



Μέρος Γ
Συστήματα Ομοτίμων
(Peer-to-Peer Systems)
και Ανάκτηση Πληροφοριών

Γιάννης Τζιτζικάς

Διάλεξη : 16-17
Ημερομηνία : 12,17-5-2006

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

1

Συστήματα Ομοτίμων
(Peer-to-Peer Systems)



Διάρθρωση

- Κίνητρο
- Τύποι Ομότιμων Συστημάτων
 - Υβριδικά
 - Αποκεντρωμένα
 - Ιεραρχικά
 - Δομημένα
- Διαφορές με Κατανεμημένη Ανάκτηση
- Ομότιμα Συστήματα και Ανάκτηση Πληροφοριών

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

3



Ομότιμα Συστήματα: Κίνητρο

- Άξιοποίηση των ελεύθερων πόρων συστημάτων προσβάσιμων μέσω Internet για την επίλυση μεγάλων προβλημάτων (π.χ. SETI@home)
- δημιουργία συστημάτων πιο κλιμακόσιμων
- δημιουργία συστημάτων με μεγαλύτερη διαθεσιμότητα
- κατάργηση μονοπωλίων στην διάθεση της πληροφορίας
- αυτό-οργάνωση αντί κεντρικής διαχείρισης (και εξόδων αυτής)

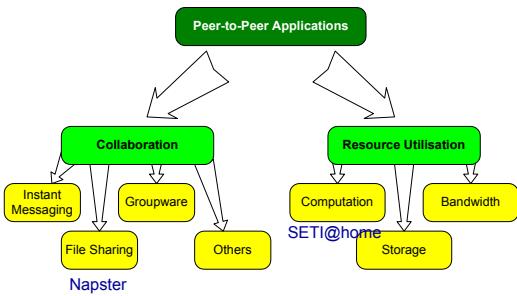
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

4



P2P: Εφαρμογές



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

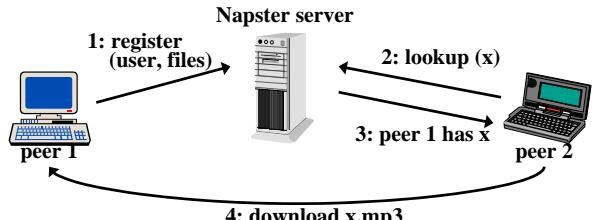
5



Ομότιμα Συστήματα 1ης Γενιάς: Υβριδικά Napster

Ονομάζονται και Υβριδικά Ομότιμα Συστήματα (Hybrid P2P systems) διότι υπάρχει ένας κεντρικός εξυπηρετής

Napster (1998-2001): διαμορφωμένος MP3



Μπορούμε να τα δούμε ως publish-subscribe systems: ο ιδιοκτήτης ενός αρχείο το διαθέτει με ένα όνομα x, οι άλλοι χρήστες μπορούν να αναζητήσουν το x, να βρουν ένα αντίγραφο και να το κατεβάσουν

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

6



Google (Client-Server) vs. Napster (P2P)



- Και οι δύο εφαρμογές έχουν την ίδια κλίματα
 - εκατομμύρια αναζητήσεις ημερησίως
 - Terabytes δεδομένων
- Google
 - Στηρίζεται σε περίπου 100.000 μηχανές
 - το στήσιμο μιας τέτοια εφαρμογής έχει μεγάλο κόστος (μόνο μια μεγάλη επιχείρηση μπορεί να κάνει τέτοια επένδυση)
- Napster
 - ο server χρησιμοποιεί μόνο 100 μηχανές
 - το κόστος αποθήκευσης και μεταφοράς των μουσικών αρχείων χρεώνεται στις μηχανές των χρηστών του συστήματος (γι' αυτό ονομάζεται P2P)
 - μικρό κόστος

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

7



Τα Πλεονεκτήματα των Ομοτίμων Συστημάτων

Διαμερισμός πόρων

– αποθηκευτικών

- οι εκατομμύρια χρήστες του Napster αποθηκεύουν τα αρχεία, όχι ο εξυπηρετητής

– επικοινωνίας

- το κατέβασμα αρχείων γίνεται μεταξύ των χρηστών, ο εξυπηρετητής δεν παρεμβάλλεται

– εισαγωγής στοιχείων

- οι χρήστες του Napster εισάγουν τα αρχεία στο σύστημα
- οι χρήστες του Napster τα κατηγοριοποιούν

Δίδαγμα:

Η αποκέντρωση επιπρέπει τη δημιουργία εφαρμογών παγκόσμιας κλίμακας χωρίς την ανάγκη μεγάλων επενδύσεων αλλά με την αξιοποίηση των πόρων που ήδη υπάρχουν

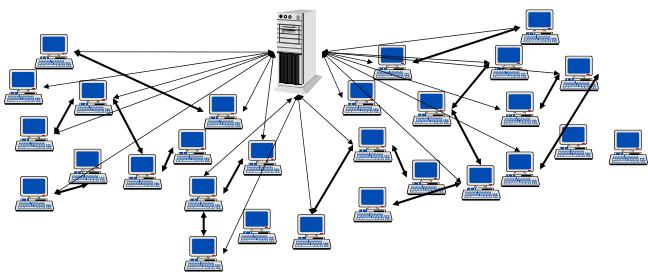
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

8



Ομότιμα Συστήματα 1ης Γενιάς: Υβριδικά Napster



A central point of failure

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

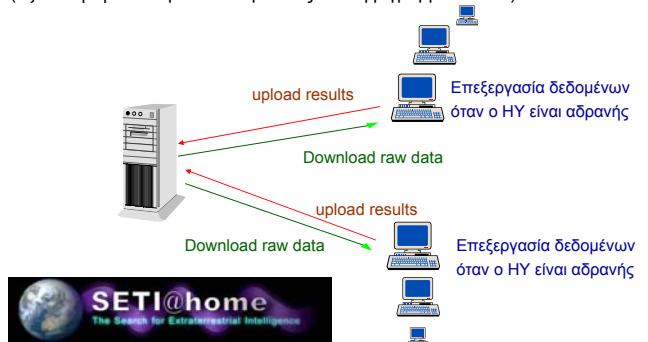
9



Ομότιμα Συστήματα 1ης Γενιάς: Υβριδικά SETI@home

Σκοπός: Διαμοιρασμός υπολογιστικών πόρων

(αξιοποίηση των περιόδων αδράνειας των εγγεγραμμένων HY)



CS463 - Information Retrieval

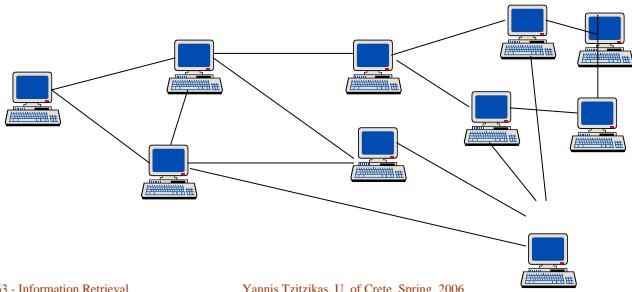
Yannis Tzitzikas, U. of Crete, Spring 2006

10



Ομότιμα Συστήματα 1ης Γενιάς: Αποκεντρωμένα GNUTELLA

- Δεν υπάρχει κανένας κεντρικός εξυπηρετητής
- Ονομάζονται και Αποκεντρωμένα (Decentralized P2P systems), Αδόμητα (Unstructured P2P systems), Pure P2P systems
- Gnutella (1999-now):



CS463 - Information Retrieval

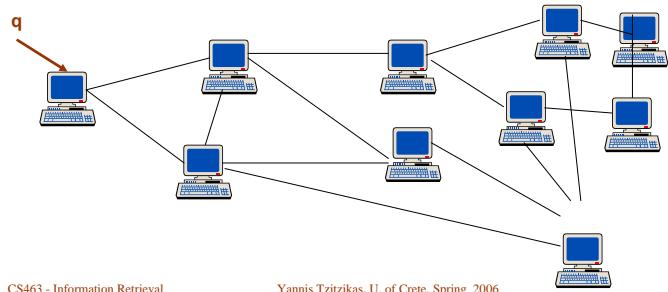
Yannis Tzitzikas, U. of Crete, Spring 2006

11



Ομότιμα Συστήματα 1ης Γενιάς: Αποκεντρωμένα GNUTELLA

- Δεν υπάρχει κανένας κεντρικός εξυπηρετητής
- Ονομάζονται και Αποκεντρωμένα (Decentralized P2P systems), Αδόμητα (Unstructured P2P systems), Pure P2P systems
- Gnutella (1999-now):



CS463 - Information Retrieval

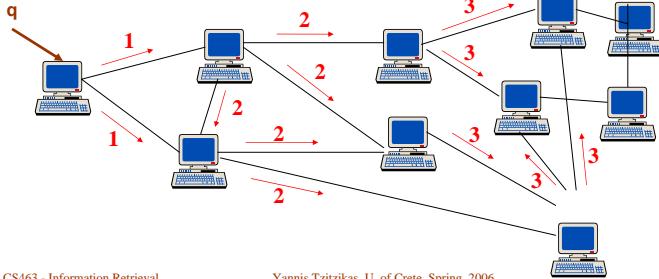
Yannis Tzitzikas, U. of Crete, Spring 2006

12



Ομότιμα Συστήματα 1ης Γενιάς: Αποκεντρωμένα GNUTELLA

Κατακλυσμός Μηνυμάτων (Message Flooding or Gossiping)



CS463 - Information Retrieval

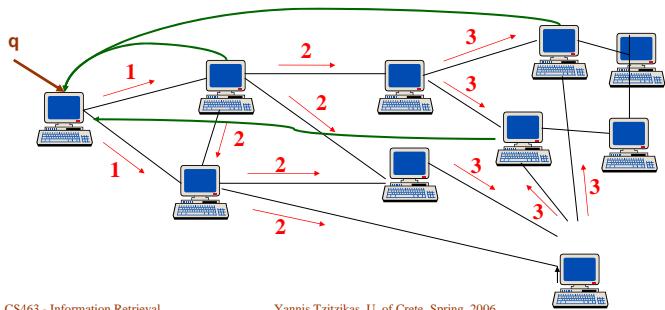
Yannis Tzitzikas, U. of Crete, Spring 2006

13



Ομότιμα Συστήματα 1ης Γενιάς: Αποκεντρωμένα GNUTELLA

Κατακλυσμός Μηνυμάτων (Message Flooding or Gossiping)



CS463 - Information Retrieval

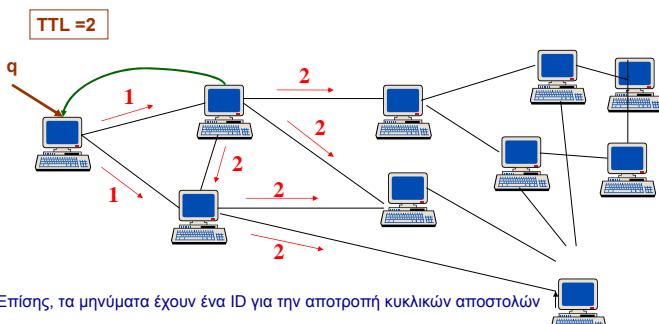
Yannis Tzitzikas, U. of Crete, Spring 2006

14



Ομότιμα Συστήματα 1ης Γενιάς: Αποκεντρωμένα GNUTELLA

- Τα μυνήματα έχουν ένα TTL (time-to-live) tag



Επίσης, τα μηνύματα έχουν ένα ID για την αποτροπή κυκλικών αποστολών

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

15



GNUTELLA: The protocol

Ping

- Used to actively discover hosts on the network. A servent receiving a Ping descriptor is expected to respond with one or more Pong descriptors.

Pong

- The response to a Ping. Includes the address of a connected Gnutella servent and information regarding the amount of data it is making available to the network.

Query

- The primary mechanism for searching the distributed network. A servent receiving a Query descriptor will respond with a QueryHit if a match is found against its local data set.

QueryHit

- The response to a Query. This descriptor provides the recipient with enough information to acquire the data matching the corresponding Query.

Push

- A mechanism that allows a firewalled servent to contribute file-based data to the network.

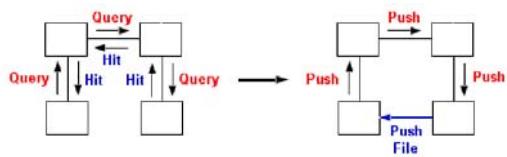
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

16



GNUTELLA: The protocol



Example 2. Query/QueryHit/Push Routing

- Συνήθως κάθε κόμβος προωθεί μια επερώτηση σε C γείτονες (συνήθως C=3)
- Τυπική τιμή TTL=7
– (πειράματα έδειξαν ότι η διάμετρος του Gnutella δικτύου είναι συνήθως 7)

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

17



Napster vs. Gnutella

Napster (υπάρχει κεντρικός εξυπηρετητής)

- single point of failure
- stochastic network topology

Gnutella (δεν υπάρχει κεντρικός εξυπηρετητής)

- δεν υπάρχει "single point of failure"
- δεν μπορεί να γίνει εύκολα στόχος νομικής επίθεσης
- δεν απαιτεί καμία επένδυση
- δεν έχει κόστος διαχείρισης (administration)
- "self-organizing system"
 - however, "free-riders" may occur

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

18



GNUTELLA: Επιδόσεις

Επιδόσεις

- Χρόνος αναζήτησης: Σχετικά μικρός
- Πλήθος Μηνυμάτων: **Μεγάλο**
- Κόστος αποθήκευσης: Μικρό (κάθε κόμβος γνωρίζει μόνο τους διπλανούς του)
- Κόστος ενημέρωσης: Μικρό (γείτονες)
- Ανθεκτικότητα σε σφάλματα: Μεγάλη

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

19



Ομότιμα Συστήματα 2ης Γενιάς

Πρωτότυπα ερευνητικά συστήματα:

Chord (MIT), CAN (Berkeley), OceanStore/Tapestry (Berkeley), Farsite (MSR), Spinglass/Pepper (Cornell), Pastry/PAST (Rice, MSR), Viceroy (Hebrew U), P-Grid (EPFL), P2P-Net (Magdeburg), Pier (Berkeley), Peers (Stanford), Kademlia (NYU), Bestpeer (Singapore), YouServ (IBM Almaden), Hyperion (Toronto), Piazza (UW Seattle), PlanetP (Rutgers), SkipNet (MSR),

Μπορούμε να διακρίνουμε 2 μεγάλες κατηγορίες

- Ιεραρχικά Ομότιμα Συστήματα (Hierarchical P2P systems)**
 - Π.χ. Το σύστημα **Kazaa**
- Δομημένα Ομότιμα Συστήματα (Structured P2P systems)**
 - Π.χ. το σύστημα **Chord**

CS463 - Information Retrieval

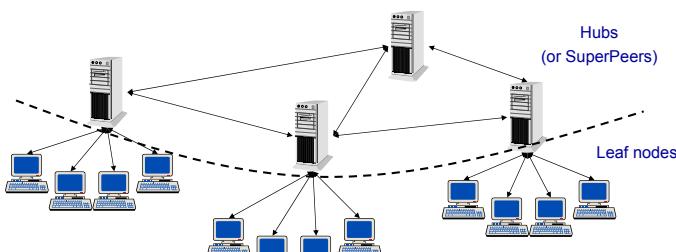
Yannis Tzitzikas, U. of Crete, Spring 2006

20



Ιεραρχικά Ομότιμα Συστήματα (Hierarchical P2P Systems)

Συστήματα: Morpheus, Kazaa, Limewire, JXTA Search, Gnutella 0.6



CS463 - Information Retrieval

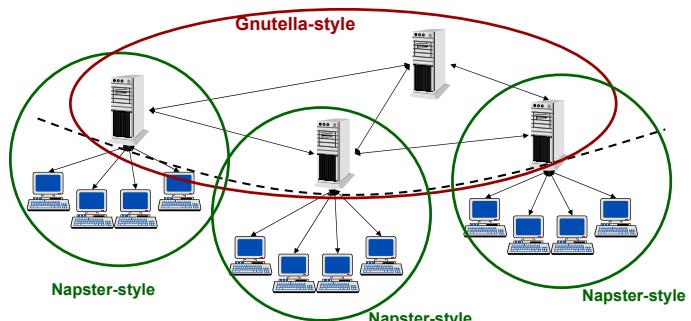
Yannis Tzitzikas, U. of Crete, Spring 2006

21



Ιεραρχικά Ομότιμα Συστήματα (Hierarchical P2P Systems)

Συνδυασμός Napster και Gnutella



CS463 - Information Retrieval

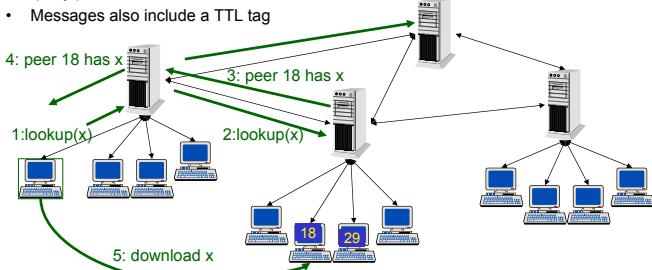
Yannis Tzitzikas, U. of Crete, Spring 2006

22



Ιεραρχικά Ομότιμα Συστήματα (Hierarchical P2P Systems)

- Searching relies on **message-passing** between nodes.
- A **query** generated by a client node and is routed to a hub, from one hub to another, or from a hub to a leaf node.
- A response message ("queryhit") is generated by a leaf node and routed back along the query path in reverse direction.
- Messages also include a TTL tag



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

23



Ιεραρχικά Ομότιμα Συστήματα (Hierarchical P2P Systems)

Επιδόσεις

- Χρόνος αναζήτησης: Πολύ μικρός
- Πλήθος Μηνυμάτων: Μικρό
- Κόστος αποθήκευσης: Μικρό στα φύλλα, Μεγάλο στους εξυπηρετητές ευρετηρίου
- Κόστος ενημέρωσης: Μικρό
- Ανθεκτικότητα σε σφάλματα: Μικρή

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

24



Δομημένα Ομότιμα Συστήματα (Structured P2P Systems)

Σκοπός:

Γρήγορη εύρεση του κόμβου που περιέχει ένα κλειδί **χωρίς τη χρήση κεντρικού εξυπηρετητή** και ανταλλάσσοντας **λίγα μηνύματα**

– Εύκολο κομμάτι:

- κατανομή ευρετηρίου σε όλους τους κόμβους

– Δύσκολο:

- κατανομή ευρετηρίου σε όλους τους κόμβους με τέτοιο τρόπο ώστε να έχουμε **υψηλοφορητή αναζήτηση**

• Συστήματα

- Freenet, Chord, CAN, Pastry, Tapestry, FreeNet, P-Grid,

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

25



Δομημένα Ομότιμα Συστήματα

• Κοινά χαρακτηριστικά των δομημένων ομότιμων συστημάτων

- **κάθε** κόμβος διατηρεί ένα **μικρό τιμήμα του καθολικού ευρετηρίου** (πίνακας δρομολόγησης)
- οι αναζητήσεις γίνονται με **προώθηση μηνυμάτων** προς τη «σωστή» κατεύθυνση

• **Διαφορετικές Προσεγίσεις**

- **FreeNet**: **caching** πληροφορίας ευρετηρίου κατά μήκος των μονοπατιών αναζήτησης
- **Chord**: κατασκευή ενός **κατανεμημένου πίνακα κατακερματισμού** (Distributed Hash Table, DHT)
- **CAN**: Δρομολόγηση βάσει **d-διάστατου χώρου**
- **P-Grid**: κατανομή ενός **υπαρκού δένδρου αναζήτησης**

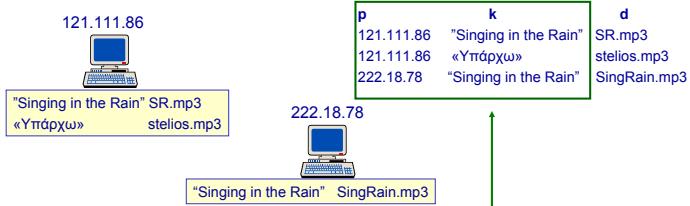
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

26



Το Πρόβλημα του Εντοπισμού Πόρου (Resource Location)



Έστω peer με δυνητικό **p** που αποθηκεύει στοιχείο **d** που χαρακτηρίζεται από το κλειδί **k**. Ζητούμενο: Δοθέντος **k** (ή συνθήκης πάνω στο **k**) **εντόπισε** τὸν peer που έχει το **d**, δηλαδή **βρες** το ζεύγος ευρετηρίου (**k,p**).
(άρα το ευρετήριο μας αποτελείται από ζεύγη της μορφής (**k,p**))

Κρίσιμο ερώτημα: Πώς μπορούμε να (α) φτιάξουμε, (β) συντηρήσουμε και (γ) να χρησιμοποιήσουμε ένα τέτοιο ευρετήριο χωρίς κεντρικό έλεγχο:

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

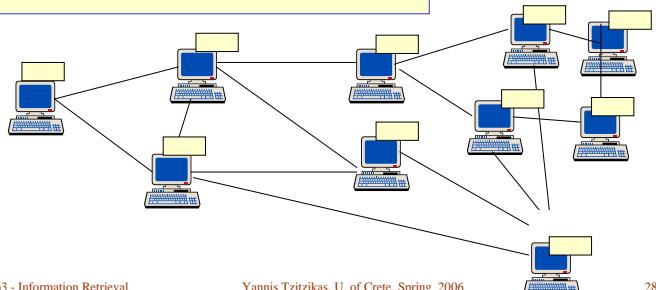
27



Freenet:

- Σύστημα για δημοσίευση και ανάκτηση δεδομένων με έμφαση στην **ανωνυμία** (και των συγγραφέων και των αναγνωστών)
- Τα κλειδιά και τα δεδομένα αποθηκεύονται **κρυπτογραφημένα**

Μοιάζει με: Gnutella + cache at each node



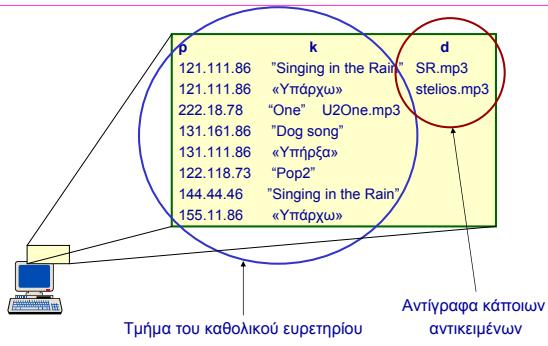
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

28



Freenet: Cache



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

29



Freenet: Τρόπος Εντοπισμού Πόρου

• **Έλευση επερώτησης k**

- Αν η έγγραφή (p,k,d) είναι στην κρυφή μνήμη επέστρεψε το **d**
- Άλλιως προώθησε την επερώτηση στον κόμβο που έχει το **πιο όμοιο κλειδί**

• **Η διαδικασία αυτή συνεχίζεται με αυτόν τον τρόπο έως ότου ευρεθεί το αναζητούμενο ή το TTL φτάσει την τιμή 0.**

• **Έλευση απάντησης (k,p,d)**

- Η τριάδα εισάγεται στην κρυφή μνήμη
- Η **παλαιότερη εγγραφή (least recently used)** διαγράφεται από την κρυφή μνήμη

• **Παρατηρήσεις**

- Οι δρομολογήσεις που κάνουν οι κόμβοι **βελτιώνονται συν το χρόνο**
- Οι κόμβοι τείνουν να έχουν στην κρυφή τους μνήμη εγγραφές με **παρόμοια κλειδιά** (άρα επιτυγχάνεται ένα είδος **ομαδοποίησης**)

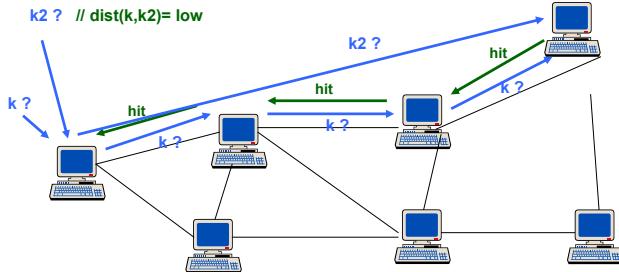
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

30



Freenet



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

31



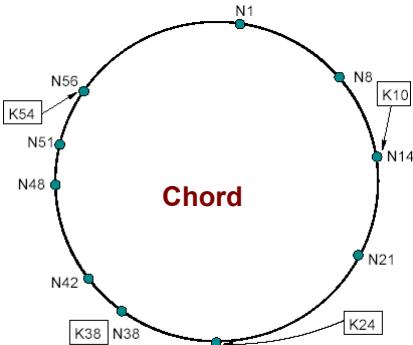
Freenet: Εισαγωγή Νέου Πόρου

- Υπολογίζουμε το κλειδί του νέου πόρου
- Φτιάχνεται η εγγραφή εισαγωγής και στέλνεται στον γείτονα με το πιο κοντινό κλειδί
- Κάθε κόμβος που λαμβάνει το νέο κλειδί, ελέγχει αν το κλειδί αυτό υπάρχει ήδη
- αν ναι, έχουμε σύγκρουση (collision), και άρα ο αρχικός κόμβος πρέπει να προτείνει ένα νέο κλειδί
- αν όχι, δρομολόγηση στον επόμενο κόμβο με τον ίδιο τρόπο
- Αν TTL=0 και δεν είχαμε καμία σύγκρουση, τότε η τριάδα αποθηκεύεται σε όλους τους κόμβους του μονοπατιού που ακολουθήθηκε

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

32



CS463 - Information Retrieval

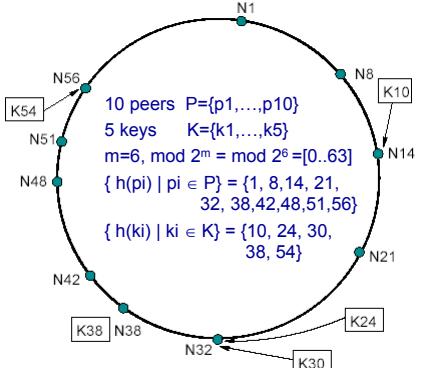
Yannis Tzitzikas, U. of Crete, Spring 2006

33



Chord (Distributed Hash Tables (DHT))

- Κατακερματισμός (Hashing) κλειδών (k) και διεύθυνσεων (p) σε δυαδικά κλειδιά με m -bits
– π.χ. $m=6$, $h(\text{κυπάρχω})=11$, $h(196.178.0.1)=3$
- Τα δυαδ. κλειδιά τοποθετούνται σε έναν κύκλο modulo 2^m
– Για $m=8$, κυκλική διάταξη των αριθμών 0...255
- Ένα κλειδί k εκχωρείται στον πρώτο κόμβο p τ.ω. $h(p) \geq h(k)$
- Αυτός ο κόμβος λέγεται **successor(k)**



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

34



Chord : Απλός τρόπος εντοπισμού κόμβων

'Εστω ότι κάθε κόμβος p ξέρει την δυστή μόνο του επόμενου του (του p' με $h(p') > h(p)$)

```
// ask node n to find the successor of id
n.find_successor(id)
if (id in (n; successor])
    return successor;
else
    // forward the query around the circle
    return successor.find_successor(id);
```

=> Number of messages linear in the number of nodes !

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

35



Chord : Ένας πιο γρήγορος τρόπος εντοπισμού κόμβων με πίνακες Δρομολόγησης

- Επιπλέον πληροφορία δρομολόγησης για επιτάχυνση
- Κάθε κόμβος η έχει έναν **πίνακα δρομολόγησης** με την εγγραφές
– οι m αυτοί κόμβοι έχουν εκθετικά αυξανόμενη απόσταση από τον π
- Η ι εγγραφή του πίνακα έχει την δυστή του πρώτου κόμβου με κλειδί μεγαλύτερο ή ίσο με $n+2^{i-1}$
 $finger[i] = successor(n + 2^{i-1})$

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

36



Chord : Παράδειγμα Πίνακα Δρομολόγησης

Finger table:

$$\text{finger}[i] = \text{successor}(n + 2^{i-1})$$

$n=8$

```

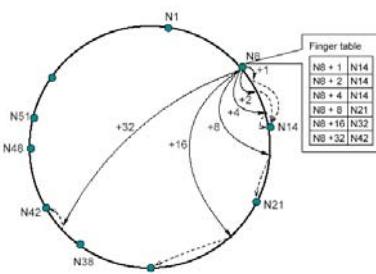
finger[1] = succ(n+1) = succ(9) = 14
finger[2] = succ(n+2) = succ(10) = 14
finger[3] = succ(n+4) = succ(12) = 14
finger[4] = succ(n+8) = succ(16) = 21
finger[5] = succ(n+16) = succ(24) = 32
finger[6] = succ(n+32) = succ(40) = 42

```

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

37



Chord: Εντοπισμός Πόρου με Πίνακες Δρομολόγησης

Έστω μια επερώτηση κ προς έναν κόμβο η Ο ο οποίας τον πίνακα δρομολόγησης του και βρίσκεται τον μικρότερο πρόσθιο μεγαλύτερο αυτού της επερώτησης. Αν δεν υπάρχει τέτοιος πρόσθιο, τότε ο ίδιος είναι υπεύθυνος για το κ (και άρα το ζητούμενο βρέθηκε) Άλλις προώθει την επερώτηση

Αφού οι εγγραφές των πινάκων δρομολόγησης είναι εκθετικά αύξουσες, η αναζήτηση (με μεγάλη πιθανότητα) λαμβάνει λογαριθμικό χρόνο.

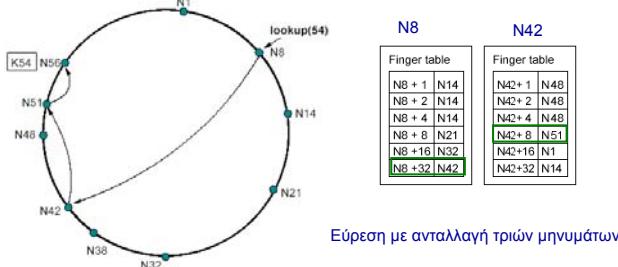
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

38



Chord: Πλήθος μηνυμάτων: $O(\log N)$



- Search in finger table for the nodes which most immediately precedes id
- Invoke `find_successor` from that node
- => Number of messages $O(\log N)$

CS463 - Information Retrieval

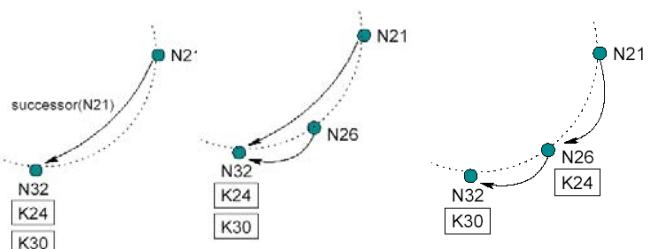
Yannis Tzitzikas, U. of Crete, Spring 2006

39



Chord: Είσοδος νέου κόμβου

- Ο νέος κόμβος πρέπει να φτιάξει τον πίνακα δρομολόγησης του
- Το κόστος κατασκευής του είναι αυτό της αναζήτησης
- Οι άλλοι κόμβοι πρέπει να ενημερώσουν τους δικούς τους πίνακες



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

40



Chord : Περίληψη

Βασικά σημεία:

- Κάθε κόμβος αποθηκεύει πληροφορία για μικρό αριθμό κόμβων (m)
 - Κάθε κόμβος ξέρει περισσότερα για τους κοντινούς του όρους (απότι για τους μακρινούς)

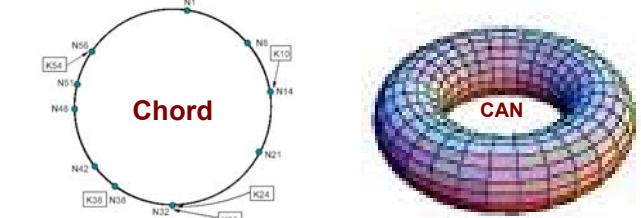
Επιδόσεις

- Χρόνος αναζήτησης: $O(\log n)$ (με μεγάλη πιθανότητα)
- Πλήθος Μηνυμάτων: $O(\log n)$ (επιλεκτική δρομολόγηση μηνυμάτων)
- Κόστος αποθήκευσης: $O(\log n)$ (πίνακας δρομολόγησης)
- Κόστος εισόδου/εξόδου κόμβου: $O(\log^2 n)$
- Κόστος ενημέρωσης: μικρό (περίπου σαν το κόστος αναζήτησης)
- Chord software
 - 3000 lines of C++ code, Library to be linked with the application, provides a `lookup(key)` – function: yields the IP address of the node responsible for the key, Notifies the node of changes in the set of keys the node is responsible for

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

41



CS463 - Information Retrieval

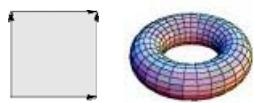
Yannis Tzitzikas, U. of Crete, Spring 2006

42



Δομημένα Ομότιμα Συστήματα CAN (Content Addressable Network)

- Βασίζεται στον κατακερματισμό κλειδών στον **κ-διάστατο**
Καρτεσιανό χώρο (torus) (συνήθως $k=2-10$)
 - Κλειδί = σημείο του κ-διάστατου χώρου
 - κ διαστάσεις, Hash(key) = (x_1, \dots, x_k)
- Κάθε κόμβος είναι υπεύθυνος για ένα κομμάτι του χώρου, μία **ζώνη**
 - Αποθηκεύει το ευρετήριο των αντικειμένων των οποίων οι συντεταγμένες εμπίπτουν στην ζώνη του
- Κάθε κόμβος αποθηκεύει τις διευθύνσεις των κόμβων των διπλανών ζωνών
- Εύρεση πόρου = δρομολόγηση στις ζώνες



<http://mathworld.wolfram.com/Torus.html>

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

43



Δομημένα Ομότιμα Συστήματα CAN

- Π.χ. για 2D, 4 peers A, B, C, D

1	B (0-0.5, 0.5-1)	C (0.5-1, 0.5-1)
0		
0	A (0-0.5, 0-0.5)	D (0.5-1, 0-0.5)
1		

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

44



Δομημένα Ομότιμα Συστήματα CAN

- Είσοδος ενός νέου κόμβου E

1	C (0.5-1, 0.75-1)
	B (0-0.5, 0.5-1)
	E (0.5-1, 0.5-75)
0	A (0-0.5, 0-0.5) D (0.5-1, 0-0.5)
1	

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

45



Δομημένα Ομότιμα Συστήματα CAN

- Ο E θέλει να ανακτήσει το αντικείμενο με συντεταγμένες (0.2, 0.2)

1	C (0.5-1, 0.75-1)
	B (0-0.5, 0.5-1)
	E (0.5-1, 0.5-75)
0	A (0-0.5, 0-0.5) D (0.5-1, 0-0.5)
1	

CS463 - Information Retrieval

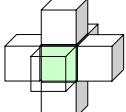
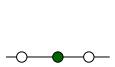
Yannis Tzitzikas, U. of Crete, Spring 2006

46



Δομημένα Ομότιμα Συστήματα CAN

- Αυξάνοντας τις διαστάσεις
 - μειώνεται το μήκος του μονοπατιού αναζήτησης
 - αυξάνεται το πλήθος των γειτόνων που πρέπει κάθε κόμβος να αποθηκεύει



- Πολυπλοκότητα αναζήτησης η κόμβοι, κ διαστάσεις

$$O(k\sqrt[n]{n})$$

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

47



Δομημένα Ομότιμα Συστήματα CAN Περίληψη

Βασικά σημεία:

- Κάθε κόμβος αποθηκεύει πληροφορία για ένα τμήμα του διανυσματικού χώρου και γνωρίζει τις διεύθυνσεις των διπλανών του κόμβων

Επιδόσεις

- Χρόνος αναζήτησης: $O(k n^{1/k})$ (με μεγάλη πιθανότητα)
- Πλήθος Μηνυμάτων: $O(k n^{1/k})$ (επιλεκτική δρομολόγηση μηνυμάτων)
- Κόστος αποθήκευσης: $O(k)$ (πίνακας δρομολόγησης)
- Κόστος ενημέρωσης: μικρό (περίπου σαν το κόστος αναζήτησης)

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

48



Περίληψη Ομότιμων Συστημάτων



Έστω ότι στην Ελλάδα κατοικούν 1000 άτομα και κάθε ένας τους έχει ένα τηλέφωνο

Τρόποι εύρεσης του τηλεφώνου ενός κυρίου X

- Napster-style
 - Εύρεση τηλεφώνου τηλεφωνώντας στο 11811 του OTE
- Gnutella-style
 - Εύρεση τηλεφώνου ρωτώντας όποιον βρούμε μπροστά μας (κ.ο.κ.)
- Kazaa-style
 - Δεν υπάρχει OTE για όλη την Ελλάδα, αλλά κάθε νομός έχει έναν τοπικό OTE. Τηλεφωνούμε στον τοπικό και αν αυτός δεν το έχει, επικοινωνεί με τους υπόλοιπους τοπικούς OTE

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

49



Περίληψη Ομότιμων Συστημάτων



• Freenet-style

- Κάθε ένας έχει μια ατζέντα περιορισμένου μεγέθους. Εύρεση τηλεφώνου τηλεφωνώντας σε αυτόν που έχει το πλησιέστερο όνομα (π.χ. λεξικογραφικά), κ.ο.κ. Όταν εν τέλει βρεθεί, ενημερώνουμε την ατζέντα μας.

• Chord-style

- Κάθε κάτοικος έχει μια ατζέντα με 10 τηλέφωνα ($10 = \log 1024$)
- Η εύρεση του τηλεφώνου του κυρίου X θα γίνει με 10 τηλεφωνήματα

• CAN-style

- Κάθε ένας έχει το τηλέφωνο των γειτόνων του
 - αν όλοι οι Έλληνες ζουν σε μονοκατοικίες τότε κάθε ένας έχει 4 γείτονες (Βορ.Νοτ.Α.Δ)
 - αν όλοι οι Έλληνες ζουν σε 1 πολυκατοικία τότε κάθε ένας έχει 6 γείτονες
- Για να τηλεφωνήσουμε σε κάποιον πρέπει να ξέρω που είναι το σπίτι του και τηλεφωνώ στο γείτονα μου που είναι προς εκείνη την κατεύθυνση (κ.ο.κ)
- Αν όλοι μένουν σε μονοκατοικίες τότε $2 * \text{SQRT}(1000) = 64$ τηλεφωνήματα
- Αν όλοι μένουν σε μια πολυκατοικία τότε $3 * \text{CubicRoot}(1000) = 3 * 10$ τηλεφωνήματα

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

50



Ανάκτηση Πληροφοριών & Συστήματα Ομοτίμων (Peer-to-Peer Systems)



Lecture : 17

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

51



Τι διαφέρει η Ανάκτηση σε P2P συστήματα από την Κατανεμημένη Ανάκτηση;

Η ανάκτηση πληροφοριών σε συστήματα ομότιμων είναι μια περίπτωση κατανεμημένης ανάκτησης

Ιδιαιτερότητες των ομότιμων συστημάτων:

- Υπερβολικά μεγάλος αριθμός πηγών (peers)
- Μεγαλύτερη αυτονομία πηγών
- Ελλειψη Σταθερότητας, Ελέγχου, Προβλεψιμότητας
 - (not stable, controllable, unpredictable)
- Επιτακτική ανάγκη για μείωση του κόστους επικοινωνίας

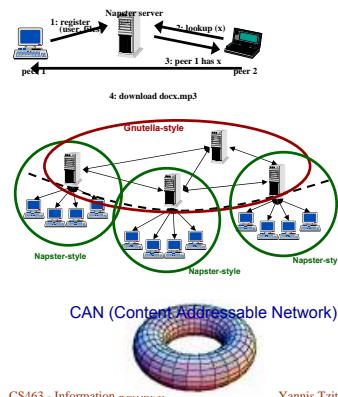
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

52



Αρχιτεκτονικές Ομότιμων Συστημάτων



CS463 - Information Retrieval

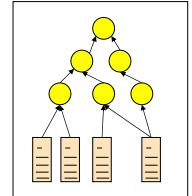
Yannis Tzitzikas, U. of Crete, Spring 2006

53



P2P and IR: Περίπτωση: Κατηγοριοποιημένα Έγγραφα

Έστω ότι κάθε έγγραφο είναι ταξινομημένο σε μια κατηγορία ενός ελεγχόμενου ευρετηρίου (ODP, Yahoo!). Ο χρήστης κάνει αναζήτηση δίνοντας μια κατηγορία



Έγγραφο ≈ mp3 αρχείο
κατηγορία έγγραφου ≈ τίτλος του mp3 αρχείου

Άρα μπορούμε να φτιάξουμε ένα ομότιμο σύστημα

- τύπου Napster (Hybrid P2P)
- τύπου Gnutella (Pure P2P)
- τύπου Kazaa (Hierarchical P2P)
- τύπου Freenet (Structured P2P)
- τύπου Chord (Structured P2P)
- τύπου CAN (Structured P2P)

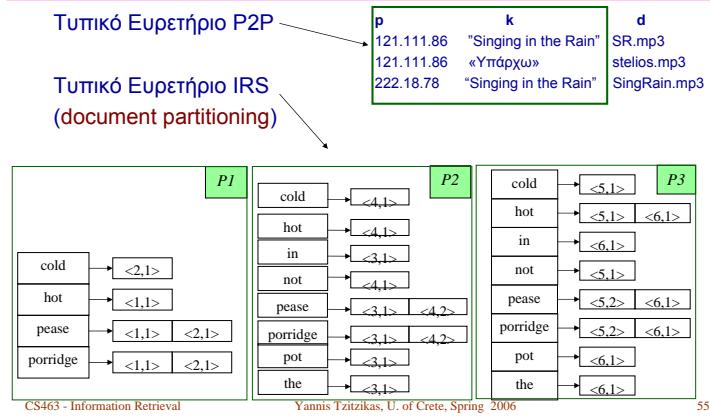
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

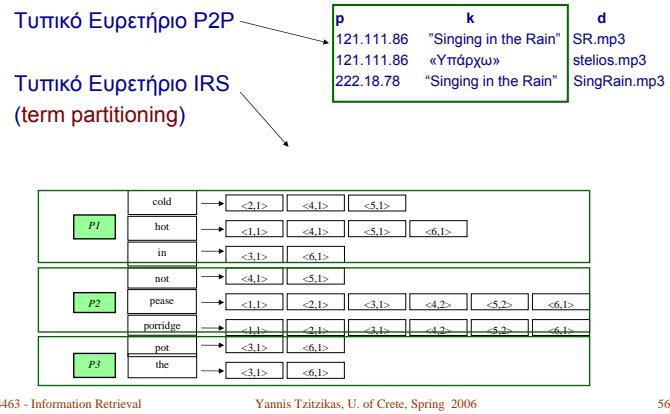
54



P2P and Statistical IR



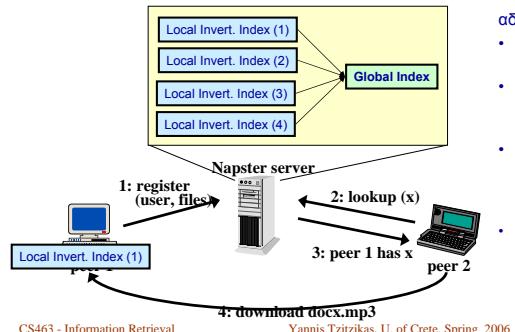
P2P and Statistical IR



P2P and IR: Ανεστραμμένα Ευρετήρια (Napster-style)

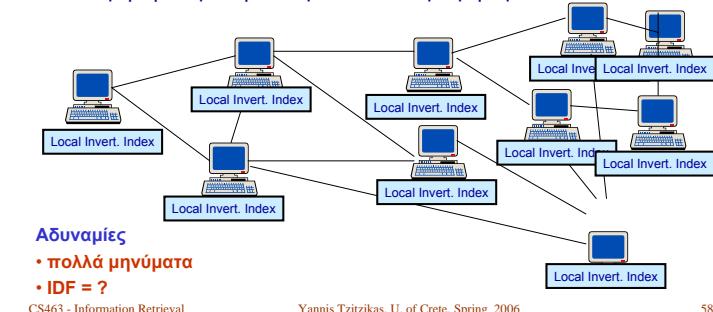


- Ένας κεντρικός εξυπηρετητής αποθηκεύει όλα τα ανεστραμμένα ευρετήρια των κόμβων



P2P and IR: (Gnutella-style)

- Κάθε κόμβος συντηρεί το ανεστραμμένο ευρετήριο των εγγράφων του.
- Αποτίμηση επερωτήσεων με κατακλυσμό μηνυμάτων



P2P and IR: (Gnutella-style)

Παραλλαγές του Κατακλυσμού μηνυμάτων

- BFS: Breadth First Search (=Gnutella)
- RBFS: κάθε κόμβος πρωθεί ένα μήνυμα σε ένα τυχαίο ποσοστό (π.χ. 20%) των γνωστών του κόμβων
 - + πιθανοκρατικός αλγόριθμος
 - μπορεί το μήνυμα να μην πάει σε κόμβους που έχουν συναφή αντικείμενα
- 1-Random Walker:
 - κάθε κόμβος πρωθεί ένα μήνυμα σε έναν τυχαία επιλεγμένο κόμβο από τους γνωστούς του
- k-Random Walkers:
 - κάθε κόμβος πρωθεί ένα μήνυμα σε κ τυχαία επιλεγμένους κόμβους από τους γνωστούς του
 - + λιγότερα μηνύματα από το RDFS
- APS: Adaptive Probabilistic Search

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

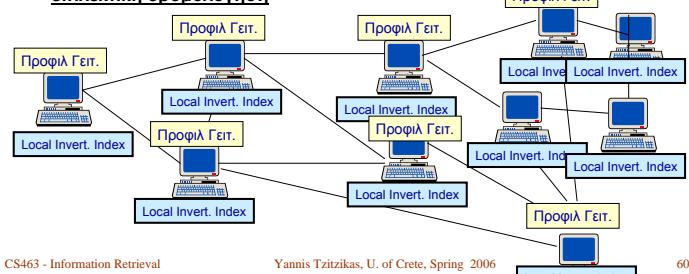
59



P2P and IR (Freenet-style)

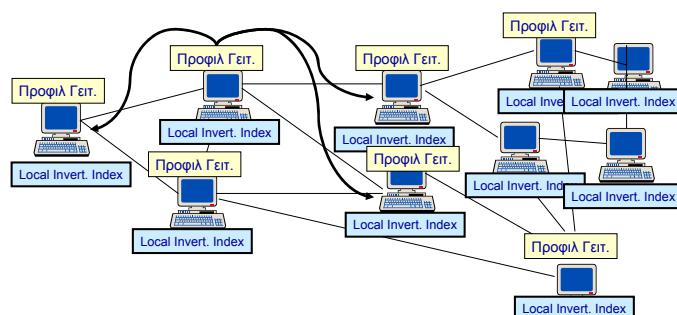
• Κάθε κόμβος:

- (α) συντηρεί το ανεστραμμένο ευρετήριο των εγγράφων του.
- (β) φτάχνει ένα προφίλ των γειτόνων του βασισμένο στις επερωτήσεις του παρελθόντος
- (γ) έχει μια φόρμουλα βαθμολόγησης κόμβων που τη χρησιμοποιεί για επιλεκτική δρομολόγηση





P2P and IR (Freenet-style)



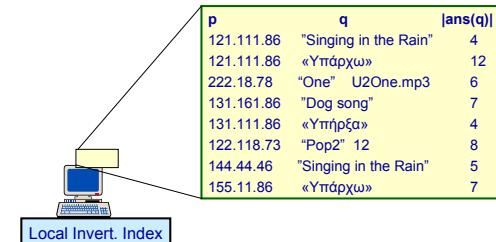
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

61



Προφίλ Γειτόνων βάσει των προηγούμενων απαντήσεων

– Το προφίλ είναι τριάδες της μορφής $(p, q, |ans(p, q)|)$

- όπου pj ένας γείτονας, q μια επερώτηση που απήνησε αυτός ο γείτονας, και $|ans(pj, q)|$ το μέγεθος της απάντησης
- LRU update policy

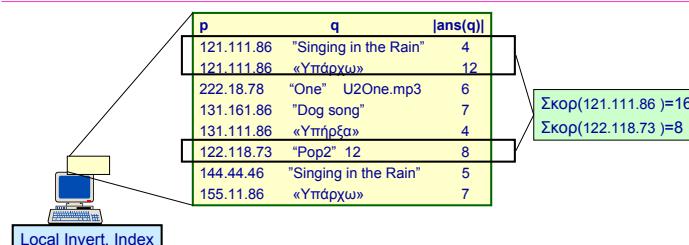
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

62



Προφίλ Γειτόνων και Δρομολόγηση: >RES (περισσότερα αποτελέσματα)



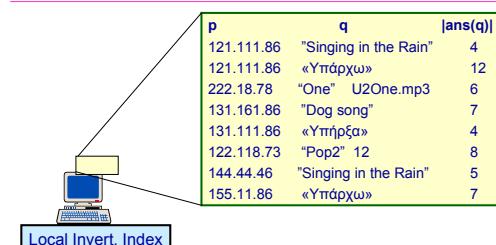
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

63



Προφίλ Γειτόνων και Δρομολόγηση: >RES και ομοιότητα επερωτήσεων



- Για την δρομολόγηση μιας επερώτησης επιλέγονται εκείνοι οι γείτονες που έχει δώσει τα περισσότερα αποτελέσματα στο παρελθόν (>RES) (συγκεκριμένα στις προηγούμενες ή επερωτήσεις)

- Το σκορ ενός γείτονα pj είναι
 - $Score(pj) = \sum \{ |ans(pj, qj)| \mid qj \text{ answered by } pj \text{ in the past} \}$

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

64



Προφίλ Γειτόνων και Δρομολόγηση: >RES και ομοιότητα επερωτήσεων

Το σκορ ενός γείτονα pj διοθείσας επερώτησης q , είναι:

>RES
 $Score(pj) = \sum \{ |ans(pj, qj)| \mid qj \text{ answered by } pj \text{ in the past} \}$

>RES και ομοιότητα επερωτήσεων
 $Score(pj, q) = \sum \{ |ans(pj, qj)| * sim(qj, q)^a \mid qj \text{ answered by } pj \text{ in the past} \}$

- $sim(qj, q)$: Π.χ. ομοιότητα συνημίτονου
- a : παράμετρος για το καθορισμό της σπουδαιότητας μεταξύ συνάφειας και μεγέθους απάντησης

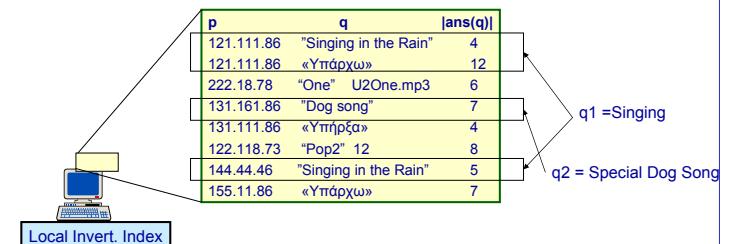
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

65



Προφίλ Γειτόνων και Δρομολόγηση: >RES και ομοιότητα επερωτήσεων



- Πότε αυτή η προσέγγιση είναι καλή;
- Απ: Οταν τα έγγραφα του κάθε κόμβου είναι σημασιολογικά κοντινά
 - Ποια η διαφορά με το Freenet ?
- Επειδή αυτό δύως δεν συμβαίνει πάντα η επερώτηση προωθείται και σε έναν τυχαία επιλεγμένο γείτονα. // επίσης για την εκκίνηση του συστήματος

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

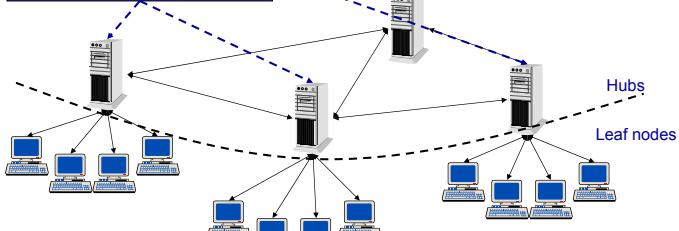
66



Ανάκτηση Κειμένων σε Ιεραρχικά Ομότιμα Συστήματα (Kazaa-style IR)

Γενική ιδέα: Κάνουμε ό,τι και στην κατανεμημένη, απλά εδώ έχουμε πολλούς μεσίτες
Κάθε μεσίτης (εδώ super-peer) έχει μια περιγραφή των περιεχομένων
των υποκείμενων κόμβων

- Επιλογή Πηγής
- Ενοποίηση Αποτελεσμάτων



CS463 - Information Retrieval

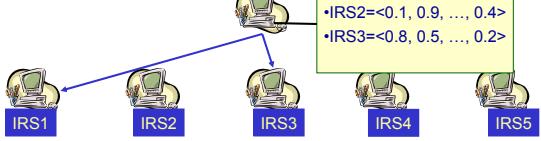
Yannis Tzitzikas, U. of Crete, Spring 2006

67



Επανάληψη: Επιλογή Πηγής με Διανύσματα Πηγών

IRS1=<0.4, 0.3, ..., 0.8>
IRS2=<0.1, 0.9, ..., 0.4>
IRS3=<0.8, 0.5, ..., 0.2>



- 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: $\log(N/n_i)$, όπου N το πλήθος των συλλογών, και n_i το πλήθος των συλλογών που έχουν τον όρο i
- Υπολογίζουμε το βαθμό ομοιότητας κάθε νέας επερώτησης με το διάνυσμα κάθε συλλογής (π.χ. ομοιότητα συνημίτουνο)
- Διατάσσουμε τις συλλογές και επιλέγουμε τις κορυφαίες

Εναλλακτικά: Αντί για ένα, μπορούμε να περιγράφουμε κάθε πηγή με Κ διανύσματα

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

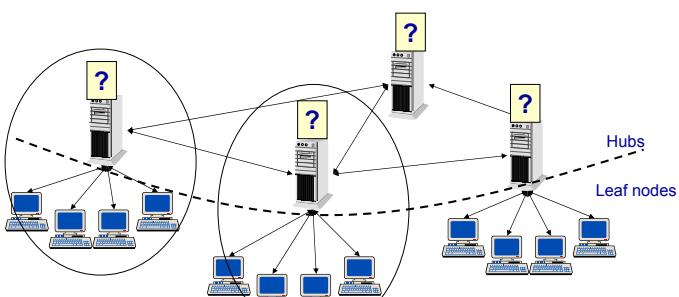
68



Ανάκτηση Κειμένων σε Ιεραρχικά Ομότιμα Συστήματα (Kazaa-style IR)

Περιγραφή των περιεχομένων των φύλλων

Ανάγκη για μείωση του αποθηκευτικού χώρου στα Hubs



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

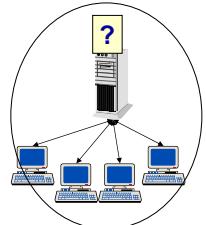
69



Ανάκτηση Κειμένων σε Ιεραρχικά Ομότιμα Συστήματα

Επιλογές

- 1/ Λεξιλόγια των υποκείμενων κόμβων + συχνότητες εμφάνισης τους
 - (δεν ξέρουμε το καθολικό λεξιλόγιο για να φτιάχνουμε το διάνυσμα πηγής)



- 2/ Λεξιλόγια των υποκείμενων κόμβων

- 3/ Λέξεις που εμφανίζονται πάνω από 1 φορά + συχνότητες τους
 - λόγω του νόμου του Zipf, ο απαιτούμενος αποθηκευτικός χώρος μειώνεται στο μισό

CS463 - Information Retrieval

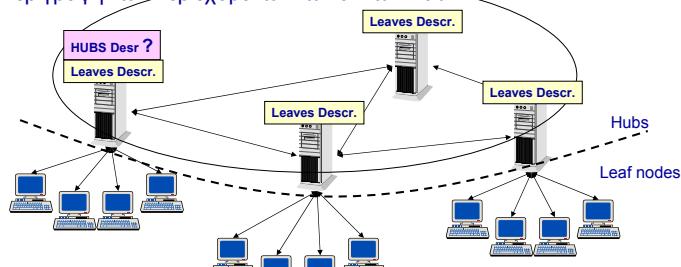
Yannis Tzitzikas, U. of Crete, Spring 2006

70



Ανάκτηση Κειμένων σε Ιεραρχικά Ομότιμα Συστήματα (Kazaa-style IR)

Περιγραφή των περιεχομένων των άλλων Hub ?



- Η περιγραφή ενός HUB είναι η ένωση των περιγραφών των υποκείμενων του κόμβου
- Καταγραφή προηγούμενων επερώτησεων που έχουν απαντηθεί

π.χ. >RES και ομοιότητα επερώτησης

Yannis Tzitzikas, U. of Crete, Spring 2006

71



Ανάκτηση Κειμένων σε Ιεραρχικά Ομότιμα Συστήματα

- A Client node sends its query to each of its connecting hubs.
- A hub that receives the query uses its **resource selection algorithm** to **rank** and **select one or more** neighboring leaf nodes as well as hubs, and routes the query to them if the message's TTL hasn't reached 0.
- A leaf node that receives the query message uses its **document retrieval algorithm** to generate a relevance ranking of its documents and responds with a queryhit message to include a list of top-ranked documents.
- Each top-level hub (the hub that connects directly to the client node that issues the request) collects the queryhit messages and uses its **result merging algorithm** to merge the documents retrieved from multiple leaf nodes into a single, integrated ranked list and returns it to the client node.
- If the client node issues the request to more than one hub, then it also needs to merge results returned by multiple toplevel hubs.

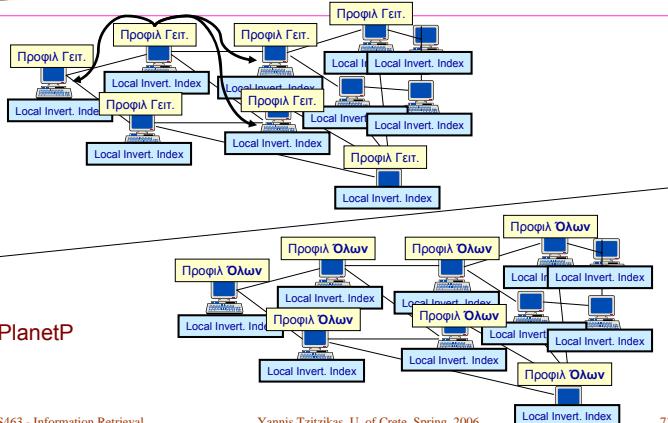
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

72



P2P and IR: Το σύστημα PlanetP



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

73

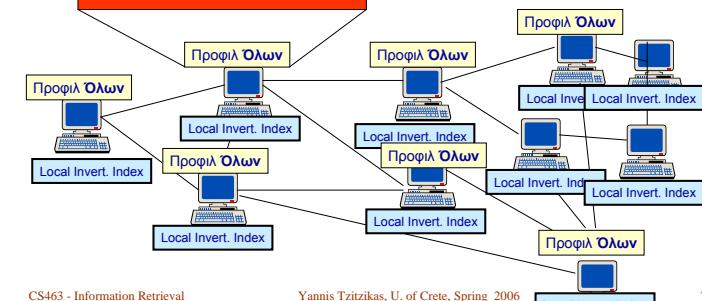


P2P and IR: Το σύστημα PlanetP

καθολικό ανεστραμμένο ευρετήριο όλων των κόμβων

? ΟΧΙ.

Ανάγκη για μια πιο συνοπτική περιγραφή



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

74



P2P and IR: Το σύστημα PlanetP Επιλογή Πηγής ???

Θυμηθείτε:
Κατανομή Συναφών Εγγράφων
(Relevant document distribution (RDD))
Διανύσματα Πηγών

- Το λεξιλόγιο κάθε κόμβου (όχι οι λίστες των εμφανίσεων) περιγράφεται με ένα Bloom φίλτρο
- ~ SIGNATURE FILES

CS463 - Information Retrieval

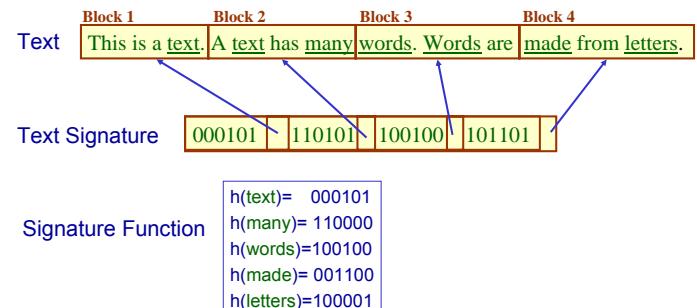
Yannis Tzitzikas, U. of Crete, Spring 2006

75



Επανάληψη: Signature files

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



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

76



Bloom filters [Burton Bloom 1970] Συμπαγής Κωδικοποίηση Συνόλων

Ένα σύνολο κωδικοποιείται σε ένα δυαδικό διάνυσμα με των **m-bits**

κ συναρτήσεις κατακερματισμού h_1, h_2, \dots, h_k , με πεδίο τιμών το $\{1, \dots, m\}$

Κωδικοποίηση στοιχείου:

$BF(\{\alpha\}) =$ διάνυσμα με άσσους στις θέσεις $h_1(\alpha), h_2(\alpha), \dots, h_k(\alpha)$

Κωδικοποίηση συνόλου:

$BF(\{\alpha_1, \alpha_2\}) = BF(\{\alpha_1\}) \text{ BitwiseOR } BF(\{\alpha_2\})$

Πώς βρίσκω αν ένα στοιχείο β ανήκει στο σύνολο A ?

1/ Υπολογίζω το BloomFilter του b

2/ Κοιτάζω αν οι άσσοι του BF(b) υπάρχουν στο BF(A)

Αν όχι, τότε σίγουρα το b δεν ανήκει στο A

Αν ναι, τότε ανήκει αλλά μπορεί και να μην ανήκει (false positive)

Όσο μεγαλύτερο είναι το m, τόσο μικρότερη η πιθανότητα για false positives

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

77



Bloom filters: Παράδειγμα

$m=14, k=3$



$hash1("apples") = 3$

$hash2("apples") = 12$

$hash3("apples") = 11$

{apples}=

$hash1("plums") = 11$

$hash2("plums") = 1$

$hash3("plums") = 8$

{apples, plums}=

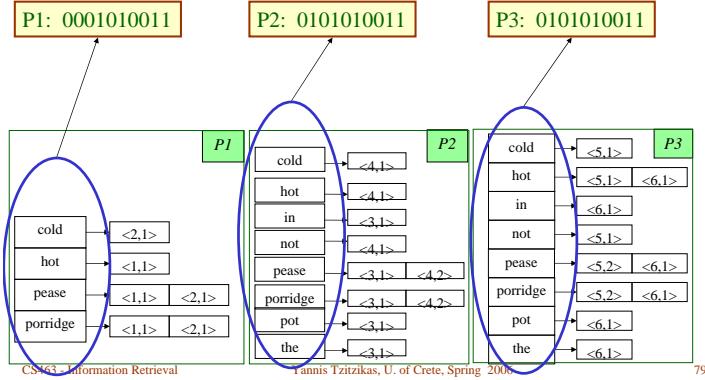
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

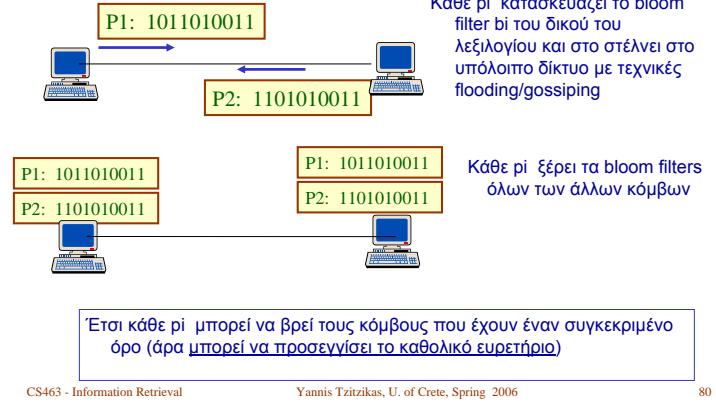
78



Περιγραφή των λεξιλογίων με Bloom filters



P2P and IR: Το σύστημα PlanetP



Bloom filters in PlanetP: Πόσο μεγάλα είναι;

AP89 Collection (Associated Press articles of 1989 from TREC):

84,678 documents, 129,603 words, collection size 266 MB

Num. Peers	Memory used (MB)	% of collection size
10	0.45	0.18%
100	1.79	0.70%
1000	4.48	1.76%

1000 Nodes: => about 4500 terms per peer

Bloom filters with less than 5% false positives =>

Bloom filter size for the vocabulary of one peer: 4.6 KB

Total size of bloom filters of peers : 4.6 MBytes

Γιατί το μέγεθος αυξάνει με το πλήθος των κόμβων;

CS463 - Information Retrieval

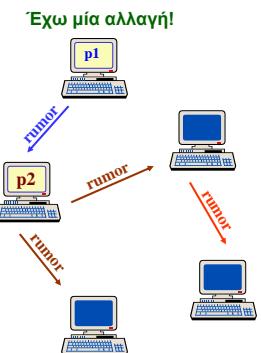
Yannis Tzitzikas, U. of Crete, Spring 2006

81

(Gossiping algorithms) Rumoring (φημολογία)

Ο p1 έχει μια αλλαγή:

- κάθε X δευτερόλεπτα, ο p1 στέλνει ένα μήνυμα με την αλλαγή σε έναν τυχαία επιλεγμένο κόμβο p2
- Αν ο p2 δεν ήξερε αυτήν την πληροφορία, τότε αρχίζει να κάνει ό,τι και ο p1
- Ο p1 σταματάει να στέλνει μηνύματα μόνο αν η συνεχόμενοι κόμβοι του πουν ότι ήταν ήδη ενήμεροι της αλλαγής.



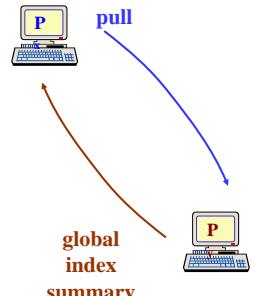
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

83

(Gossiping algorithms) anti-entropy

- Κάθε X δευτερόλεπτα, κάθε κόμβος επιλέγει τυχαία έναν άλλο κόμβο (από το καθολικό του ευρετήριο) και του ζητάει να του στείλει μια περίληψη του δικού του καθολικού ευρετήριο.
- Αν διαπιστώσει ότι δεν είναι ενημερωμένος, του ζητάει ό,τι χρειάζεται.
- Purpose: The algorithm allows to avoid the possibility of rumors dying out before reaching everyone



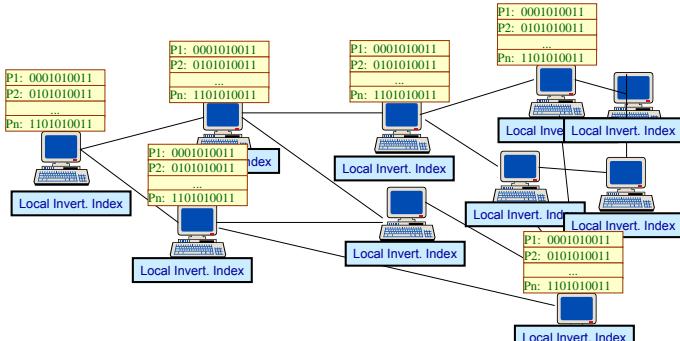
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

84



P2P and IR: Το σύστημα PlanetP



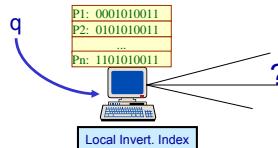
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

85



PlanetP: Επιλογή Κόμβου



- 1/ **Βαθμολόγηση κόμβων** βάσει της πιθανότητας να έχουν έγγραφα συναφή με την q
- 2/ **Επιλογή** των κόμβων που θα επερωτηθούν και ενοποίηση των αποτελεσμάτων που θα επιστρέψουν

Inverse Peer Frequency (IPF) of a term t =

$$\text{IPF}(t) := |\text{total number of peers}| / |\text{peers that contain the term } t|$$

$$\text{Score}(pj, q) = \sum \{ \text{IPF}(t) \mid t \in q, t \in Bfilter(pj) \}$$

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

86



PlanetP: Αποτελεσματικότητα & Επιδόσεις

- Η αποτελεσματικότητα προσεγγίζει αυτήν που θα είχαμε αν κάθε κόμβος είχε ολόκληρο το ευρετήριο
- Τα μηνύματα φτάνουν σε 20%-40% περισσότερους κόμβους σε σχέση με την περίπτωση όπου κάθε κόμβος γνώριζε ακριβώς το καθολικό ευρετήριο
- Gossiping rate 1/second => PlanetP can propagate a Bloom filter containing 1000 terms in less than 40 secs for a community of 1000 peers. This requires an average of 24KB/s per peer.

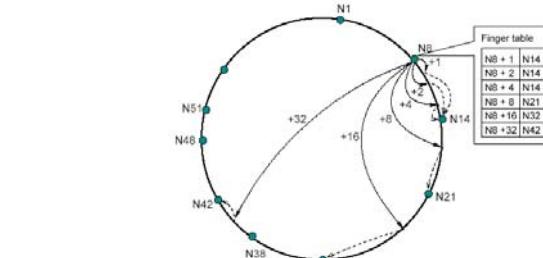
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

87



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (Chord-style)



- Ποια είναι εδώ τα κλειδιά ?

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

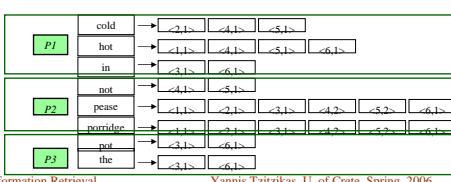
88



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (Chord-style)

Περίπτωση (I): Κάθε όρος είναι ένα κλειδί

- Το ευρετήριο κατανέμεται βάσει των όρων
 - (άρα έχουμε term-partitioning: Θυμηθείτε την παράλληλη Α.Π.)
- Αδυναμία: Η ενημέρωση των ευρετηρίων είναι ακριβή:
 - Εισαγωγή ενός νέου εγγράφου:
 - Για κάθε λέξη του εγγράφου, πρέπει να βρούμε τον κόμβο που είναι υπεύθυνος για αυτήν την λέξη και να του στείλουμε την ανεστραμμένη λίστα



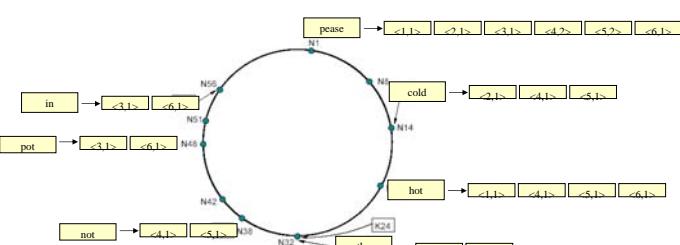
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

89



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (Chord-style): Κάθε όρος είναι ένα κλειδί



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

90



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (Chord-style)

– Αποτίμηση επερώτησης q

- Βρίσκουμε κάθε κόμβο που έχει τουλάχιστον έναν όρο του q (χρησιμοποιώντας τους πίνακες δρομολόγησης)
- Σενάριο 1: κάθε ένας από αυτούς τους κόμβους υπολογίζει τα μερικά σκορ και τα στέλνει στον ερωτώντα (αφού τον στείλουμε και την επερώτηση)
- Σενάριο 2: κάθε ένας από αυτούς τους κόμβους επιστρέφει τις ανεστραμμένες λίστες
- [...] Ανταλλαγή πολλών μηνυμάτων για επερωτήσεις με πολλούς όρους



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

91



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (Chord-style)

Υπόθεση: Έστω ότι το σύστημα λαμβάνει πολύ συχνά επερωτήσεις με 2 όρους

Περίπτωση (II): Θεωρούμε ως κλειδί κάθε ζευγάρι όρων

- Αν η επερώτηση έχει 2 όρους, τότε ένας μόνο κόμβος θα έχει όλο το κομμάτι του ευρετηρίου που χρειάζεται
- Άρα έτσι έχουμε λίγα μηνύματα

• Π.χ. q= Hotels Crete

- Ξέρω ότι υπάρχει ένας κόμβος που έχει τις ανεστραμμένες λίστες και των δυο όρων, άρα ο κόμβος αυτός μπορεί να αποτιμήσει πλήρως την επερώτηση

• Αδυναμία: |V|* (|V|-1) κλειδιά, άρα η ανεστραμμένη λίστα κάθε λέξης είναι αποθηκευμένη |V|-1 φορές



Η είσοδος ενός νέου εγγράφου είναι ακόμα πιο ακριβή

Yannis Tzitzikas, U. of Crete, Spring 2006

92



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα

• Περίπτωση (III): Θεωρούμε ως κλειδιά τα διανύσματα των εγγράφων

- **Ερ:** Ποια προσέγγιση δομημένων συστημάτων είναι κατάλληλη για την παράσταση διανυσμάτων (Chord ή CAN);
- **Απ:** Η προσέγγιση του CAN διότι βλέπει τον χώρο των κλειδιών ως ένα κ-διάστατο χώρου
- Άρα διαμερίζουμε τα έγγραφα στους κόμβους βάσει των διανυσμάτων τους.
- (άρα document-partitioning (θυμηθείτε την Παράλληλη Α.Π.))
- **Ερ:** Τι κερδίζουμε διαμερίζοντας τα έγγραφα όπως το CAN ?
- **Απ:** Τα κοντινά (ως προς το μέτρο συνημίτονου) έγγραφα τοποθετούνται στον ίδιο ή σε κοντινούς κόμβους.

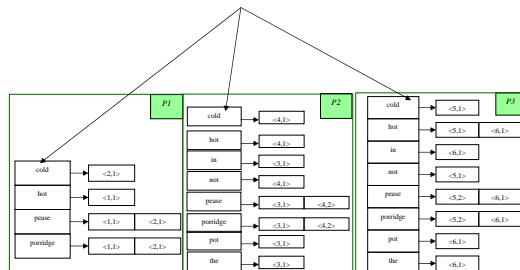
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

93



Document Partitioning: Ο υπολογισμός των καθολικών στατιστικών (IDF) απαιτεί επικοινωνία



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

94



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (CAN-style)

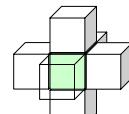
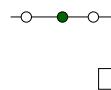
– **Ερ:** Πόσες διαστάσεις έχουν τα διανύσματα των εγγράφων;

– **Απ:** Συνήθως πολλές (π.χ. 10.000)

– **Ερ:** Πόσους γείτονες έχει μια περιοχή κ-διάστατου χώρου;

– **Απ:** κατά μέσο όρο 2k

- Για k=1 έχω 2
- Για k=2 έχω 4
- Για k=3 έχω 6
- Για k=10.000 έχω 20.000 !



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

95



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (CAN-style). Το σύστημα pSearch

• Μείωση των διαστάσεων των διανυσμάτων για

– (I) Μείωση του αριθμού των γειτόνων που πρέπει να γνωρίζει (αποθηκεύει) ένας κόμβος.

– (II) Ομαδοποίηση εγγράφων

• Αξιοποίηση συνωνύμων, συνεμφανιζόμενων λέξεων, μείωση θορύβου

• Τρόπος μείωσης διαστάσεων: **Latent Semantic Indexing**

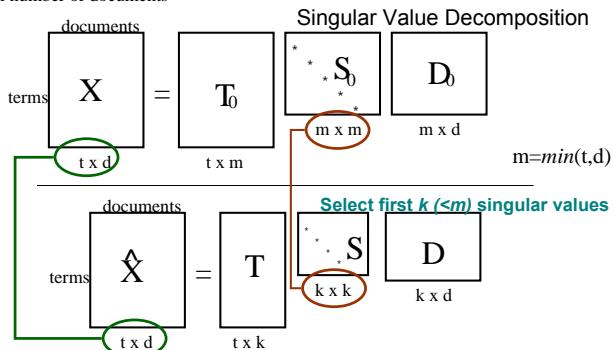
Yannis Tzitzikas, U. of Crete, Spring 2006

96



Επανάληψη: Latent Semantic Indexing:

t: total number of index terms
d: total number of documents



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

97



Επανάληψη LSI: Paper example

Index terms in italics

Titles:

- c1: *Human machine interface for Lab ABC computer applications*
- c2: *A survey of user opinion of computer system response time*
- c3: *The EPS user interface management system*
- c4: *System and human system engineering testing of EPS*
- c5: *Relation of user-perceived response time to error measurement*

- m1: The generation of random, binary, unordered *trees*
- m2: The intersection graph of paths in *trees*
- m3: *Graph minors IV: Widths of trees and well-quasi-ordering*
- m4: *Graph minors: A survey*

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

98



Επανάληψη LSI: term-document Matrix

Terms	Documents								
	c1	c2	c3	c4	c5	m1	m2	m3	m4
human	1	0	0	1	0	0	0	0	0
interface	1	0	1	0	0	0	0	0	0
computer	1	1	0	0	0	0	0	0	0
user	0	1	1	0	1	0	0	0	0
system	0	1	1	2	0	0	0	0	0
response	0	1	0	0	1	0	0	0	0
time	0	1	0	0	1	0	0	0	0
EPS	0	0	1	1	0	0	0	0	0
survey	0	1	0	0	0	0	0	0	1
trees	0	0	0	0	0	1	1	1	0
graph	0	0	0	0	0	0	1	1	1
minors	0	0	0	0	0	0	0	1	1

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

99



Επανάληψη LSI: T_0, S_0, D_0

$$T_0 = \begin{bmatrix} 0.22 & -0.11 & 0.29 & -0.41 & 0.11 & -0.34 & 0.52 & -0.06 & -0.13 \\ 0.20 & -0.07 & 0.14 & -0.55 & 0.28 & 0.50 & -0.07 & -0.01 & 0.11 \\ 0.24 & 0.04 & -0.16 & -0.59 & -0.11 & -0.25 & -0.30 & 0.06 & 0.49 \\ 0.40 & 0.06 & 0.17 & -0.17 & 0.17 & 0.21 & -0.27 & 0.01 & -0.21 \\ 0.64 & -0.17 & 0.36 & 0.33 & -0.16 & -0.21 & -0.17 & 0.03 & 0.27 \\ 0.27 & 0.11 & -0.43 & 0.07 & 0.08 & -0.17 & 0.28 & -0.02 & -0.05 \\ 0.54 & 0.23 & -0.16 & 0.57 & 0.27 & 0.21 & -0.37 & 0.26 & -0.02 \\ 0.30 & -0.14 & 0.33 & 0.19 & 0.11 & 0.27 & 0.03 & -0.02 & -0.17 \\ 0.21 & 0.27 & -0.18 & -0.03 & -0.54 & 0.08 & -0.47 & -0.04 & -0.58 \\ 0.48 & 0.19 & 0.10 & 0.02 & 0.39 & 0.30 & -0.34 & 0.45 & -0.23 \\ 0.04 & 0.62 & 0.22 & 0.00 & -0.07 & 0.11 & 0.16 & -0.68 & 0.23 \\ 0.03 & 0.45 & 0.14 & -0.01 & -0.30 & 0.28 & 0.34 & -0.68 & 0.11 \end{bmatrix}$$

$$S_0 = \begin{bmatrix} 1.34 & 2.54 & 2.35 & 1.64 & 1.50 & 1.31 & 0.85 & 0.56 & 0.36 \end{bmatrix}$$

$$D_0 = \begin{bmatrix} 0.20 & -0.06 & 0.11 & -0.95 & 0.05 & -0.08 & 0.18 & -0.01 & -0.06 \\ 0.46 & -0.13 & 0.21 & -0.04 & 0.38 & 0.72 & -0.24 & 0.01 & 0.02 \\ 0.54 & -0.23 & 0.57 & 0.27 & -0.21 & -0.37 & 0.26 & -0.02 & -0.08 \\ 0.54 & 0.23 & -0.16 & 0.57 & 0.27 & 0.21 & -0.37 & 0.26 & -0.02 \\ 0.00 & 0.19 & 0.10 & 0.02 & 0.39 & -0.30 & -0.34 & 0.45 & -0.62 \\ 0.01 & 0.44 & 0.19 & 0.02 & 0.35 & -0.21 & -0.15 & 0.76 & 0.02 \\ 0.02 & 0.63 & 0.28 & 0.01 & 0.15 & 0.60 & 0.25 & 0.45 & 0.52 \\ 0.98 & 0.53 & 0.08 & -0.03 & -0.60 & 0.36 & 0.04 & -0.07 & -0.11 \end{bmatrix}$$

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

100



Επανάληψη LSI: SVD with minor terms dropped

$$T = \begin{bmatrix} 0.22 & -0.11 & 0.20 & -0.06 & 0.20 & 0.06 & 0.20 & 0.06 & 0.20 & 0.06 \\ 0.20 & -0.07 & 0.14 & -0.17 & 0.17 & 0.27 & 0.27 & 0.27 & 0.27 & 0.27 \\ 0.24 & 0.04 & -0.16 & -0.17 & 0.11 & 0.27 & 0.27 & 0.27 & 0.27 & 0.27 \\ 0.40 & 0.06 & 0.17 & 0.17 & 0.11 & -0.23 & 0.11 & 0.19 & 0.44 & 0.62 \\ 0.64 & -0.17 & 0.36 & 0.33 & -0.16 & -0.21 & -0.17 & 0.03 & 0.27 & 0.27 \\ 0.27 & 0.11 & -0.43 & 0.07 & 0.08 & -0.17 & 0.28 & -0.02 & -0.05 & 0.27 \\ 0.54 & 0.23 & -0.16 & 0.57 & 0.27 & 0.21 & -0.37 & 0.26 & -0.02 & -0.08 \\ 0.30 & -0.14 & 0.33 & 0.19 & 0.11 & 0.27 & 0.03 & -0.02 & -0.17 & 0.27 \\ 0.21 & 0.27 & -0.18 & -0.03 & -0.54 & 0.08 & -0.47 & -0.04 & -0.58 & 0.27 \\ 0.48 & 0.19 & 0.10 & 0.02 & 0.39 & 0.30 & -0.34 & 0.45 & -0.62 & 0.27 \\ 0.04 & 0.62 & 0.22 & 0.00 & -0.07 & 0.11 & 0.16 & -0.68 & 0.23 & 0.27 \\ 0.03 & 0.45 & 0.14 & -0.01 & -0.30 & 0.28 & 0.34 & -0.68 & 0.11 & 0.27 \end{bmatrix}$$

$$S = \begin{bmatrix} 1.34 & 2.54 & 2.35 & 1.64 & 1.50 & 1.31 & 0.85 & 0.56 & 0.36 \end{bmatrix}$$

$$D' = \begin{bmatrix} 0.20 & 0.61 & 0.46 & 0.54 & 0.28 & 0.00 & 0.02 & 0.02 & 0.08 \\ 0.46 & 0.13 & 0.21 & 0.04 & 0.38 & 0.72 & -0.24 & 0.01 & 0.02 \\ 0.54 & -0.23 & 0.57 & 0.27 & -0.21 & -0.37 & 0.26 & -0.02 & -0.08 \\ 0.54 & 0.23 & -0.16 & 0.57 & 0.27 & 0.21 & -0.37 & 0.26 & -0.02 \\ 0.00 & 0.19 & 0.10 & 0.02 & 0.39 & -0.30 & -0.34 & 0.45 & -0.62 \\ 0.01 & 0.44 & 0.19 & 0.02 & 0.35 & -0.21 & -0.15 & 0.76 & 0.02 \\ 0.02 & 0.63 & 0.28 & 0.01 & 0.15 & 0.60 & 0.25 & 0.45 & 0.52 \\ 0.98 & 0.53 & 0.08 & -0.03 & -0.60 & 0.36 & 0.04 & -0.07 & -0.11 \end{bmatrix}$$

TS define coordinates for documents in latent space

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

101



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συστά (CAN-style). Το σύστημα pSearch

- Διάσταση διανυσμάτων μετά την εφαρμογή LSI: **50-350**
- Φτιάχνουμε ένα CAN με διαστάσεις όσες των διανυσμάτων (μετά το LSI).
- Εισαγωγή ενός νέου εγγράφου:
 - Φτιάχνεται το «semantic διάνυσμα» του εγγράφου (βάσει των διαστάσεων που προέκυψαν από την εφαρμογή του LSI) και εισάγεται στον κατάλληλο κόμβο
- Είσοδος μιας νέας επερώτησης
 - Φτιάχνεται το semantic διάνυσμα της επερώτησης και δρομολογείται στον κατάλληλο κόμβο
 - Μόλις φτάσει στον κόμβο, διαδίδεται στους γείτονες σε απόσταση ρ
 - Το ρ μπορεί να διεταί μαζί με την αρχική επερώτηση

CS463 - Information Retrieval

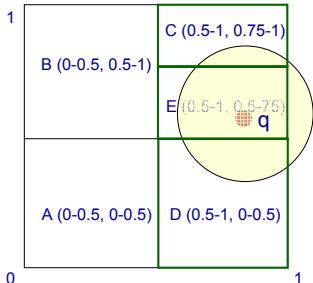
Yannis Tzitzikas, U. of Crete, Spring 2006

102



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (CAN-style). Το σύστημα pSearch

- Επερώτηση



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

103



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (CAN-style). Το σύστημα pSearch

- Ο υπολογισμός του LSI απαιτεί Καθολικά στατιστικά (IDF)
- Επίσης όλοι οι κόμβοι πρέπει να γνωρίζουν την βάση του σημασιολογικού χώρου (για να υπολογίζουμε τα σημασιολογικά διανύσματα των νέων εγγράφων).
- Τα παραπάνω πρέπει να διαδοθούν σε όλους τους κόμβους.

- Το πρόβλημα των διαστάσεων

- 300 LSI διαστάσεις. Αν έχω λίγους κόμβους τότε η πραγματική διάσταση του CAN είναι μικρότερη γιατί δεν υπάρχουν αρκετοί κόμβοι. Έτσι πολλές διαστάσεις παραμένουν αδιαμέριστες, μεγαλώνοντας έτσι το μήκος του μονοπατιού αναζήτησης.

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

103

CS463 - Information Retrieval

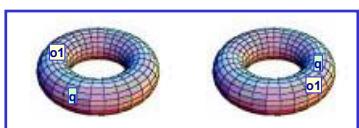
Yannis Tzitzikas, U. of Crete, Spring 2006

104



CAN & Multiple Realities

- Ένας τρόπος αύξησης της ευρωστίας / ανθεκτικότητας είναι να θεωρήσουμε Πολλαπλές Πραγματικότητες (Multiple Realities)
 - Δεν έχουμε 1 αλλά m διαφορετικά συστήματα συντεταγμένων
 - Κάθε κόμβος έχει μια ζώνη για κάθε σύστημα συντεταγμένων
 - Έτσι έχουμε m αντίγραφα ευρετήριου
 - Μείωση του μήκους του μονοπατιού αναζήτησης (επιλέγεται το σύστημα συντεταγμένων βάσει του οποίου η αναζητούμενη ζώνη είναι εγγύτερη)



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

105



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (CAN-style). Το σύστημα pSearch

- Διαμερισμός των διανυσμάτων σε πολλά διανύσματα μικρότερης διάστασης
 - $(x_1, \dots, x_n) \Rightarrow (x_1, \dots, x_n), (x_{n+1}, \dots, x_n), (x_{n+2}, \dots, x_n), \dots, (x_n)$
 - Τα πρώτα διανύσματα αποθηκεύονται σε ένα CAN1
 - Τα δεύτερα σε ένα CAN2, κ.ο.κ
 - Το διάνυσμα μιας επερώτησης επίσης διαμερίζεται σε διανύσματα μικρότερης διάστασης
 - :

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

106



Ανάκτηση Πληροφοριών σε Δομημένα Ομ. Συσ/τα (CAN-style). Το σύστημα pSearch: Σύνοψη

- Φτιάχνουμε ένα ευρετήριο όπου κάθε έγγραφο δεν περιγράφεται από το διάνυσμα του, αλλά από το διάνυσμα που προκύπτει αν πρώτα εφαρμόσουμε **Latent Semantic Indexing**
 - διανύσματα μικρότερης διάστασης, ομαδοποίηση εγγράφων
- Τα ευρετήρια αυτό διανέμεται στους κόμβους. Το κλειδί του κάθε εγγράφου είναι το διάνυσμα του (μετά την εφαρμογή του LSI). // Αυτό θα τοποθετηθεί στον ίδιο κόμβο εννοιολογικά συναφή έγγραφα
- Ο υπολογισμός των διανυσμάτων απαιτεί καθολικά στατιστικά (άρα υπάρχει ανάγκη επικοινωνίας). Επίσης πρέπει να συμφωνηθεί η βάση των διανυσμάτων.
- Μπορεί να χρησιμοποιηθεί και για πολυμέσα (θυμηθείτε Feature-based Multimedia Indexing).

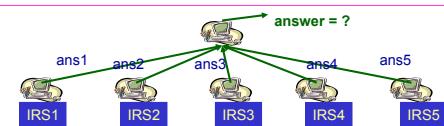
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

107



Ενοποίηση Αποτελεσμάτων & Ομότιμα Συστήματα



- Τεχνικές Ενοποίησης Αποτελεσμάτων

- Round Robin Inter-leaving
- Score-based (~ merge sort)
 - καλή αν τα σκόρ υπολογίζονται βάσει των καθολικών στατιστικών
- Weighted-score based
 - Έστω di προερχόμενο από μια πηγή Sj
 - $score(di) = score(Sj, di) * score(Sj)$
- Λαμβάνοντας υπόψη μόνο τις διατάξεις και όχι τα σκόρ (ενοποίηση διατάξεων)
 - Borda, Condorcet, Kemeny, Arrow's Impossibility Theorem

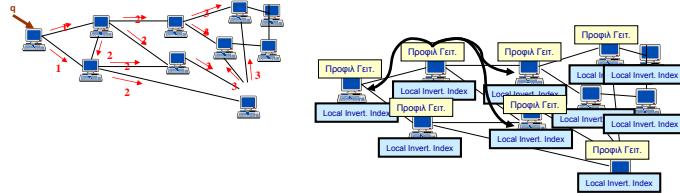
CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

108



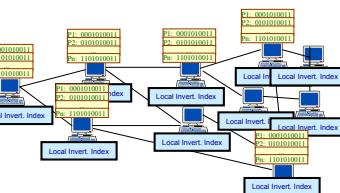
Ενοποίηση Αποτελεσμάτων σε Ομότιμα Συστήματα (I): Οι κόμβοι δεν έχουν στη διάθεση τους καθολικά στατιστικά



- Gnutella-like systems (document-partitioning):
 - Ενοποίηση: Round-robin interleaving, Score-based, Rank-Aggregation
- Συστήματα βασισμένα σε προφίλ γειτόνων και >RES
 - Ενοποίηση: Weighted score-based



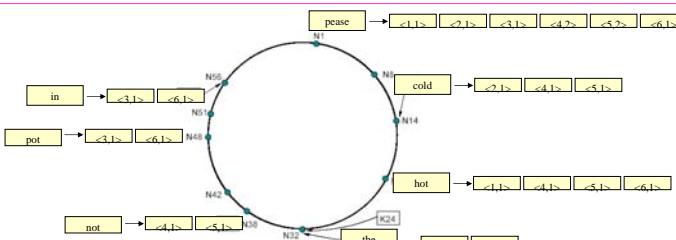
Ενοποίηση Αποτελεσμάτων σε Ομότιμα Συστήματα (II): Οι κόμβοι μπορούν να προσεγγίσουν τα καθολικά στατιστικά



- Π.χ. PlanetP (κάθε κόμβος μπορεί να προσεγγίσει το καθολικό ευρετήριο)
 - Ενοποίηση: Weighted score-based
 - (καλύτερο από το προφίλ γειτόνων, λιγότερα μηνύματα)



Ενοποίηση Αποτελεσμάτων σε Ομότιμα Συστήματα (III): Οι κόμβοι έχουν στη διάθεση τους τα καθολικά στατιστικά



- Π.χ. Chord-like (term-partitioning)
 - ο κόμβος που είναι υπεύθυνος για έναν όρο γνωρίζει τις συχνότητες εμφάνισης του καθώς και το πλήθος των κόμβων που έχουν έγγραφα που περιέχουν αυτόν τον όρο
 - Ενοποίηση: απλό Score-based είναι μια χαρά
 - κάθε κόμβος υπολογίζει partial scores, ο ερωτών τα αθροίζει και παράγει την τελική διάταξη



Ενοποίηση Αποτελεσμάτων σε Ομότιμα Συστήματα (III): Οι κόμβοι έχουν στη διάθεση τους τα καθολικά στατιστικά

- Έστω σύστημα όπως το Chord, στο οποίο τα κλειδιά είναι οι όροι και το οποίο συνολικά έχει 100.000 έγγραφα
- Η ανεστραμμένη λίστα ενός όρου έχει το πολύ 100.000 αναφορές σε έγγραφα (έστω ότι κατά μέσο όρο έχει 10.000 αναφορές)
- Έστω ότι ο λαμβάνει επερώτηση q με 5 δρους. Κάθε όρος της q (μαζί με βάρος του στο q) θα πρωθηθεί στον υπεύθυνο κόμβο για τον όρο αυτό
- Κάθε ένας από τους 5 κόμβους θα διστάξει τα έγγραφα βάσει του όρου αυτού και θα επιστρέψει μια λίστα μερικών αποτελεσμάτων
 - το πολύ 100.000 τριάδες ($p, docId, score$) κάτα μέσο όρο 10.000
- Ο θα λάβει αυτές τις 5 λίστες και θα αθροίσει τα μερικά σκορ
 - $score(doc) = score1(doc) + \dots + score5(doc)$
- Άρα $5 * 10.000$ τριάδες ακεραίων πρέπει να μεταφερθούν στο δίκτυο
 - $TotalBytes = 50K * 3 * 4 = 600 KB$
- Ερώτηση: Αν ο ρ θέλει να βρει μόνο τα κορυφαία κ (π.χ. $k=10$) έγγραφα. Πώς μπορούμε να ελαχιστοποιήσουμε την πληροφορία που πρέπει να μεταφέρουμε;



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 k αντικείμενα με το υψηλότερο ενοποιημένο σκορ.

Εφαρμογές:

- Υπολογισμός των κορυφαίων- k στοιχείων της απάντησης
 - ενός ΣΑΠ που βασίζεται στο διανυσματικό μοντέλο (τα m κριτήρια είναι οι m όροι της επερώτησης)
 - ενός μεσίτη πάνω από τα Συστήματα Ανάκτησης Πληροφοριών
 - μιας επερώτησης σε μια Βάση Πολυμέσων
 - κριτήρια: χρώμα, μορφή, υφή, ...



Άλλο ένα παράδειγμα εφαρμογής

- Ενοποίηση απαντήσεων σε Μεσολαβητές (middleware)
 - έστω μια υπηρεσία εύρεσης εστιατορίων βάσει τριών κριτηρίων:
 - τιμή γεύματος
 - απόσταση από ένα σημείο
 - κατάταξη εστιατορίου
 - όπου ο χρήστης μπορεί να ορίσει τον επιθυμητό τρόπο υπολογισμού του ενοποιημένου σκορ ενός εστιατορίου
 - π.χ. $\text{Σκορ} = \text{Τιμή} * 0.5 + \text{Stars} * 0.25 + 0.25 * \text{DistanceFromHome}$
 - η υπηρεσία αυτή υλοποιείται με χρήση τριών απομακρυσμένων υπηρεσιών
 - (a) `getRestaurantsByPrice`
 - (b) `getRestaurantsByStars`
 - (c) `getRestaurantsByDistance`
 - Πώς μπορώ να ελαχιστοποιήσω το πλήθος των στοιχείων που πρέπει να διαβάσω από την απάντηση της κάθε υπηρεσίας, προκειμένου να βρω τα κορυφαία 5 εστιατόρια;



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 k

Παρατηρήσεις

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

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

115



Εύρεση των κ-κορυφαίων Παράδειγμα: Απλοϊκός Τρόπος

$$\begin{aligned} S1 &= \langle A 0.9, C 0.8, E 0.7, B 0.5, F 0.5, G 0.5, H 0.5 \rangle \\ S2 &= \langle B 1.0, E 0.8, F 0.7, A 0.7, C 0.5, H 0.5, G 0.5 \rangle \\ S3 &= \langle A 0.8, C 0.8, E 0.7, B 0.5, F 0.5, G 0.5, H 0.5 \rangle \end{aligned}$$

Ο Απλοϊκός Τρόπος

$$\begin{aligned} \text{Score}(A) &= 0.9 + 0.7 + 0.8 = 2.4 \\ \text{Score}(B) &= 0.5 + 1.0 + 0.5 = 2 \\ \text{Score}(C) &= 0.8 + 0.5 + 0.8 = 2.1 \\ \text{Score}(E) &= 0.7 + 0.8 + 0.7 = 2.2 \\ \text{Score}(F) &= 0.5 + 0.7 + 0.5 = 1.7 \\ \text{Score}(G) &= 0.5 + 0.5 + 0.5 = 1.5 \\ \text{Score}(H) &= 0.5 + 0.5 + 0.5 = 1.5 \\ \text{Τελική διάταξη: } &\langle A, E, C, B, F, G, H \rangle \end{aligned}$$

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

116



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 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**.

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

117



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 η κατηγορία
- 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 k

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

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

118



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

$$\begin{aligned} S1 &= \langle A 0.9, C 0.8, E 0.7, B 0.5, F 0.5, G 0.5, H 0.5 \rangle \\ S2 &= \langle B 1.0, E 0.8, F 0.7, A 0.7, C 0.5, H 0.5, G 0.5 \rangle \\ S3 &= \langle A 0.8, C 0.8, E 0.7, B 0.5, F 0.5, G 0.5, H 0.5 \rangle \end{aligned}$$

Έστω ότι θέλω το Top-1

Το Ε εμφανίζεται σε όλες

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

Το Ε δεν είναι σίγουρα ο νικητής.

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

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

Πράγματι, top-1 = {A}

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

119



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

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

120



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

$$\begin{aligned} S1 &= \langle A 0.9, C 0.8, E 0.7, B 0.5, F 0.5, G 0.5, H 0.5 \rangle \\ S2 &= \langle B 1.0, E 0.8, F 0.7, A 0.7, C 0.5, H 0.5, G 0.5 \rangle \\ S3 &= \langle A 0.8, C 0.8, E 0.7, B 0.5, F 0.5, G 0.5, H 0.5 \rangle \end{aligned}$$

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

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

121



Εύρεση των κ-κορυφαίων Παράδειγμα: Αλγόριθμος TA:

$$\begin{aligned} S1 &= \langle A 0.9, C 0.8, E 0.7, B 0.5, F 0.5, G 0.5, H 0.5 \rangle \\ S2 &= \langle B 1.0, E 0.8, F 0.7, A 0.7, C 0.5, H 0.5, G 0.5 \rangle \\ S3 &= \langle A 0.8, C 0.8, E 0.7, B 0.5, F 0.5, G 0.5, H 0.5 \rangle \end{aligned}$$

Έστω ότι θέλω το Top-1

$$\begin{aligned} \text{Score}(A) &= 0.9 + 0.7 + 0.8 = 2.4 \\ \text{Score}(B) &= 0.5 + 1.0 + 0.5 = 2 \\ \text{UpperBound} &= 0.9 + 1.0 + 0.8 = 2.7 \\ \text{αφού } 2.7 &> 2.4 \text{ συνεχίζω} \end{aligned}$$

$$\begin{aligned} \text{Score}(C) &= 0.8 + 0.5 + 0.8 = 2.1 \\ \text{Score}(E) &= 0.7 + 0.8 + 0.7 = 2.2 \\ \text{UpperBound} &= 0.8 + 0.8 + 0.8 = 2.4 \\ \text{αφού } 2.4 &\text{ δεν είναι μεγαλύτερο του } 2.4 \text{ (σκορ του A) σταματάω.} \end{aligned}$$

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

122



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.

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

123



Ενοποίηση Αποτελεσμάτων σε Ομότιμα Συστήματα (III): Οι κόμβοι έχουν στη διάθεση τους τα καθολικά στατιστικά

- Έστω σύστημα όπως το Chord, στο οποίο τα κλειδιά είναι οι όροι και το οποίο συνολικά έχει 100.000 έγγραφα
- Η ανεστραμμένη λίστα ενός όρου έχει το πολύ 100.000 αναφορές σε έγγραφα (έστω ότι κατά μέσο όρο έχει 10.000 αναφορές)
- Έστω ότι ο ρ λαμβάνει επερώτηση q με 5 δρους. Κάθε όρος της q (μαζί με βάρος του στο q) θα πρωθηθεί στον υπεύθυνο κόμβο για τον όρο αυτού
- Κάθε ένας από τους 5 κόμβους θα διστάξει τα έγγραφα βάσει του όρου αυτού και θα επιστρέψει μια λίστα μερικών αποτελεσμάτων
 - το πολύ 100.000 τριάδες ($p, docId, score$) κάτα μέσο όρο 10.000
- Ο ρ θα λάβει αυτές τις 5 λίστες και θα αθροίσει τα μερικά σκορ
 - $score(doc) = score1(doc) + \dots + score5(doc)$
- Άρα $5 * 10.000$ τριάδες ακεραίων πρέπει να μεταφερθούν στο δίκτυο
 - TotalBytes = $50K * 3 * 4 = 600$ KB
- Ερώτηση: Αν ο ρ θέλει να βρει μόνο τα κορυφαία κ (π.χ. $k=10$) έγγραφα. Πώς μπορούμε να ελαχιστοποιήσουμε την πληροφορία που πρέπει να μεταφέρουμε;

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

124



Ομότιμα Συστήματα (P2P) και Ανάκτηση Πληροφοριών

- Διαφορές με Κατανεμημένη Ανάκτηση
- Napster-style
- Gnutella-style (local inv. Index)
- Freenet-style
 - ($p, q, |ans(q)|, >RES$
 - ($p, q, |ans(q)|, >RES * sim(q)$
- Hierarchical
- PlanetP (Bloom filters)
- Chord-style: key=1 term, a term pair, ...
 - term partitioning
- CAN-style: key = LSI vector pSearch (LSI + CAN)
 - document partitioning
 - Result aggregation Γενικά: P2P & IR = αντικείμενο έρευνας σήμερα



CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

125



Αναφορές

- D. Zeinalipour-Yazti, Vana Kalogeraki, Dimitrios Gunopoulos, Information Retrieval in P2P Networks
- Text-Based Content Search and Retrieval in ad hoc P2P Communities, Francisco Matias Cuenca-Acuna and Thu D. Nguyen
- Jie Lu, Jamie Callan, «Federated Search of Text-Based Digital Libraries in Hierarchical Peer-to-Peer Networks», SIGMOD'04 workshop
- Fagin, Lotem, and Naor, Optimal Aggregation Algorithms for Middleware (PODS 2001)

CS463 - Information Retrieval

Yannis Tzitzikas, U. of Crete, Spring 2006

126