



HY463 - Συστήματα Ανάκτησης Πληροφοριών  
Information Retrieval (IR) Systems

Προχωρημένες Λειτουργίες Επερώτησης (II)  
Advanced Query Operations

Γιάννης Τζίτζικας

Διάλεξη : 12

Ημερομηνία :

CS463 - Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

45



Επέκταση Επερώτησης  
(Query Expansion)

In *relevance feedback*, users give additional input  
(relevant/non-relevant) on documents.

In *query expansion*, users give additional input (good/bad  
search term) on words or phrases



## Επέκταση Επερώτησης (Query Expansion)

- Τοπική Ανάλυση
  - Αναλύουμε τα (κορυφαία) έγγραφα της απάντησης
- Καθολική Ανάλυση
  - Αναλύουμε όλα τα έγγραφα της συλλογής



## Επέκταση Επερώτησης (Query Expansion) Τοπική Ανάλυση (Local Analysis)



## Αυτόματη Τοπική (Επιτόπια) Ανάλυση Automatic Local Analysis

- Μετά την διατύπωση της επερώτησης, ανάλυσε (στατιστικά) τις λέξεις που εμφανίζονται μόνο στα κορυφαία ανακτημένα έγγραφα
  - π.χ. επιλέγουμε τις 10 πιο συχνά εμφανιζόμενες λέξεις των κορυφαίων 5 εγγράφων
- Το σύστημα παρουσιάζει στο χρήστη τις πιο συχνά εμφανιζόμενες λέξεις και ο αυτός επιλέγει εκείνες που θέλει να προστεθούν στην επερώτηση
  - εναλλακτικά η επιλογή μπορεί να γίνει αυτόμata (χωρίς την παρέμβαση ή συγκατάθεση του χρήστη)
- **Επίδραση στην αποτελεσματικότητα της ανάκτησης**
  - Οι ασαφείς (ή αμφίσημες) λέξεις δημιουργούν λιγότερα προβλήματα (απ' ότι στην καθολική ανάλυση – την οποία θα αναλύσουμε παρακάτω)
  - Παράδειγμα: με τοπική ανάλυση η επερώτηση “Apple computer” μπορεί να επεκταθεί στην “Apple computer Powerbook laptop”



## Παράδειγμα εφαρμογής

YOU ARE HERE > [Home](#) > [My InfoSpace](#) > [Meta-Search](#) > Web Search Results

### Web Search Results

#### Your Search

Select:

[Yellow Pages](#)  [White Pages](#)  [Classifieds](#)

Are you looking for?

[Jacksonville Jaquars](#) [Jaquar Car](#) [Black Jaquar](#) [Jaquar Xk8](#)  
[Wild Jaquars](#) [Jaquare](#) [Jaquar Accessories](#) [Jaquar Automobile](#)

Also: see altavista, teoma



YAHOO! SEARCH

Web | Images | Video | Local | Shopping | more »

Jaguar

Search

Advanced Search

Search Results

1 - 10 of about 45,700,000 for **Jaguar** - 0.21 sec. (About this page)

Also try: [jaguar cars](#), [jaguar animal pictures](#), [jaguar parts](#), [jaguar picture](#)  
[More...](#)

SPONSOR RESULTS

- Jaguar**  
www.Shopping.com - Millions of Products from Thousands of Stores All in One Place.
- Jaguar Xk**  
Cars.InfoSpot1000.com - Seeking **Jaguar** xk Info? See The Results You Want Now.
- Jaguar Cars**  
cars.nextag.com - Compare multiple free quotes on a new car from local dealers.

1. **Jaguar**

Official site of the Ford Motor Company division featuring new **Jaguar** models and local dealer information.

[www.jaguar.com](#) - [More from this site](#)

SPONSOR RESULTS

**Jaguar**

Shop for Car Parts. Compare products, stores & prices.  
[www.Dealtime.com](#)

**Jaguar Merchandise Book**

Buy **Jaguar** merchandise Book at SHOP.COM.  
[www.SHOP.com](#)

**Jaguar Natural Spray on Cataloglink**

Find **Jaguar** natural spray on Cataloglink

MyStuff | Settings



Web | Images | Video | More ▶

jaguar

Showing results 1-10 of 10,190,000

Advanced Search

Narrow

Jaguar Cars

Black Jaguar

Cat Jaguar

Jaguar Big Cats

Jaguars Habitat

What Do Jaguars Eat

Panthera Onca

Where Do Jaguars Live

More ▶

Expand

Cheetah

Ferrari

More ▶

Related Names

Ford

Wolf

More ▶

jaguar



**Jaguar** | Save

**Kingdom:** Animalia **Phylum:** Chordata **Class:**

Mammalia **Order:** Carnivora **Family:** Felidae

**Genus:** Panthera **Species:** Panthera onca

The biggest and most powerful North American cat, the Jaguar is the only one that roars. It moves over a large home range with a diameter of 3 to 15 miles (5-25 km) where prey is abundant, larger where prey is scarce. This cat hunts... [More »](#)

[Key Facts](#) | [Images](#) | [Encyclopedia](#)

Images



[More »](#)

Dictionary

**Definitions of 'jaguar'**

(jägwar, jägyü–är) • 1 definition

The American Heritage® Dictionary

jaguar (n.) A large feline mammal (Panthera onca) of Central and South America, closely related to the leopard & having a tawny coat spotted with black rosettes.

All Music Guide



**Jaguar**

By: [Fred Small](#)

Whether an artist is conservative, centrist, liberal or downright radical, there nothing wrong with getting on [\\_](#)



## Στο google/mitos

A very simple technique is currently supported:

- For each term  $t_i$  that appears in the top L (by default L=5) documents returned by the Query Evaluator, we sum its term frequencies (i.e. all  $tf_{ij}$  where j in top-L documents) and we recommend to the user the S terms (by default S=5) with the highest accumulative frequency.

The screenshot shows the mitos search interface with the query 'google' entered. The results page displays a list of documents matching the search. A green oval highlights the query expansion section, which includes a link to 'HY-463 Συστήματα Ανάκτησης Πληροφορίας' and a note about expanding the query with terms like ανακτηση, τημ, πληροφορ, assign, and project.

Table 9. Query Expansion Examples

Initial Query		Expanded Terms					
1	retrieval	imag	medic	index	storag	system	
2	web	system	servic	page	process	cours	
3	user	interfac	layer	system	develop	softwar	

Table 10. Query Expansion Average Times

L	Time (sec)
5	0.002
10	0.003
15	0.004
20	0.004

CS463 - Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

53



## Αυτόματη Τοπική (Επιτόπια) Ανάλυση

### Τεχνικές αυτόματης τοπικής ανάλυσης

- Association Matrix
  - based on the co-occurrence of terms in documents
- Metric Correlation Matrix
  - based on the co-occurrence and proximity of terms in documents
- //Scalar Clusters
- //Local context analysis

CS463 - Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

54



## (a) Association Matrix and Normalized Association Matrix

D: τα έγγραφα της απάντησης και  $w_1 \dots w_n$  οι όροι που εμφανίζονται σε αυτά.

	$w_1$	$w_2$	$w_3$	.....	$w_n$
$w_1$	$c_{11}$	$c_{12}$	$c_{13}$	.....	$c_{1n}$
$w_2$	$c_{21}$				
$w_3$	$c_{31}$				
.	.				
.	.				
$w_n$	$c_{n1}$				

$c_{ij}$ : Correlation factor between term  $i$  and term  $j$ :

$$c_{ij} = \sum_{d_k \in D} f_{ik} \times f_{jk}$$

$f_{ik}$ : frequency of term  $i$  in document  $k$

- Normalized Association Matrix

- Frequency based correlation factor favors more frequent terms.

- Normalize association scores:

$$s_{ij} = \frac{c_{ij}}{c_{ii} + c_{jj} - c_{ij}}$$

- Normalized score is 1 if two terms have the same frequency in all documents in  $D$ .

Από αυτόν τον πίνακα μπορούμε να βρούμε τους όρους που είναι πιο κοντά σε αυτούς της επερώτησης (θυμηθείτε και τον πίνακα συσχέτισης στο fuzzy model του μαθήματος 4)



## (b) Metric Correlation Matrix

- Association correlation does not account for the proximity of terms in documents, just co-occurrence frequencies within documents.
- Metric correlations** account for term proximity.

$V_i$ : Set of all occurrences of term  $i$  in any document in  $D$ .

$r(k_u, k_v)$ : Distance in words between word occurrences  $k_u$  and  $k_v$  ( $=\infty$  if  $k_u$  and  $k_v$  are occurrences in different documents).

$$c_{ij} = \sum_{k_u \in V_i} \sum_{k_v \in V_j} \frac{1}{r(k_u, k_v)}$$

- Normalized Metric Correlation Matrix

- to account for term frequencies:

$$s_{ij} = \frac{c_{ij}}{|V_i| \times |V_j|}$$



## Query Expansion with (Association or Metric) Correlation Matrix

	$w_1$	$w_2$	$w_3$	.....	$w_n$
$w_1$	$c_{11}$	$c_{12}$	$c_{13}$	.....	$c_{1n}$
$w_2$		$c_{21}$			
$w_3$		$c_{31}$			
.		.			
.		.			
$w_n$		$c_{n1}$			

- For each term  $i$  in the query  $q$ , expand query with  $n$  terms, those with the highest value of  $c_{ij}$ .
- This adds semantically related terms in the “neighborhood” of the query terms.



Αυτόματη Καθολική Ανάλυση  
(Automatic Global Analysis)



## Αυτόματη Καθολική Ανάλυση Automatic Global Analysis

- Προσδιορισμός βαθμού ομοιότητας μεταξύ των όρων βάσει στατιστικής ανάλυσης ολόκληρης της συλλογής
  - Υπολογισμός πινάκων συσχέτισης (association matrices) που πιστοποιούν την ομοιότητα μεταξύ των όρων ανάλογα με το πόσο συχνά συνεμφανίζονται
- Επέκταση επερώτησης με τους πιο όμοιους όρους.
- Επίδραση στην αποτελεσματικότητα της ανάκτησης
  - Οι ασαφείς (ή αμφίσημες) λέξεις δημιουργούν **περισσότερα προβλήματα** (απ' ότι στην τοπική ανάλυση)
  - Παράδειγμα: με καθολική ανάλυση η επερώτηση “Apple computer” μπορεί να επεκταθεί στην “Apple red fruit orange computer”
- **Μια λύση:**
  - Query Expansion Based on a Similarity Thesaurus



## Query Expansion Based on a **Similarity Thesaurus**

- **Βασική ιδέα**
  - Οι όροι που προστίθενται στην επερώτηση καθορίζονται με βάση την απόσταση τους **από ολόκληρη την επερώτηση** (και όχι βάσει της απόστασής τους από κάθε όρο της επερώτησης ξεχωριστά)
- **Στην αντίθετη περίπτωση θα είχαμε:**
  - “Apple computer” → “Apple red fruit computer”
- **Ενώ τώρα**
  - “fruit” not added to “Apple computer” since it is far from “computer.”
  - “fruit” added to “apple pie” since “fruit” close to both “apple” and “pie.”



## Query Expansion Based on a Similarity Thesaurus

- Τρόπος

- Έστω  $N$  έγγραφα, τί όροι  $K=\{k_1, \dots, k_t\}$
- Παριστάνουμε **κάθε όρο** με ένα διάνυσμα στον χώρο των  $N$  διαστάσεων
  - Είναι σαν να έχουμε αντιστρέψει το ρόλο των όρων και των εγγράφων: έχουμε λοιπόν μια διανυσματική παράσταση των όρων (κάθε έγγραφο αποτελεί μια διάσταση στο χώρο των διανυσμάτων). Προσαρμόζουμε το σχήμα βάρυνσης TF-IDF βάσει αυτής της θεώρησης.

$$\vec{k}_i = (w_{i1}, \dots, w_{iN})$$

itf: Inverse term frequency (το ανάλογο του idf):

$$w_{ij} = \frac{(0.5 + 0.5 \frac{f_{ij}}{\max_j(f_{ij})})itf_j}{\sqrt{\sum_{l=1}^N (0.5 + 0.5 \frac{f_{il}}{\max_l(f_{il})})^2 itf_j^2}}$$

$$itf_j = \frac{\text{Num of terms in the collection}}{\text{Num of distinct terms in } d_j}$$

←ανάλογο της βάρυνσης TF\*IDF μόνο που εδώ χρησιμοποιούμε το inverse term frequency.

Yannis Tzitzikas, U. of Crete

61

CS463 - Information Retrieval Systems



## Query Expansion Based on a Similarity Thesaurus (II)

- Υπολογισμός ομοιότητας δυο όρων
  - (π.χ. με εσωτερικό γινόμενο)

$$c_{u,v} = \vec{k}_u \cdot \vec{k}_v$$

- Τα βήματα για την επέκταση της επερώτησης

- (1) Represent query in the concept space that we used to represent terms

$$\vec{q} = \sum_{k_i \in q} w_{iq} \vec{k}_i$$

- (2) Compute  $\text{sim}(q, k_u)$  for each  $k_u$

$$\text{sim}(q, k_u) = \vec{q} \cdot \vec{k}_u$$

- (3) Expand  $q$  with the top  $r$  ranked terms. The weight of each added term  $k_u$  is set

$$w_{uq'} = \frac{\text{sim}(q, k_u)}{\sum_{k_i \in q} w_{iq}}$$

- Results

- 20% improved retrieval performance

CS463 - Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

62



## Καθολική vs. Επιτόπια Ανάλυση

- Η καθολική ανάλυση έχει μεγάλο υπολογιστικό κόστος αλλά μόνο στην αρχή
  - υποθέτοντας ότι τα έγγραφα της συλλογής είναι σταθερά
- Η τοπική ανάλυση έχει αρκετό υπολογιστικό κόστος για κάθε επερώτηση
  - (παρόλο που το πλήθος των όρων και των εγγράφων είναι μικρότερο αυτού της καθολικής)
- Η τοπική ανάλυση δίδει καλύτερα αποτελέσματα



## Επέκταση επερωτήσεων: Συμπεράσματα

- Η επέκταση των επερωτήσεων με σχετιζόμενους όρους μπορεί να βελτιώσει την αποτελεσματικότητα της ανάκτησης, ιδιαίτερα την ανάκληση (recall).
- Η αλόγιστη επιλογή σχετιζόμενων όρων μπορεί να μειώσει την ακρίβεια (precision).



## Θησαυροί Όρων και Καθολική Ανάλυση



### Θησαυροί Όρων

- Ένας θησαυρός παρέχει πληροφορίες για συνώνυμα κα σημασιολογικά κοντινές λέξεις και φράσεις [see also Sec 7.2.5]

- Παράδειγμα:

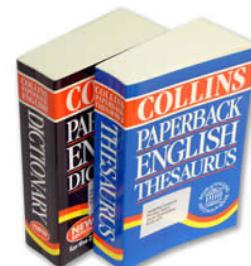
physician

syn: ||croaker, doc, doctor, MD, medical, mediciner,  
medico, ||sawbones

rel: medic, general practitioner, surgeon,

- Online-Θησαυροί:

- Roget's thesaurus
- INSPEC thesaurus
- WordNet (<http://wordnet.princeton.edu/>)
- The free dictionary <http://www.thefreedictionary.com/>





## Χρήσεις Θησαυρού

- Ευρετηρίαση κειμένων/βιβλίων με επιλογή όρου από θησαυρό
- Αναζήτηση χρησιμοποιώντας όρους του θησαυρού
  - (αυτόματη ή ύστερα από επιλογή του χρήστη)
- **Για βελτίωση της ανάκτησης**
  - Αν η απάντηση μιας επερώτησης είναι μικρή, μπορούμε να προσθέσουμε όρους βάσει των σχέσεων του θησαυρού (συνώνυμα, ..)
  - Αν απάντηση είναι πολύ μεγάλη, μπορούμε να συμβουλευτούμε το θησαυρό και να αντικαταστήσουμε κάποιους όρους της επερώτησης με πιο ειδικούς.

The screenshot shows a search results page from Ask.com. At the top, there's a navigation bar with 'MyStuff | Settings' and a search bar containing 'jaguar'. Below the search bar are links for 'Advanced Search', 'Narrow', and 'Expand'. The main search results are listed under 'Related Names' and include 'Jaguar Cars', 'Black Jaguar', 'Cat Jaguar', 'Jaguar Big Cats', 'Jaguars Habitat', 'What Do Jaguars Eat', 'Panthera Onca', and 'Where Do Jaguars Live'. There are also 'More >' links for each category. The bottom section is labeled 'Related Names' and lists 'Ford' and 'Wolf' with a 'More >' link.



## Διάκριση Θησαυρών

- **Γλωσσικοί Θησαυροί**
  - Πχ Roget's thesaurus. Designed to assist the writer in creatively selecting vocabulary
- **Θησαυροί κατάλληλοι για Information Retrieval**
  - for coordinating the basic processes of indexing and retrieval
  - designed for specific subject areas and are therefore domain dependent
  - Examples
    - INSPEC



## INSPEC thesaurus (for IR)

- Domain: physics, electrical engineering, electronics, computers
- Types of relationships between two terms
  - **UF: Used For (converse: USE)** // π.χ. USE X σημαίνει ότι ο X είναι ο δόκιμος όρος
  - **BT: Broader Term (converse NT)**
  - **TT: Top Node, i.e. root of the hierarchy**
  - **RT: Related Term**
- Example:
  - computer-ai ded instruction
    - see also education
    - UF teaching machines (UF: Used For, converse: USE)
    - BT educational computing (BT: Broader Term)
    - TT computer applications (TT: Top Node, i.e. root of the hierarchy)
    - RT education, teaching (RT: Related Term)



## WordNet (<http://wordnet.princeton.edu/>)

- A more detailed database of semantic relationships between English words. Developed by famous cognitive psychologist George Miller and a team at Princeton University.
- About 144,000 English words. Nouns, adjectives, verbs, and adverbs grouped into about 109,000 synonym sets called **synsets**.

### Synset Relationships

- **Antonym**: front → back
- **Attribute**: benevolence → good (noun to adjective)
- **Pertainym**: alphabetical → alphabet (adjective to noun)
- **Similar**: unquestioning → absolute
- **Cause**: kill → die
- **Entailment**: breathe → inhale
- **Holonym**: chapter → text (part-of)
- **Meronym**: computer → cpu (whole-of)
- **Hyponym**: tree → plant (specialization)
- **Hypernym**: fruit → apple (generalization)



- Controlled vocabulary for describing and retrieving information: fine art, architecture, decorative art, and material culture.
- Almost 120,000 terms for objects, textual materials, images, architecture and culture from all periods and all cultures.
- Used by archives, museums, and libraries to describe items in their collections.
- Used to search for materials.
- Used by computer programs, for information retrieval, and natural language processing.



## Χαρακτηριστικά Θησαυρών

- Coordination Level (**βαθμός συντονισμού**)
  - refers to the construction of phrases from individual terms
  - **Pre-coordination:** the thesaurus contain phrases
    - + the vocabulary is very precise
    - - the user has to be aware of the phrase construction rules, large size
  - **Post-coordination:** the thesaurus does not contain phrases. They are constructed while indexing/searching
    - + user does not worry about the order of the words
    - - precision may fall
- Term Relationships
  - equivalence relations (e.g. synonymy)
  - hierarchical relations (e.g. dogs BT animals,)
  - nonhierarchical relations (e.g. RT)



## Χαρακτηριστικά Θησαυρών (2)

- Number of Entries per Term
  - preferably: a single entry for each thesaurus term
  - however homonyms does not make this possible
    - parenthetical qualifiers:
      - bonds(chemical), bonds(adhesive) // χημικός δεσμός / υλικό συγκόλλησης
- Specificity of Vocabulary
  - high specificity -> large vocabulary size
- Control of Term Frequency of Class Members (for statistical thesauri)
  - the terms of a thesaurus should have roughly equal frequencies
  - the total frequency in each class (of terms) should be equal
- Normalization of Vocabulary
  - terms should be in noun form
  - other rules related to singularity of terms, spelling, capitalization, abbreviations, initials, acronyms, punctuation



## Τρόποι Κατασκευής Θησαυρών

### [A] Χειροποίητη Δημιουργία

### [B] Αυτόματη Κατασκευή

#### [B.1] από συλλογή κειμένων

Προϋπόθεση: Να υπάρχει μια μεγάλη και αντιπροσωπευτική συλλογή κειμένων

#### [B.2] από συγχώνευση άλλων θησαυρών

Προϋπόθεση: Να υπάρχουν >2 διαθέσιμοι θησαυροί για την περιοχή που μας ενδιαφέρει



## [A] Χειροποίητοι Θησαυροί (διαδικασία κατασκευής)

- define subject boundaries
- partition into divisions and subject areas
- collection of terms
  - sources: encyclopedias, handbooks, textbooks, journal titles, catalogues, other thesauri, subject experts, potential users
- analysis of terms (synonyms, hierarchical structure, definitions, scope notes)
- reviewing phase
- delivery in both hierarchical and in alphabetical arrangement
- maintenance (new terms, etc)

Very long, laborious and costly process



## Επέκταση επερωτήσεων βάσει Θησαυρού Thesaurus-based Query Expansion

- **Τρόπος:**
  - Γιά κάθε όρο της επερώτησης, πρόσθεσε στην επερώτηση τα συνώνυμα και τις σχετικές λέξεις (related terms) του της
  - Τα βάρη των νέων λέξεων μπορεί να είναι χαμηλότερα των βαρών των λέξεων της αρχικής επερώτησης
  - E.g. of a WordNet-based Query Expansion
    - Add synonyms in the same synset.
    - Add hyponyms to add specialized terms.
    - Add hypernyms to generalize a query.
    - Add other related terms to expand query.
- **Αποτέλεσμα**
  - Αυξάνει την ανάκληση (recall.)
  - Μπορεί να μειώσει την ακρίβεια (precision), ιδιαίτερα όταν η επερώτηση περιέχει αμφίσημες λέξεις
    - “interest rate” → “interest rate fascinate evaluate”



## [B1] Αυτόματη Κατασκευή Θησαυρών από Κείμενα

- Η κατασκευή (από ανθρώπους) ενός θησαυρού είναι πολύ **χρονοβόρα** και δεν υπάρχουν θησαυροί για όλες τις γλώσσες
- Οι πληροφορίες που μπορούμε να χρησιμοποιήσουμε από έναν θησαυρό περιορίζονται στις σχέσεις που υποστηρίζει ο θησαυρός
- **Ιδέα: Μπορούμε να ανακαλύψουμε σημασιολογικές σχέσεις μεταξύ λέξεων αναλύοντας στατιστικά μια μεγάλη συλλογή κειμένων**
- Στάδια
  - **1/ Κατασκευή λεξιλογίου**
  - **2/ Υπολογισμός ομοιότητας μεταξύ όρων**
  - **3/ Οργάνωση (συνήθως ιεραρχική) του λεξιλογίου**



## Αυτόματη Κατασκευή Θησαυρών από Κείμενα (II)

### 1/ Κατασκευή Λεξιλογίου

- Απόφαση: Ποιος θέλουμε να είναι ο βαθμός εξιδίκευσης (desired specificity)
  - if high then emphasis will be given on identifying precise phrases
- Οι όροι (terms) μπορούν να επιλεγούν από τους τίτλους, τις περιλήψεις (abstracts), ή ακόμα και από το πλήρες κείμενο (full text)
- Normalization: stemming, stoplists
- Criteria for selecting a term:
  - frequency of occurrence (**divide words to 3 categories: low, medium, high, select terms with medium frequency**)
  - discrimination value ~ idf
- Κατασκευή φράσεων (phrase construction) αν κάτι τέτοιο είναι επιθυμητό (θυμηθείτε coordination level)

### 2/ Υπολογισμός Ομοιότητας μεταξύ όρων

- Παραδείγματα μετρικών: Cosine, Dice



## Αυτόματη Κατασκευή Θησαυρών από Κείμενα (III)

### 3/ Οργάνωση (συνήθως ιεραρχική) του λεξιλογίου

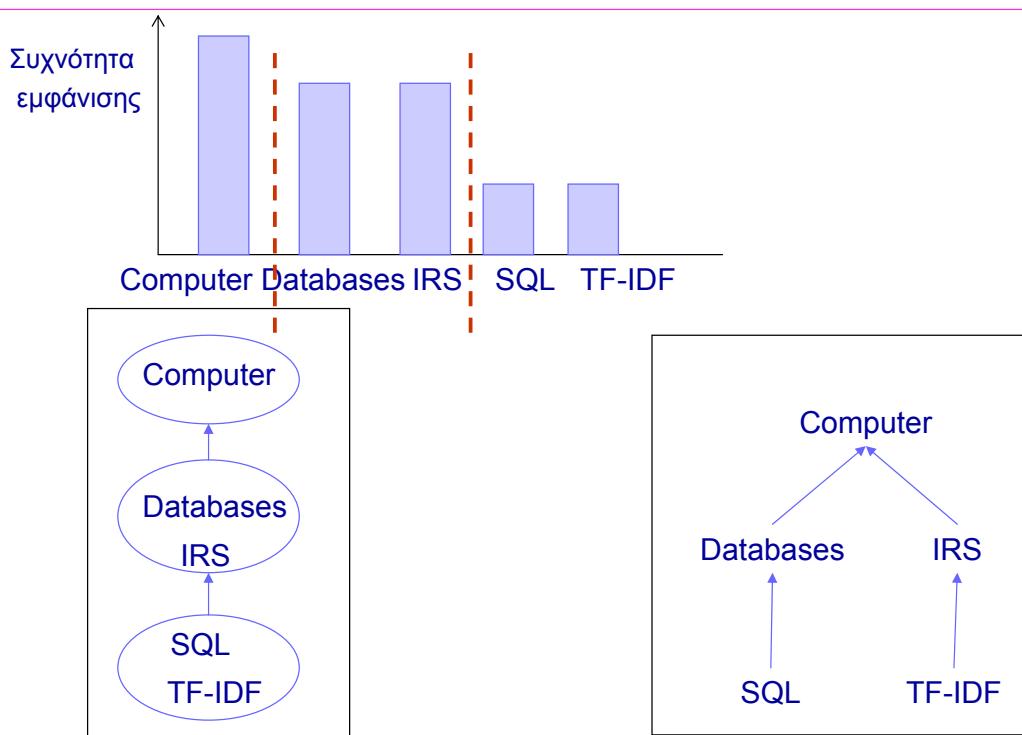
- Οποιοσδήποτε αλγόριθμος clustering μπορεί να χρησιμοποιηθεί

Ένας αλγόριθμος για ιεραρχική οργάνωση ενός λεξιλογίου:

- Identify a set of frequency ranges
- Group the vocabulary terms into different classes based on their frequencies and the ranges selected in Step 1. There will be one term class for each frequency range
- The highest frequency class is assigned level 0, the next level 1, and so on
- Parent-child links: The parent(s) of a term at level i is the most similar term in level i-1 (a term is allowed to have multiple parents)
- Continue until reaching level 1



### Παράδειγμα με 3 κλάσεις συχνοτήτων





## Case: grOOGLE'2007

- (1) Compute the minimum and maximum frequency of the words in the lexicon (denoted by  $df_{mn}$  and  $df_{mx}$  respectively).
- (2) Partition the interval  $[df_{mn}, df_{mx}]$  into  $L$  successive intervals (where  $L$  is administrator-provided), i.e.  $[df_{mn}, df_1], \dots, [df_{L-1}, df_{mx}]$ . We will refer to them with  $lev_1, \dots, lev_L$  respectively.
- (3) Ignore the intervals corresponding to low frequencies, specifically keep only the  $M$  intervals with the highest frequencies ( $M$  is administrator-provided and it should be  $M < L$ ), i.e. keep only  $lev_{L-M-1}, \dots, lev_L$ .
- (4) Assign to each of these  $M$  intervals those words whose frequency falls to that interval.
- (5) For each word  $w_i$  of level  $z$  (where  $z \leq L - 1$ ) connect it with the most "correlated" word of the level  $z + 1$  (that word will be the "parent" of  $w_i$ ).

Regarding step (5), the correlation  $c_{ij}$  between two words  $w_i$  and  $w_j$  is computed using the formula:

$$c_{ij} = \sum_{d_k \in D} tf_{ik} \times tf_{jk} \quad (1)$$

where  $tf_{ik}$  is the frequency of term  $i$  in document  $k$ .



(cont)

As an example, Table 11 describes the partitioning obtained assuming  $L = 20$  (for each level the table shows the number of words that belong to that level). To construct the taxonomy we have considered only the last 5 groups (empty groups, like level 19, are considered as non existant). So the taxonomy includes 35 words in total. After creating the connections between words we realized that each word has an average of 1.4 child nodes.

	Low frequency															High frequency					
Level	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	
Num. Of Words	21	7	14	2	11	0	3	23	29	2	19	9	12	8	3	83	83	53	52	25	18

The reason for partitioning words into groups (according to their frequency) is for avoiding computing the correlation matrix between all pairs of words (which would be formidably expensive<sup>7</sup>). In addition, ignoring those words that occur rarely further improves efficiency (as more than 95% of the vocabulary has a very small document frequency) and does not harm the quality of the result as these words do not describe the main concepts of the document corpus, and we have not anyway adequate statistical information to connect them right in a hierarchy.



(cont)

Resulting taxonomy:

```

<1> http
<2> system
<3> us
<3.1> new
<3.1.1> url
<3.1.1.1> map
<3.1.1.2> network
<3.1.1.2.1> commun
<3.1.1.2.2> gener
<3.1.1.2.3> site
<3.1.1.2.4> scienc
<3.1.1.2.5> web
<3.1.1.3> page
<3.1.1.3.1> link
<3.1.1.3.2> applic
<3.1.1.4> document
<3.1.1.5> access
<3.1.1.6> univers
<3.1.1.7> data
<3.1.1.8> process
<3.1.2> time
<3.1.3> base
<4> inform
  
```

As you can see this taxonomy is **not very good/useful**

Possible improvements:

- **Better vocabulary construction**

- The terms with high frequency are not very informative as you can see (e.g.. http, system, url, ...). Therefore we should try the **middle** levels.
- Furthermore if we had selected words that appear only in titles/abstracts then we would avoid words like: http, url, ..
- The user at run-time could even specify how specific/general the taxonomy should be (his/her choice would determine the visible part of the taxonomy)

- **Other improvements**

- It's better to show the original words (rather than stems)
- Use phrases instead of single words as terms

	Low frequency													High frequency						
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Of Words	21	7	14	2	12	83	83	53	52	25	18	18	14	14	7	8	2	0	4	



Αυτόματη Κατασκευή Ιεραρχιών

[M. Sanderson and W. B. Croft. Deriving concept hierarchies from text. In SIGIR'1999]

- Given two terms  $x$  and  $y$  from a document collection, we say that  $x$  *subsumes*  $y$ , and we write  $x \rightarrow y$  if:  $P(x|y) > 0.8$  and  $P(y|x) < 1$

$P(x|y)$  is the probability that term  $x$  occurs in a document, given that term  $y$  does

- This technique leads to creation of a hierarchy of terms, where
  - General terms appear as top-level categories
  - More specific terms appear as lower-level categories
- Pros
  - Simple and effective
- Cons
  - Requires  $n^2$  computations of conditional probabilities, where  $n$  is the number of terms in the collection
  - Requires the terms to have a unique meaning
    - However If we use this technique only on query results and by using only terms that appear more frequently in the query results than in the whole collection. then this lessens the problem of ambiguity and reduces the number of terms that form the subsumption hierarchy.



- It describes an approach for constructing multifaceted hierarchies.
- Includes methods for selecting the best parts of the generated hierarchies when it is not possible to fit all the categories on screen
- Experiments with real-life data sets indicate that automatic construction of multifaceted interfaces is feasible, and generates high-quality hierarchies



## A Data Mining approach (to organize the set of terms hierarchically)

- Let  $I = \{i_1, \dots, i_m\}$  be a set of items
- Let  $D$  be a set of transactions where each transaction is a subset of  $I$
- An association rule is an implication of the form  $X \rightarrow Y$  where  $X, Y$  are subsets of  $I$  and  $X \cap Y = \emptyset$
- A rule  $X \rightarrow Y$  holds in the transaction set  $D$  with
  - confidence  $c$  if  $c\%$  of the transactions in  $D$  that contain  $X$  also contain  $Y$
  - support  $s$  if  $s\%$  of the transactions in  $D$  contain  $X \cup Y$

Consider the case of an IR system. In that case

- The set  $I$  could be the set of all terms (the vocabulary)
- The set  $D$  could be the set of binary vectors of the documents
- A rule  $X \rightarrow Y$  would be an implication between set of terms
  - If  $|X|=|Y|=1$  then the implications are between single terms
  - If  $|X|=|Y|=2$  then the implications are between pairs of terms
- So we could exploit data mining algorithms to get a taxonomy from an IR system