HY463 - Συστήματα Ανάκτησης Πληροφοριών
Information Retrieval (IR) Systems

Parallel and Distributed IR
Παράλληλη και Κατανεμημένη ΑΠ

Γιάννης Τζίτζικας

Διάλεξη : 16
Ημερομηνία :

Διάρθρωση Περιεχομένου

Μέρος Α: Παράλληλη Ανάκτηση Πληροφοριών (Parallel IR)

Μέρος Β: Κατανεμημένη Ανάκτηση Πληροφοριών (Distributed IR)
- Επιλογή Πηγής
- Ενοποίηση Αποτελεσμάτων

Μέρος Γ: Ανάκτηση Πληροφοριών σε Ομότιμα Συστήματα (Peer-to-Peer Systems)

Μέρος Α

Παράλληλη Ανάκτηση Πληροφοριών

Παράλληλη Ανάκτηση Πληροφοριών: Διάρθρωση

- Κίνητρο
- Μέτρα Απόδοσης Παράλληλων Προγραμμάτων
- Παράλληλη Επεξεργασία και Ανάκτηση Πληροφοριών
  - Parallel Multitasking
  - Partitioned Parallel Processing
- Διαμερισμός Εγγράφων (για MIMD αρχιτεκτονική)
- Διαμερισμός Όρων (για MIMD αρχιτεκτονική)

Κίνητρο

- Όσο πιο μεγάλη είναι μια συλλογή κειμένων, τόσο πιο ακριβή γίνεται η διαχείρισή της από ένα ΣΑΠ
- Ανάγκη για αρχιτεκτονικές και τεχνικές για **βελτίωση της απόδοσης**
  - The volume of electronic text available online today is staggering.
  - The WWW contains over 30 billions pages of text.

Παράλληλος Προγραμματισμός

- Παράλληλος Προγραμματισμός: Η ταυτόχρονη χρήση πολλών επεξεργαστών για την επίλυση ενός προβλήματος
- Ταξινομία αρχιτεκτονικών (κατά Flynn):
  - SISD single instruction, single data
  - SIMD single instruction, multiple data
    - N processors running the same program on different parts of the data, e.g. Thinking machine
  - MISD multiple instruction, single data
    - N processors running different programs on a single data stream in shared memory
  - MIMD multiple instruction, multiple data
    - N processors, N instruction streams, N data streams
    - the most common architecture. It also captures ***distributed*** computing architectures
      - the main difference between MIMD parallel computer and a Distributed System is the communication cost (which is less in MIMD)

Μέτρα Απόδοσης Παράλληλων Προγραμμάτων (Parallel Program Performance Measures)

Speedup

$$S = \frac{\text{Running time of best available sequential algorithm}}{\text{Running time of parallel algorithm}}$$

Αν έχω N επεξεργαστές, τότε στην ιδανική περίπτωση Speedup=N

Δυστυχώς, αυτό δεν είναι πάντα (συνήθως) εφικτό διότι:

- ένα πρόβλημα μπορεί να μην αναλύεται σε N ανεξάρτητα υποπροβλήματα
- επιπλέον κόστος ελέγχου (scheduling, συχρονισμός)
- το πρόβλημα μπορεί να περιλαμβάνει ένα εγγενώς σειριακό υποπρόβλημα

Μέτρα Απόδοσης Παράλληλων Προγραμμάτων (Parallel Program Performance Measures)

[Amdahl's Law]

Αν f είναι το ποσοστό του προβλήματος που πρέπει να επιλυθεί σειριακά, τότε **η μέγιστη επιτάχυνση** (speedup) που μπορεί να επιτευχθεί με χρήση N επεξεργαστών είναι:

$$S \leq \frac{1}{f + (1-f)/N} \leq \frac{1}{f}$$

Αν f=0 τότε S <= 1/(0+(1-0)/N) = 1/(1/N)=N

Αν f=1 τότε S <= 1/(1+(1-1)/N) = 1

Αν f=0.5 τότε S <= 1/(0.5+(1-0.5)/N) = 1/(0.5 + 0.5/N)=2N/(N+1)

για N=2 S=4/3 = 1.3

για N=10 S=20/11 = 1.81

Ανάκτηση Πληροφοριών και
Παράλληλη Επεξεργασία

Ανάκτηση Πληροφοριών και Παράλληλη Επεξεργασία

- Προσεγγίσεις
  - (A) Σχεδιασμός **νέων** τεχνικών ΑΠ που να είναι κατάλληλες για παράλληλη επεξεργασία
  - (B) **Προσαρμογή υπαρχόντων** τεχνικών για παράλληλη επεξεργασία
    - θα εστιάσουμε σε αυτή την προσέγγιση και θα δούμε πως γνωστές τεχνικές μπορούν να εφαρμοστούν σε αρχιτεκτονικές MIMD

MIMD Architectures

- MIMD (multiple instruction, multiple data)
  - N processors, N instruction streams, N data streams

- Ένα ΣΑΠ μπορεί να εκμεταλευτεί μια MIMD μηχανή με δυο τρόπους:
  - Parallel multitasking;
  - Partitioned parallel processing.

MIMD Architectures: **Parallel Multitasking**

Parallel multitasking on a MIMD machine

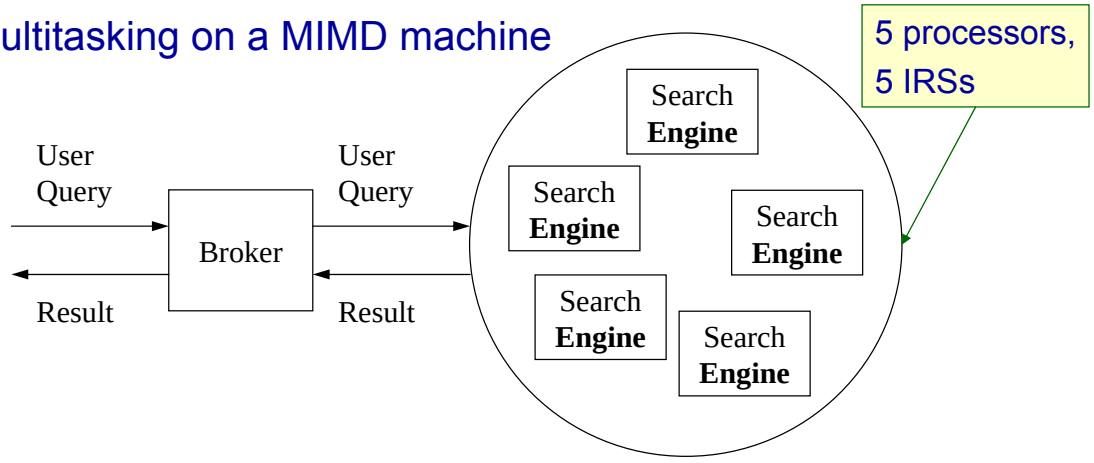

- όσο περισσότεροι επεξεργαστές υπάρχουν, τόσο περισσότερες είναι οι επερωτήσεις που μπορούν να απαντηθούν στον ίδιο χρόνο
- ο χρόνος αποτίμησης μιας επερώτησης παραμένει ο ίδιος
- η πρόσβαση στο δίσκο μπορεί να προκαλέσει συμφόρηση
  - αντιμετώπιση: επανάληψη δεδομένων (replication)

MIMD Architectures: **Partitioned Parallel Processing**

Partitioned parallel processing on a MIMD machine

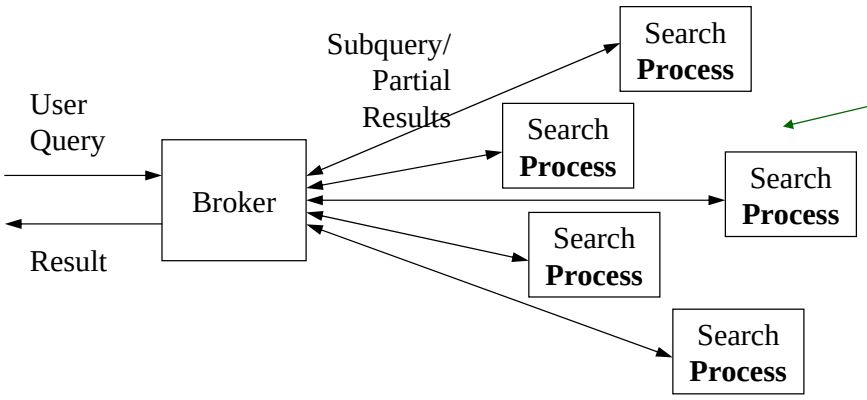

Η αποτίμηση έχει διαμεριστεί σε 5 διαδικασίες. Κάθε μία εκτελείται σε έναν επεξεργαστή

- εδώ ο χρόνος αποτίμησης μιας επερώτησης είναι μικρότερος
  - οι υπολογισμοί για την αποτίμηση **μιας** επερώτησης **κατανέμονται** σε πολλούς επεξεργαστές
  - κάθε επεξεργαστής υπολογίζει ένα τμήμα της επερώτησης και στέλνει τα αποτελέσματα στον Broker.

MIMD Architectures: Partitioned Parallel Processing

Partitioned parallel processing on a MIMD machine

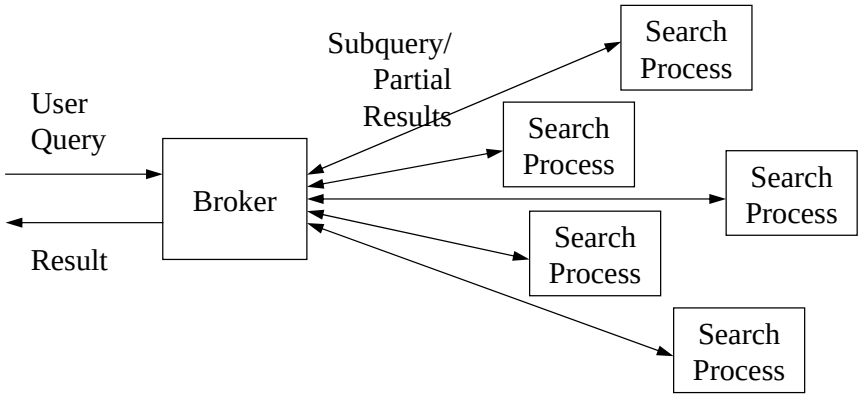

Πώς να διαμερίσουμε την αποτίμηση μιας επερώτησης ;

=>

Πώς να διαμερίσουμε τα δεδομένα ενός ΣΑΠ;

Τα βασικά δεδομένα που επεξεργάζεται ένα αλγόριθμος ανάκτησης

Indexing Items

Documents		k_1	k_2	. . .	k_i	. . .	k_t
	d_1	$w_{1,1}$	$w_{2,1}$	. . .	$w_{i,1}$	. . .	$w_{t,1}$
	d_2	$w_{1,2}$	$w_{2,2}$	. . .	$w_{i,2}$	. . .	$w_{t,2}$
	. . .	. . .	. . .	. . .	. . .	. . .	. . .
	d_j	$w_{1,j}$	$w_{2,j}$	. . .	$w_{i,j}$	. . .	$w_{t,j}$
	. . .	. . .	. . .	. . .	. . .	. . .	. . .
	d_N	$w_{1,N}$	$w_{2,N}$	. . .	$w_{i,N}$	. . .	$w_{t,N}$

Document Partitioning

Indexing Items

Documents		k_1	k_2	. . .	k_i	. . .	k_t
	d_1	$w_{1,1}$	$w_{2,1}$	. . .	$w_{i,1}$	. . .	$w_{t,1}$
	d_2	$w_{1,2}$	$w_{2,2}$	. . .	$w_{i,2}$	. . .	$w_{t,2}$
	. . .	. . .	. . .	. . .	. . .	. . .	. . .
	d_j	$w_{1,j}$	$w_{2,j}$	. . .	$w_{i,j}$	. . .	$w_{t,j}$
	. . .	. . .	. . .	. . .	. . .	. . .	. . .
	d_N	$w_{1,N}$	$w_{2,N}$	. . .	$w_{i,N}$	. . .	$w_{t,N}$

- the *N* documents are distributed across the *P* processors
- each parallel process evaluates the query on the subcollection of *N/P* documents assigned to it

Term Partitioning

Indexing Items

Documents	k_1	k_2	. . .	k_i	. . .	k_t
d_1	$w_{1,1}$	$w_{2,1}$	. . .	$w_{i,1}$	. . .	$w_{t,1}$
d_2	$w_{1,2}$	$w_{2,2}$	. . .	$w_{i,2}$	. . .	$w_{t,2}$
. . .	. . .	. . .	. . .	. . .	. . .	. . .
d_j	$w_{1,j}$	$w_{2,j}$	. . .	$w_{i,j}$	. . .	$w_{t,j}$
. . .	. . .	. . .	. . .	. . .	. . .	. . .
d_N	$w_{1,N}$	$w_{2,N}$	. . .	$w_{i,N}$	. . .	$w_{t,N}$

- the *t* indexing items are distributed across the *P* processors
- the evaluation process for each document is spread over multiple processors

Document and Term Partitioning **for Inverted Files**

- Document Partitioning
  - **Physical** Document Partitioning
  - **Logical** Document Partitioning
- Term Partitioning

Παράδειγμα Συλλογής Κειμένων και του Ανεστραμμένου Ευρετηρίου

Document Corpus

Doc	Text
1	Pease porridge hot
2	Pease porridge cold
3	Pease porridge in the pot
4	Pease porridge hot, pease porridge not cold
5	Pease porridge cold, pease porridge not hot
6	Pease porridge hot in the pot

Inverted File

Dictionary	Inverted Lists
cold	<2,1> <4,1> <5,1>
hot	<1,1> <4,1> <5,1> <6,1>
in	<3,1> <6,1>
not	<4,1> <5,1>
pease	<1,1> <2,1> <3,1> <4,2> <5,2> <6,1>
porridge	<1,1> <2,1> <3,1> <4,2> <5,2> <6,1>
pot	<3,1> <6,1>
the	<3,1> <6,1>

MIMD
Inverted Files: **Physical** Document Partitioning

Doc	Text	
1	Pease porridge hot	*P1*
2	Pease porridge cold	
3	Pease porridge in the pot	*P2*
4	Pease porridge hot, pease porridge not cold	
5	Pease porridge cold, pease porridge not hot	*P3*
6	Pease porridge hot in the pot	

Η συλλογή εγγράφων κατανέμεται στους επεξεργαστές

Κάθε υποσυλλογή έχει το **δικό της ανεστραμμένο αρχείο**

P1

cold	<2,1>
hot	<1,1>
pease	<1,1> <2,1>
porridge	<1,1> <2,1>

P2

cold	<4,1>
hot	<4,1>
in	<3,1>
not	<4,1>
pease	<3,1> <4,2>
porridge	<3,1> <4,2>
pot	<3,1>
the	<3,1>

P3

cold	<5,1>
hot	<5,1> <6,1>
in	<6,1>
not	<5,1>
pease	<5,2> <6,1>
porridge	<5,2> <6,1>
pot	<6,1>
the	<6,1>

MIMD
Inverted Files: **Physical** Document Partitioning

Original
Inverted File

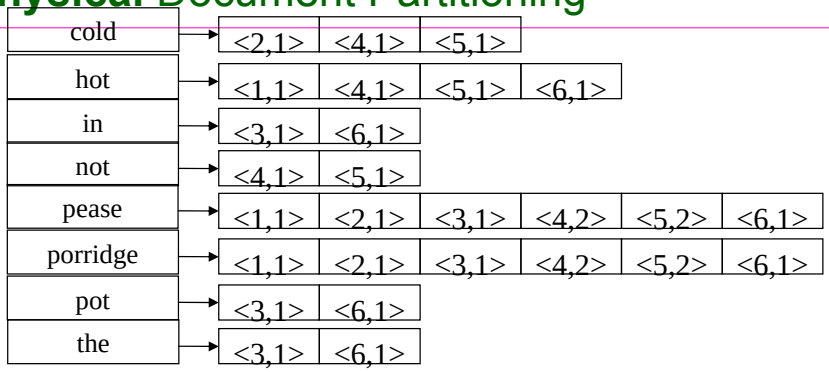

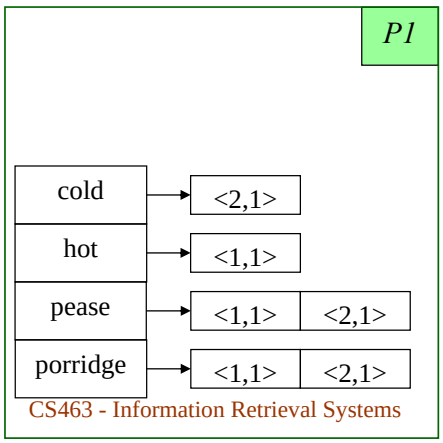

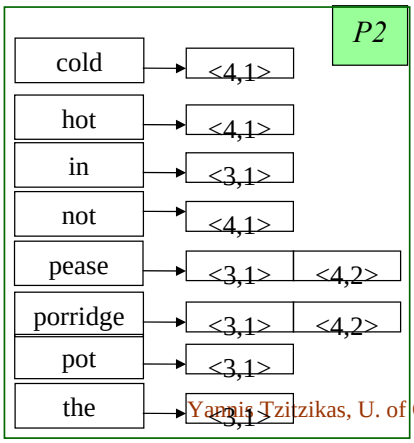

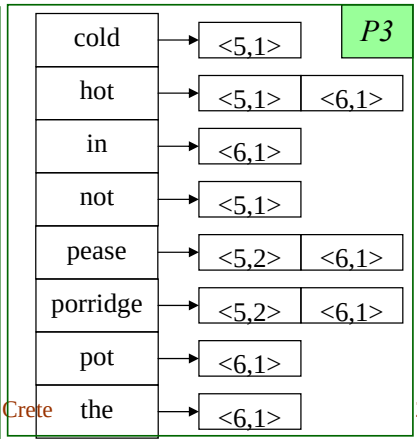

MIMD
Inverted Files: **Physical** Document Partitioning

- Κατασκευή Ανεστραμμένων Ευρετηρίων
  - Κάθε επεξεργαστής κατασκευάζει (εν παραλλήλω), ένα **πλήρες ευρετήριο** για τα έγγραφα του.
  - Κάνουμε ένα **βήμα συγχώνευσης** προκειμένου να υπολογίσουμε τα καθολικά στατιστικά (global statistics), δηλαδή **IDF**, και κατόπιν τα στέλνουμε στα ευρετήρια των επεξεργαστών.
- Αποτίμηση Επερωτήσεων
  - Ο μεσίτης (broker) ξεκινά *P* παράλληλες επεξεργασίες
  - Κάθε επεξεργασία εκτελεί τον ίδιο αλγόριθμο (scoring) στα έγγραφα που έχουν εκχωρηθεί στον επεξεργαστή
  - Ο μεσίτης παράγει την τελική διάταξη των εγγράφων

Document and Term Partitioning **for Inverted Files**

- Document Partitioning
  - **Physical** Document Partitioning
  - **Logical** Document Partitioning
- Term Partitioning

Inverted Files: **Logical** Document Partitioning

Η συλλογή εγγράφων κατανέμεται στους επεξεργαστές, αλλά κάθε υποσυλλογή **δεν έχει το δικό της ευρετήριο**, αλλά η δομή του ευρετηρίου επιτρέπει στον κάθε επεξεργαστή την άμεση πρόσβαση στο κομμάτι του ευρετηρίου που τον ενδιαφέρει

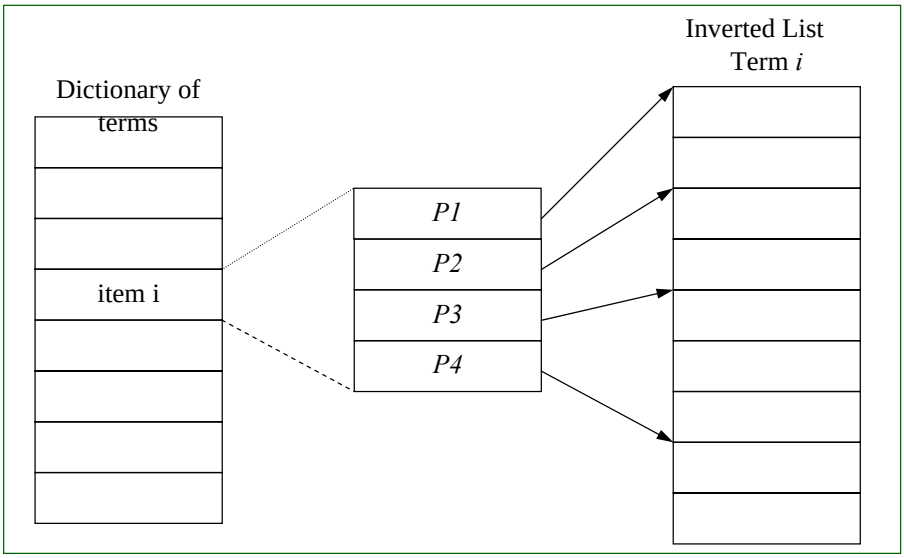

Logical Document Partitioning

Original Inverted File

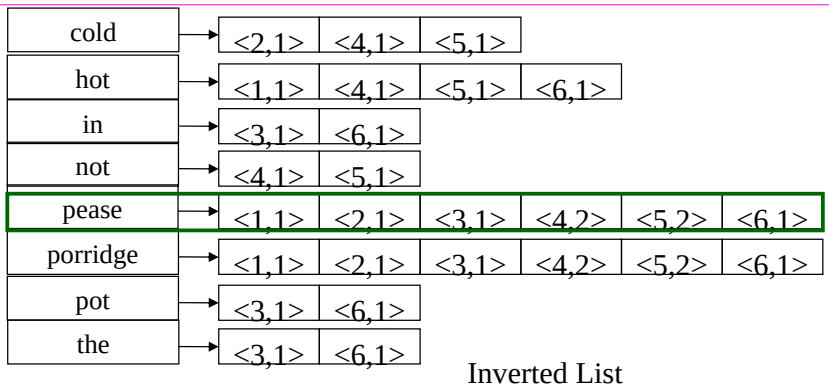

Extended Dictionary

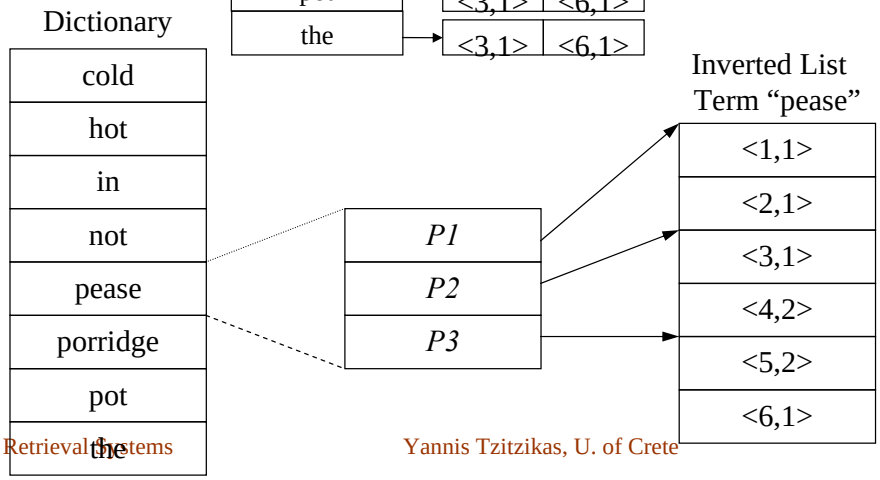

MIMD
Inverted Files: **Logical** Document Partitioning

- Κατασκευή Ανεστραμμένου Ευρετηρίου
  - Τα έγγραφα διαμερίζονται στους επεξεργαστές;
  - Κάθε επεξεργαστής ευρετηριάζει τα δικά του και δημιουργεί **ανεστραμμένες λίστες** ("lala", doc1(2), doc2(6)) , ταξινομημένες αλφαβητικά
  - Συγχωνεύουμε τις λίστες αυτές για έτσι προκύπτει το **τελικό ευρετήριο**
    - θυμηθείτε από την διάλεξη 9: Merging partial indices to obtain the final
- Αποτίμηση Επερωτήσεων (όπως και το Physical Doc. Partitioning)
  - Ο μεσίτης (broker) ξεκινά *P* parallel επεξεργασίες
  - Κάθε επεξεργασία εκτελεί τον ίδιο αλγόριθμο (scoring) στα έγγραφα που έχουν εκχωρηθεί στον επεξεργαστή
  - Τα αποτελέσματα γράφονται σε έναν κοινό πίνακα (shared array)
  - Ο μεσίτης παράγει την τελική διάταξη των εγγράφων

Διαφορές μεταξύ Physical kai Logical document partitioning

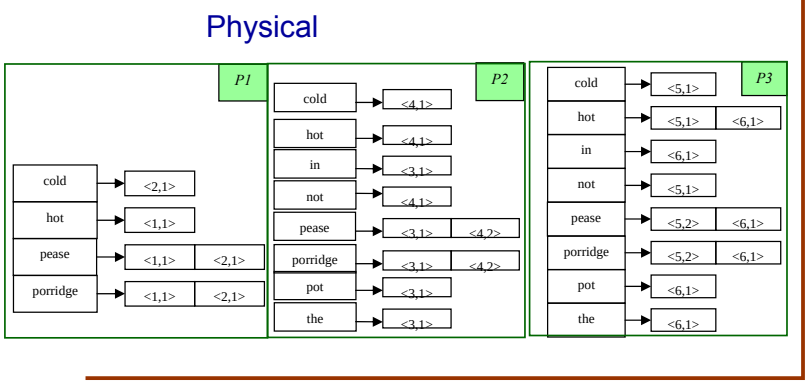

- Logical Document Partitioning
  - Κάθε λέξη του λεξιλογίου είναι αποθηκευμένη μόνο 1 φορά
  - οι διαδικασίες προσπελαύνουν το ίδιο κεντρικό ευρετήριο
    - προσβάσεις ανάγνωσης, άρα δεν έχουμε συμφόρηση
    - λιγότερη επικοινωνία (στο Physical, υπάρχει η φάση υπολογισμού των καθολικών στατιστικών (IDF)).

MIMD Architectures: Partitioned Parallel Processing
Document and Term Partitioning **for Inverted Files**

- Document Partitioning
  - **Physical** Document Partitioning
  - **Logical** Document Partitioning
- **Term Partitioning**

MIMD
Inverted Files:**Term** Partitioning

Term Partitioning

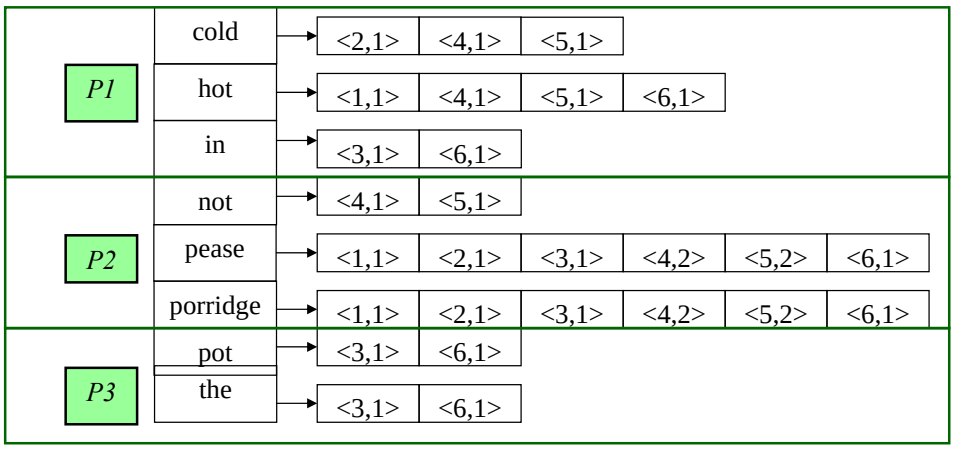

MIMD
Inverted Files:**Term** Partitioning

- Κατασκευή Ανεστραμμένου Ευρετηρίου (όπως στο Log. D. Par.)
  - Τα έγγραφα διαμερίζονται στους επεξεργαστές;
  - Κάθε επεξεργαστής ευρετηριάζει τα δικά του και δημιουργεί **ανεστραμμένες λίστες** (“lala”, doc1(2), doc2(6)) , ταξινομημένες αλφαβητικά
  - Συγχωνεύουμε τις λίστες αυτές για έτσι προκύπτει το **τελικό ευρετήριο**
  - **Κατόπιν το ευρετήριο διαμερίζεται στους επεξεργαστές**

- Αποτίμηση Επερωτήσεων
  - Η επερώτηση αναλύεται στους όρους της, και κάθε ένας στέλνεται στον επεξεργαστή που έχει την αντίστοιχη ανεστραμμένη λίστα
  - Οι επεξεργαστές υπολογίζουν **μερικά-σκορ** (partial document scores) και τα στέλνουν στον μεσίτη
  - Ο μεσίτης υπολογίζει τα τελικά σκορ **συνδιάζοντας τα μερικά**, και παράγει την τελική απάντηση

MIMD: Document and Term Partitioning for Inverted Files: **Σύνοψη**

- Οργάνωση ευρετηρίου σε μία MIMD μηχανή:
  - Document partitioning (physical or logical);
  - Term partitioning.
- Document partitioning
  - simpler inverted index construction and maintenance than term partitioning;
  - performs better when term distributions in the documents and queries are more skewed
- Term Partitioning
  - performs better when terms are uniformily distributed in user queries.
  - Επίσης όταν οι επερωτήσεις περιέχουν λίγους όρους

MIMD: Partitioned Parallel Processing
Document Partitioning **for Signature Files**

Signature Files: Επανάληψη

b=3 (3 words per block) B=6 (bit masks of 6 bits)

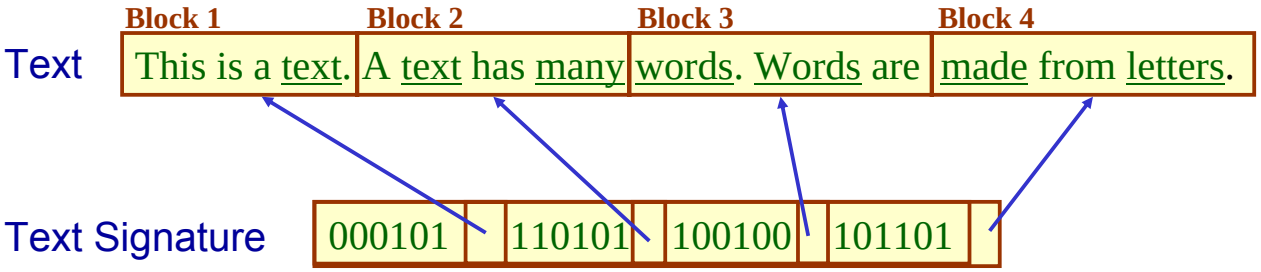

Signature Function

h(text)= 000101
h(many)= 110000
h(words)=100100
h(made)= 001100
h(letters)=100001

MIMD: Partitioned Parallel Processing

Document Partitioning **for Signature Files**

Doc	Text	
1	Pease porridge hot	*P1*
2	Pease porridge cold	
3	Pease porridge in the pot	*P2*
4	Pease porridge hot, pease porridge not cold	
5	Pease porridge cold, pease porridge not hot	*P3*
6	Pease porridge hot in the pot	

Sign. File 1 | Sign. File 2

Sign. File 3 | Sign. File 4

Sign. File 5 | Sign. File 6

- Each processor creates the signatures of its own documents
- Each processor evaluates the query signature totally. The broker then merges the results

Μέρος Β

Κατανεμημένη Ανάκτηση Πληροφοριών
(Distributed Information Retrieval)

Κατανεμημένη Ανάκτηση Πληροφοριών: Διάρθρωση

- Κίνητρο
- Σχέση μεταξύ Παράλληλης και Κατανεμημένης Αν. Πληροφοριών
- Σχεδιαστικά Ζητήματα
- Διαμέριση Συλλογών και Εγγράφων
- Επιλογή Πηγής
- Ενοποίηση Αποτελεσμάτων

Κατανεμημένη ΑΠ: Κίνητρο

- Το κίνητρο για Παράλληλη ΑΠ ήταν η **βελτίωση της απόδοσης**
- Για την Κατανεμημένη ΑΠ δεν είναι μόνο αυτό.
- Είναι και η ανάγκη **ενοποιημένης πρόσβασης** στα έγγραφα πολλών συστημάτων ανάκτησης πληροφοριών

Κατανεμημένη Ανάκτηση Πληροφοριών

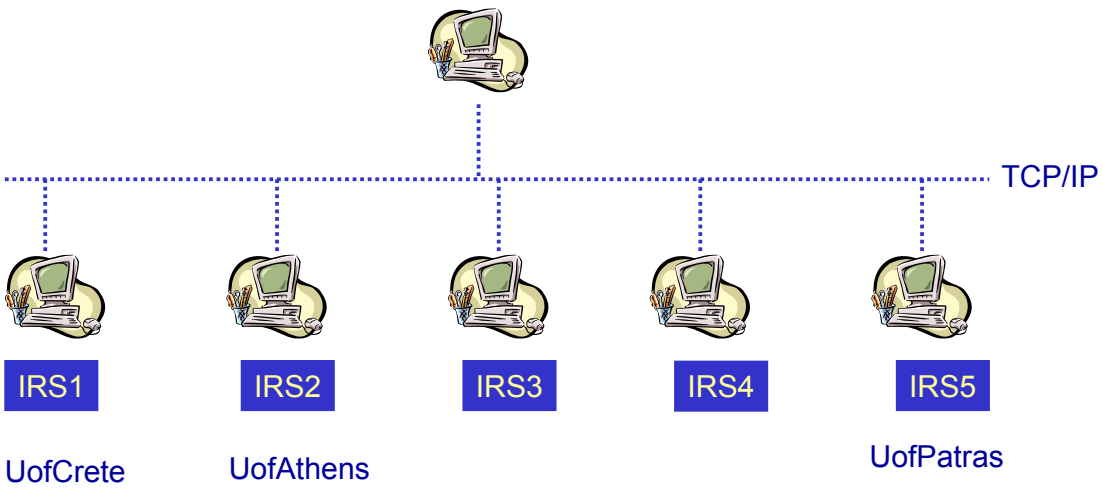

Κατανεμημένη Ανάκτηση Πληροφοριών

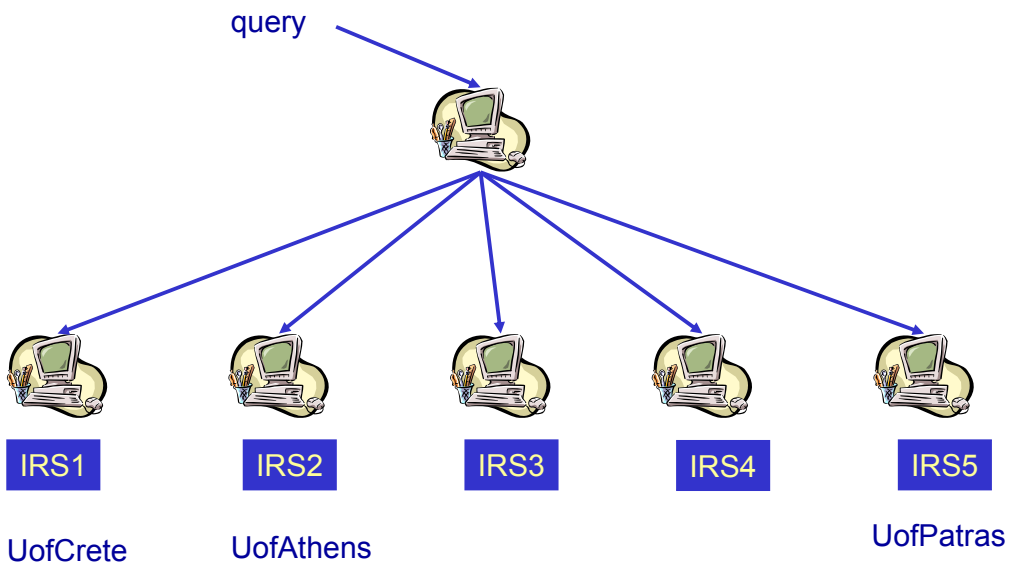

Κατανεμημένη Ανάκτηση Πληροφοριών

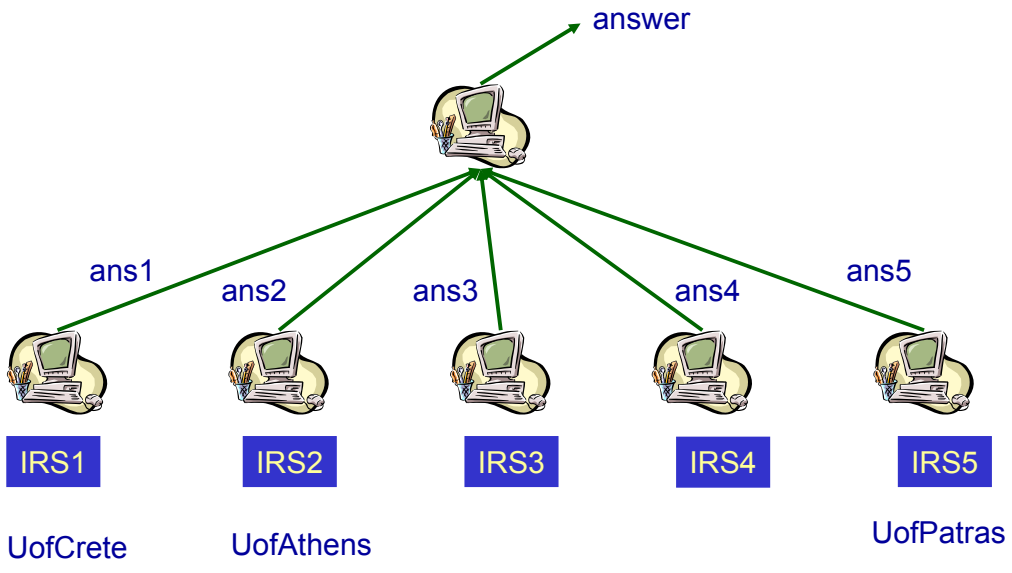

Ποια η Σχέση μεταξύ Παράλληλης και Κατανεμημένης Ανάκτησης Πληροφοριών;

- Η κατανεμημένη μοιάζει με την παράλληλη αρχιτεκτονική MIMD
- Διαφορές με την MIMD
  - το **κανάλι επικοινωνίας** μεταξύ των επεξεργαστών είναι πολύ πιο αργό
  - δεν έχουμε τους ίδιους επεξεργαστές (όπως σε μια παράλληλη μηχανή)
  - στην κατανεμημένη ο μεσίτης (broker) συχνά επιλέγει να χρησιμοποιήσει μόνο ένα υποσύνολο των υποκείμενων συστημάτων

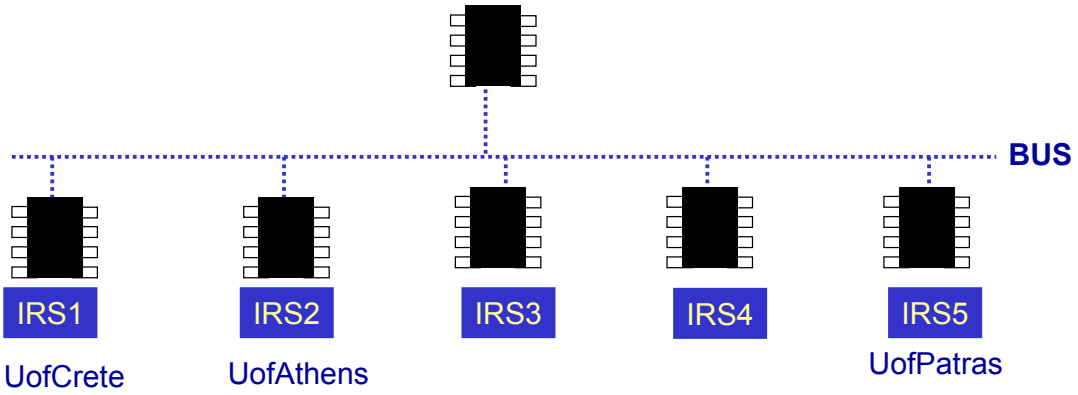

Σχέση μεταξύ Παράλληλης και Κατανεμημένης Αν. Πλ.

Ποια προσέγγιση του **Partitioned Parallel Processing** είναι κατάλληλη για την Κατανεμημένη Ανάκτηση;

- **document partitioning:** ενδείκνυται για την κατανεμημένη ανάκτηση
- **term partitioning:** δεν είναι πολύ καλή διότι απαιτεί περισσότερη επικοινωνία (για αυτό σπάνια υιοθετείται από ένα κατανεμημένο σύστημα

Κατανεμημένη Ανάκτηση: Σχεδιαστικά ζητήματα

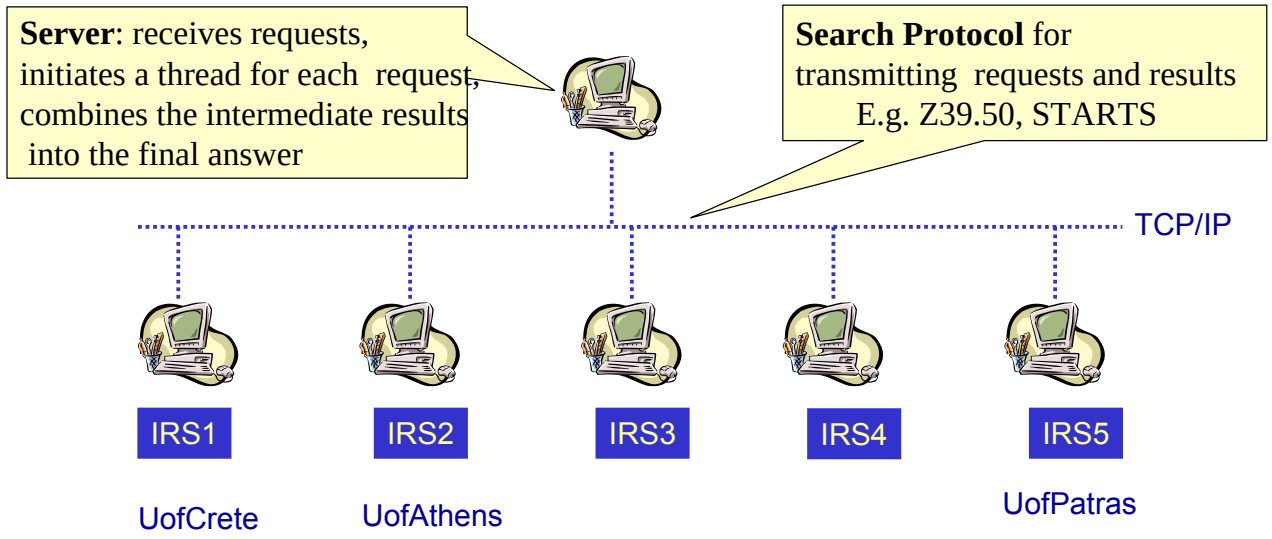

- **distribute** documents across servers
- **selection** of the servers to receive a particular request
- **combine** the results of multiple servers

Διαμερισμός Συλλογών (Collection Partitioning)

- Δεν τίθεται τέτοιο ζήτημα αν τα υποκείμενα συστήματα είναι ετερογενή

- Σενάρια για την περίπτωση που υπάρχει κεντρικός έλεγχος:
  - **Semantic**-based partition of collections to servers
    - Search Servers focusing on a particular subject area
      - E.g. Maths, Physics, etc
  - **Semantic**-based partition of documents to servers
    - π.χ. με χρήση ενός αλγορίθμου ομαδοποίησης (clustering)
  - **Replications** of collections to all servers
    - για βελτίωση throughput (μοιάζει με το multitasking)
    - όταν οι συλλογές δεν είναι μεγάλες
  - **Τυχαία διανομή** εγγράφων στους servers
    - για βελτίωση της απόδοσης στην περίπτωση που η συλλογή είναι πολύ μεγάλη

Επιλογή Πηγής (Source Selection)

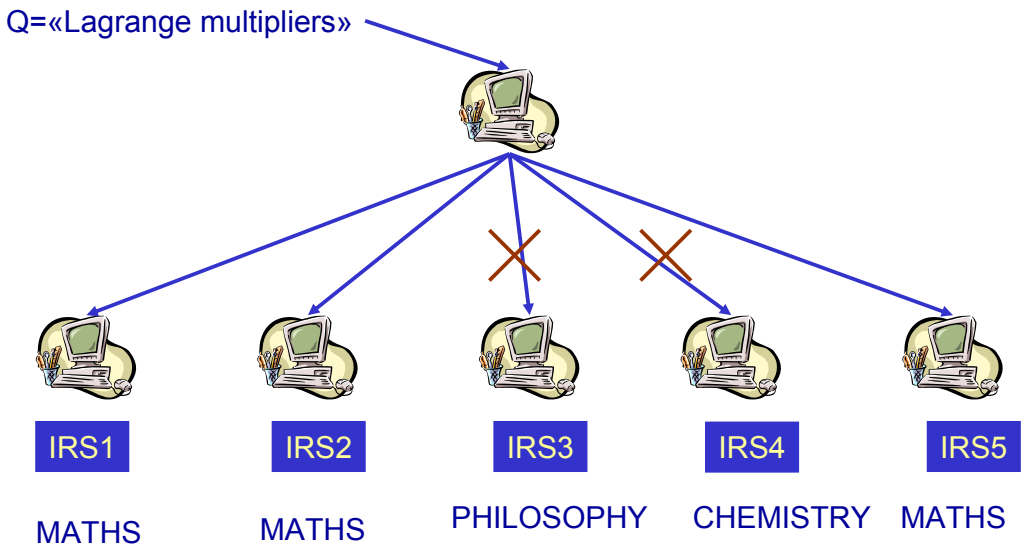

Source Selection: Επιλογή των συλλογών που είναι πιθανόν να έχουν συναφή έγγραφα με την τρέχουσα επερώτηση

Για ποιο λόγο να κάνουμε Επιλογή Πηγής;

- Η αναζήτηση σε κάθε συλλογή μπορεί:
  - να είναι **ακριβή σε χρόνο** (αφού μπορεί να έχουμε εκατοντάδες συλλογές)
  - να είναι **ακριβή σε χρήμα** (η αναζήτηση μπορεί να έχει χρηματικό κόστος)
  - να καθορίσει την **αποτελεσματικότητα** (effectiveness) της ανάκτησης

Επιλογή Πηγής: Επιλογή **Όλων**

- Κατάλληλη κυρίως για διαμερισμό μιας μεγάλης συλλογής πάνω από ένα **τοπικό δίκτυο**
- Εύκολη ενοποίηση αποτελεσμάτων για το Boolean model
  - answer(q) = ans1(q) ∪ … ∪ ansk(q)
- Η ενοποίηση αποτελεσμάτων για τα στατιστικά μοντέλα είναι πιο δύσκολη (*το ζήτημα αυτό θα μελετηθεί παρακάτω*)

Επιλογή Πηγής: **Χειρονακτική Ομαδοποίηση** και Επιλογή

- Θεματική οργάνωση συλλογών (χειρονακτικώς)
  - πχ ***μαθηματικά, φυσική, ειδήσεις***, κλπ
  - προβλήματα
    - χρονοβόρα διαδικασία, ευάλωτη σε ασυνέπειες/παραλείψεις, δεν θα δουλέψει καλά για μη-συνηθισμένες επερωτήσεις
- Ο χρήστης επιλέγει τη θεματική κατηγορία

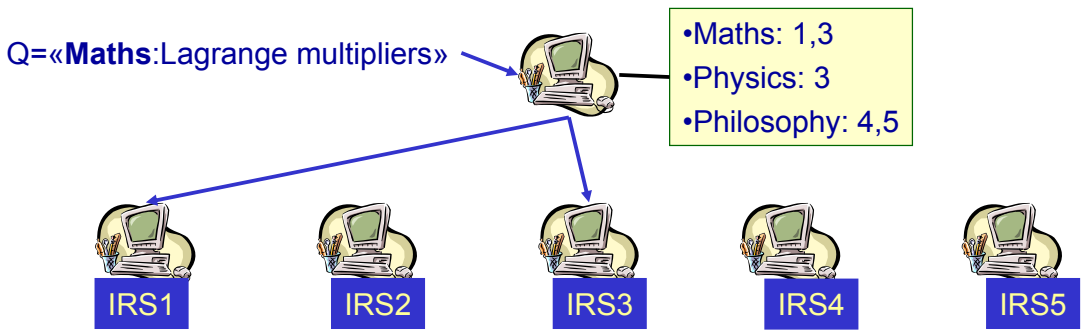

Επιλογή Πηγής βάσει **Κανόνων** (Rule-based)

- Τα περιεχόμενα κάθε συλλογής περιγράφονται σε μια **Βάση Γνώσης**
- Ένα Σύστημα Κανόνων επιλέγει τις πηγές για κάθε εισερχόμενη επερώτηση
- Αδυναμίες
  - κόστος συγγραφής κανόνων
  - ανάγκη συντήρησης των κανόνων (αν οι συλλογές είναι δυναμικές)

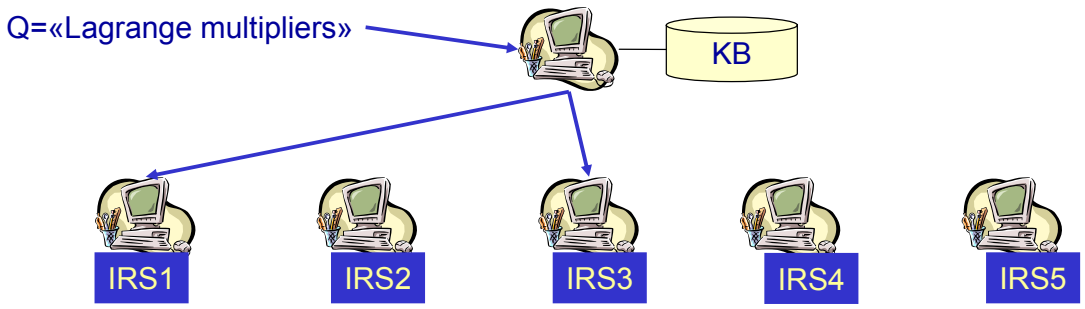

Επιλογή Πηγής: **Κατανομή Συναφών** Εγγράφων (Relevant Document Distribution (RDD))

Φτιάξε μια βάση με επερωτήσεις και την πιθανή κατανομή των συναφών εγγράφων σε κάθε συλλογή (με κάποιο τρόπο)

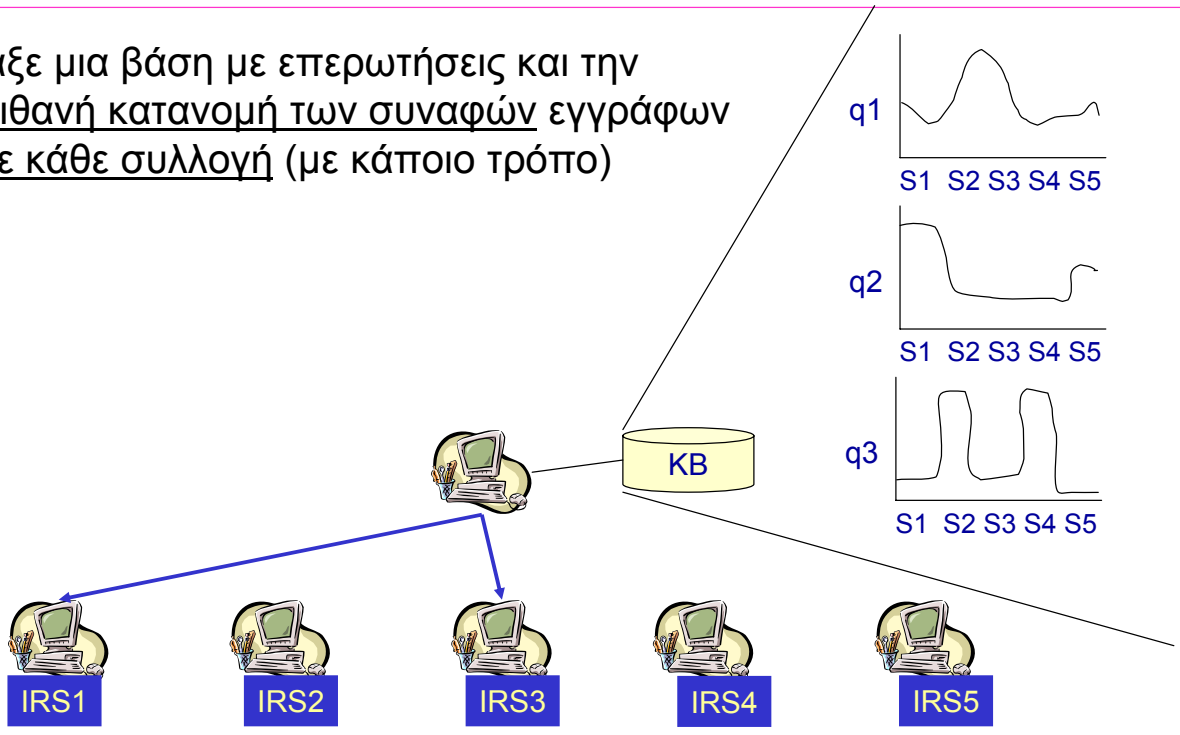

Επιλογή Πηγής: **Κατανομή Συναφών** Εγγράφων (Relevant Document Distribution (RDD))

Για κάθε νέα επερώτηση q που λαμβάνει το σύστημα

- Βρίσκουμε τις κ πιο κοντινές επερωτήσεις στη βάση (similar past queries)
- Από τις κατανομές τους, εκτιμούμε πόσα συναφή έγγραφα με την νέα επερώτηση έχει κάθε πηγή
- Αποφασίζουμε πόσα έγγραφα να ζητήσουμε από κάθε συλλογή (αν 0 δεν στέλνουμε επερώτηση)

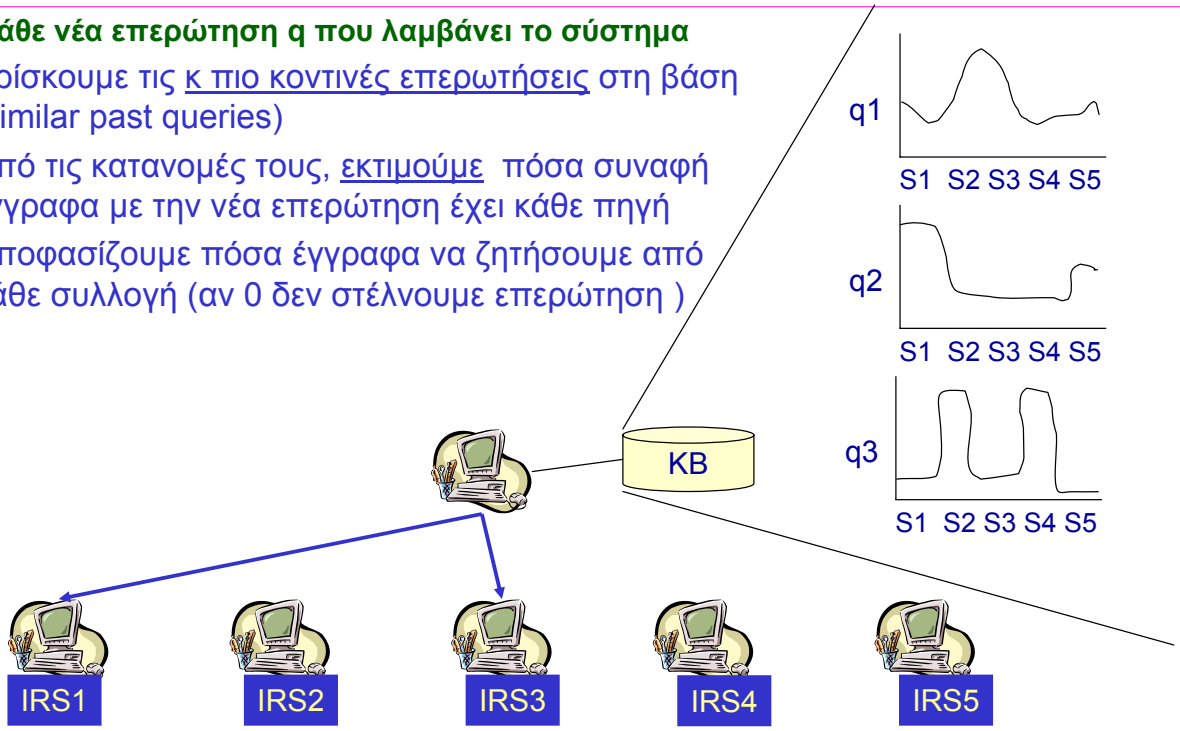

Επιλογή Πηγής: **Επερώτηση Βολιδοσκόπησης** (Query Probing)

- Στέλνουμε μια **επερώτηση βολιδοσκόπησης** σε κάθε συλλογή (που μπορεί να περιλαμβάνει μερικούς από τους όρους της επερώτησης)
  - κάθε συλλογή απαντά με στατιστικές πληροφορίες
    - πχ: μέγεθος συλλογής, πόσα έγγραφα έχουν τον κάθε όρο, πόσα έγγραφα έχουν όλους τους όρους της επερώτησης, κλπ
  - βάσει αυτών των στοιχείων επιλέγουμε την πηγή

- Υποθέσεις
  - η επεξεργασία των επερωτήσεων βολιδοσκόπησης είναι πολύ φθηνότερη
    - περιέχουν λίγους όρους, δεν χρειάζεται να υπολογίσουμε βαθμούς συνάφειας ή να διατάξουμε τα έγγραφα ως προς τη συνάφεια τους

Επιλογή Πηγής με **Διανύσματα Πηγών**

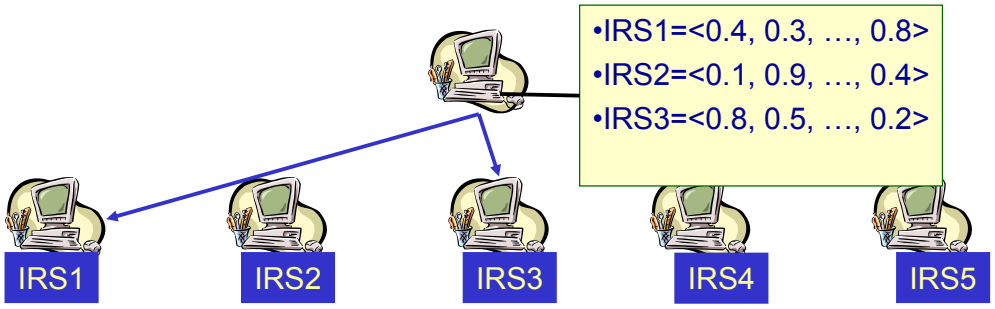

- Βλέπουμε **κάθε συλλογή** ως ένα **μεγάλο έγγραφο**
- Φτιάχνουμε ένα **διάνυσμα για κάθε συλλογή** (τύπου TF-IDF)
  - tfij: συνολικές εμφανίσεις του όρου i στη συλλογή j
  - idfi: log(N/ni), όπου N το πλήθος των συλλογών, και ni το πλήθος των συλλογών που έχουν τον όρο i
- Υπολογίζουμε το **βαθμό ομοιότητας κάθε νέας επερώτησης με το διάνυσμα κάθε συλλογής** (π.χ. ομοιότητα συνημίτονου)
- Διατάσσουμε τις συλλογές και επιλέγουμε τις κορυφαίες

Επιλογή Πηγής με **Διανύσματα Πηγών (II)**

- Μια αδυναμία:
  - Μπορεί ο βαθμός ομοιότητας με μία συλλογή να είναι μεγάλος, αλλά να μην υπάρχει κανένα έγγραφο εκεί με μεγάλο βαθμό συνάφειας
- Ένας τρόπος αντιμετώπισης:
  - Για κάθε συλλογή φτιάξε N/B διανύσματα, δηλαδή ένα διάνυσμα για κάθε B έγγραφα της συλλογής
  - Αν B=1 τότε ο server είναι σαν να έχει το ευρετήριο όλων των συστημάτων
  - Αν B=N τότε έχουμε ένα διάνυσμα για κάθε συλλογή

Επιλογή Πηγής: **GlOSS**
(**Gl**ossary of **S**ervers **S**erver)

- Estimate the number of potentially relevant documents in a collection C for a Boolean AND query Q as:

$$|C| \cdot \prod_{t \in Q} \frac{df_t}{|C|}$$

$$df_t : \text{number of docs in C that contain t}$$

- |C| the number of documents in the collection C
- Requires that for each collection *C we* have an entry in a centralized index
  - centralized index is small, easy to maintain

Επιλογή Πηγής: **gGlOSS** και **hGlOSS**

- **gGlOSS**
  - Extends the GlOSS approach to the vector space model
    - Each collection is represented by its centroid vector
    - Standard inner product similarity measure of query to each collection
    - Rank collections accordingly
- **hGlOSS** (hierarchical GlOSS)
  - Extends the gGlOSS approach to sets of gGlOSS indexes
  - Each gGlOSS index is represented by its centroid vector

Επιλογή Πηγής: Σύνοψη

- Προσεγγίσεις για μικρό αριθμό συλλογών
  - **Επιλογή Όλων**
  - **Χειρονακτική Ομαδοποίηση (και χειρονακτική επιλογή)**
  - **Επιλογή βάσει Κανόνων (Rule-based selection)**
  - **Κατανομή Συναφών Εγγράφων (Relevant document distribution (RDD))**
  - **Βολιδοσκόπηση Επερώτησης (Query Probing)**
  - **Διανύσματα Πηγών**
- Προσεγγίσεις για μεγάλο αριθμό συλλογών
  - **Διανύσματα Πηγών**
  - **GIOSS**

HARVEST

A distributed architecture to gather and distribute data
- used by CIA, NASA, US National Academy of Sciences

Gatherers: ευρετηριάζουν >=1 Web Server περιοδικά

Brokers: απαντούν επερωτήσεις βασιζόμενοι στα ευρετήρια των gatherers ή άλλων brokers (και ενημερώνουν αυξητικά τα ευρετήρια τους)

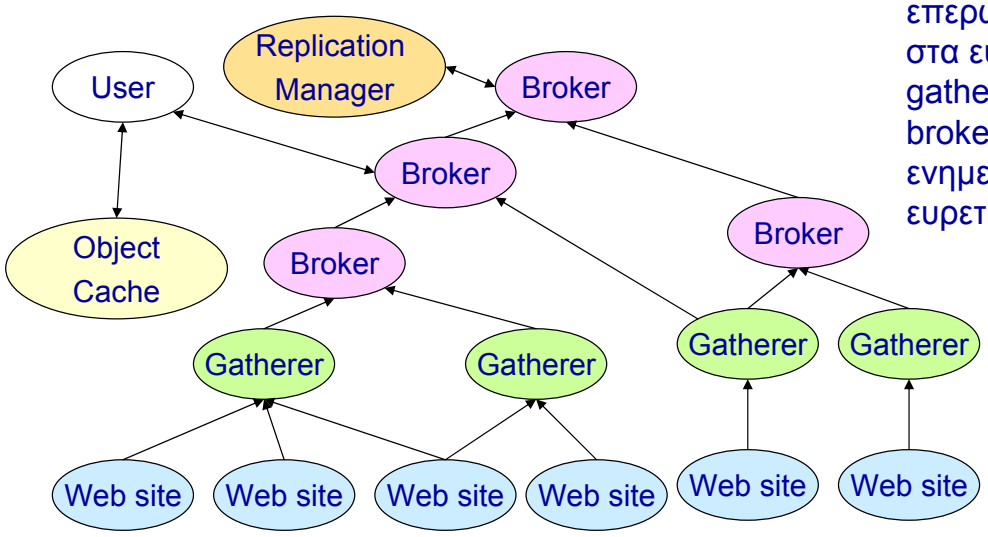

HY463 - Συστήματα Ανάκτησης Πληροφοριών
Information Retrieval (IR) Systems

Parallel and Distributed IR
Παράλληλη και Κατανεμημένη ΑΠ

Ενοποίηση Αποτελεσμάτων
(… Results Merging, Fusion, Rank Aggregation, ...)

Γιάννης Τζίτζικας

Διάλεξη :
Ημερομηνία :

Ενοποίηση Αποτελεσμάτων
Διάρθρωση

- Κατηγορίες Τεχνικών Ενοποίησης: Απομονωμένες και Ολοκληρωμένες
- Τεχνικές Ενοποίησης
  - Round Robin interleaving
  - Score-based
  - Weighted Score-based
  - Global-statistics
- Μετα-Μηχανές Αναζήτησης
- Ενοποίηση Διατάξεων (Rank-Aggregation)
  - Επιθυμητές Ιδιότητες
  - Ενοποίηση κατά Borda
  - Ενοποίηση κατά Condorcet
  - Το Θεώρημα του Ανέφικτου του K. Arrow (Arrow's Impossibility theorem)
  - Ενοποίηση κατά Kemeny
  - Αποδοτικοί αλγόριθμοι υπολογισμού των κορυφαίων κ στοιχείων της ενοποιημένης διάταξης (Top-K Rank Aggregation)

Ενοποίηση Αποτελεσμάτων

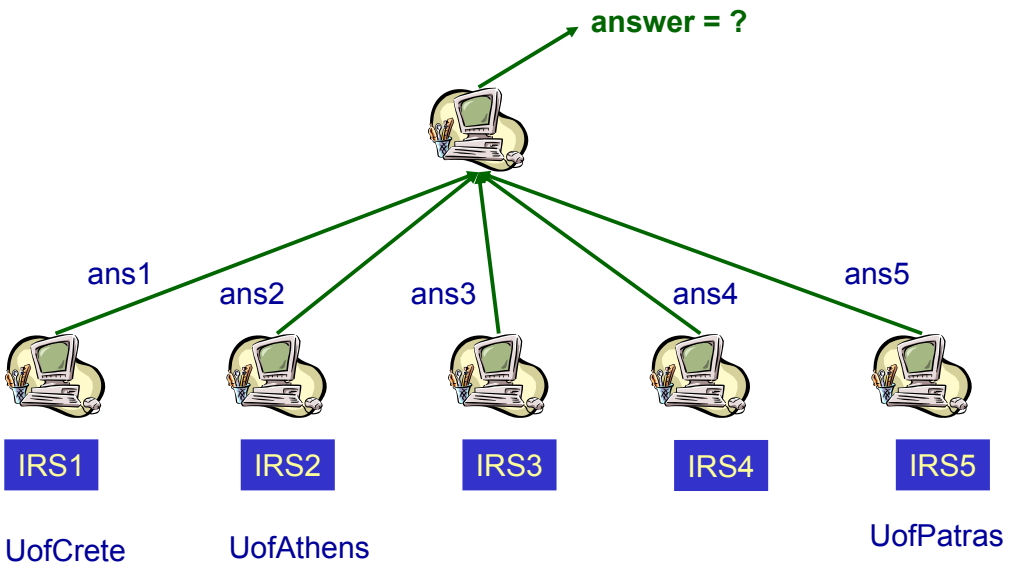

Περιπτώσεις

- Ενοποίηση **Συνόλων** (π.χ. απαντήσεων σε Exact Match Queries)
  - answer(q) = ans1(q) ∪ … ∪ ansk(q)
  - Άρα η ενοποίηση αποτελεσμάτων για το Boolean model είναι εύκολη
- Ενοποίηση **Διατάξεων** (απαντήσεων Partial Match Queries)
  - Η ενοποίηση αποτελεσμάτων είναι πιο δύσκολη
    - οι διατάξεις/σκορ **δεν είναι πάντα συγκρίσημες** (αφού εξαρτώνται από τα στατιστικά της συλλογής του κάθε συστήματος (e.g. idf)
    - υπάρχουν πολλοί διαφορετικοί τρόποι συνάθροισης διατάξεων
  - Συχνά μας αρκεί η εύρεση των κορυφαίων στοιχείων της ενοποιημένης διάταξης

Κατηγορίες Στρατηγικών Ενοποίησης Διατάξεων

(A) **Ολοκληρωμένες** Τεχνικές (**Integrated**)

- Οι πηγές παρέχουν **επιπρόσθετη πληροφορία** που χρησιμοποιείται κατά την ενοποίηση
- Αδυναμίες:
  - Στενό πεδίο εφαρμογής - απαιτούν συμφωνία μεταξύ των πηγών (e.g. protocol)
  - Συχνά λαμβάνουν υπόψη τους μέτρα όπως Precision/Recall, τα οποία δεν είναι πάντα «αντικειμενικά» ή συγκρίσιμα.

(B) **Απομονωμένες** Μέθοδοι (**Isolated**)

- Δεν απαιτούν **καμία επιπλέον πληροφορία** από τις πηγές (μπορούν να εφαρμοστούν και στις μετα-μηχανές αναζήτησης)
- Είναι ανεξάρτητες των τεχνικών ευρετηρίασης και των μοντέλων ανάκτησης των υποκείμενων συστημάτων
- Άρα κατάλληλες για δυναμικά περιβάλλοντα όπου υπάρχουν πολλά συστήματα των οποίων η λειτουργία εξελίσσεται συχνά και απρόβλεπτα
- Σχετικές τεχνικές: round robin interleaving, score-based, Borda, Condorcet, download and re-index the contents of the objects (web pages)

Ενοποίηση Διατάξεων: **Round Robin interleaving** (isolated)

(δηλαδή merge sort)

Παράδειγμα:

- ans1(q) = <d10,d2, d30, d7>
- ans2(q) = <d4, d12, d5, d9>

- ANS(q) = < {d10,d4}, {d2,d12}, {d30,d5}, {d7,d9}>

Προβλήματα

- στην πραγματικότητα όλα τα έγγραφα του ans1(q) μπορεί να είναι καλύτερα (πιο συναφή) από το 1ο στοιχείο της ans2(q)

Ενοποίηση Διατάξεων: **Score-based** (isolated)

Παράδειγμα:

- ans1(q) = < (d3,0.8), (d2,0.7) >
- ans2(q) = < (d5,0.6), (d6,0.3) >
- ans3(q) = < (d4,0.9) >

- ANS(q) = < d4, d3, d2, d5, d6>

Προβλήματα

- τα σκορ διαφορετικών συστημάτων δεν είναι συγκρίσιμα (κανονικοποιημένα), αφού εξαρτώνται από τα στατιστικά της συλλογής του κάθε συστήματος (e.g. idf).

Ενοποίηση Διατάξεων: **Weighted Score-based**

- Λαμβάνουμε υπόψη το σκορ της πηγής που υπολογίσαμε όταν κάναμε *Επιλογή Πηγής (source selection)*

  Πχ
  - Score(IRS1) = 0.9 // υπολογίστηκε στη φάση επιλογής πηγής
  - Score(IRS2) = 0.5 // υπολογίστηκε στη φάση επιλογής πηγής
  - ans1(q) = <(d1, 0.7)>
  - ans2(q) = <(d2, 0.9)>
  - ANS(q) = < (d1, 0.63), (d2, 0.45)> // 0.63 = 0.9*0.7

- Εδώ πολλαπλασιάσαμε το σκορ της πηγής με το σκορ των εγγράφων.
- Υπάρχουν και άλλες παραλλαγές (π.χ. [Callan94,95])

Ενοποίηση Διατάξεων: **Download and re-index/re-score** (isolated)

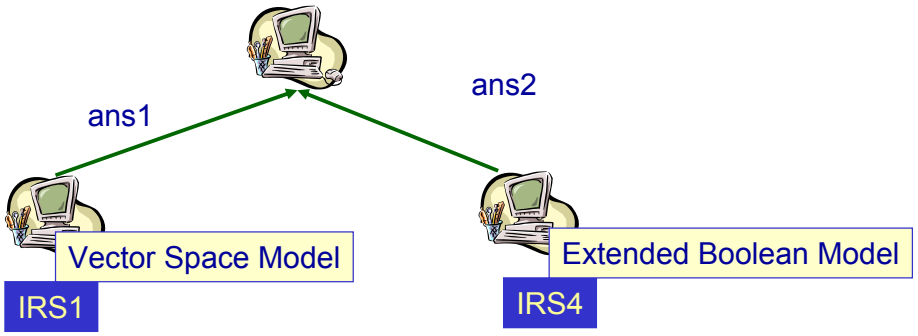

- Εδώ ανακτούμε τα έγγραφα των απαντήσεων κάθε πηγής, τα επαναευρετηριάζουμε και επαναυπολογίζουμε το βαθμό συνάφειας τους
- Μειονέκτημα
  - Χρονοβόρα διαδικασία

Ενοποίηση Διατάξεων: **Global term statistics** (**integrated**)

- Μπορούμε να κάνουμε συγκρίσιμα τα σκορ διαφορετικών συστημάτων αν επιβάλουμε τα ίδια στατιστικά στοιχεία σε όλα τα συστήματα (global statistics)
- Τα στατιστικά αυτά στοιχεία μπορούν να αποκτηθούν στη φάση της επιλογής πηγής (πχ Διανύσματα Πηγής, Probe Queries, …)
- Αποτίμηση Επερωτήσεων σε 2 φάσεις
  - στην 1η συλλέγονται τα στατιστικά (ο server στέλνει την επερώτηση και οι πηγές απαντούν με τα στατιστικά των όρων που περιέχονται στην επερώτηση)
  - στην 2η ο server στέλνει σε κάθε πηγή την επερώτηση μαζί με τα καθολικά στατιστικά των όρων της
  - κάθε πηγή αποτιμά την επερώτηση με τα καθολικά στατιστικά και επιστρέφει την απάντηση
  - Ο server λαμβάνει έτοιμα σκορ και απλά τα ενοποιεί (merge sort)

Ενοποίηση Διατάξεων: Global term statistics Παράδειγμα

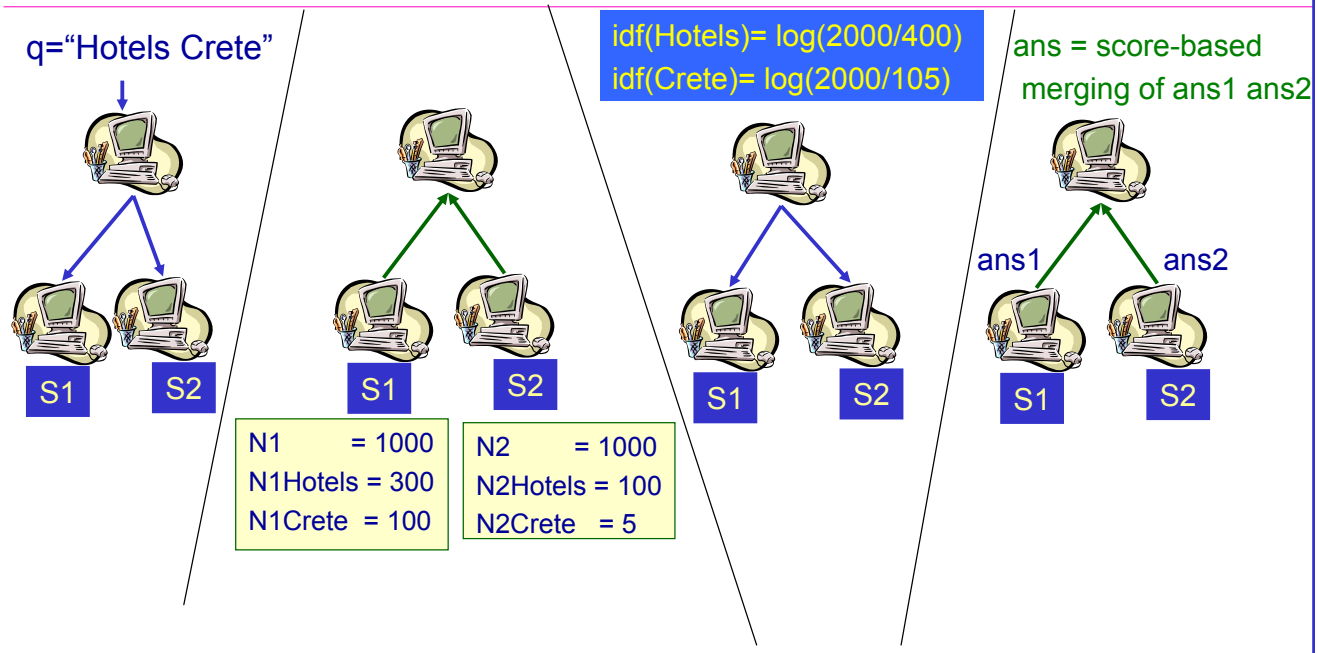

Μέτα-μηχανές Αναζήτησης

Μετα-Μηχανές Αναζήτησης

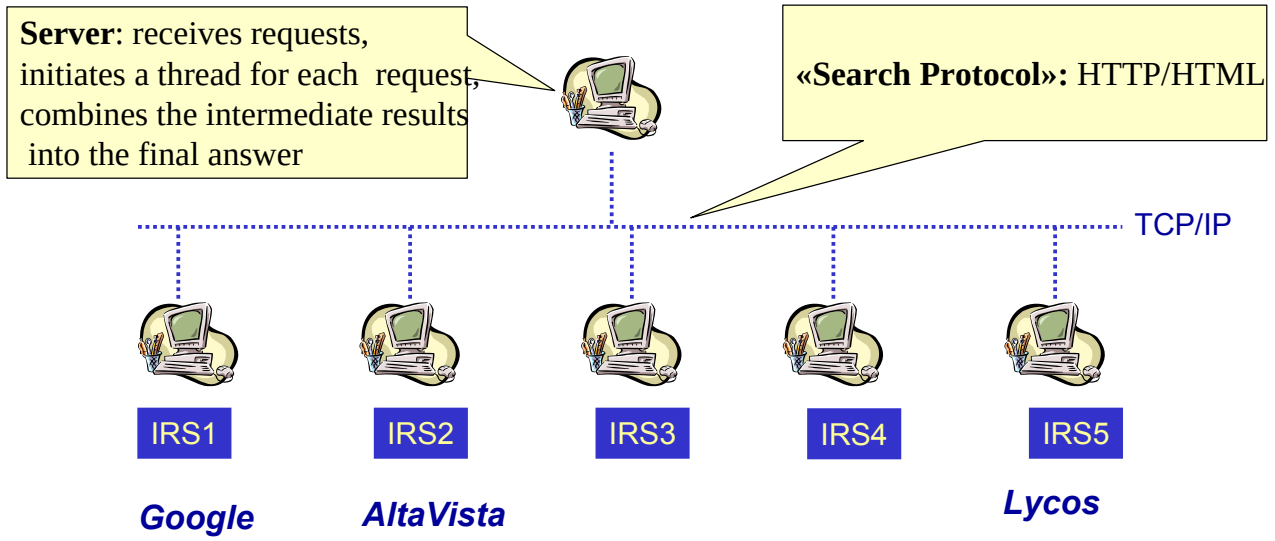

Μετα-Μηχανή Αναζήτησης: Μηχανή αναζήτησης που προωθεί την επερώτηση σε πολλές μηχανές αναζήτησης και ενοποιεί τα αποτελέσματα που επιστρέφουν

Γιατί φτιάχνουμε μετα-μηχανές αναζήτησης;

- Καλύτερη **κάλυψη**:
  - Το σύνολο των σελίδων που είναι γνωστές (ευρετηριασμένες) σε κάθε μηχανή είναι διαφορετικό
- **Διάταξη Πλειοψηφούσας Γνώμης** (consensus ranking)
  - Η διαθεσιμότητα πολλών μηχανών μας δίνει την δυνατότητα να ορίσουμε ένα αθροιστικό (πλειοψηφικό) μέτρο συνάφειας
    - Ενοποίηση αποτελεσμάτων = Πρόβλημα απόφασης ομάδας (group decision problem)
- **Μείωση spam**:
  - Δύσκολα μια spam σελίδα μπορεί να ξεγελάσει όλες τις μηχανές

Μετα-Μηχανές Αναζήτησης

- Ενδεικτικές μηχανές:
  - Dogpile (http://www.dogpile.com/)
    - over Google, Yahoo!, msn, Ask Jeaves
  - SurfWax (http://www.surfwax.com/)
  - http://www.jux2.com/
  - Metacrawler, SavvySearch,
- Βήματα Λειτουργίας
  - Submit queries to host sites.
  - **Parse resulting HTML pages** to extract search results.
  - **Integrate multiple rankings into a "consensus" ranking**.
  - Present integrated results to user.
- Διαφορές με την Κατανεμημένη Ανάκτηση Πληροφοριών
  - οι υποκείμενες μηχανές δεν παρέχουν term-statistics, άρα μπορούμε να χρησιμοποιήσουμε μόνο απομονωμένες (isolated) τεχνικές ενοποίησης αποτελεσμάτων
  - οι υποκείμενες μηχανές δεν υποστηρίζουν την ίδια ερωτηματική γλώσσα

Ενοποίηση Διατάξεων: **Rank Aggregation (or Meta-Ranking)** (isolated)

Διατύπωση του Προβλήματος

- ***D***: ένα σύνολο αντικειμένων (π.χ. εγγράφων)
- ***S1,…Sk***: ένα σύνολο διατάξεων του D

- Σκοπός: Ενοποίηση των διατάξεων *S1,..Sk σε μία*

The metaphor: **elections**

- Objects → Candidates
- Sources → Electors
- Ordering by a system → Elector's voting ticket
- Fused ordering → Election list

Διάρθρωση

- Ενοποίηση
  - κατά Borda
  - κατά Condorcet
  - κατά Kemeny
- Επιθυμητές Ιδιότητες Τεχνικών Ενοποίησης Διατάξεων
- Το Θεώρημα του Ανέφικτου του Arrow
- Αποδοτικοί αλγόριθμοι υπολογισμού των κορυφαίων κ στοιχείων της ενοποιημένης διάταξης (Top-K Rank Aggregation)

Plurality Ranking (Απλή Πλειοψηφία)

Ο υποψήφιος με τις περισσότερες πρώτες θέσεις είναι ο νικητής.

Έστω 6 πηγές (S1,…,S6) και 4 σελίδες a,b,c,d.

Κάθε σύστημα επιστρέφει μια γραμμική διάταξη των σελίδων:

S1: <a,c,d,b>

S2: <a,b,c,d>

S3: <b,c,a,b>

S4: <b,a,d,c>

S5: <a,d,c,b>

S6: <c,a,b,d>

Μετράμε πόσες πρώτες θέσεις κατέλαβε κάθε σελίδα

a: 3

b: 2

c: 1

d: 0

Άρα η τελική κατάταξη είναι η **<a,b,c,d>**

Plurality Ranking (Απλή Πλειοψηφία)
Κάποια προβλήματα

3 συστήματα	<a,c,d,b>
6 συστήματα	<a,d,c,b>
3 συστήματα	<b,c,d,a>
5 συστήματα	<b,d, c, a>
2 συστήματα	<c,b,d,a>
5 συστήματα	<c,d,b,a>
2 συστήματα	<d,b,c,a>
4 συστήματα	<d,c,b,a>

a:9
b:8
c:7
d:6
Τελική διάταξη: **<a,b,c,d>**

Απόσυρση του d
(που ήταν τελευταίο
στην ενοποιημένη διάταξη)

3 συστήματα	<a,c,b>
6 συστήματα	<a,c,b>
3 συστήματα	<b,c,a>
5 συστήματα	<b,c, a>
2 συστήματα	<c,b,a>
5 συστήματα	<c,b,a>
2 συστήματα	<b,c,a>
4 συστήματα	<c,b,a>

a:9
b:10
c:11
Τελική διάταξη: **<c,b,a>**
Αντίστροφη της αρχικής!

Plurality Ranking (Απλή Πλειοψηφία)
Κάποια προβλήματα

3 συστήματα	<a,c,d,b>
6 συστήματα	<a,d,c,b>
3 συστήματα	<b,c,d,a>
5 συστήματα	<b,d, c, a>
2 συστήματα	<c,b,d,a>
5 συστήματα	<c,d,b,a>
2 συστήματα	<d,b,c,a>
4 συστήματα	<d,c,b,a>

a:9
b:8
c:7
d:6
Τελική διάταξη: **<a,b,c,d>**

Απόσυρση του d
Τελική διάταξη: **<c,b,a>**

Απόσυρση του a
Τελική διάταξη: **<d,c,b>**

Απόσυρση του b
Τελική διάταξη: **<d,c,a>**

Απόσυρση του c
Τελική διάταξη: **<d,b,a>**

Ενοποίηση Διατάξεων κατά **Borda**
[Jean-Charles Borda 1770]

Reinvented (for the context of Meta-Searching) in [Tzitzikas 2001]

The votes of an object o $V(o) = \sum_{i=1..k} r_i(o)$

$r_i(o)$: the position of the object o in the ordering of system S_i

The fused ordering M is derived by ordering the objects in *ascending* order wrt to their *votes*

Example:

$S_1 : < o_1, o_2, o_3 >$
$S_2 : < o_1, o_3, o_2 >$
$S_3 : < o_3, o_1, o_2 >$

$V(o_1) = 1+1+2 = 4$
$V(o_2) = 2+3+3 = 8$
$V(o_3) = 3+2+1 = 6$

$M : < o_1, o_3, o_2 >$

If each source S_i returns an ordered *subset* O_i of *Obj*.

$$r_i(o_j) = \begin{cases} \text{position of } o_j \text{ in } O_i, & \text{if } o_j \in O_i \\ F+1 & \text{otherwise} \end{cases} \quad \text{where } F = \max\{|O_1|,...,|O_k|\}$$

Γιατί;

Ενοποίηση Διατάξεων κατά Borda
[Tzitzikas, 2001] **Βαθμός Συμφωνίας**

The *distance* between two orderings i and j: $dist(i,j) = \sum_{o \in O} |r_i(o) - r_j(o)|$

The *mean distance* of the fused ordering 0 $Dem = \frac{\sum_{i=1..k} dist(0,i)}{k}$

The ***level of agreement*** of the fused ordering 0:

linear transformation $LA = \frac{C - Dem}{C}$ C : max possible mean distance

inversion transformation $LA = C^{-Dem}$ $C > 1$, e.g. C = 2

- **High** level may drive the user to read only the very first documents since probably they are the more relevant
- **Low** level may drive the user to read more documents

Ενοποίηση Διατάξεων κατά **Condorcet** [1785]

Condorcet: the winner is a candidate that defeats every other candidate in pairwise majority-rule election

S1: <a,b,c>
S2: <b,a,c>
S2: <c,a,b>

a:b 2:1 // το a νικά το b δύο φορές (και χάνει μία)
a:c 2:1 // το a νικά το c δύο φορές (και χάνει μία)

Αρα η τελική κατάταξη κατά Condorset είναι: **<a,b,c>**

Ενοποίηση Διατάξεων κατά **Condorcet** [1785]

S1: <a,b,c>
S2: <b,c,a>
S3: <c,a,b>

a:b 2:1 // άρα το b δεν μπορεί να είναι ο νικητής
a:c 1:2 // άρα το a δεν μπορεί να είναι ο νικητής
c:b 1:2 // άρα το c δεν μπορεί να είναι ο νικητής

Δεν υπάρχει πάντα Condorset νικητής!

Borda vs Condorcet

S1: <a,b,c>

S2: <b,a,c>

S2: <c,a,b>

- Condorset
  - a:b 2:1
  - a:c 2:1
  - Condorset ordering: <a,b,c>
- Borda
  - a: 1+2+2 = 5
  - b: 2+1+3 = 6
  - c: 3 + 3 + 1 = 7
  - Borda ordering: <a,b,c>

Borda ≠ Condorcet

Borda (1770)

- Member of French Academy of Sciences
- Noted for work in hydraulics, optics, navigation instrument
- Purpose: Reforming the election procedure of French Academy.
- Criticize plurality method

Condorcet (1785)

- Viewed Borda as an enemy
- Finding best ordering by hypothesis testing
- Switch to propose Condorcet winner

Borda ≠ Condorcet

S1: <a,b,c,d,e>
S2: <b,c,e,d,a>
S3: <e,a,b,c,d>
S4: <a,b,d,e,c>
S5: <b,a,d,e,c>

- Borda
  - a: 1 + 5 + 2 + 1 + 2 = 11
  - b: 2 + 1+ 3 + 2 + 1 = 9
  - c: 3 + 2 + 4 + 5 + 5 =19
  - d: 4 + 4 + 5 + 3 + 3 = 19
  - e: 5+3 +1 + 4 + 4 = 17
  - **Borda winner : b**
- Condorset
  - a:b 3:2
  - a:c 4:1
  - a:d 4:1
  - a:e :3:2
  - **Condorset winner a**

Prurality ≠ Borda ≠ Condorcet

	49 votes	48 votes	3 votes
1*st*	*x*	*y*	*z*
2*nd*	*y*	*z*	*y*
3*rd*	*z*	*x*	*x*

- Prurality winner: x
- Borda winner: y
- Condorcet: z> x

Condorcet and Order

- Θεωρείστε την περίπτωση τριών υποψηφίων (a,b,c) και 13 εκλεκτόρων

	a	*b*	*c*
a	–	8	6
b	5	–	11
c	7	2	–

Έχουμε συνοψίσει τις διατάξεις που έδωσαν οι εκλέκτορες κατασκευάζοντας έναν πίνακα C, όπου το C[i,j] εκφράζει πόσες φορές το i νικά το j

Μπορούμε να υπολογίσουμε τη στήριξη (support) κάθε πιθανής γραμμικής διάταξης αθροίζοντας τη στήριξη της κάθε συσχέτισής της.

- <a,b,c> has support 25
  - a>b:8, a>c:6, b>c:11
- <b,c,a> has support 23
  - a<b:5, c>a:7, b>c:11

Ενοποίηση Διατάξεων κατά **Kemeny** (1959)
(Kemeny developed BASIC language)

- Απόσταση μεταξύ δυο διατάξεων = πλήθος των διαφωνιών στη διάταξη ζευγαριών

- Παράδειγμα 1
  - r1 = <a,b,c>
  - r2 = <b, a, c>
  - K(r1, r2) = 1
    - $(a >_{r1} b, a <_{r2} b)$
- Παράδειγμα 2
  - r1 = <a, b, c, d>
  - r2 = <b, d, a, c>
  - K(r1, r2) = 3
    - $(a >_{r1} b, a <_{r2} b)$ $(a >_{r1} d, a <_{r2} d)$ $(c >_{r1} d, c <_{r2} d)$

Ενοποίηση Διατάξεων κατά **Kemeny** (1959)

Kemeny Optimal Aggregation

- Η καλύτερη ενοποιημένη διάταξη είναι εκείνη που απέχει το λιγότερο από όλες τις διατάξεις
- Έστω n διατάξεις: r1, r2, …, rn
- Ενοποιημένη διάταξη $r = \arg\min \sum K(r,ri)$
- Η εύρεση της ενοποιημένης διάταξης είναι ακριβή
  - (πρόβλημα NP-hard)
- Reconciles Borda and Condorcet

Ενοποίηση Διατάξεων: **Επιθυμητές Ιδιότητες**

- Ουδετερότητα (Neutrality)
  - Καμία εναλλακτική δεν πρέπει να ευνοείται
- Pareto Optimality
  - Αν X > Y (σε όλες τις διατάξεις) τότε X>Y (στην τελική)
- Μονοτονία (Monotonicity) // Ranking higher should not hurt a candidate
  - X νικητής (στην τελική), αλλαγή ενός ψηφοδελτίου YZX → YXZ, ο X παραμένει νικητής (στην τελική)
- Ανεξαρτησία από άσχετες εναλλακτικές (Independence from Irrelevant Alternatives)
  - X > Y (στην τελική), αλλαγή ενός ψηφοδελτίου XZY → ZXY, to X>Y παραμένει στην τελική
- Συνέπεια (Consistency)
  - Αν οι ψηφοφόροι διαιρεθούν σε δύο ομάδες και κάθε ομάδα αναδείξει τον ίδιο νικητή, τότε ο τελικός νικητής (αν λάβουμε υπόψη τις ψήφους και των 2 ομάδων) πρέπει να είναι ο ίδιος

Arrow's Impossibility Theorem

Kenneth J. Arrow, *Social Choice and Individual Values* (1951). Won Nobel Prize in 1972

No voting scheme over three or more alternatives can satisfy the following conditions

- Universality (no restriction on individual ordering. All orderings are achievable)
- Monotonicity
- Independence of irrelevant alternatives
- Pareto Optimality
- Non-dictatorship

Συμπέρασμα: δεν υπάρχει μια απολύτως ικανοποιητική συνάρτηση ενοποίησης διατάξεων

Διάρθρωση

- Ενοποίηση
  - κατά Borda
  - κατά Condorcet
  - κατά Kemeny
- Επιθυμητές Ιδιότητες Τεχνικών Ενοποίησης Διατάξεων
- Το Θεώρημα του Ανέφικτου του Arrow
- **Αποδοτικοί αλγόριθμοι υπολογισμού των κορυφαίων κ στοιχείων της ενοποιημένης διάταξης (Top-K Rank Aggregation)**

Top-k Rank Aggregation

- Έχουμε **N** αντικείμενα και τους **βαθμούς** τους βάσει **m** διαφορετικών **κριτηρίων**.
- Έχουμε έναν τρόπο να συνδυάζουμε τα m σκορ κάθε αντικειμένου σε ένα ενοποιημένο σκορ
  - π.χ. min, avg, sum
- Στόχος: Βρες τα **κ** αντικείμενα με το υψηλότερο ενοποιημένο σκορ.

Εφαρμογές:

- Υπολογισμός των κορυφαίων-κ στοιχείων της απάντησης
  - ενός ΣΑΠ που βασίζεται στο διανυσματικό μοντέλο (τα m κριτήρια είναι οι m όροι της επερώτησης)
  - ενός μεσίτη (π.χ. μετα-μηχανής αναζήτησης) πάνω από m Συστήματα Ανάκτησης Πληροφοριών
  - μιας επερώτησης σε μια Βάση Πολυμέσων
    - κριτήρια (και συνάμα χαρακτηριστικά/features): χρώμα, μορφή, υφή, …

Άλλο ένα παράδειγμα εφαρμογής

- Ενοποίηση απαντήσεων σε Μεσολαβητές (middleware) πάνω από πηγές που αποθηκεύουν δομημένες πληροφορίες
  - έστω μια υπηρεσία εύρεσης εστιατορίων βάσει τριών κριτηρίων:
    - απόσταση από ένα σημείο
    - κατάταξη εστιατορίου
    - τιμή γεύματος, και άλλα
  - όπου ο χρήστης μπορεί να ορίσει τον επιθυμητό τρόπο υπολογισμού του ενοποιημένου σκορ ενός εστιατορίου
    - π.χ. Σκορ(εστΧ) = Stars(εστΧ)*0.25 + 0.75*DistanceFromHome(εστΧ)
  - η υπηρεσία αυτή υλοποιείται με χρήση τριών απομακρυσμένων υπηρεσιών
    - (α) getRestaurantsByStars
      - επιστρέφει όλα τα εστιατόρια σε φθίνουσα σειρά ως προς τα αστέρια που έχουν (κάθε εστιατόριο συνοδεύεται με ένα σκορ)
    - (β) getRestaurantsByDistance(x,y)
      - επιστρέφει όλα τα εστιατόρια σε φθίνουσα σειρά ως προς την απόσταση τους από ένα συγκεκριμένο σημείο με συντεταγμένες (x,y) // κάθε εστιατόριο συνοδεύεται από την απόσταση του από το (x,y)
  - **Πως μπορώ να ελαχιστοποιήσω το πλήθος των στοιχείων που πρέπει να διαβάσω από την απάντηση της κάθε υπηρεσίας, προκειμένου να βρω τα κορυφαία 5 εστιατόρια (βάσει σκορ όπως υπολογίζεται από της συνάρτηση βαθμολόγησης που έδωσε ο χρήστης);**

Εύρεση των κ-κορυφαίων
Απλοϊκός Αλγόριθμος

1/ Ανέκτησε ολόκληρες τις m λίστες
2/ Υπολόγισε το ενοποιημένο σκορ του κάθε αντικειμένου
3/ Ταξινόμησε τα αντικείμενα βάσει του σκορ και επέλεξε τα πρώτα κ

Παρατηρήσεις
- Κόστος γραμμικό ως προς το μήκος των λιστών
- Δεν αξιοποιεί το γεγονός ότι οι λίστες είναι ταξινομημένες

Εύρεση των κ-κορυφαίων
Παράδειγμα: Απλοϊκός Τρόπος

Έστω οτι θέλουμε να συναθροίσουμε τις διατάξεις που επιστρέφουν 3 πηγές S1, S2, S3 και ο τρόπος συνάθροισης είναι το άθροισμα.

S1 = < **A** 0.9, **C** 0.8, **E** 0.7, **B** 0.5, **F** 0.5, **G** 0.5, **H** 0.5 >
S2 = < **B** 1.0, **E** 0.8, **F** 0.7, **A** 0.7, **C** 0.5, **H** 0.5, **G** 0.5 >
S3 = < **A** 0.8, **C** 0.8, **E** 0.7, **B** 0.5, **F** 0.5, **G** 0.5, **H** 0.5 >

Ο Απλοϊκός Τρόπος

Score(**A**) = 0.9 + 0.7 + 0.8 = 2.4
Score(**B**) = 0.5 + 1.0 + 0.5 = 2
Score(**C**) = 0.8 + 0.5 + 0.8 = 2.1
Score(**E**) = 0.7 + 0.8 + 0.7 = 2.2
Score(**F**) = 0.5 + 0.7 + 0.5 = 1.7
Score(**G**) = 0.5 + 0.5 + 0.5 = 1.5
Score(**H**) = 0.5 + 0.5 + 0.5 = 1.5
Τελική διάταξη: < **A, E, C, B, F, G, H**>

Εύρεση των κ-κορυφαίων
Πιο Αποδοτικοί Αλγόριθμοι

- Γενική ιδέα: ***Άρχισε να διαβάζεις τις διατάξεις από την κορυφή. Προσπάθησε να καταλάβεις πότε πρέπει να σταματήσεις***.
- Αλγόριθμοι
  - **Fagin Algorithm (FA)** [Fagin 1999, J. CSS 58]
  - **Threshold Algorithm (TA)** [Fagin et al., PODS'2001]

Υποθέσεις

- Υποθέτουμε ότι έχουμε στη διάθεση μας 2 τρόπους πρόσβασης στα αποτελέσματα μιας πηγής:
  - **Σειριακή πρόσβαση** στις διατάξεις: φθίνουσα ως προς το σκορ
  - **Τυχαία προσπέλαση**: Δυνατότητα εύρεσης του σκορ ενός συγκεκριμένου αντικειμένου με μία πρόσβαση
- Συναρτήσεις βαθμολόγησης (σκορ)
  - Τα σκορ ανήκουν στο διάστημα [0,1]
  - Η συνάρτηση ενοποιημένου σκορ είναι **μονότονη**
    - αν όλα (m) τα σκορ ενός αντικειμένου A είναι μεγαλύτερα ή ίσα των αντίστοιχων σκορ ενός αντικειμένου B, τότε σίγουρα το ενοποιημένο σκορ του A είναι μεγαλύτερο ή ίσο του σκορ του B

Εύρεση των κ-κορυφαίων
Ο Αλγόριθμος του Fagin (FA) [1999]

1.α/ Κάνε σειριακή ανάκτηση αντικειμένων από κάθε λίστα (αρχίζοντας από την κορυφή), έως ότου η τομή των αντικειμένων από κάθε λίστα να έχει κ αντικείμενα

1.β/ Για κάθε αντικείμενο που ανακτήθηκε (στο 1.α) συνέλεξε τα σκορ που λείπουν (με χρήση του μηχανισμού τυχαίας προσπέλασης)

2/ Υπολόγισε το ενοποιημένο σκορ του κάθε αντικειμένου

3/ Ταξινόμησε τα αντικείμενα βάσει του ενοποιημένου σκορ και επέλεξε τα πρώτα κ

Σχόλια

Αξιοποιεί (α) το γεγονός ότι οι λίστες είναι ταξινομημένες και (β) ότι η συνάρτηση ενοποίησης είναι μονότονη

[-] Το πλήθος των αντικειμένων που θα ανακτηθούν μπορεί να είναι μεγάλο

Εύρεση των κ-κορυφαίων
Παράδειγμα: Αλγόριθμος του Fagin (FA)

S1 = < **A** 0.9, **C** 0.8, **E** 0.7, **B** 0.5, **F** 0.5, **G** 0.5, **H** 0.5 >
S2 = < **B** 1.0, **E** 0.8, **F** 0.7, **A** 0.7, **C** 0.5, **H** 0.5, **G** 0.5 >
S3 = < **A** 0.8, **C** 0.8, **E** 0.7, **B** 0.5, **F** 0.5, **G** 0.5, **H** 0.5 >

Έστω ότι θέλω το Top-1

Το E εμφανίζεται σε όλες

(μονοτονία => δεν μπορεί κάποιο δεξιότερο του E να είναι καλύτερο του E

Το E δεν είναι σίγουρα ο νικητής.

Υποψήφιοι νικητές = {A, B, C, E, F}. Κάνουμε τυχαίες προσπελάσεις για να βρούμε τα σκορ που μας λείπουν

getScore(S2,A), getScore(S1,B), getScore(S3,B), getScore(S2,C), …

Πράγματι, top-1= {A}

Εύρεση των κ-κορυφαίων
Παράδειγμα: Αλγόριθμος του Fagin (FA)

S1 = < **A** 0.9, **C** 0.8, **E** 0.7, **B** 0.5, **F** 0.5, **G** 0.5, **H** 0.5 >
S2 = < **B** 1.0, **E** 0.8, **F** 0.7, **A** 0.7, **C** 0.5, **H** 0.5, **G** 0.5 >
S3 = < **A** 0.8, **C** 0.8, **E** 0.7, **B** 0.5, **F** 0.5, **G** 0.5, **H** 0.5 >

Έστω ότι θέλω το Top-2

Το E, B (και το A) εμφανίζονται σε όλες

(μονοτονία => δεν μπορεί κάποιο δεξιότερο του B να είναι καλύτερο του B

Εύρεση των κ-κορυφαίων
Ο Αλγόριθμος TA (Threshold Algorithm) [Fagin et al. 2001]

Ιδέα:

Υπολόγισε το μέγιστο σκορ που μπορεί να έχει ένα αντικείμενο που δεν έχουμε συναντήσει ακόμα.

1/ Κάνε σειριακή ανάκτηση αντικειμένων από κάθε λίστα (αρχίζοντας από την κορυφή) και με χρήση τυχαίας προσπέλασης βρες όλα τα σκορ κάθε αντικειμένου

2/ Ταξινόμησε τα αντικείμενα (βάσει του ενοποιημένου σκορ) και κράτησε τα καλύτερα κ

3/ Σταμάτησε την σειριακή ανάκτηση όταν τα σκορ των παραπάνω κ αντικειμένων δεν μπορεί να είναι μικρότερα του μέγιστου πιθανού σκορ των απαρατήρητων αντικειμένων (threshold).

Εύρεση των κ-κορυφαίων
Παράδειγμα: Αλγόριθμος TA:

S1 = < **A** 0.9, **C** 0.8, **E** 0.7, **B** 0.5, **F** 0.5, **G** 0.5, **H** 0.5 >

S2 = < **B** 1.0, **E** 0.8, **F** 0.7, **A** 0.7, **C** 0.5, **H** 0.5, **G** 0.5 >

S3 = < **A** 0.8, **C** 0.8, **E** 0.7, **B** 0.5, **F** 0.5, **G** 0.5, **H** 0.5 >

Έστω ότι θέλω το Top-1

Score(A) = 0.9 + 0.7 + 0.8 = 2.4
Score(B) = 0.5 + 1.0 + 0.5 = 2
UpperBound = 0.9 + 1.0 + 0.8 = 2.7
αφού 2.7 > 2.4 συνεχίζω

Score(C) = 0.8 + 0.5 + 0.8 = 2.1
Score(E) = 0.7 + 0.8 + 0.7 = 2.2
UpperBound = 0.8 + 0.8 + 0.8 = 2.4
αφού 2.4 δεν είναι μεγαλύτερο του 2.4 (σκορ του A) σταματάω.

Σύγκριση: Fagin vs. TA

- Ο FA ποτέ δεν τερματίζει ενωρίτερα του TA
- Ο TA χρειάζεται μόνο έναν μικρό (k) ενταμιευτή (buffer)
- Ο TA μπορεί όμως να κάνει περισσότερες τυχαίες προσπελάσεις

Ο TA είναι βέλτιστος για όλες τις μονότονες συναρτήσεις σκορ

- Συγκεκριμένα, είναι ”instant optimal”: είναι καλύτερος πάντα (όχι μόνο στην χειρότερη περίπτωση ή στην μέση περίπτωση)

- Επεκτάσεις
  - Αλγόριθμος NRA (Non Random Access)
    - Έκδοση του TA για την περίπτωση που η τυχαία πρόσβαση είναι αδύνατη. Επίσης “instant optimal”.
      - Do sequential access until there are *k* objects whose lower bound no less than the upper bound of all other objects
    - Αλγόριθμος CA (Combined Algorithm)
      - Έκδοση του TA που θεωρεί τις τυχαίες προσπελάσεις ακριβότερες των σειριακών.