



HY463 - Συστήματα Ανάκτησης Πληροφοριών
Information Retrieval (IR) Systems

Προχωρημένες Λειτουργίες Επερώτησης (II)
Advanced Query Operations

Γιάννης Τζιτζίκας

Διάλεξη : 12

Ημερομηνία : 4-5-2007



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 αυτόματα (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)
 - 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 Jaguars](#) [Jaguar Car](#) [Black Jaguar](#) [Jaguar Xk8](#)
[Wild Jaguars](#) [Jaguare](#) [Jaguar Accessories](#) [Jaguar Automobile](#)

Also: see altavista, teoma



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.

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

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



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

Showing results 1-10 of 10,190,000



Source

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

Jaguar

Gama actual, concesionarios, historia, noticias, anuncios y servicios financieros.

www.jaguar.com/

Jaguar (Panthera onca)

Jaguar (Panthera onca) facts, photos and videos. ... The Jaguar is the largest cat in the Western Hemisphere and the third largest cat in ...

www.thebigzoo.com/Animals/Jaguar.asp - Cached

Jaguar

The jaguar measures five to six feet from its nose to the tip of its tail and weighs 140 to 220 pounds (females are slightly smaller).

www.kidsplanet.org/factsheets/jaguar.html - Cached

Jaguar

Images



More >

Dictionary

Definitions of 'jaguar'

(jägwär, jägyü-är) - 1 definition
The American Heritage® Dictiona

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 &



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



(a) Association Matrix and Normalized Association 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}				

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.

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.

$r(k_u, k_v)$: 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 ποσοτικοποιούν 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

- **Keypoint**
 - Οι όροι που προστίθενται 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, t 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.

$$k_i = (w_{i1}, \dots, w_{iN})$$

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



Query Expansion Based on a Similarity Thesaurus (II)

- Υπολογισμός ομοιότητας δυο όρων

– (π.χ. με εσωτερικό γινόμενο)

$$c_{u,v} = k_u \cdot k_v$$

- Τα βήματα για την επέκταση της επερώτησης

– (1) Represent query in the concept space

$$q = \sum_{k_i \in q} w_{iq} k_i$$

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

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

– (3) Expand q with the top r ranked terms

- Results

– 20% improved retrieval performance

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



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 και 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.



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**)
 - **BT: Broader Term** (converse **NT**)
 - **TT: Top Node**, i.e. root of the hierarchy)
 - **RT: Related Term**
- Example:
 - **computer-aided 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)



AAT (Art and Architecture Thesaurus)

- 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



[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:
 - Για κάθε όρο t της επερώτησης, πρόσθεσε στην επερώτηση τα συνώνυμα και τις σχετικές λέξεις (related terms) του t
 - 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
 - Decision: Desired specificity
 - if high then emphasis will be given on identifying precise phrases
 - Terms can be selected from titles, abstracts, or even the 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
 - Phrase construction (if desired, recall coordination level)
- 2/ Υπολογισμός Ομοιότητας
 - Παραδείγματα μετρικών: Cosine, Dice



Αυτόματη Κατασκευή Θησαυρών από Κείμενα (III)

3/ Οργάνωση (συνήθως ιεραρχική) του λεξιλογίου

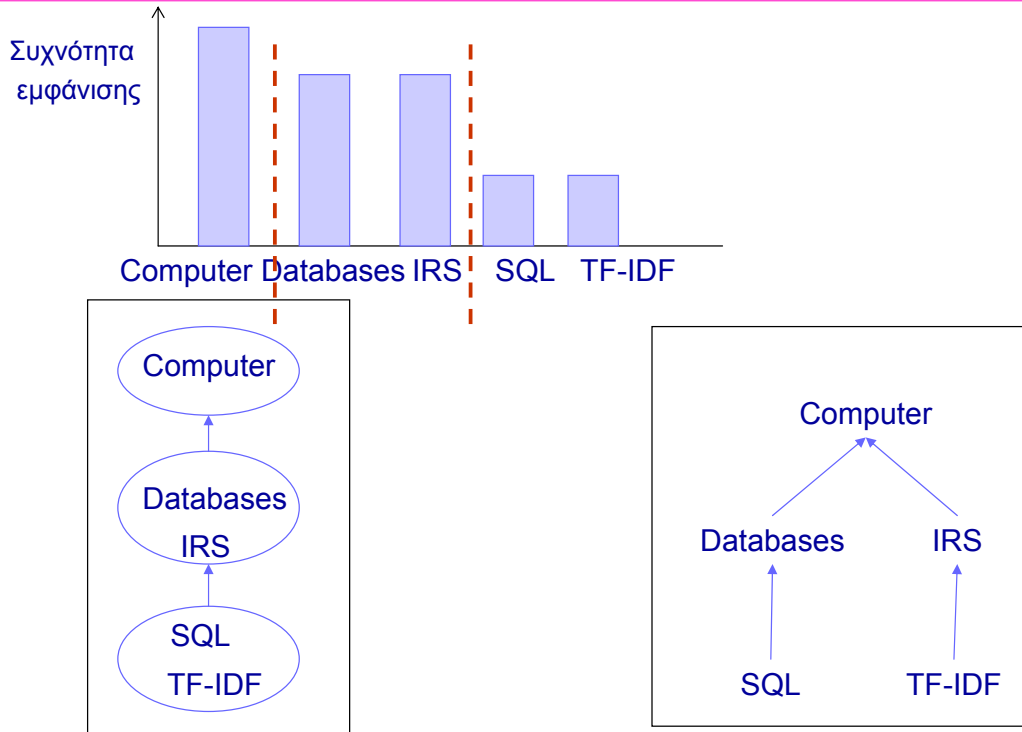
- Οποιοσδήποτε αλγόριθμος clustering μπορεί να χρησιμοποιηθεί

Ένας αλγόριθμος για ιεραρχική οργάνωση ενός λεξιλογίου

- 1/ Identify a set of frequency ranges
- 2/ 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
- 3/ The highest frequency class is assigned level 0, the next level 1, and so on
- 4/ 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)
- 5/ Continue until reaching level 1



Παράδειγμα με 3 κλάσεις συχνότητων



CS463 - Information Retrieval Systems

Yannis Tzitzikas, U. of Crete, Spring 2007

79



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

CS463 - Information Retrieval Systems

Yannis Tzitzikas, U. of Crete, Spring 2007

80