

UNIVERSIDADE FEDERAL DE SANTA CATARINA

Construindo Aplicações na Web Semântica

Buscas Semânticas

Renato Fileto
fileto@inf.ufsc.br

Programa de Pós-graduação em Ciência da Computação – PGCC
Departamento de Informática e Estatística – INE
Centro Tecnológico – CTC

Conteúdo

- **Motivação**
- **Definição do problema**
- **Abordagens e ferramentas**
- **Conclusões**

Recuperação da Informação

- **Medidas da eficácia das soluções**

precisão = $\frac{\text{nro. de docs relevantes recuperados}}{\text{nro. de docs recuperados}}$

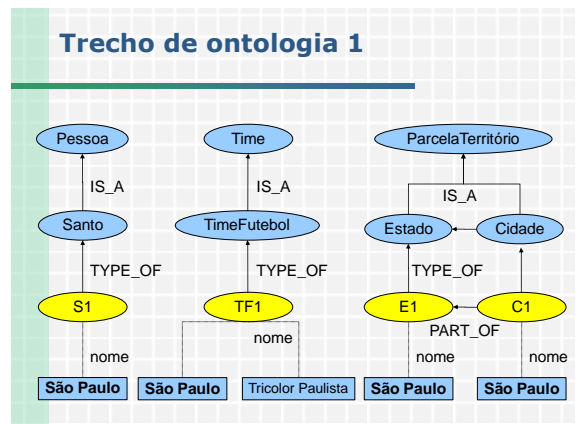
cobertura = $\frac{\text{nro. de docs relevantes recuperados}}{\text{nro. de docs relevantes}}$

Problemas da RI tradicional

- Usa somente informação léxica e sintática
- Traz todos os resultados relacionados sintaticamente com uma palavra-chave, sem organização quanto aos possíveis significados
- Não recupera resultados cujo conteúdo ou metadados referencie outras palavras com significado parecido ou relacionado
- Menospreza as características dos usuários quanto ao significado que atribuem a determinados termos

Buscas semânticas

- Consideram os significados (das consultas e do conteúdos ou metadados), procurando:
 - evitar, identificar e/ou tratar ambigüidades,
 - expandir semanticamente as buscas para significados relacionados,
 - orientar o usuário no refinamento das suas consultas,
 - apresentar os resultados classificados segundo os significados a eles atribuídos
 - ordenar os resultados segundo a relevância estimada dos diferentes significados para a consulta e o usuário que a estipulou,
 - Tornar mais rica, agradável e efetiva a interação do usuário com o sistema de busca.



Classificação de abordagens para buscas semânticas

(Mangold, 2007)

- Arquitetura
- Acoplamento entre ontologias e documentos
- Transparência
- Contexto do usuário
- Modificação de consultas
- Estrutura das ontologias
- Tecnologia para representar as ontologias
- Desempenho, escalabilidade e distribuição
- Adaptabilidade
- Ranking

Arquiteturas para buscas semânticas

- **Máquina de busca *stand alone***: armazena metadados sobre os documentos em índices com os quais avalia as consultas
- **Meta-máquina de busca**: distribui as consultas para outras máquinas de busca e combina os resultados

Acoplamento ontologias-documentos

- **Acoplamento forte**: os metadados dos documentos referem-se explicitamente aos conceitos de uma ontologia e vice-versa (requer anotação semântica)
- **Acoplamento fraco**: os documentos são independentes de quaisquer ontologias disponíveis (pode restringir a capacidade de busca)

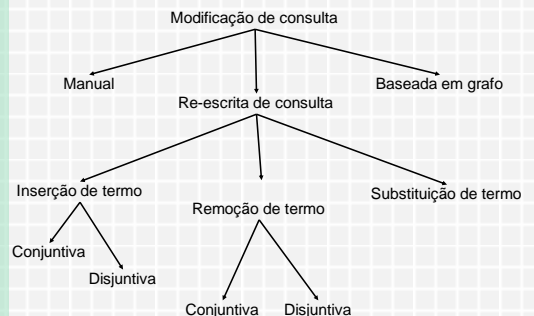
Contexto do usuário

- **Learning**: extraído na interações do usuário com o sistema (histórico das consultas e refinamentos de consultas)
- **Hard-coded**: as consultas são organizadas em categorias que definem a informação solicitada (e.g., "location of", "resources for" ...)

Modificação de consultas

- **Manual**: o sistema retorna um trecho apropriado da ontologia junto com a resposta, permitindo ao usuário navegar na ontologia e reformular a consulta pela adição e remoção de termos
- **Re-escrita automática**: a consulta é otimizada automaticamente pelo sistema
- **Baseada em grafo**: considera conceitos e documentos como nodos de um grafo, efetuando propagação da consulta a partir dos nodos correspondentes a termos de busca

Modificação de consultas



Estrutura da ontologia

- **Propriedades anônimas:** as relações entre conceitos não são nomeadas, indicando apenas que eles compartilham o mesmo contexto
- **Propriedades padronizadas:** sinônimia, hipernímia, meronímia, negação, etc.
- **Propriedades específicas de domínio:** além das propriedades padrão, considera propriedades específicas de um domínio (e.g., "tipo de câmera" em sistema para a área de fotografia)

Tecnologia da ontologia

- F-Logic
- RDF
- DAML+OIL
- Frames
- OWL
- :

Comparação de abordagens

Prototype/preparator	SWDF	Inquiral!	ZAP	Minimal grounding architecture	ZSA	Librarian agent
Ref.	Hollan and Resnicke (2000)	Stevan et al. (2001)	Babus et al. (2005)	Archer et al. (2004)	Burton-Jones et al. (2001)	Isomuro et al. (2000)
Focus	WWW	WWW	WWW	WWW	WWW	WWW
Architecture	Stand-alone	Meta	Meta	Stand-alone	Meta	Stand-alone
Coupling	Tight	-	Loose	Tight	Loose	Tight
Transparency	Interactive	Transparent	Hybrid	Transparent	Minimal	Interactive
User control	None	Hard-coded	Hard-coded and learning	None	None	Learning
Query evaluation	Manually	Comp. supp.	Graphical part-graphical	Graph-based	All sets of query rewriting	Comp. reasoning
Ontology structure	Hypertext	-	Asymmetric	Disease specific	Hypertext	Asymmetric
Ontology technology	Proprietary	-	RDF	UcInet	ZINC concepts + Friend set	Proprietary


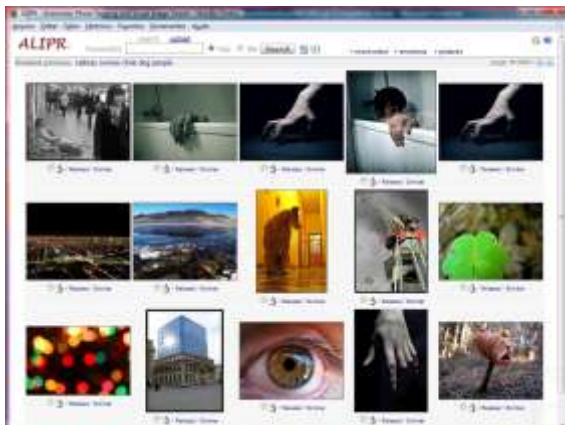
Comparação de abordagens (cont.)

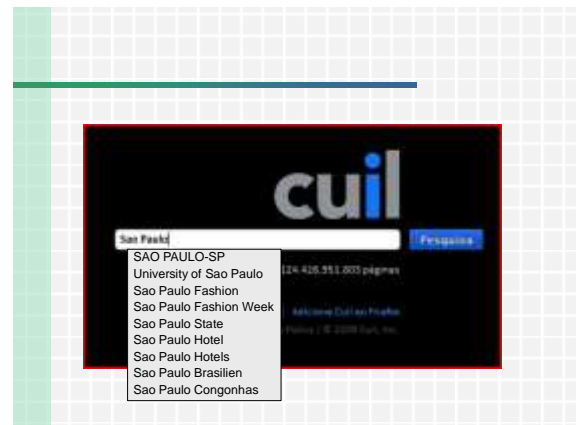
Prototype/preparator	SCORE	TRUST	Andie data-oriented	Designor	Semantically more effective
Ref.	Shen et al. (2001)	Jammi et al. (2004)	Chen et al. (2000)	Wolcott et al. (2001)	-
Focus	Information systems	Information systems	Is for audio data retrieval	Is for image retrieval	-
Architecture	Stand-alone	Hybrid	Stand-alone	Stand-alone	Open
Coupling	Tight	Hybrid	Tight	Tight	Hybrid
Transparency	Interactive	UcInet	Transparent	Interactive	Hybrid
User control	UcInet	Hard-coded	None	Hard-coded	Hard-coded and learning
Query evaluation	Manually	Comp. supp.	Comp. supp.	Substitution	Open
Ontology structure	Hypertext	Hypertext	Hypertext	Hypertext	Facilitation
	Domain	Domain	Domain	Domain	size of 28
	Specific	Not specific	Generic	Domain specific	
Ontology technology	UcInet	Proprietary	Proprietary	Proprietary	Standard

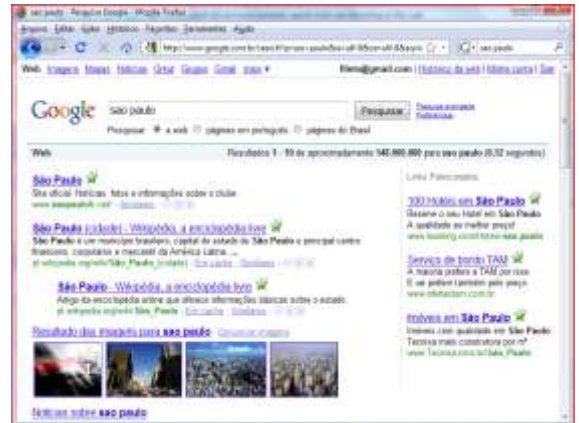
Buscas semânticas na Web hoje

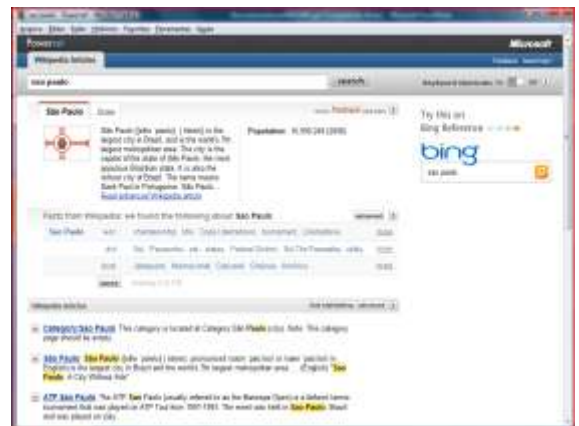
- <http://www.alipr.com> (imagens)
- <http://www.cognition.com>
- <http://www.deepdyve.com>
- <http://www.bing.com>
- <http://www.cuil.com>
- <http://www.freebase.com>
- <http://www.google.com>
- <http://www.kosmix.com>
- <http://www.hakia.com>
- <http://www.powerset.com>
- <http://www.sensebot.net>
- <http://developer.yahoo.com/searchmonkey>
- <http://swoogle.umbc.edu> (ontologias)

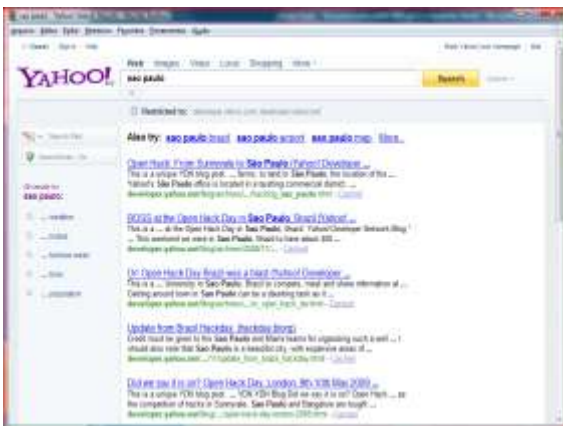















Algumas questões em aberto

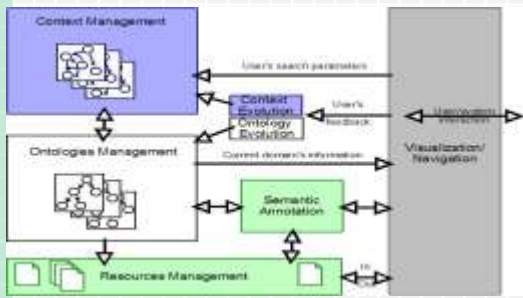
- Representação de contextos de usuários e mapeamento desses a ontologias
- Análise dos efeitos de modificações de consultas
- Meta-buscas semânticas
- Análise da aceitação dos usuários
- Adaptabilidade a diferentes ontologias
- Ranking dos resultados
- Integração com sistemas de gerenciamento de documentos/conteúdo
- Tratamento de dados multimídia
- Interfaces homem-máquina
- Desempenho e escalabilidade

Contextual Semantic Search (CSS)

(D'Agostine, Fileto - SBBD2007)



General Architecture for CSS



The Weighted Topic Graph


(D'Agostine, Fileto, Dantas, Gauthier - ICEIS 2008)

- A weighted topic graph is a graph $TM(T, A)$
 - T is a set of topics (vertices)
 - A is a set of associations (edges)
- Let O be an ontology
 - Each topic t in T corresponds to a ontology term o in O
- Each topic t has a weight $[0,1]$. The sum from the weights from all topics with same name equals 1
- Each association a has a weight $[0,1]$. The sum from all the weights from all association departing a single topics equals 1


The Weights in the Topic Graph

- **Topic weights:** used to disambiguate
 - E.g., interest in *São Paulo* city instead of *São Paulo* state
- **Association weights:** used to semantically expand searches
 - E.g., Actual interest in Guarulhos and airport while searching for *São Paulo* city


Capturing the User's Context

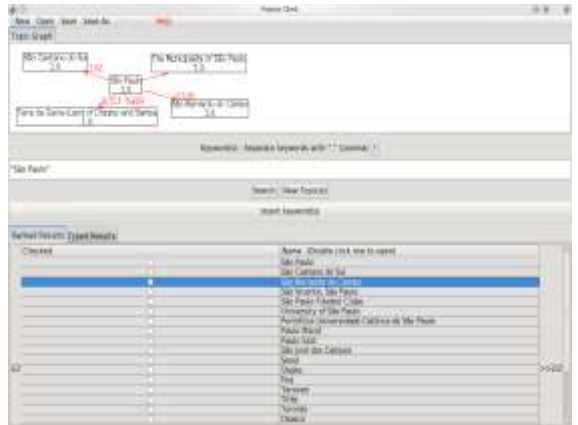
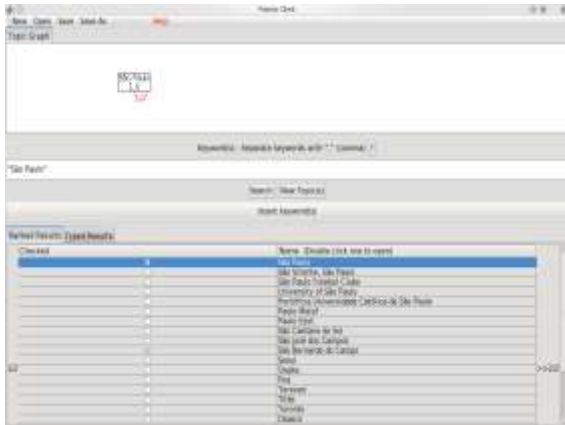
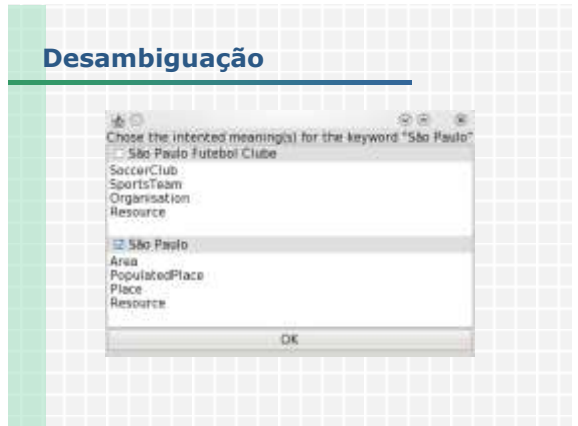


Generated Topic Graph with the Ontological User's Context



The Contextual Semantic Search Process





Fundamento dos algoritmos de busca sobre contexto ontológico

Traços de feromônio

Heurísticas de estigmergia (Ant Colony Optimization - ACO)

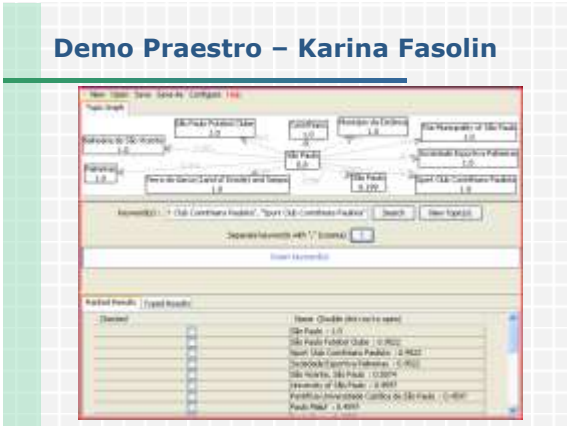
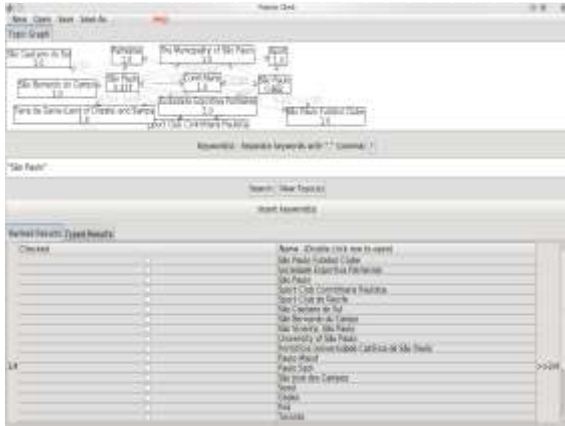
Algoritmo de busca semântica baseada em ACO

Entrada: palavras-chave [];

Dados: G(T,A), Onto, repositório,
 limite_de_profundidade,
 limite_mínimo_de_peso,
 λ // fator de atenuação de peso;

início Algoritmo Busca Contextual 1 Estigmergia
 resultados = busca_G_ou_Onto(palavras-chave[]);
 atenuaG(indice); // $\lambda \in [0, 1]$
 manutenção(coleta_feedback(resultados));

fim



Alguns trabalhos relacionados

Name	Article	Comments
Graupmann et al. 2005	The SphereSearch engine for unified ranked retrieval of heterogeneous XML and web documents	Searches through around given elements to both contexts. Made tests with stress testing no benchmark for this kind of novel system.
Park e Cheyer 2006	Just For Me: Topic Maps and Ontologies	Manages knowledge in three layers: Topics, Knowledge Structures, Documents. Not implemented (at least at the time of publication).
Michlmayr, et al. 2007	Adaptive User Profiles for Enterprise Information Access	Represents context as an individual graph. The graph is composed based on tags used to semantically annotate the content which considers to be relevant. However, the tags are only that, only labels. They are not tied-down to a formal definition.

Alguns trabalhos relacionados (cont.)

Name	Article	Comments
Aleman-Meza et al. 2003	Context-Aware Semantic Association Ranking	Also defines context as regions. But the regions are static, defined in the ontology which is used by the system. So the contexts are defined the same for every single user.
Mani and Sundaram 2007	Modeling user context with applications to media retrieval	Creates a graph representing the user's context. Each node corresponds to an instance in the ontology. The edges represent relations between the instances. Built to search through multimedia documents. However, it does not associate the vocabulary the user uses with the instances.
Challam et al. 2007	Contextual Search Using Ontology-Based User Profiles	Monitors the user's activity capturing content from open Internet Explorer, MS-Office and MSN. The captured information is stored and used to build a user's contextual profile bases on an ontology. The context is tightly coupled with the ontology.
Vallat et al. 2006	Personalized Information Retrieval in Context	Stores context as a graph constructed based on the ontology used by the system. Similar to Mani and Sundaram, including its limitations (mapping the vocabulary), however it built for text documents.
Sieg et al. 2007	Ontological User Profiles for Personalized Web Search	Similar to Challam et al., but it gets the context information from the ontology terms used to annotate the retrieved relevant context. Also limited by the structure of the ontology.

Alguns trabalhos relacionados (cont.)

Name	Deals with objective knowledge (ontology)?	Deals with subjective knowledge (user's context)?	The knowledge management is transparent?	Idea / Implemented
Graupmann et al. 2005	X			IMPL.
Park e Cheyer 2006	X	X	X	IDEA
Michlmayr, et al. 2007		X	X	IMPL.
Aleman-Meza et al. 2003	X		X	IMPL.
Mani e Sundaram 2007	X	X	X	IMPL.
Challam et al. 2007	X	X?	X	IMPL.
Vallat et al. 2006	X	X?	X	IMPL.
Sieg et al. 2007	X	X?	X	IMPL. (incomplete)
Praestro	X	X	X	IMPL. (prototype)

Trabalhos futuros

- Processos parcialmente automatizados para geração e atualização de ontologias e anotações semânticas ???
- Experimentos para comprovar a eficácia das técnicas e ferramentas utilizadas
- Validação de soluções de problemas de busca semântica em diversos domínios de aplicação
- Determinação de níveis adequados de acoplamento entre contextos e ontologias e dessas com os recursos a serem recuperados

Notícias e análises

- <http://news.cnet.com/new-search-engine-cuil-takes-aim-at-google/>
- http://www.readwriteweb.com/archives/is_google_a_semantic_search_engine.php
- http://www.readwriteweb.com/archives/semantic_search_the_myth_and_reality.php
- <http://www.pandia.com/sew/1262-top-5-semantic-search-engines.html>
- <http://mindset.research.yahoo.com/>
- http://news.cnet.com/8301-13953_3-9982015-80.html
- <http://www.searchenginejournal.com/askcom-focuses-on-semantic-search/8252/>
- http://news.bbc.co.uk/2/hi/programmes/click_online/default.stm
- http://news.bbc.co.uk/2/hi/programmes/click_online/8144765.stm

Web semântica e buscas semânticas

- <http://www.w3.org/2001/sw/>
- <http://semanticweb.org/>
- http://en.wikipedia.org/wiki/Semantic_Web
- http://en.wikipedia.org/wiki/Semantic_search

Artigos básicos

- <http://www.aifb.uni-karlsruhe.de/WBS/pha/publications/ontology-ir-ictir07.pdf>
- <http://portal.acm.org/citation.cfm?id=1359840>
- http://espace.library.curtin.edu.au/R/?func=dbin-jump-full&object_id=116029&local_base=GEN01
- <http://www.seco.tkk.fi/publications/2005/makela-semantic-search-2005.pdf>

Referências em buscas semânticas

- Guha, R., McCool, R., and Miller, E. 2003. **Semantic search**. In *Proc. of the 12th international Conference on World Wide Web (WWW)*, Budapest, Hungary. ACM, New York, NY, 2003, 700-709.
- Reeve, L. and Han, H. 2005. **Survey of semantic annotation platforms**. In *Proceedings of the ACM Symposium on Applied Computing*, Santa Fe, New Mexico. ACM, New York, NY, 2005, 1634-1638.
- Eetu Makela. **Survey of Semantic Search Research**
- Mangold, C. **A Survey and classification of semantic search approaches**. *Journal of Metadata Semantics and Ontology*, 2(1), 2007.
- Stephan Bloehdorn, Philipp Cimiano, Alistair Duke, Peter Haase, Jörg Heizmann, Ian Thurlow, Johanna Völker. **Ontology-Based Question Answering for Digital Libraries**. *ECDL 2007*: 14-25.
- Hai Dong; Hussain, F.K.; Chang, E. **A survey in semantic search technologies**. In *2nd IEEE International Conference on Digital Ecosystems and Technologies*. 2008, 403-408

Algumas referências grupo UFSC

- D'Agostini, C. S. ; Fileto, R. **Capturing Users' Preferences and Intentions in a Semantic Search System**. In: *21st International Conference on Software Engineering & Knowledge Engineering (SEKE)*, Boston, 2009. p. 587-591.
- D'Agostini, C. S. ; Fileto, R. ; Dantas, M. A. R. ; Gauthier, F. A. O. **Contextual Semantic Search - Capturing, using the User's Context to Direct Semantic Search**. In: *10th International Conference on Enterprise Information Systems (ICEIS)*, Barcelona, Spain, 2008. v. SAIC. p. 154-159.
- D'Agostini, C. S. ; Fileto, R. **Capturing and managing user context for improving information retrieval**. In: *Workshop de Teses e Dissertações do Simpósio Brasileiro de Bancos de Dados (WTDBD/SBBD)*, Campinas: Unicamp, Brazil, 2008.
- Vian, J. ; Silveira, R. A. ; Fileto, R. **Proposal of a Multi-agent System for Indexing and Recovery applied to Learning Objects**. In: *9th IFIP World Conference on Computers in Education (WCCE)*, Bento Gonçalves, Brazil, 2009.

Perguntas?

