

Incremental Methods for Information Access in Context: The Role of Topic Descriptors and Discriminators


Carlos M. Lorenzetti – Rocío L. Cecchini
Ana G. Maguitman

Laboratorio de Inv. y Des. en IA – Universidad Nacional del Sur






Problemas: ambigüedad






Problemas: ambigüedad





Problemas: ambigüedad

Animales






Problemas: ambigüedad

Animales




Computación





Problemas: ambigüedad



Animales



Computación




Alimentos

BRITISH AMERICAN
TOBACCO



Problemas: ambigüedad



Animales



Computación



BRITISH AMERICAN
TOBACCO


Alimentos



Entretenimiento



Problemas: ambigüedad



Animales



Computación



BRITISH AMERICAN
TOBACCO

Alimentos




Entretenimiento



Geografía



Problemas: ambigüedad



Animales



Computación



BRITISH AMERICAN
TOBACCO

Alimentos



Entretenimiento




Geografía



Plantas



Problemas: ambigüedad



Animales



Computación



BRITISH AMERICAN
TOBACCO

Alimentos



Entretenimiento



Geografía



Plantas



Barcos




Soluciones

Proponemos:

- identificar términos específicos
- encontrar fuentes relevantes
- generar incrementalmente consultas




Una solución: CONTEXTO





Una solución: CONTEXTO





Importancia de los términos

Método tradicional: TF-IDF

emplea la forma más simple

$$TFIDF(d,t) = TF(d,t) \times IDF(t)$$



Importancia de los términos

Método tradicional: TF-IDF

emplea la forma más simple

$$TFIDF(d, t) = TF(d, t) \times IDF(t)$$

Cuenta las apariciones
de un término en el
documento

Penaliza a aquella
palabras que son
muy comunes



Importancia de los términos

Método Propuesto: Incremental

- *Descriptores*

Términos que aparecen **muchas veces** en documentos de un mismo tema:

¿Sobre qué trata este tema?

- *Discriminadores*

Términos que **sólo** aparecen en documentos de un mismo tema:

¿Qué palabras utilizo para encontrar información similar?



Descriptores y Discriminadores

Java	Máquina	Lenguaje
Virtual	Ruby	Programación
Computadoras	NetBeans	Applets
Código	JVM	
	JDK	

Tópico: Máquina Virtual de Java



Descriptores y Discriminadores

Java

Máquina

Virtual

Ruby

Computadoras

Código

Buenos descriptores

Lenguaje

Programación

Applets

NetBeans

JVM

JDK

Tópico: Máquina Virtual de Java



Descriptores y Discriminadores





Cálculo de Descriptores y Discriminadores



Descriptores y Discriminadores en Documentos

Contexto Inicial		H			
		(1)	(2)	(3)	(4)
java	4	2	5	5	2
máquina	2	6	3	2	0
virtual	1	0	1	1	0
lenguaje	1	0	2	1	1
programación	3	0	2	2	0
café	0	3	0	0	3
isla	0	4	0	0	2
provincia	0	4	0	0	1
jvm	0	0	2	1	0
jdk	0	0	3	3	0

Tópico: Máquina Virtual de Java

- (1) espressotec.com
- (2) netbeans.org
- (3) sun.com
- (4) wikitravel.org

$$H[d_i, t_j] = k$$

Cantidad de **ocurrencias** del término k en el documento i



Descriptores de Documentos

Contexto Inicial

		$\lambda(d_0, t_j)$
java	4	0,718
máquina	2	0,359
virtual	1	0,180
lenguaje	1	0,180
programación	3	0,539
café	0	0,000
isla	0	0,000
provincia	0	0,000
jvm	0	0,000
jdk	0	0,000

Tópico: Máquina Virtual de Java

Poder **descriptivo** de un término de un **documento**

$$\lambda(d_i, t_j) = \frac{\mathbf{H}[i, j]}{\sqrt{\sum_{k=0}^{n-1} (\mathbf{H}[i, k])^2}}$$



Discriminadores de Documentos


Contexto Inicial

		$\delta(t_i, d_0)$
java	4	0,447
máquina	2	0,500
virtual	1	0,577
lenguaje	1	0,500
programación	3	0,577
café	0	0,000
isla	0	0,000
provincia	0	0,000
jvm	0	0,000
jdk	0	0,000

Tópico: Máquina Virtual de Java

Poder **discriminante** de un
término de un **documento**

$$\delta(t_i, d_j) = \frac{s(\mathbf{H}^T[i, j])}{\sqrt{\sum_{k=0}^{m-1} s(\mathbf{H}^T[i, k])}}$$



Criterio de comparación
de documentos:
Similitud por coseno

$$\sigma(d_i, d_j) = \sum_{k=0}^{n-1} (\lambda(d_i, t_k) \cdot \lambda(d_j, t_k))$$

Similitud entre
documentos



Descriptores de Tópicos

Contexto Inicial

		$\Lambda(d_0, t_j)$
java	4	0,385
máquina	2	0,158
jdk	0	0,124
café	0	0,089
isla	0	0,064
programación	3	0,055
lenguaje	1	0,040
provincia	0	0,040
jvm	0	0,032
virtual	1	0,014

Tópico: Máquina Virtual de Java

Poder **descriptivo** de un término en el tópico de un documento

$$\Lambda(d_i, t_j) = \frac{\sum_{k=0, k \neq i}^{m-1} (\sigma(d_i, d_k) \cdot \lambda(d_k, t_j)^2)}{\sum_{k=0, k \neq i}^{m-1} \sigma(d_i, d_k)}$$



Discriminadores de Tópicos

Contexto Inicial

		$\Delta(t_i, d_0)$
jvm	0	0,848
jdk	0	0,848
virtual	1	0,566
programación	3	0,566
máquina	2	0,524
lenguaje	1	0,517
java	4	0,493
café	0	0,385
isla	0	0,385
provincia	0	0,385

Tópico: Máquina Virtual de Java

Poder **discriminante** de un término en el tópico de un documento

$$\Delta(t_i, d_j) = \sum_{k=0, k \neq j}^{m-1} (\sigma(d_k, d_j) \cdot \delta(t_i, d_k)^2)$$




Implementación






Framework






Framework






Framework






Framework






Framework





Framework





Evaluación



Evaluación

Intelligent Incremental Method

1. Generar k consultas usando los términos del contexto
2. Enviar las $Q(i)$ al motor de búsqueda
3. Obtener las respuestas y convertirlas a repres. vectorial
4. Generar una lista ordenada de **descriptores**, L'_Δ
5. Generar una lista ordenada de **discriminadores**, L'_Λ
6. Actualizar incrementalmente las listas L_Λ y L_Δ
7. Generar k consultas, $Q(i) \leftarrow$ una combinación de L_Λ y L_Δ
8. Enviar las $Q(i)$ al motor de búsqueda
9. Obtener las respuestas y convertirlas a repres. vectorial
10. Para cada respuesta, comprobar si es una **buenas consulta**
11. Para cada **mala consulta**, tratar de reformularla
12. ir al paso 4



Evaluación

Naïve Method

1. Generar k consultas usando los términos del contexto
2. Enviar las $Q(i)$ al motor de búsqueda
3. Obtener las respuestas y convertirlas a repres. Vectorial
4. Generar una lista ordenada términos L_{TF} por frecuencia
5. Generar k consultas, $Q(i) \leftarrow$ una combinación de L_{TF}
6. ir al paso 2



Evaluación

Contexto Inicial

- 15 páginas en inglés del DMOZ
- Tópicos: Recreación, Negocios, Sociedad

Consulta



- 5 términos L_Δ + 1 término L_Λ
- 20 consultas simultáneas
- $\forall \alpha = 0.4$
- Motor de búsqueda: Google

Resultados analizados

- Similitudes promedio mínima y promedio por iteración



Evaluación





Trabajo a Futuro

- Evaluaciones intensivas con colecciones estándar (TREC, etc)
- Mejorar la pérdida del foco
- Evaluar métodos cualitativos para reordenar los resultados basándose en preferencias
- Pruebas con usuarios

Incremental Methods for Information Access in Context: The Role of Topic Descriptors and Discriminators

Carlos M. Lorenzetti – Rocío L. Cecchini
Ana G. Maguitman

Laboratorio de Inv. y Des. en IA – Universidad Nacional del Sur

