

Novos rumos na reformulação de consultas para RIG

Por: Nuno Cardoso

Orientadores:
Diana Santos e Mário J. Silva

Simpósio Doutoral da Linguateca
4 de Outubro de 2007

Faculdade de Ciências
Universidade de Lisboa


1

Resumo da apresentação

- Há um ano atrás...
- mudanças na linha de investigação nos últimos 12 meses
- Participação no GeoCLEF 2007 e novas ideias que surgiram
- Primeiros esboços concretos de Motivação e Objectivos
- Plano de trabalhos até o SD de Abril de 2008

2

Há um ano atrás...



"(...) exploração de recursos alternativos, novas técnicas inspiradas em PLN, desenvolvimento de novos módulos para a reformulação automática de consultas"

3

Ideias em 2006

Foco na **reformulação automática de consultas** de todos os tipos.

- Uso de **recursos alternativos** e ainda pouco explorados
 - registos dos servidores *web*
 - ontologias específicas (ex. geográficas)
 - recursos Linguateca (BACO, RepEntiNo, etc)

4

Ideias em 2006 (cont.)

Foco na **reformulação automática de consultas** de todos os tipos.

- prospecção de texto, técnicas PLN
 - Detecção de termos compostos / EM
 - Correlações entre termos
 - Expansão por tesouros / sinónimos
 - extracção de lemas
- Aplicação de módulos no tumba!

5

Nos últimos 12 meses...


- Foco de investigação ainda em **reformulação de consultas**, mas num cenário mais particular: **consultas de cariz geográfico, num sistema de RI geográfico (RIG)**.
- Melhor conhecimento do estado da arte no domínio de RIG e em reformulação de consultas.
- “Mãos na massa”: GeoCLEF permitiu desenvolver um novo sistema RIG para testar novas técnicas e abordagens.

6

Nos últimos 12 meses (cont.)

- Novo sistema de RI baseado no MG4J (Boldi & Vigna, Universidade de Milão)
 - Permite construções de consultas mais elaboradas (AND, OR, distância de termos, *wildcards*)
 - Permite re-pesagem de termos de consulta
- Melhorias ao sistema de RIG (no XLDB, em colaboração com David Cruz)
 - Assinaturas geográficas
 - Novas **medidas de semelhança geográfica** (ainda por avaliar e melhorar)
 - **Novo motor de reformulação de consultas**

Sinopse do sistema RIG actual



QueOnde: Processamento de consultas

QueOnde = Query Engine for Ontology Defined Entities

- Lidar com as **diferentes formas de consultas** de cariz geográfico (nem tudo é *restaurantes em Lisboa*)
- Divisão em **<O quê, relação espacial, onde>**
- Reconhecimento de **"entidades geográficas" (features)** e de **"tipos de entidades geográficas" (feature types)**

Exemplo: Tráfego marítimo nas ilhas portuguesas =

Tráfego marítimo nas ilhas portuguesas

9

Reformulação de consultas


QuerCol: Query Collator, agora com dois eixos de expansão:

- Expansão geográfica
 - Orientada pelo tipo de consulta, e presença de relações espaciais, features e feature types
 - Baseada na informação da ontologia
- Expansão de termos
 - Até agora, só usei *blind relevance feedback* (retorno de relevância cego)

10


Expansão geográfica

- 1) tráfego marítimo em Portugal
- 2) tráfego marítimo em ilhas
- 3) tráfego marítimo em ilhas portuguesas



11

Expansão de termos: blind relevance feedback



- A esmagadora maioria dos grupos de investigação participantes no GeoCLEF (XLDB incluído) usam BRF. Não há nada mais "inteligente"?!¹²

Utilidade da participação no GeoCLEF em 2007

- Primeiros testes com expansão geográfica de acordo com os critérios geográficos existentes
- Usar *feature types* de maneira mais inteligente (não só para desambiguar)
- Usar assinaturas geográficas nos documentos e nas consultas (ou seja, várias entidades geográficas como parte do âmbito)
- Ou seja, dar os primeiros passos em **reformulação de consultas mais inteligente**

13

Os resultados no GeoCLEF

- A maioria dos sistemas não consegue grandes ganhos de desempenho, ao adicionar processamento geográfico.
- Inclusive, muitos sistemas RI puros obtêm resultados melhores do que RIGs!
- Porém, este ano:

	GeoScore	IR	GIR		IR/GIR
		Terms only	Geo. QE before RF	Geo. QE after RF	Terms/GIR
PT	Initial run	0.210	0.126	0.084	0.210
	Maximum		0.125	0.104	0.205
	Mean	0.233	0.022	0.021	0.048
	Boolean		0.135	0.125	0.268
	Null		0.115	0.093	0.021
a) Results for the Portuguese monolingual subtask.					
EN	Initial run	0.175	0.086	0.089	0.175
	Maximum		0.093	0.104	0.218
	Mean	0.166	0.043	0.044	0.044
	Boolean		0.131	0.135	0.204
	Null		0.081	0.087	0.208
b) Results for the English monolingual subtask.					

Esmiuçando os resultados

Parecia intuitivo que:

- separar a parte temática da parte geográfica ao início...
- ...expandir separadamente a parte temática com expansão de termos, e a parte geográfica com expansão guiada pela ontologia...
- ...usar dois índices separados (temático e geográfico)...

...produzisse melhores resultados, mas não₁₅


Termo temático vs termo geográfico

Aviso: “consuma” os seguintes exemplos com moderação.

- “Actividades piscatórias em Portugal”
 - piscatória pode dar boas indicações de que os locais de interesse são zonas costeiras
- “Naufrágios de barcos portugueses”
 - Naufrágios sugere zonas aquáticas, perto de costas, ilhas, etc.
 - termos geográficos (*portugueses*) também podem ser bons termos de expansão (ex: nomes de ilhas)

16

Separar à nascença? Sim ou não?



Rescaldo: novas experiências na forja

- Rollback completo nos sistemas GIR.
 - Analisar cada módulo ao detalhe
 - Avaliar, avaliar, avaliar (que é o grande problema da área de GIR, na minha opinião: se calhar, avançamos demasiado rápido)
 - Só depois de medir o módulo n , passar ao módulo $n+1$, e analisar a propagação dos erros
- Ou seja, de volta ao QueOnde...

18

Rescaldo: novas experiências na forja (cont.)

- Analisar os resultados com “misturas” entre parte geográfica e parte temática

	Temático	Geográfico
1
2
3
4
5
6
7
8
9
10

Table 1. Dependence of results on geographic queries.

19

Rescaldo: novas experiências na forja (cont.)

- QuerCol: mais experiências e avaliações com a reformulação de consultas
 - Adição de termos: deve haver bem melhor do que BRF
 - Re-pesagem de termos: ainda não usado
 - Termos compostos: usar índices próprios?
 - EM: útil para consultas tipo “James Bond”
 - Construção de consultas com os operadores disponíveis
 - Avaliar^{avaliar}

20

Avaliação (em cima do joelho) do QueOnde

- “Corpus”: 75 tópicos dos três anos de GeoCLEF (só títulos)
- Avaliação sistemática por módulo, ao longo do doutoramento.
- E não esquecer de fazer com consultas reais!

Ano dos tópicos do GeoCLEF	2005			2006			2007			todos os anos			
Tipo de consultas	total			total			total			total			
WHAT, REL, WHERE (feat)	20	18	2	19	14	5	13	13		52	45	7	87%
WHAT, REL, WHERE (feat + feat.type)	3	1	2	1		1	7	6	1	11	7	4	64%
WHAT, REL, WHERE (feat.type)							4	4		4	4	0	100%
REL, WHERE (feat, feat.type)	1	1		4	3	1	1	1		6	5	1	83%
REL, WHERE (feat.type)				1		1				1	0	1	0%

21

Rescaldo: novas experiências na forja (cont.)

- Wikipedia: o recurso da moda :)
 - Rico (digo eu) em referências geográficas
 - Já há trabalhos (Overell et al.) de desambiguação e mapeamento de ref. geográficas na Wikipedia na ontologia TGN.
- Proposto para o GeoCLEF 2008, a ver se é usado.
 - Assuntos novos, permite consultas novas
 - bom recurso para complementar falhas de ontologia (plano B)

23

Avaliação (em cima do joelho) do QueOnde

Ano dos tópicos do GeoCLEF	2005			2006			2007			todos os anos			
Tipo de features	total			total			total			total			
Continente (ex: Europa)	9	9	0	1	1		1,5	1,5		11,5	11,5	0	100%
Subconjunto (Ex: Sudeste Asiático)				5	4	1	5	5		10	9	1	90%
Países (ex: Portugal)	9	7	2	2,5	2,5		2,5	2,5		14	12	2	86%
Região (ex: Grande Lisboa)	2,5	0,5	2	8,5	5,5	3	5	5		16	11	5	69%
Cidade (ex: Evora)				2	2	0	3	3		5	5	0	100%
Mares/Oceanos (ex: Mediterrâneo)	2,5	2,5	0	3	3		1	1		6,5	6,5	0	100%
Ilhas (ex: ilhas escocesas)	1	1	0				2	2		3	3	0	100%
Rios/Lagos (ex: Douro)				2	2	0				2	2	0	100%
montanhas (ex: Himalaias)							1	1		1	1	0	100%
Sem features				1	0	1	4	4		5	4	1	80%

Ano dos tópicos do GeoCLEF	2005			2006			2007			todos os anos			
Tipo de relações espaciais	total			total			total			total			
Parte de + próximo	23	22	1	20	18	2	15,5	15,5		58,5	55,5	3	95%
Adjacente (beira, ao longo)	1	0	1	1	0	1				2	0	2	0%
Distância numerada (a X km de)				2	2	0				1	0	1	0%
Distância não especificada (perto)				1	0	1				1	0	1	0%
Entre							2	2		3	2	1	67%
Not (excluindo)							1	1		1	1	0	100%
nas costas							0,5	0,5		0,5	0,5	0	100%
Sem relação (ao, de, com)	1	1	0				1	1		2	2	0	100%
							5	5		5	5	0	100%

24

Porquê Wikipedia no GeoCLEF?

Dois tópicos concretos do GeoCLEF:

- “Regiões vinícolas à beira de rios na Europa”
- “Eleições livres em África”
- Intuitivamente, parece que a Wikipedia é melhor para o 1º tópico, e o CHAVE para o 2º tópico
- Por outro lado, a Wikipédia pode permitir tópicos geográficos com outra granularidade e morfologia, bem mais “desafiadores” para os sistemas RIG

Uma boa motivação

- Qual é realmente a melhor abordagem de tratamento dos termos das consultas num sistema RIG?
- Qual a melhor técnica de reformulação de consultas? Não há melhor que BRF? E a expansão geográfica já realizada carece de uma avaliação detalhada
- Que outros recursos valiosos se pode explorar, que melhorem significativamente os resultados?

25

Uma boa motivação (cont.)

- Agora que tenho um sistema RIG pronto para realizar experiências, posso analisar:
 - novas técnicas de reformulação temática (e comparar com *blind relevance feedback*)
 - aperfeiçoar a reformulação geográfica
 - talvez usar novos recursos (tesauros, dicionários de co-ocorrências, extracções referências Wikipedia) para as expansões
 - Verificar o peso de cada termo no processamento temático e no geográfico.

26

Espero, até Abril de 2008:

- Ter já uma ideia bem concreta de qual a melhor prática de utilização dos termos das consultas.
- Ter propostas concretas de novas técnicas de:
 - reformulação temática, com contribuição do raciocínio geográfico oriundo da ontologia e de outros recursos
 - reformulação geográfica, com a maturação de análise de tipos de restrições geográficas, o seu tratamento e o uso de índices temáticos

27

Espero, até Abril de 2008:

- Ter uma ideia mais concreta dos melhores recursos a “atacar”
 - avaliar a utilidade da Wikipedia, tesauros, diários de registos e outros recursos para o sistema RIG
- Prazo do GeoCLEF 2008: provavelmente, 30 de Maio. Ou seja, já ter um plano traçado para a participação, e já identificadas as experiências a avaliar.

28

Novas ideias para reformulação de consultas para RIG

Por: Nuno Cardoso

Orientadores:
Diana Santos e Mário J. Silva

Seminário Doutoral da Linguateca
4 de Outubro de 2007

Faculdade de Ciências
Universidade de Lisboa