo. Logo que o ficheiro tenha sido carregado, será direccionado para a área de *Edição de Meta-dados* do ficheiro.	Muitas vezes o sistema que extrai o texto dos Ficheiros originais não consegue reconhecer quebras de linha. Sempre que isso ocorre, o texto é constituído apenas por uma linha, contendo todas as frases do texto, ou não é visível. Para solucionar este problema, no menu "Operações", clique em "Frasear". ***Não se esqueça de gravar!***
Depois de fazer o Fraseamento o texto continua a não aparecer.	**Qual é a utilidade de "Verificar Fraseamento"?**	**Como Editar um texto?**
Em algumas ocasiões o sistema não consegue extrair texto, muitas vezes devido à qualidade do ficheiro. Por exemplo, há ficheiros PDF que parecem ser de texto, mas que são apenas imagens. Quando isto acontece, o ficheiro em questão não pode ser usado.	O Corpógrafo faz a divisão automática dos textos em frases, no entanto, podem haver algumas falhas nessa divisão. Ao clicar em "Verificar Fraseamento", pode verificar se a divisão foi ou não bem feita. Note que, depois de fazer o *Fraseamento*, terá de gravar as alterações antes de *Verificar o Fraseamento*. Para corrigir qualquer falha de Fraseamento, terá de o fazer na interface de edição de texto.	Para editar o texto basta clicar em qualquer parte do mesmo. Pode apagar ou acrescentar o que quiser, não esquecendo que, tal como num documento Word, é preciso gravar todas as alterações. Para gravar as alterações basta clicar em "Gravar" no menu "Operações" do lado direito.
Como gravar um ficheiro para o meu computador?	**Como criar um Corpus?**	**Como apagar um Corpus?**
Neste momento o Corpógrafo não oferece nenhuma funcionalidade que permita gravar um Ficheiro no computador. No entanto, pode seleccionar o texto inteiro (carregue CTRL+A), copiá-lo e colá-lo num documento Word ou NotePad.	No *Gestor de Ficheiros*, clique em "Compilar Novo Corpus". Atribua um nome ao Corpus que deseja criar e preencha os campos que desejar. Em seguida, coloque um visto à frente dos Ficheiros que pretende que façam parte do Corpus. Por fim, clique em "Criar".	No *Gestor de Ficheiros*, clique em "Listar Corpora". Clique no Corpus que pretende eliminar. Por fim, clique em "Remover Corpus", no menu do lado direito.

Figura 2: Funcionalidades do Gestor de Ficheiros do Corpógrafo

(http://poloclup.linguateca.pt/ferramentas/gc/docs/corp_passo_passo.pdf)

2.1.2. O ToolKit BootCaT

O BootCaT[11], extrator automático de córpus e de termos (do inglês "Bootstrapping Corpora and Terms"), propõe a montagem de córpus, de modo iterativo, a partir de textos obtidos na Web. O BootCaT é composto por várias ferramentas escritas em Perl[12], que foram projetadas para executar pequenas partes do processo de montagem de córpus.

Basicamente, o processo de montagem de córpus do BootCaT é composto de quatro passos:

1) construir um córpus automaticamente a partir de buscas ao Google[13] utilizando um pequeno conjunto de sementes (*seeds*);

2) extrair novas sementes desse córpus;

3) utilizar essas novas sementes para novas buscas ao Google, cujos textos recuperados serão concatenados ao córpus, aumentando-o;

4) extrair novas sementes desse córpus complementado, e assim por diante. A montagem de córpus proposta pelo BootCaT segue o diagrama da Figura 3.

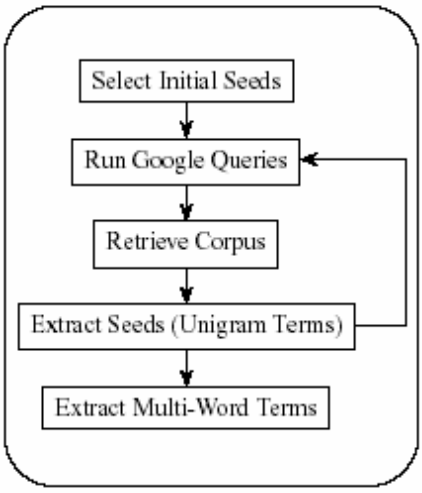

Figura 3: Fluxo de montagem de um córpus no BootCaT [4]

O primeiro passo é selecionar as sementes iniciais. Isso é feito manualmente, e boas sementes são termos típicos em textos do domínio específico do qual busca-se construir a

[11] http://sslmit.unibo.it/~baroni/bootcat.html
[12] http://www.perl.com
[13] http://www.google.com.br/

amostragem. No segundo passo, essas sementes são combinadas entre si e algumas dessas combinações (à escolha do usuário) são enviadas como buscas ao Google. No terceiro passo, as URLs retornadas das buscas são processadas para obter-se apenas o texto contido nelas, convertendo-as para texto puro e "limpando-os", quando for possível. São aproveitados somente os formatos (ou linguagem de marcação) HTML e TXT. Nesse momento, um primeiro corpus já está formado. Desse primeiro córpus são extraídos *unigramas* (termos com apenas uma palavra), e a freqüência de cada unigrama obtido no córpus é apurada. Sabendo-se a freqüência de cada unigrama, esses podem ser comparados entre si. A relevância de cada unigrama é mensurada utilizando a medida estatística *log odds ratio* [4], com o apoio de um córpus de referência na mesma língua. Uma lista de unigramas, ordenada pela relevância calculada pela medida *log odds ratio*, é então gerada, e os primeiros elementos da lista são considerados bons candidatos a sementes. Caso o córpus obtido até o momento não seja satisfatório (seja pequeno, por exemplo), podemos eleger os primeiros unigramas da lista como novas sementes e repetir o processo, voltando ao segundo passo. Segundo Baroni e Bernardini [4], córpus representativos podem ser montados com poucas sementes iniciais (entre 5 e 15), e também afirmam que com duas ou três iterações é possível obter um córpus satisfatório.

O BootCaT também dispõe de ferramentas para extração de termos com mais de uma palavra, ou termos multi-palavra. Para tal propósito, precisamos de duas listas, ambas obtidas no córpus de referência: uma de *conectores* e uma de *stopwords*. Conectores são compostos por palavras ou bigramas que ocorrem freqüentemente entre dois unigramas e *stopwords* são termos muito freqüentes, geralmente formados por palavras de classe fechada de uma língua como os artigos, as conjunções, as preposições e os pronomes que não são conectores. As listas descritas acima não precisam necessariamente ser obtidas pelo BootCaT, podem ser dadas ou obtidas de outras fontes. Com as listas acima é possível definir o que são termos multi-palavra, segundo as restrições abaixo:

1. Contém ao menos um unigrama;
2. Não contém *stopwords*;
3. Podem ter conectores, desde que esses não estejam nas extremidades do termo e não sejam consecutivos;
4. Têm freqüência maior que um limiar (*threshold*), que é relativo ao tamanho do termo;

5. Não podem ser parte de termos multi-palavras maiores com freqüência superior a *k*fq*, onde *k* é uma constante entre 0 e 1 (normalmente k é um valor perto de 1) e i *fq* é a freqüência do termo atual;
6. Reciprocamente, não podem conter termos multi-palavras menores com freqüência superior a (*1/k*) * *fq;*

Os termos multi-palavras são procurados recursivamente, inicialmente buscando por bigramas e depois concatenando palavras à esquerda e à direita, na busca de um (n+1)grama. Parâmetros como a freqüência mínima para bigramas (utilizado para calcular o limiar da restrição 4) e o valor de *k* das restrições 5 e 6 devem ser informados pelo usuário.

O BootCaT é extremamente modular: para executar o processo de montagem de córpus e extração de termos são utilizadas várias ferramentas, sendo que o resultado de cada ferramenta serve de entrada para outra. Essa característica nos permite utilizar subconjuntos de ferramentas, conferir os arquivos de saída intermediários, adicionar novas ferramentas, substituir uma ferramenta ou alterar uma ferramenta sem preocupar-se com as outras, apenas cuidando para que ela aceite o mesmo tipo de entrada e produza o mesmo tipo de saída. Essa característica reduz re-implementações de algoritmos com implementações consolidadas, evitando a replicação desnecessária de código. Alterações intuitivamente complexas, como adaptações de ferramentas para trabalhar com línguas diferentes, têm sido experimentadas e comprovam os benefícios das ferramentas modulares. Adaptações para o BootCaT foram feitas para construção de córpus em língua japonesa [6], com taxas encorajadoras de reaproveitamento de ferramentas e código. O Apêndice 1 contém uma breve descrição dos scripts do BootCaT que são utilizados na construção de córpus.

2.1.3. A API do Google[14]

As buscas e a recuperação das URLs dessas buscas requisitadas pelo BootCaT ao Google são possíveis por meio da API (Interface para Programação de Aplicativos) do Google. Essa API permite ao programador enviar e recuperar facilmente uma busca feita ao Google. Ela contém bibliotecas em várias linguagens (como Perl, Java e Visual Studio.NET) e possibilita ao programador utilizar rotinas de busca diretamente ao Google e obter os resultados em formato fácil de recuperar, como mostrado na Figura 4. Nessa figura, temos vários campos importantes,

[14] http://www.google.com/apis/

como a URL, o título (Title) e um trecho do conteúdo da URL (snippet). No BootCAT, apenas o campo URL é aproveitado.

```
 [
  URL  = "http://www.icmc.sc.usp.br/"
  Title = "Instituto de Ciências Matemáticas e de Computação - <b>ICMC</b>-USP"
  Snippet = "O <b>ICMC</b> está localizado no Campus da USP em São Carlos - SP e
oferece cursos nas<br>  áreas de Matemática e Ciência da Computação."
  Directory Category = {SE="",
FVN="Top/World/Português/Referência/Educação/Universidades_e_Ensino_Superior/Brasil/Uni
versidade_de_São_Paulo"}
  Directory Title = "<b>ICMC</b> - Instituto de Ciências Matemáticas e de Computação"
  Summary = "O <b>ICMC</b> está localizado no Campus da USP em São Carlos - SP e
oferece cursos nas<br>  áreas de Matemática e Ciência da Computação."
  Cached Size = "16k"
  Related information present = true
  Host Name = ""
  ],
```

Figura 4: Estrutura de um elemento retornado por uma busca feita pela API do Google

Para a utilização da API do Google, e conseqüentemente do BootCaT, é necessário obter a licença de uso dessa no site do Google. Para obter essa licença, o usuário precisa cadastrar-se, e a chave da licença lhe é enviada por e-mail. Essa licença permite que o usuário execute diariamente até 1000 buscas e retorne no máximo 10000 resultados.

2.1.4. Extração automática de termos

Para o projeto de desenvolvimento de uma estrutura conceitual (ontologia) para a área de Nanotecnologia, que ampara o Portal da Nanotecnologia, foi compilado um córpus de língua inglesa da referida área de conhecimento a partir de textos da Web, cuja extensão é de 2.570.792 de palavras. Esse córpus (chamado aqui de Nano) é composto por 22 livros e 200 artigos de revistas, além de 9.982 resumos de artigos, com seus respectivos títulos, e palavras-chaves e lista de tópicos (subjects) quando presentes. Os artigos, em especial, foram compilados dos periódicos (i) *Journal of Nanoscience and Nanotechnology*[15], (ii) *Nanotechonology*[16], (iii) Nature[17] e (iv)

[15] http://www.aspbs.com/html/a0600frm.htm

Science[18]. Os resumos de artigos foram compilados do site Web of Nanotechonoloy[19] sobre os tópicos Nanotechnology, Genomics e Nanobiotechnology. Este córpus, criado por um membro da equipe do referido projeto, tem sido usado para o desenvolvimento da ontologia para o Portal da Nanotecnologia pelos três métodos de extração de termos usados no projeto: um método estatístico baseado na freqüência e proposto em [15] para extração de uni, bi e trigramas; um método baseado em conceitos de redes complexas; e o método do BootCaT. Os dois primeiros serão comentados na Seção 2.2; o método do BootCaT foi descrito na Seção 2.1.2. A mesma lista de *stopwords* foi usada por todos os métodos.

A ontologia para o Portal ainda está sendo desenvolvida e neste trabalho utilizamos a sua terceira versão, apresentada de forma resumida no Apêndice 2. Esta ontologia está sendo construída com os resultados dos 3 métodos de extração de termos citados acima, e mais outras fontes, como glossários, outras ontologias e o próprio conhecimento da área que um dos membros do projeto possui.

Para a comparação dos métodos foram utilizadas duas métricas: a **precisão**, que é a razão entre as respostas corretas pelo total de respostas obtidas pelo método e a **revocação** (**recall**), que é a razão das respostas corretas pelo total de respostas corretas possíveis. O total de respostas corretas possíveis é calculado com as listas de unigramas, bigramas e trigramas da versão 3 da ontologia que vieram do córpus, e, portanto, só faz sentido falar em **revocação** quando a ontologia estiver sendo comparada.

2.2. Trabalhos Relacionados

Um dos objetivos deste trabalho foi a avaliação do método de extração de termos do BootCaT. Para esta avaliação, os termos extraídos do córpus Nano pelo BootCaT foram comparados com dois outros métodos de extração: um baseado em estatística, que aceita como termos (uni, bi e trigramas) apenas se estes tiverem uma freqüência maior que um limite mínimo (o limite utilizado é 22 para unigramas e está relacionado com o tamanho do córpus Nano); e outro, que modela o córpus como uma rede complexa e usa métricas da rede para a extração de unigramas, somente.

---

[16] http://www.iop.org/EJ/S/3/451/YfSAujvDHdF2s7uXEE6cyg/journal/Nano
[17] http://www.nature.com/cgi-taf/DynaPage.taf?file=/nature/journal/v433/n7025/index.html
[18] http://www.sciencemag.org/
[19] http://access.isiproducts.com/dwon

O método baseado em estatística, um dos 15 métodos desenvolvidos em um mestrado do ICMC [5], faz um corte na freqüência, ou seja, aceita como termos apenas se estes tiverem uma freqüência acima do valor de corte. Para este método foram utilizadas rotinas do pacote NSP (*N-gram Statistic Package*)[20]. O NSP foi implementado por Ted Pedersen, Satanjeev Banerjee e Amruta Purandare da Universidade de Minnesota, Duluth, é escrito em Perl e possui dez medidas estatísticas de associação para bigramas e duas para trigramas, enquanto para unigramas apenas a freqüência pode ser medida.

O outro método baseia-se nos conceitos de redes complexas [7, 8]. As redes complexas são grafos basicamente, com a ressalva de que apresentam uma diversidade de técnicas e modelos que auxiliam no entendimento e previsão do comportamento dos sistemas. Três conceitos merecem destaque no estado da arte em redes complexas [7]: as redes *small-world*, o coeficiente de clusterização (*clustering coefficient*) e as redes livres de escala (*scale-free*). O conceito "livre de escala" refere-se ao fato de que, mesmo enormes, a maioria das redes apresenta um caminho relativamente curto entre quaisquer dois nós. Já o coeficiente de clusterização quantifica a tendência de aglomeração dos nós da rede. A maioria das redes complexas apresenta um alto coeficiente de clusterização, quando comparado com o coeficiente de uma rede randômica de mesmo número de nós e arestas. Medidas da rede, como graus de entrada e saída dos nós, pesos das arestas e os conceitos mencionados acima, podem ser utilizadas para extração de termos de um córpus modelado como uma rede complexa.

Esses dois últimos métodos foram aplicados no córpus Nano por dois membros da equipe de trabalho, descrita na Seção 3.2.

2.3. Análise Crítica

A construção manual de córpus para experimentos lingüísticos é uma tarefa muito custosa e tem motivado o desenvolvimento de aparatos computacionais para atenuar estes custos, tais como o Corpógrafo e o BootCaT. O Corpógrafo, embora englobe muitas funcionalidades tais como suporte a conversão de vários tipos de texto e organização de córpus, requer que o usuário já tenha recolhido o material que formará o córpus. Além disso, o Corpógrafo é um sistema fechado, o que impede a colaboração de outras pessoas. O BootCaT, entretanto, é totalmente

[20] `http://www.d.umn.edu/~tpederse/nsp.html`

aberto e permite que melhorias sejam agregadas, novas ferramentas sejam desenvolvidas e acopladas e até mesmo a substituição e remoção de ferramentas. Por ser tão maleável, a manipulação das ferramentas do BootCaT exige conhecimento avançado de comandos do sistema operacional e de linguagens de programação, que inviabiliza o seu uso por vários interessados na montagem de córpus que nem sempre detém este tipo de conhecimento.

Neste projeto tentamos produzir algo que atenda os interessados tanto no auxílio computacional para a montagem de córpus quanto no estudo, compreensão, customização e colaboração da ferramenta em si. Além disso, como o BootCaT também oferece métodos para a extração de termos simples e multi-palavras e o projeto do Portal da Nanotecnologia, que se propunha a oferecer uma taxonomia para essa área, precisava de ajuda de métodos automáticos de extração de terminologia. Esse projeto já estava sendo ajudado por outros métodos de extração para auxiliar no levantamento de termos (sendo um método tradicional e outro recente), e então resolvemos também gerar uma lista de candidatos para que estes pudessem ajudar na construção da taxonomia e, além disso, pudéssemos fazer uma comparação mais ampla entre os métodos.

3. Estado atual do trabalho

3.1. Projeto

O projeto desenvolvido possui duas partes: 1) utilizar as tecnologias estudadas nesse projeto no **Portal de Nanotecnologia**, especificamente, utilizar o BootCaT para a extração de termos simples e multi-palavras e comparar os termos obtidos com a ontologia e com outros dois métodos (freqüência e redes complexas); 2) dar suporte à construção de um módulo do ambiente a ser desenvolvido no projeto **Extração automática de termos e elaboração colaborativa de terminologias para o intercâmbio de conhecimento especializado**, especificamente, acoplar o BootCaT aos módulos já previstos nesse projeto para facilitar a criação do córpus de trabalho.

3.1.1. Extração de unigramas e termos multi-palavras e comparação entre métodos

Foram construídas listas de unigramas, bigramas e trigramas usando as ferramentas do BootCaT. Essas listas foram comparadas com outros dois métodos: o de freqüência e baseado em conceitos de redes complexas.

No método que usou a freqüência como medida estatística, as freqüências mínimas requeridas para que os candidatos a termo fossem considerados foram 23, 6 e 6 para unigramas, bigramas e trigramas, respectivamente. Unigramas e bigramas com pelo menos uma *stopword* foram descartados (método OR), enquanto trigramas só foram descartados quando compostos exclusivamente de *stopwords* (método AND).

O método que modela o córpus como uma rede complexa obteve três listas de unigramas, a partir de três métricas distintas da rede: grau de entrada sem, peso grau de entrada com peso e clusterização.

Duas formas de comparação foram propostas: avaliação dos 3 métodos pela da intersecção de seus elementos e avaliação com a versão 3 da ontologia, calculando a precisão e a revocação. Os métodos também colaboraram para a criação da versão 4 da ontologia, com os termos recuperados que não estavam presentes na versão 3.

3.1.2. Suporte à extração automática de córpus

Com relação ao projeto *Extração automática de termos e elaboração colaborativa de terminologias para o intercâmbio de conhecimento especializado* foram desenvolvidas e adaptadas ferramentas para serem incluídas no ambiente Web denominado **e-Termos**, como um módulo extra aos 5 previstos e mostrados no Anexo 1 que traz um esquema genérico da arquitetura computacional do Ambiente.

O Ambiente Web Colaborativo proposto no projeto de doutorado é, sob uma perspectiva genérica, um sistema Web cuja entrada principal é um córpus-alvo de um determinado domínio do conhecimento, e a saída um produto terminológico (glossário, dicionário etc.) do domínio em questão. Para facilitar o uso de tal ambiente por usuários que não tem familiaridade com a construção de córpus, o projeto de graduação projetou o módulo de construção automática de córpus a partir de um conjunto pequeno de termos de uma área e um outro membro da equipe implementou a interface gráfica que chamam as rotinas do BootCaT, que são de domínio público. Além de incorporar estas rotinas, também apontamos suas limitações, para que possamos alterá-las ou acrescentar novas ferramentas para minimizar essas restrições.

3.2. Equipe

Este projeto de graduação está inserido no escopo de dois projetos maiores. O primeiro projeto, *Extração automática de termos e elaboração colaborativa de terminologias para o intercâmbio de conhecimento especializado*, é coordenado pela Profa. Dra. Gladis Maria de Barcellos Almeida do Departamento de Letras (DL) da Universidade Federal de São Carlos (UFSCar) e pela Profa Sandra Maria Aluísio do ICMC-USP. Este projeto de graduação adaptou as ferramentas do BootCaT para suporte à montagem de córpus em um ambiente Web. Marcos Felipe Tonelli de Carvalho, aluno do Bacharelado em Informática e bolsista do NILC, desenvolveu uma interface para as ferramentas serem acessadas no ambiente Web. No segundo projeto, Desenvolvimento de uma estrutura conceitual (ontologia) para a área de Nanotecnologia, que é coordenado pela Profa. Sandra Maria Aluísio, temos também os professores Osvaldo Novais de Oliveira Jr. do IFSC-USP (especialista do domínio), Maria das Graças Volpes Nunes do ICMC-USP e Gladis Maria de Barcellos Almeida do DL da UFSCar; os alunos de doutorado Ariani Di Felippo e Leandro Henrique Mendonça de Oliveira que trabalham no NILC, e o aluno

de graduação, também desenvolvendo um projeto de graduação orientado pela Profa. Maria das Graças Volpes Nunes, Lucas Antiqueira.

3.3. Descrição das Atividades Realizadas

As atividades pontuais realizadas são itemizadas abaixo.

3.3.1. Avaliação dos scripts do BootCaT: levantando suas limitações

O BootCaT foi instalado em um computador do NILC e um experimento foi realizado para compor um córpus, sem fazer iterações nem extrair termos multi-palavras. Os tipos de arquivo endereçados pelas das URLs retornadas pelo Google estavam distribuídos da seguinte maneira: 556 hipertextos, 46 PDF, 6 docs, 5 TXT, 1 PS, nenhum RTF e 5 de outros tipos (como PPT), totalizando 619 URLs. Observamos então que cerca de 10% das URLs retornadas pelo Google foram descartadas pela ferramenta de obtenção de textos da Web, entre documentos PDF, DOC, PS e RTF. Nenhum conteúdo de páginas com frames e redirecionamentos foi obtido pela ferramenta.

As ferramentas do BootCaT que foram utilizadas para a geração do primeiro córpus foram profundamente estudadas, que resultou num roteiro de uso do BootCaT, desde a sua instalação até a construção do primeiro córpus e extração dos unigramas. Esse roteiro, juntamente com uma breve descrição do BootCaT, foi apresentado aos alunos da disciplina de pós-graduação *SCE-5819-2: Tópicos em Inteligência Artificial*. Foi proposto aos alunos que seguissem o roteiro apresentado para a construção de um córpus e a extração de unigramas. As dificuldades relatadas pelos alunos contribuíram consideravelmente para a avaliação do BootCaT, desde falha de conversão como problemas de portabilidade.

3.3.2. Inclusão de novas ferramentas para conversão de tipos de arquivo

Uma das grandes limitações do BootCaT são suas restrições de tipos de arquivo que são convertidos e incluídos ao córpus. As URLs retornadas pelo Google que se referem a arquivos em formato PDF (Portable Document Format) e DOC (Microsoft Word Document), por exemplo, são ignorados pela ferramenta. Normalmente, esses arquivos contêm textos mais informativos e confiáveis que os em formato HTML. Buscando ampliar a gama de tipos de arquivos a serem aproveitados, alguns programas, todos eles de livre distribuição e disponíveis na Web, foram

estudados e dois deles se mostraram eficientes ao propósito de transformar os tipos de arquivo citados acima para texto, e foram incorporados à ferramenta do BootCaT que obtêm os textos a partir das URLs.

O aplicativo **xpdf**[21], dentre outras funções, converte arquivos PDF para texto. A grande maioria dos arquivos PDF testados foi corretamente convertida para texto, embora arquivos PDF protegidos por criptografia não possam ser convertidos. Além disso, existem versões do xpdf tanto para sistemas Windows quanto para Linux.

O aplicativo **wvware**[22] permite converter arquivos do tipo DOC para texto. Nos testes realizados, este aplicativo fez boas conversões, sem deixar resíduos de conversão. Assim como o xpdf, o wvware também tem versões tanto pra sistema Linux quanto Windows.

3.3.3. Extração de unigramas usando o BootCaT

Primeiramente *tokenizamos* o córpus, que consiste em separar cada palavra do córpus, e geramos um arquivo de córpus *tokenizado* com uma palavra por linha. Este córpus também foi transformado para minúsculo, para não discriminar maiúsculas de minúsculas. Com o córpus *tokenizado*, calculamos a freqüência de cada palavra distinta do córpus, no qual cada linha contém a palavra seguida da sua freqüência no córpus, ordenada decrescentemente pela freqüência.

O próximo passo foi calcular a medida estatística *log odd ratio* para cada palavra da lista de freqüência. Nesta tarefa, precisamos da lista de freqüência de um córpus de referência, e escolhemos o córpus Brown[23]. Para calcularmos a medida *log odd ratio,* precisamos de um arquivo com a freqüência de cada palavra do córpus ao lado da freqüência dessa palavra no córpus de referência +1 (mais um). Calculamos o *log odd ratio* de cada palavra e selecionamos os 10% melhores unigramas classificados pela medida, gerando uma lista com 7343 unigramas. Dessa lista, foram removidos os unigramas que também estavam na lista de *stopwords*, resultando numa lista final com 7297 unigramas. Os comandos relativos aos passos citados acima para a geração de unigramas podem ser analisados no Apêndice 3.

3.3.4. Extração de bigramas e trigramas usando o BootCaT

[21] www.foolabs.com/xpdf/
[22] http://wvware.sourceforge.net/
[23] clwww.essex.ac.uk/w3c/corpus_ling/ content/corpora/list/private/brown/brown.html

Para este passo, precisamos da lista de unigramas obtida na Seção 3.3.3**.** Então extraímos conectores de uma e duas palavras, e escolhemos os 10% primeiros de uma palavra e os 5% primeiros de duas palavras. Poderíamos extrair a lista de *stopwords* da lista de freqüência do córpus Brown, mas usamos a lista de *stopwords* do Apêndice 4, que também foi utilizada pelos dois outros métodos de extração descritos na Seção 3.1.1**.** Como vimos na Seção 2.1.2, a extração de termos multi-palavras começa com a extração de bigramas. A partir dos bigramas é que podemos extrair trigramas olhando no unigrama que sucede ou precede o bigrama, e assim por diante. Foram extraídos 6,5% dos possíveis bigramas contidos no córpus Nano, para que o número de bigramas retornados se equiparasse com o número extraído pelo método da freqüência. Com esses bigramas, partimos para a extração de trigramas, que consiste em tentar eleger bigramas que são partes de trigramas. A extração de trigramas baseia-se nas regras de formação de termos multi-palavras, descritas na seção 2.1.2. Da lista dos 6,5% bigramas de maior freqüência escolhidos, a menor freqüência é 5. O valor que escolhemos para *k* foi de 0.75, o mesmo usado no trabalho dos autores do BootCaT, e para um trigrama *X* que contém o bigrama *Y* ser classificado com trigrama, a freqüência de *X* de ser superior a *k*(freqüência de Y)*. A Tabela 1 mostra alguns bigramas, e suas respectivas freqüências no córpus, que estão contidos nos trigramas da Tabela 2. Os termos em negrito são os termos que estão nas listas finais de bigramas e trigramas obtidas pelo BootCaT.

Bigramas	Freqüência
biochemical research	495
research methods	494
scanning probe	123

Tabela 1: Candidatos a bigramas

Trigrama	Freqüência
scanning probe microscopy	51
scanning probe microscope	23
scanning probe microscopes	15
Biochemical research methods	490

Tabela 2: Candidatos a trigramas

O trigrama *"scanning probe microscopy"* não foi incluído na lista de trigramas, embora seja um termo da área, pois sua freqüência é menor que a mínima exigida:

Freqüência mínima = *k**(*freqüência de "scanning probe") = 0.75 * 123* ≈ ***93***

Se o córpus fosse maior ou se sofresse um processo de singularização a freqüência de *"scanning probe microscopy"* seria maior e ele seria escolhido.

Já o trigrama *"biochemical research methods"* foi incluído na lista final de trigramas, excluindo portanto os bigramas *"biochemical research" "research methods"* da lista de bigramas, pois sua freqüência é maior que a freqüência mínima:

Freqüência mínima = *k**(*"freqüência de "biochemical research") = 0.75 *495 ≈* ***372***

A freqüência mínima exigida para trigramas é a freqüência do menor bigrama (5) vezes k (0.75), que é 3.75, e como freqüência é um valor inteiro, o mínimo exigido foi 4.

Os comandos relativos aos passos para a obtenção de lista de bigramas e trigramas podem ser vistos no Apêndice 3.

3.4. Resultados Obtidos

3.4.1. Extração de unigramas e termos multi-palavras

Na Tabela 3 são apresentados os números de uni, bi e trigramas da Ontologia, extraídos pelo BootCaT e pelo método da freqüência, respectivamente nas colunas 2, 3 e 4.

N-grama	Ontologia	BootCaT	Freqüência
Unigramas	1187	7297	7645
Bigramas	2261	6780	1954
Trigramas	2530	152	3216

Tabela 3: Número dos candidatos a termos obtidos pelos métodos do BootCaT, Freqüência e da ontologia

O método baseado em conceitos de redes complexas extraiu apenas unigramas, mas extraiu três listas, utilizando três métricas da rede (Tabela 4).

Métrica da rede	Quantidade de unigramas
Grau de entrada sem peso	3107
Grau de entrada com peso	2350
Coeficiente de clusterização	3391

Tabela 4: Número de candidatos a termos obtido das redes complexas

N-grama	Termos na Intersecção	Precisão	Revocação
Unigramas	651	8.92%	54.84%
Bigramas	248	3.65%	10.96%
Trigramas	9	5.92%	0.35%

Tabela 5: Comparação entre os termos obtidos utilizando o BootCaT e a ontologia

A Tabela 5 apresenta o resultado da comparação entre a ontologia e os termos obtidos pelo BootCaT. O método da freqüência teve mais sucesso que os outros dois métodos como podemos ver na intersecção dos termos com a ontologia. Porém, os unigramas, bigramas e trigramas retornados pelo BootCaT que não estão na ontologia servirão para alimentar a quarta versão desta, se após o julgamento por um especialista forem considerados termos da área. Na Tabela 6 temos o resultado da comparação entre a ontologia e os termos obtidos pelo método da freqüência.

N-grama	Termos na Intersecção	Precisão	Revocação
Unigramas	815	10.66%	68.66%
Bigramas	252	12.89%	11.14%
Trigramas	30	0.93%	1.18%

Tabela 6: Comparação entre os termos obtidos utilizando a freqüência e a ontologia

Na tabela 7, temos a comparação entre os unigramas da ontologia e os unigramas obtidos pela rede complexa.

Métrica da rede	Termos na Intersecção	Precisão	Revocação
Grau de entrada sem peso	542	17.44%	45.66%
Grau de entrada com peso	469	19.95%	39.51%
Coeficiente de clusterização	27	0.79%	2.27%

Tabela 7: Comparação entre os unigramas obtidos utilizando diferentes métricas da redes complexas e a ontologia

A comparação entre os métodos mostrada nas Tabelas 8 e 9 visa avaliar a **similaridade** entre esses no ranqueamento de termos. Para que a comparação fosse justa, listas de n-gramas de tamanhos diferentes foram reduzidas ao menor tamanho entre as duas.

N-grama	Termos Comparados	Termos na Intersecção	Porcentagem
Unigramas	7297	3742	51.28%
Bigramas	1954	1212	62.02%
Trigramas	152	1	0.65%

Tabela 8: Comparação entre os termos obtidos utilizando o BootCaT e os obtidos pelo corte na freqüência

Métrica da rede	Termos Comparados	Termos na Intersecção	Porcentagem
Grau de entrada sem peso	3107	1052	33.85%
Grau de entrada com peso	2350	720	30.63%
Coeficiente de clusterização	3391	23	0.67%

Tabela 9: Comparação entre os unigramas obtidos utilizando diferentes métricas da redes complexas e os unigramas obtidos pelo BootCaT

3.4.2. Suporte à montagem de córpus

As ferramentas do BootCaT foram preparadas para que fossem utilizadas no ambiente Web do **e-Termos**, e já estão sendo utilizadas a partir de uma interface gráfica, que pode ser vista no Anexo 2. Esse anexo mostra todos os passos necessários para a construção de córpus descartáveis para pesquisa terminológica.

3.5. Dificuldades e Limitações

A busca por ferramentas de conversão é uma tarefa exaustiva, custosa e muitas vezes improdutiva. A maioria das ferramentas de conversão é comercial, o que inviabiliza a inclusão dessas no projeto. Outras não são comerciais, mas demandam interação com o usuário, inviabilizando a automatização do processo.

Segundo a documentação do BootCaT, as ferramentas foram testadas em sistemas tipo Unix, mas não haveria problema em rodar o BootCaT sobre sistemas emulados, como o CygWin. Algumas horas de projeto foram dedicadas à adaptação do BootCaT ao CygWin, devido a entraves devido às diferenças sutis entre os sistemas.

4. Conclusões e Trabalhos Futuros

Neste projeto foi realizado o estudo e a adaptação das ferramentas do BootCaT, um conjunto de programas Perl que auxilia na montagem de córpus de textos provindos da Web, com o intuito de aprimorar suas ferramentas e prepará-las para que pudessem comportar-se como um módulo de montagem automática de córpus para o projeto *Extração automática de termos e elaboração colaborativa de terminologias para o intercâmbio de conhecimento especializado.* Além disso, suas ferramentas fornecem um método alternativo de extração de termos multi-palavras, para auxiliar na construção da ontologia da área de nanotecnologia, que integrará o *Portal da Rede de Nanotecnologia da USP*.

As ferramentas do BootCaT foram preparadas para que pudessem ser facilmente utilizadas em um ambiente Web. Listas de unigramas, bigramas e trigramas foram extraídas do córpus compilado para o projeto de nanotecnologia, e os candidatos a termos que não pertenciam à ontologia foram enviados para especialistas trabalharem na construção da próxima versão da ontologia.

O suporte à montagem de córpus, incorporado no Ambiente Web, sobrecarrega muito o servidor, pois todo o *download* do córpus, que pode ser de alguns MBytes mesmo para uma pequena lista de termos (*seeds*), fica a cargo do servidor. As buscas são feitas por meio da API do Google, que restringe o número de resultados retornados e obriga a quem for usar esta ferramenta do BootCaT a ter uma senha para utilizar a API do Google, embora esta tenha apenas que ser solicitada. Também existem problemas quando a URL não é bem definida, ou seja, não fica explícito na URL qual é o tipo de arquivo endereçado por ela. Neste caso, a ferramenta do BootCaT tenta, por exemplo, interpretar um PDF como um hipertexto, gerando vários kbytes de puro lixo. Tentamos resolver o problema por meio da API do Google, mas os resultados retornados pelo Google não apresentam o tipo de arquivo que está apontado pela URL.

A conversão entre formatos de arquivos também pode ser melhorada, adicionando novos formatos (como PS e RTF), incorporando uma ferramenta que trata páginas HTML com frames e redirecionamentos e tratando o lixo gerado no processo. Também seria interessante avaliar a qualidade do córpus montado com o processo iterativo do BootCaT, talvez usando-o para gerar um córpus com aproximadamente o mesmo número de palavras do usado neste projeto, e aplicando os mesmos métodos e extração para verificar a intersecção entre os termos extraídos do

córpus compilado manualmente e o córpus obtido pelas ferramentas do BootCaT. Existe uma ferramenta escrita em Java por este aluno que extrai texto de páginas com frames e redirecionamentos com a ajuda do navegador de modo texto **lynx**[24], que ainda precisa ser incorporada ao BootCaT.

[24] http://lynx.browser.org/

Referências Bibliográficas

[1] GARSIDE, R.; LEECH, G.; MCENERY, A.M. (eds.) (1997). *Corpus Annotation*. Longman.

[2] LUÍS SARMENTO, BELINDA MAIA & DIANA SANTOS. The Corpógrafo: a Web-based environment for corpora research Proceedings of LREC 2004 . Lisboa, Portugal, 25 May 2004.

[3] BELINDA MAIA & LUÍS SARMENTO. CG - An integrated Environment for Corpus Linguistics. Poster apresentado na conferência CL2003: CORPUS LINGUISTICS 2003 - Lancaster University (UK), 28 - 31 March 2003.

[4] M. BARONI e S. BERNARDINI. 2004. BootCaT: Bootstrapping corpora and terms from the web. Proceedings of LREC 2004.

[5] TELINE, M. F. (2004). Avaliação de métodos para extração automática de terminologia de textos em português. ICMC-USP, São Carlos, 2004. Dissertação de Mestrado.

[6] M. BARONI e M. UEYAMA. 2004. Retrieving Japanese specialized terms and corpora from the World Wide Web. Proceedings of KONVENS 2004.

[7] ALBERT, R.; BARABÁSI, A.L. Statistical Mechanics of Complex Networks. Rev. Modern Phys., 74, pp. 47–97, 2002.

[8] NEWMAN, M.E.J. The Structure and Function of Complex Networks. SIAM Review 45, 167-256, 2003.

Apêndice 1: Resumo das ferramentas de obtenção de córpus do BootCaT

build_random_tuples.pl		
Descrição	Gera uma combinação entre sementes	
Sintaxe	perl build_random_tuples.pl **-n***X* **-l***Y* **Entrada**	
Opções	**-n**	*X* é o tamanho das tuplas geradas
	-l	*Y* é o número de tuplas retornadas
Entrada	Arquivo com as sementes, uma por linha	
Saída	As combinações na STDOUT, uma por linha	

collect_urls_from_google.pl		
Descrição	Faz uma busca ao Google e obtém os links retornados	
Sintaxe	perl collect_urls_from_google.pl **-k** *chave* **-l** *lang* **-c** *nr* **Entrada**	
Opções	**-k**	chave é a GOOGLE_API_KEY (obrigatório)
	-l	lang é a língua das páginas buscadas
	-c	nr é número de resultados coletados em cada busca
Entrada	Arquivo com as buscas, uma busca por linha	
Saída	Para cada busca, uma linha "CURRENT SEED" seguido da busca e até *nr* primeiras URLs retornadas, uma por linha	

print_pages_from_url_list.pl	
Descrição	Obtém o córpus da Web e o transforma para txt
Sintaxe	perl print_pages_from_url_list.pl **Entrada**
Entrada	O arquivo com URLs que devem ser baixadas e passadas para txt, uma por linha. Apenas as linhas que começarem com "http://" serão processadas. Não há tratamento para links repetidos
Saída	Para cada URL, uma linha "CURRENT URL" seguido da URL e abaixo o texto obtido na URL

basic_tokenizer.pl		
Descrição	asasas Tokenizador simples Sadasdasdsadsa	
Sintaxe	perl basic_tokenizer.pl **-i -e -a Entrada** **-i**	
Opções	**-i**	transforma todas as letras em minúsculas
	-e	informa que é para tratar apóstrofes para língua Inglesa
	-a	descarta caracteres não alfabéticos
Entrada	Arquivo do córpus em txt	
Saída	O córpus tokenizado, um token por linha	

Apêndice 2: Recorte da Ontologia sobre Nanociência e Nanotecnologia

A ontologia possui seus grandes conceitos (enumerados abaixo) e mais duas entradas chamadas Major Topics Related to N&N e Key Concepts in N&N, que trazem os tópicos mais importantes e as palavras-chaves da área, respectivamente.

1. Synthesis, Processing and Fabrication

- Chemical synthesis
- Sol-gel methods
  - Colloidal sol-gel
  - Inorganic polymeric gel
  - Organic polymeric gel
- Molecular beam epitaxy
  - Homoepitaxy
  - Heteroepitaxy
- Laser cooling and trapping
- Self-assembly
  - Chemisorption
  - Physical adsorption (layer-by-layer technique)
- Vapor processing
  - Chemical vapor deposition
  - Physical vapor deposition
- Atom Optics
  - Laser focused atom deposition
  - Laser collimation
  - Fabrication via reactive-ion etching laser focusing
- Nanoscale crystal growth

...

2. Materials

- Metals and alloys
  - Aluminum
    - Aluminium alloys
  - Silver
  - Calcium
  - Cobalt

- Copper
  - Copper alloys
- Gold
  - Gold-palladium alloy
- Iron
- Lead
- Lithium
- Magnesium
  - Magnesioum alloys
- Magnetite
- Mercury
- Molybdenum
- Nickel
  - Nickel alloy
  - Nickel-iron alloy
- Niobium
- Palladium
- Platinum
- Steel
- Superalloys
- Superconductors
- Titanium
  - Titanium alloy
- Tungsten
- Zinc
  - Zinc alloys

- Gases and vapors

...

3. Properties and Characterization techniques

- Electrical Properties
  - Electronic transport, etc.
- Optical Properties
  - Photorefractive
  - Near-field optics
- Linear and nonlinear spectroscopy

Vibrational spectroscopy
Fourier-transformed infrared (FTIR)
Correlation spectroscopy
Raman
Circular dichroism
UV-visible spectroscopy
NMR spectroscopy
Tribology
...

4. Machines and Devices

Molecular and supramolecular nanomachines
Functional nanostructures incorporating responsive modules

Photodetectors
Quantum well infrared photodetectors
Sensors and actuators
Atomic and molecular sensors
Biosensors
Gas sensors
Chemical sensors
Taste sensors
Protein-coupled receptors
Nanomanipulators
...

5. Theories and Computational methods

Quantization and confinement phenomena

Spintronics
Quantum information theory
Atomistic simulation methods
Nanoscale fluid mechanics
Nanoelectronics
Molecular dynamics simulation
High throughput screening
Combinatory chemistry
Neural networks
...

6. Applications

- Acoustics
  - Telecommunications
    - Radio
    - Telephone
    - Television
    - Ultrasound
    - Sound absorber
    - Sound amplifier
    - Noise barriers
    - Radio Frequency Identification Tags
- Agriculture
  - Agrochemicals
    - Herbicides
    - Pest Repellents
    - Pesticides
- Airplanes

...

Apêndice 3: Geração das listas de unigramas, bigramas e trigramas

Os roteiros abaixo foram rodados no shell bash de sistemas do tipo Linux. O Shell de emuladores de Linux (como o CygWin para MS Windows) também deve aceitar esses comandos sem maiores problemas.

Geração de unigramas

Dado um córpus armazenado no arquivo “corpus.txt”, veremos os passos que foram seguidos na extração da lista de unigramas:

O primeiro passo é tokenizar o córpus, usando um tokenizador qualquer. A opção “-i” passa o córpus todo para minúsculo.

```
./tokenizer2.sh -i corpus.txt > corpusTok.txt
```

Agora já podemos calcular a freqüência do córpus.

```
cat corpusTok.txt | sort | uniq -c | awk '{print $2,$1}' >
freqCorpus.txt
```

O arquivo “freqCorpus.txt” contém uma lista das palavras do córpus ordenada, com a freqüência de cada uma delas na frente. Os passos abaixo calculam a medida *log odd ratio* usando a lista de freqüência já calculada e a lista de freqüência de um córpus de referência, todo em minúsculo (pois nosso córpus também está em minúsculo). Neste projeto, usamos o córpus Brown, denominado “ci_brown_tok_fqs.txt” nos comandos abaixo:

```
nwc=`wc corpus.txt | tr -s " " " " | cut -d" " -f3`
nw2=`perl add1_smoothing2.pl -t ci_brown_tok_fqs.txt freqCorpus.txt
smoothCorpus.add1`
```

```
paste freqCorpus.txt smoothCorpus.add1  | awk '{print $1,$2,$4}' | \
perl log_odds_ratio.pl $nwc $nw2 - | sort -nrk2 > logOdds.txt
```

O comando abaixo ordena os unigramas de acordo com seus valores de *log odd ratio*, e armazena esta lista ordenada em “corpusRank.txt”

```
perl print_rank.pl -f2 logOdds.txt | awk '{print $2,$1}' | sort -nk2 >
corpusRank.txt
```

Abaixo escolhemos os 10% melhores classificados pela medida *log odd ratio* como nossos unigramas.

```
perl get_top_percentage.pl 10 corpusRank.txt | awk '{print $1}' >
candUnigramList.txt
```

Agora só falta remover os unigramas dessa lista que são *stopwords*, e gerar a lista final de unigramas em unigramList.txt

```
perl simple_filter.pl –s stopwordList.txt candUnigramList.txt >
unigramList.txt
```

Gerando bigramas e trigramas

Para gerarmos bigramas e trigramas, precisaremos dos arquivos com a lista de conectores (unigramList.txt) e o córpus tokenizado e transformado para minúsculo (corpusTok.txt), já obtidos na extração de unigramas.

```
./find_conectors.sh uni unigramList.txt corpusTok.txt 10 > uni_con.txt
./find_conectors.sh bi unigramList.txt corpusTok.txt 5 > bi_con.txt
```

Acima, obtemos a lista de conectores, com 10% para conectores com um tokem e 5% para conectores com 2 tokens.

O comando abaixo conecta conectores com dois tokens para poderem ser tratados com uma palavra só.

```
perl connect_bi_connectors.pl bi_con.txt corpusTok.txt >corpusBitok.txt
```

Agora começamos a extração de bigramas, e pegaremos os 6,5% mais freqüentes.

```
./extract_bigram.sh corpusBitok.txt stopwordList.txt unigramList.txt >
allgrams.txt
awk '(NF==3){print}' allgrams.txt | sort -nrk3 | perl
get_top_percentage.pl 6.5 - > topBigrams.txt
```

Agora vemos se alguns dos bigramas são trigramas na verdade. Informamos o valor de k (0.75), e geramos uma lista com os termos multi-palavras em “biEtri_grams.txt”.

```
./extract_multi.sh uni_con.txt bi_con.txt allgrams.txt topBigrams.txt
0.75 > biEtri_grams.txt
```

Tanto os bigramas quanto os trigramas estão nesta lista. Agora é só separar os que têm duas palavras dos que têm três palavras.

```
cat biEtri_grams.txt | awk '{if (NF==2){print}}' > bigramList.txt
cat biEtri_grams.txt | awk '{if (NF==3){print}}' > trigramList.txt
```

Assim temos os bigramas em “bigramList.txt” e os trigramas em “trigramList.txt”.

Scripts extras

Nos comandos para extração de unigramas, bigramas e trigramas vistos neste apêndice, vimos alguns comandos com extensão ".sh", que foram criados neste projeto para clarificar a finalidade de alguns comandos realmente obscuros. Abaixo temos o código de cada um destes comandos.

Tokenizer2.sh

```
#!/bin/sh

help () {
 echo "--> Ferramenta:   Tokenizador"
 echo "    Modo de uso:  $0 [-ih] <arq_corpus>"
 echo "    Dependecies:  -"
 echo "    Resultado:    Arquivo tokenizado em STDOUT"
 exit
}

corpus=$1

while getopts "ih" op; do
 case "$op" in
        h )help;;
        i )echo "Ignorar case insensitive";
           ignoreCase=true;
           corpus=$2;;
 esac
done

if ! [ $corpus ]; then
 help
fi

if [ $ignoreCase = true ]; then
 perl -ne 'if(/CURRENT URL/){print "CURR_DOC\n";next} \
 s/\x92/\x27/g; s/^(.)/ _ $1/; s/\s\s/ _ /g; \
 s/\-\-/\- \-/g; s/[^\s+]+\.[^\s]+/ _ /g; \
 s/[^a-zA-Z\x27\s0-9\-]+/ _STOP_ /g; \
 s/([a-z])([A-Z])/$1 $2/g; s/\s+/\n/g; \
 print' $corpus |tr 'A-Z' 'a-z' | egrep "[A-Za-z]" |\
 perl -ne 'BEGIN{$seen=0} if ( /^CURR_DOC/ ) {print; next} if ( /^_STOP_/ )
{if ($seen==0){$seen=1; print}next;} $seen=0; s/^[\x27\-]+//g; \
 s/[\x27\-]+$//g; if (/[A-Za-z]/){print}'
else
 perl -ne 'if(/CURRENT URL/){print "CURR_DOC\n";next} \
 s/\x92/\x27/g; s/^(.)/ _ $1/; s/\s\s/ _ /g; \
 s/\-\-/\- \-/g; s/[^\s+]+\.[^\s]+/ _ /g; \
 s/[^a-zA-Z\x27\s0-9\-]+/ _STOP_ /g; \
 s/([a-z])([A-Z])/$1 $2/g; s/\s+/\n/g; \
 print' $corpus | egrep "[A-Za-z]" |\
 perl -ne 'BEGIN{$seen=0} if ( /^CURR_DOC/ ) {print; next} if ( /^_STOP_/ )
{if ($seen==0){$seen=1; print}next;} $seen=0; s/^[\x27\-]+//g; \
 s/[\x27\-]+$//g; if (/[A-Za-z]/){print}'
fi
```

find_conectors.sh

```
#!/bin/sh

help () {
 echo "--> Ferramenta:      Gera lista de conectores"
 echo "    Modo de uso:     $0 <\"uni|bi\"> <arq_candidatos_unitermos>
<arq_corpus_tokenizado> <percentagem>"
 echo "    Dependecies(2):  get_connector_grams.pl; get_top_percentage.pl"
 echo "    Resultado:       a lista de unigramas ou bigramas conectores
coletados no corpus"
}

if ! ( [ $1 ] && [ $2 ] && [ $3 ] && [ $4 ] ); then
 help
 exit
fi

candsUni=$2
corpusTok=$3
percent=$4

if [ $1 = "uni" ]; then
 perl get_connector_grams.pl 3 $candsUni $corpusTok |\
           grep -v _ | sort | uniq -c |\
        perl -ane 'if ($F[0]>2){print $F[2];print "\n";}' | sort | uniq -c |\
           awk '{print $2,$1}' |  sort -nrk2 | perl get_top_percentage.pl
$percent - |\
        awk '{print $1}' | sort

else
 perl get_connector_grams.pl 4 $candsUni $corpusTok |\
           grep -v _ | sort | uniq -c |\
           perl -ane 'if ($F[0]>2){print join " ",@F[2...($#F-1)];print
"\n";}' |\
        sort | uniq -c | awk '{print $2,$3,$1}' | sort -nrk3 |\
        perl get_top_percentage.pl $percent - | awk '{print $1,$2}' | sort
fi
```

extract_bigram.sh

```
#!/bin/sh

#por enquanto, soh ateh trigramas

help () {
 echo "--> Ferramenta:      Gera lista de bigramas"
 echo "    Modo de uso:     $0 <bitok_corpus> <lista_stopwords>
<arq_candidatos_unitermos>"
 echo "    Dependecies(1):  print_good_ngrams.pl"
 echo "    Resultado:       a lista de candidatos a bigramas coletados no
corpus"
}

if ! ( [ $1 ] && [ $2 ] && [ $3 ] ); then
 help
 exit
fi
```

```
#clarificando as variaveis
biTok_corpus=$1
stopwordList=$2
candsUniterm=$3

awk '/curr_doc/{print "_stop_"} $0 !~/curr_doc/{print}' $biTok_corpus |\
 perl print_good_ngrams.pl 3 $stopwordList $candsUniterm - | sort |\
 uniq -c | perl -ane '$fq = shift @F; print join(" ",@F); print " $fq\n";'
```

extract_multi.sh

```
#!/bin/sh

help () {
 echo "--> Ferramenta:      Extrator de termos multi-palavras"
 echo "    Modo de uso:     $0 <unigramas_conectores> <bigramas_conectores>
<lista_candidatos_ngramas> <top_bigramas> <k>"
 echo "    Dependecies(1):  collect_mw_terms.pl"
 echo "    Resultado:       a lista de termos multi-word extraida do corpus"
}

if ! ( [ $1 ] && [ $2 ] && [ $3 ] && [ $4 ] && [ $5 ] ); then
 help
 exit
fi

#clarificando as variaveis
uni_connectors=$1
bi_connectors=$2
allGrams=$3
top_bigrams=$4
k=$5

awk '(NF>3){print}' $allGrams | perl -ane 'if ($F[$#F]>4){print}' >
XXXTEMP_top_morethanbi_grams_XXX

perl -ne 's/ /_/;print' $uni_connectors $bi_connectors| \
 perl collect_mw_terms.pl $k - XXXTEMP_top_morethanbi_grams_XXX $top_bigrams
rm XXXTEMP_top_morethanbi_grams_XXX
```

Apêndice 4: Lista de Stopwords

a		anybody		beforehand		consequently		enough
able		anyhow		behind		consider		entirely
about		anyone		being		considering		especially
above		anything		believe		contain		et
abstract		anyway		below		containing		etc
according		anyways		beside		contains		even
accordingly		anywhere		besides		conclusion		ever
across		apart		best		corresponding		every
actually		appear		better		could		everybody
acknowledge		appreciate		between		course		everyone
after		appropriate		beyond		currently		everything
afterwards		apendix		both		d		everywhere
again		are		brief		definitely		ex
against		around		but		described		exactly
all		as		by		despite		example
allow		aside		c		did		except
allows		ask		came		different		f
almost		asking		can		do		far
alone		associated		cannot		does		few
along		at		cant		doing		fifth
already		available		cause		done		first
also		away		causes		down		figure
although		awfully		certain		downwards		fig;
always		b		certainly		during		fig.
am		be		changes		e		five
among		became		chapter		each		followed
amongst		because		clearly		edu		following
an		become		co		eg		follows
and		becomes		com		eight		for
another		becoming		come		either		former
annex		been		comes		else		formerly
any		before		concerning		elsewhere		forth

foreword		hereupon		j		meanwhile		nothing
four		hers		just		merely		novel
from		herself		k		might		now
further		hi		keep		more		nowhere
furthermore		him		keeps		moreover		o
g		himself		kept		most		obviously
get		his		know		mostly		of
gets		hither		knows		much		off
getting		hopefully		known		must		often
given		how		l		my		oh
gives		howbeit		last		myself		ok
go		however		lately		n		okay
goes		i		later		name		old
going		ie		latter		namely		on
gone		if		latterly		nd		once
got		ignored		least		near		one
gotten		immediate		less		nearly		ones
greetings		in		lest		necessary		only
h		inasmuch		let		need		onto
had		inc		like		needs		or
happens		indeed		liked		neither		other
hardly		indicate		likely		never		others
has		indicated		little		nevertheless		otherwise
have		indicates		look		new		ought
having		inner		looking		next		our
he		insofar		looks		nine		ours
hello		instead		ltd		no		ourselves
help		into		m		nobody		out
hence		introduction		mainly		non		outside
her		inward		many		none		over
here		is		may		noone		overall
hereafter		it		maybe		nor		own
hereby		its		me		normally		p
herein		itself		mean		not		part

particular		says		sorry		therefore		unfortunately
particularly		second		specified		therein		unless
per		secondly		specify		theres		unlikely
perhaps		see		specifying		thereupon		until
placed		seeing		still		these		unto
please		seem		sub		they		up
plus		seemed		such		think		upon
possible		seeming		sup		third		us
presumably		seems		sure		this		use
preface		seen		t		thorough		used
probably		self		table		thoroughly		useful
provides		selves		tab;		those		uses
q		sensible		tab.		though		using
que		sent		take		three		usually
quite		serious		taken		through		uucp
qv		seriously		tell		throughout		v
r		seven		tends		thru		value
rather		several		th		thus		various
rd		shall		than		to		very
re		she		thank		together		via
really		should		thanks		too		viz
reasonably		since		thanx		took		vs
regarding		six		that		toward		w
regardless		so		thats		towards		want
regards		some		the		tried		wants
relatively		somebody		their		tries		was
respectively		somehow		theirs		truly		way
right		someone		them		try		we
s		something		themselves		trying		welcome
said		sometime		then		twice		well
same		sometimes		thence		two		went
saw		somewhat		there		u		were
say		somewhere		thereafter		un		what
saying		soon		thereby		under		whatever

when		whereupon		whole		within		yet
whence		wherever		whom		without		you
whenever		whether		whose		wonder		your
where		which		why		would		yours
whereafter		while		will		would		yourself
whereas		whither		willing		x		yourselves
whereby		who		wish		y		z
wherein		whoever		with		yes		

Anexo 1: Ambiente Web colaborativo do Projeto *Extração automática de termos e elaboração colaborativa de terminologias para o intercâmbio de conhecimento especializado*

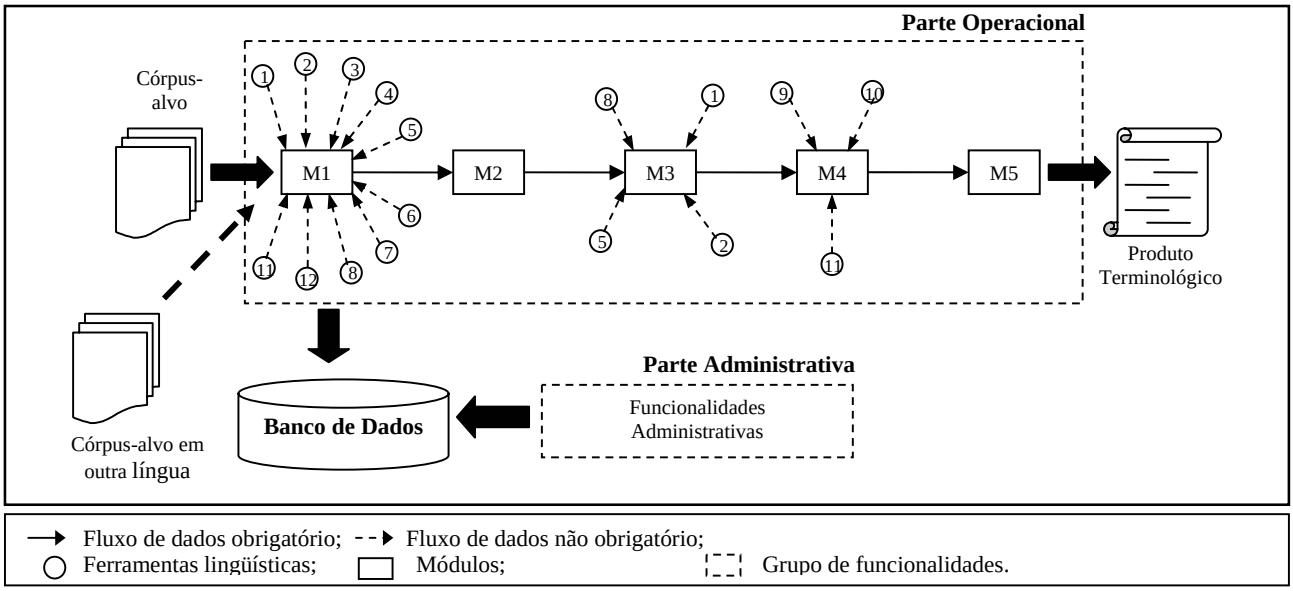

Figura 5: Estrutura do Ambiente Web Colaborativo

Na Figura 5, o Módulo 1 (M1) é responsável pelo suporte e análise da qualidade dos córpus-alvo; o Módulo 2 (M2) pela Extração automática de termos; o Módulo 3 (M3) pela Edição da estrutura conceitual e categorização de termos; o Módulo 4 (M4) pelo Gerenciamento da base de dados terminológicos e o Módulo 5 (M5) pelo Intercâmbio e difusão de termos. A Tabela 10 mostra (de acordo com os círculos numerados na Figura 1) o conjunto de ferramentas de PLN que serão utilizadas no Ambiente do projeto Extração automática de termos e elaboração colaborativa de terminologias para o intercâmbio de conhecimento especializado, fazendo com que ele se diferencie dos demais.

Número	Nome da Ferramenta
1	Contadores de freqüência de palavras
2	Contadores de freqüência de uma única palavra ou expressão
3	Concordanceadores
4	Identificação e separação de lexias complexas
5	Identificação e recuperação de termos do corpus
6	Etiquetadores (taggers)
7	Segmentador Sentencial
8	Lematizadores
9	Corretores gramaticais (identificação de erros ortográficos e sintáticos – parsers)
10	Editores de definição (tipologia de definição)
11	Alinhador de palavras
12	Identificação de Unigrama, Bigramas e Trigramas

Tabela 10: Conjunto de ferramentas de PLN

Anexo 2: Interface Web do Ambiente e-Termos apresentado o Módulo de criação de córpus decartáveis implementado com o BootCat

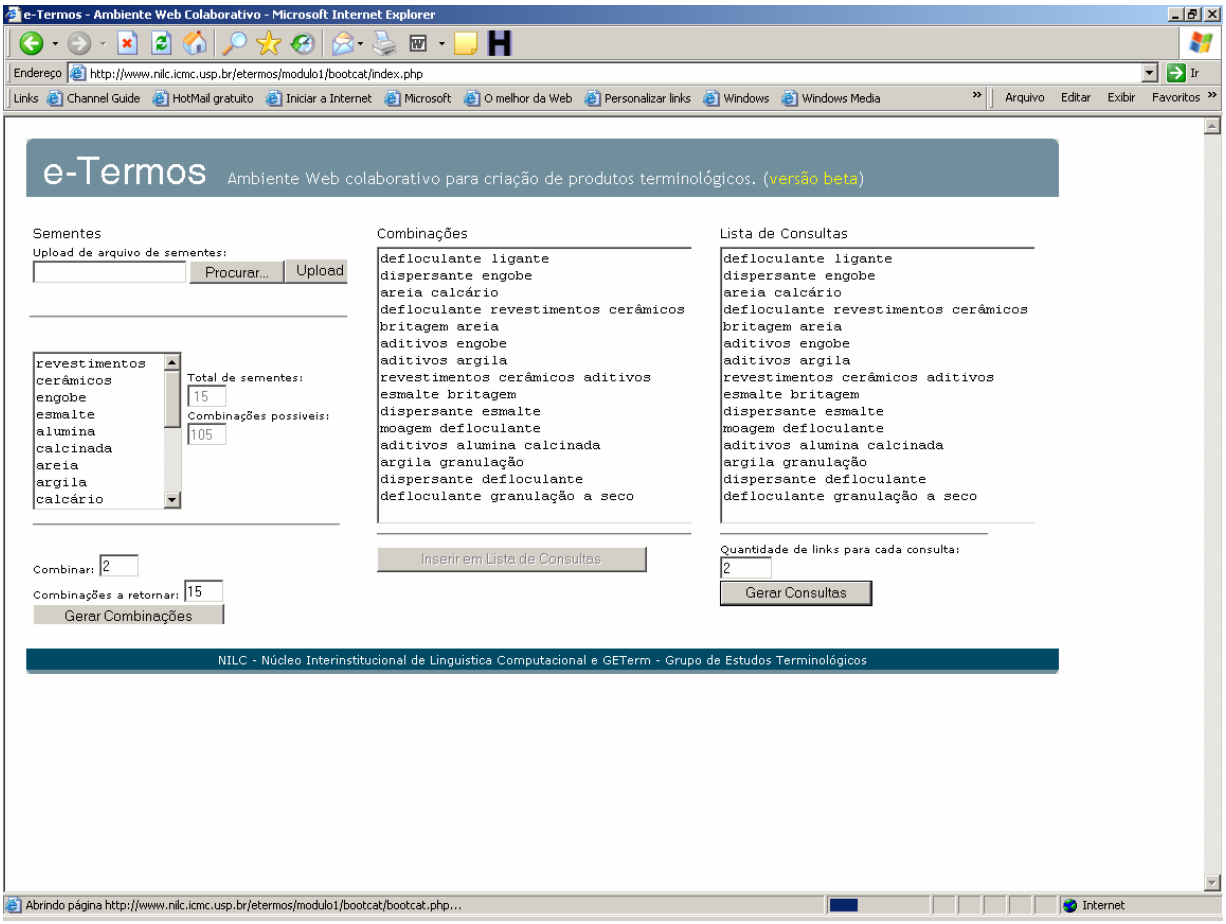

Figura 6: Tela inicial do Processo de Geração de um Córpus Descartável para Pesquisas Terminológicas. Essa tela permite fazer o *upload* de um arquivo com semestes (os autores do BootCat recomendam de 5 a 15 sementes que são termos discriminantes do domínio de pesquisa); no exemplo da figura foram escolhidas 15 sementes e pedida a combinação 2 a 2 com elas -- o que daria 105 combinações no máximo – e para retornar 15 combinações desse conjunto de 105. O domínio escolhido foi o de Revestimentos Cerâmicos. Na segunda janela ("Combinações") são apresentadas as 15 combinações com 2 termos escolhidas e na terceira janela ("Lista de Consultas") as combinações que serão passadas como buscas ao Google. Escolhe-se também a quantidade de links a serem gerados para cada consulta. No caso da figura foram escolhidos 2 links.

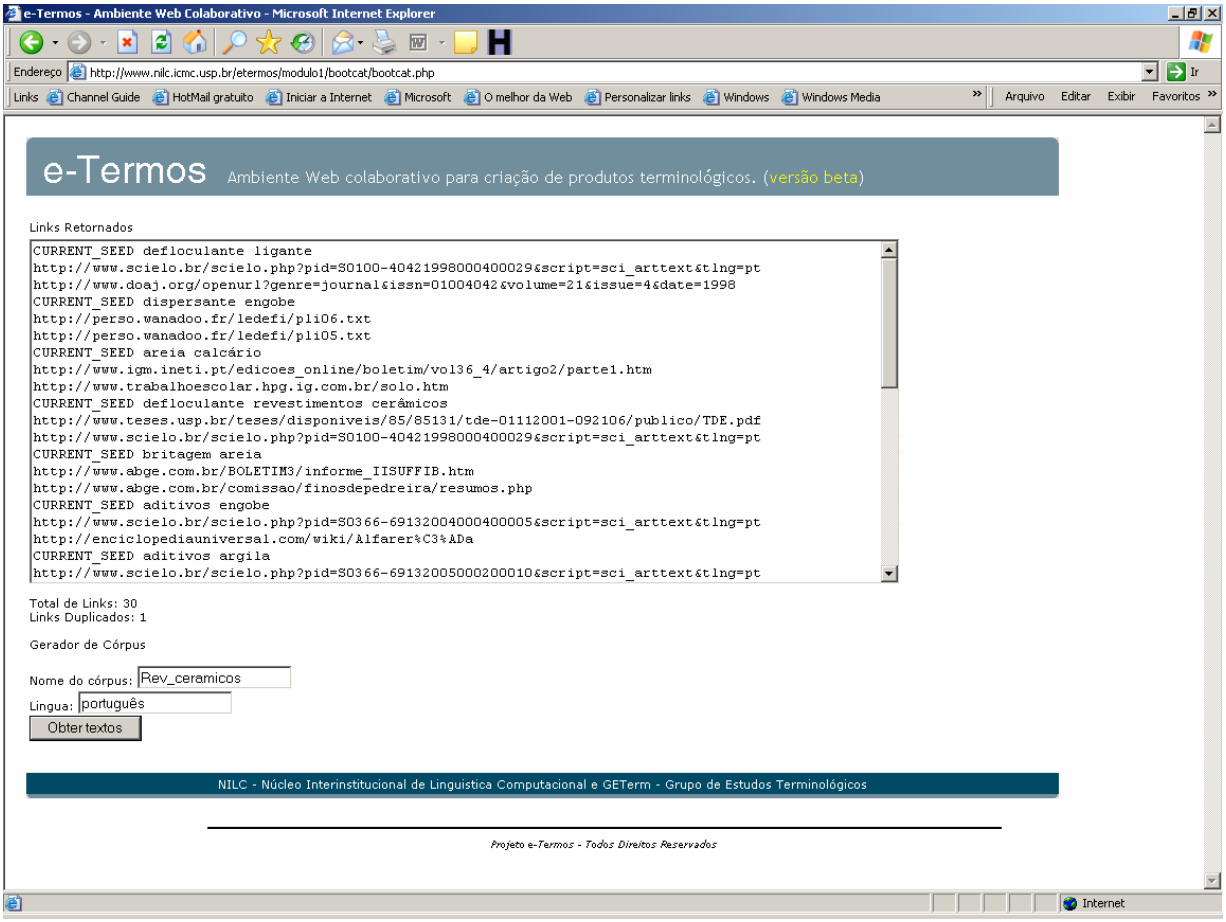

Figura 7. Segunda tela do Processo de Geração de um Córpus Descartável para Pesquisas Terminológicas. Essa tela mostra o total de links retornados e o número de duplicados. Pede o nome do córpus a ser criado e a língua. Ao clicar no botão "Obter Textos" o processo de obtenção de textos da Web com o Google se inicia.

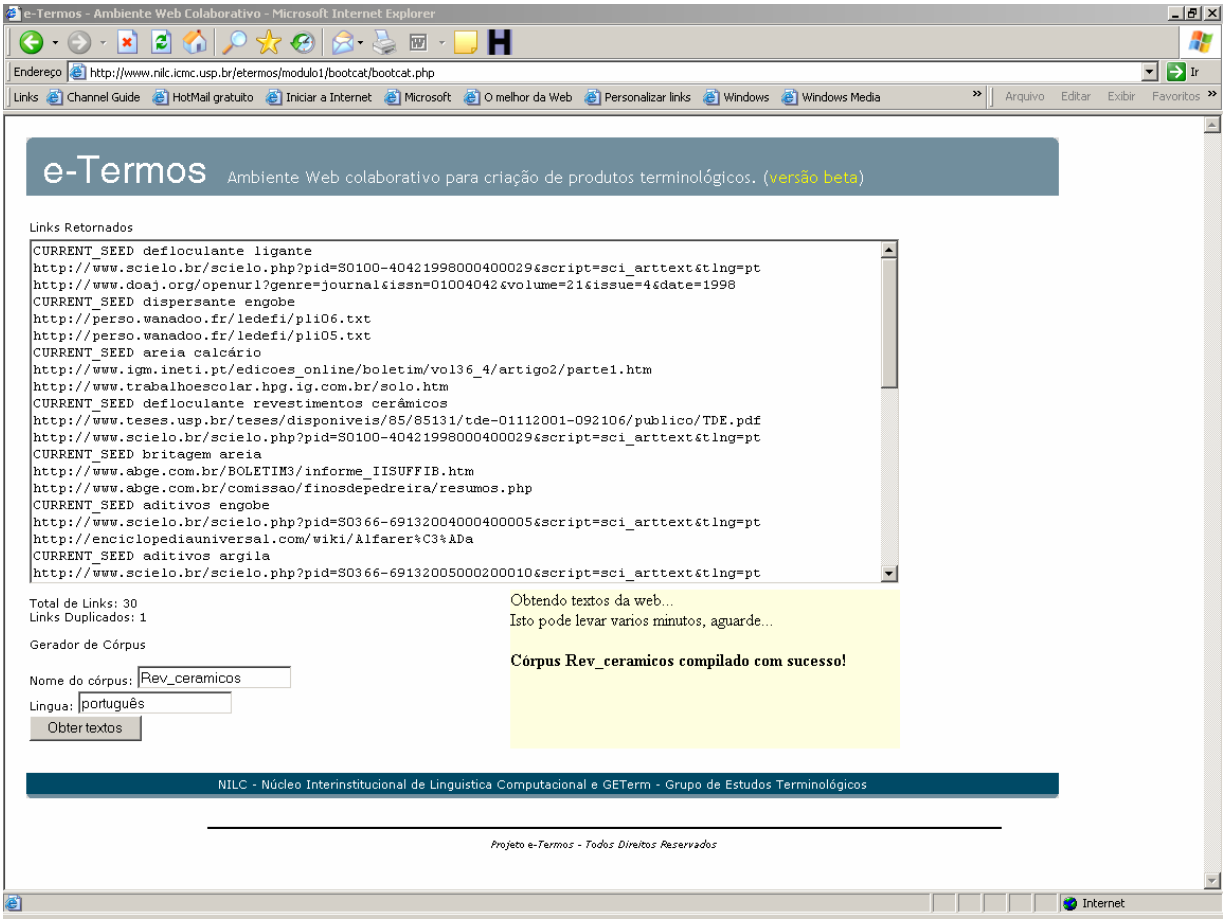

Figura 7: Córpus compilado com sucesso. O córpus Rev_ceramicos fica então disponível para os próximos módulos do ambiente e-Termos mostrado esquematicamente no Anexo 1.

Glossário

Token: uma palavra, um segmento de texto considerado uma palavra.

Unigrama: termo composto por 1 token.

Bigrama: termo composto por 2 tokens.

Trigrama: termo composto por 3 tokens.

N-grama: termo composto por N tokens.

Termo multi-palavra: termo que envolve 2 ou mais tokens.

Script: Um conjunto de comandos escrito em uma linguagem interpretada, como Perl ou Bash.