

Επεξεργασία Ερωτήσεων

Θέματα Βάσεων Λεδοράνων 1999-2000 *Εναγγέλια Πτυχορά* 1

Εισαγωγή

1. ΜΟΝΤΕΛΑ ΔΕΔΟΜΕΝΩΝ

Μοντέλα
Γλώσσες Ερωτήσεων
Επεξεργασία Ερωτήσεων

—————> **Επεξεργασία Ερωτήσεων σε Ημιδομημένα Δεδομένα**

2. ΑΡΧΙΤΕΚΤΟΝΙΚΕΣ
3. ΤΡΟΠΟΙ ΜΕΤΑΔΟΣΗΣ

Θέματα Βάσεων Λεδοράνων 1999-2000 *Εναγγέλια Πτυχορά* 2

Εισαγωγή

1. ΜΟΝΤΕΛΑ ΔΕΔΟΜΕΝΩΝ

...

Επεξεργασία Ερωτήσεων
Επεξεργασία Ερωτήσεων σε Ημιδομημένα Δεδομένα
Αποθήκευση
—————> Εμφετήρια
Κατανεμημένος Υπολογισμός
Συστήματα (Lore, Strudel)

2. ΑΡΧΙΤΕΚΤΟΝΙΚΕΣ
3. ΤΡΟΠΟΙ ΜΕΤΑΔΟΣΗΣ

Θέματα Βάσεων Λεδοράνων 1999-2000 *Εναγγέλια Πτυχορά* 3

Επεξεργασία Ερωτήσεων για Ημι-δομημένα Δεδομένα

Θέματα Βάσεων Λεδοράνων 1999-2000 *Εναγγέλια Πτυχορά* 4

Επεξεργασία Ερωτήσεων

Τα ίδια βασικά στάδια

1. Μετάφραση - ένα σχέδιο εκτέλεσης
2. Βελτιστοποίηση
3. Μηχανή Εκτέλεσης

- Έλλειψη σχήματος
- Κατανομή/Αρχιτεκτονικές

Θέματα Βάσεων Λεδοράνων 1999-2000 *Εναγγέλια Πτυχορά* 5

Αποθήκευση

- Storage back-end
- Type information

Τρόποι Αποθήκευσης

1. Κείμενο
2. Σχέσιακή Βάση Δεδομένων
3. Αντικειμενο-στραφή Βάση Δεδομένων
4. Αυτο-οργάνωση - Υβριδική αποθήκευση

Θέματα Βάσεων Λεδοράνων 1999-2000 *Εναγγέλια Πτυχορά* 6

Ευρετήρια

Ευρετήρια για

1. Εκφράσεις Μονοπατιών (σε δέντρα & γράφους)
2. XML documents (και γενικά tagged αρχεία)
3. Κείμενο (text files) - search engines

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγέλια Πτυχορά* 7

Ευρετήρια για εκφράσεις μονοπατιών

Ευρετήρια για εκφράσεις μονοπατιών

Σχήμα 8.8 (σελίδα 181)

Ερωτήσεις:

- (R1) part.name
- (R2) part.supplier.name
- (R3) *_supplier.name
- (R4) part_*_subpart.name

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγέλια Πτυχορά* 8

Ευρετήρια για εκφράσεις μονοπατιών

κόμβοι που ακριβώς τα ίδια μονοπάτια από τη ρίζα ($\pi\chi$, κόμβοι $n1$, $n3$ και $n12$ - $n2$, $n13$ και $n4$ στο Σχήμα 8.8)

p1 and p2 language-equivalent: for any path expression query, either both p1 and p2 are in the answer or none is

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγέλια Πτυχορά* 9

Ευρετήρια για εκφράσεις μονοπατιών

Για κάθε κόμβο x

$L_x = \{w \mid \exists \text{ path from the root to } x \text{ labeled } w\}$

L_x

- μπορεί να είναι άπειρο αν ο γράφος έχει ικόνους
- γενικά περιγράφεται από μια κανονική έκφραση

x and y language-equivalent: ($x \equiv y$) if $L_x = L_y$

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγέλια Πτυχορά* 10

Ευρετήρια για εκφράσεις μονοπατιών

Εστω $[x]$ η κλάση ισοδυναμίας για το x

Κατασκευή των ευρετηρίων

ένα κόμβο για κάθε κλάση ισοδυναμίας
υπάρχει ακμή από το $[x]$ στο $[y]$ με label a αν υπάρχουν κόμβοι x' στο $[x]$ και y' στο $[y]$ που συνδέονται με κάποια ακμή με label a

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγέλια Πτυχορά* 11

Ευρετήρια για εκφράσεις μονοπατιών

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγέλια Πτυχορά* 12

Ευρετήρια για εκφράσεις μονοπατιών

Ερωτήσεις:

- (R1) part.name
 $h1 \rightarrow h2 \rightarrow hn$
- (R2) part.supplier.name
 $h1 \rightarrow h2 \rightarrow h3 \rightarrow h11$
- (R3) _* supplier.name
 $??$
- (R4) part._* subpart.name
search all nodes in the subtree rooted at h2

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγελία Πτυχιά* 13

Ευρετήρια για εκφράσεις μονοπατιών

Πώς θα υπολογίσουμε αν $x \equiv y$;

Reverse graph
ισχύει
 $\forall x,y, x = y \Rightarrow x \equiv y$

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγελία Πτυχιά* 14

Ευρετήρια για XML text

Ευρετήρια για XML text

- περιοχή (region): ένα συνεχόμενο (contiguous) τμήμα κειμένου στο αρχείο
- σύνολο περιοχών (region set) : ένα σύνολο περιοχών τέτοιο ώστε δύο οποιεσδήποτε περιοχές του συνόλου είτε είναι ξένες (disjoint) είτε η μία περιεχεται στην άλλη

Στη δεντρική αναπαράσταση

κάθε κόμβος ορίζει μια περιοχή (π χ, ο κόμβος p2 αντιστοιχεί στο κείμενο κάτω από τον κόμβο p2)

σύνολο περιοχών: σύνολο κόμβων

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγελία Πτυχιά* 15

Ευρετήρια για XML text

Ιδιαίτερο ενδιαφέρον - σύνολα περιοχών που αντιστοιχούν σε XML tags



$\pi\chi$, part ορίζει το σύνολα περιοχών {p1, p2, p3}
subpart ορίζει το σύνολα περιοχών {s1, s2, s3, s4, s5}

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγελία Πτυχιά* 16

Ευρετήρια για XML text

Περιοχή
ζεύγος (x, y) : start and end position of the region in the text file

Σύνολο Περιοχών
ordered tree: κάθε κόμβος μια περιοχή


- $r = (x, y)$ ancestor of $r' = (x', y')$ ($r' \subseteq r$)
 - if $x \leq x' \leq y \leq y'$

 - r to the left of r'
if $x \leq y \leq x' \leq y'$


Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγελία Πτυχιά* 17

Ευρετήρια για XML text

Παράδειγμα

subpart {s1,s2,s3,s4,s5}



```

graph TD
    Root --- S1
    Root --- S3
    Root --- S4
    Root --- S5
    S1 --- S2
  
```

Θέματα Βάσεων Λεδοράδων 1999-2000 *Εναγγελία Πτυχιά* 18

Ευρετήρια για XML text

Region Algebra (άλγεβρα για περιοχές)

- πάνω σε σύνολα περιοχών
- τελεστές (op) που δίνουν ως αποτέλεσμα σύνολα περιοχών: s1 op s2

νέα σύνολα περιοχών -- όχι νέες περιοχές αυτές θεωρούνται προκαθορισμένες (αντιστοιχούν στους κόμβους)

Θέματα Βάσεων Λεδοράδων 1999-2000 Εναγγέλια Πτυχορά 19

Ευρετήρια για XML text

Παραδείγματα τελεστών μιας άλγεβρας περιοχών

```

s1 intersect s2 ≡ {r | r ∈ s1, r ∈ s2}
s1 included s2 ≡ {r | r ∈ s1, ∃ r' ∈ s2, r ⊆ r'}
s1 including s2 ≡ {r | r ∈ s1, ∃ r' ∈ s2, r ⊇ r'}
s1 parent s2 ≡ {r | r ∈ s1, ∃ r' ∈ s2, r is a parent of r'}
s1 child s2 ≡ {r | r ∈ s1, ∃ r' ∈ s2, r is a child of r'}

```

Θέματα Βάσεων Λεδοράδων 1999-2000 Εναγγέλια Πτυχορά 20

Ευρετήρια για XML text

Παραδείγματα

- subpart {s1, s2, s3, s4, s5} part {p1, p2, p3}
- subpart included part {s1, s2, s3, s5}
- part including subpart {p2, p3}

- name {n1, n2, ..., n12} part {p1, p2, p3}
- name child part {n1, n3, n12}
- name included part {n1, n2, ..., n9, n12}

Θέματα Βάσεων Λεδοράδων 1999-2000 Εναγγέλια Πτυχορά 21

Ευρετήρια για XML text

Υπολογισμός Τελεστών

s1 op s2
traverse the tree representations of s1 and s2 simultaneously similar to a merge join

Θέματα Βάσεων Λεδοράδων 1999-2000 Εναγγέλια Πτυχορά 22

Ευρετήρια για XML text

Παράδειγμα : s1 included s2
(υποθέτουμε ότι τα s1 και s2 είναι σύνολα ξένων περιοχών)

Αρχικά (x1, y1) το πρώτο στοιχείο του s1 και (x2, y2) το πρώτο στοιχείο του s2

Μέχρι το τέλος της λίστας s1 ή s2

Av x1 < x2, advance s1	x2		x1	y1	y2
------------------------	----	--	----	----	----

Av y1 > y2, advance s2

Αλλιώς, πρόσθεσε το (x1, y1) στο αποτέλεσμα, advance s1

Θέματα Βάσεων Λεδοράδων 1999-2000 Εναγγέλια Πτυχορά 23

Ευρετήρια για XML text

Ερωτήσεις

(R1) part.name
 name child (part child root)

(R2) part.supplier.name
 name child (supplier child (part child root))

(R3) _ * supplier.name
 name child supplier

(R4) part._ * subpart.name
 name child (subpart included (part child root))

Θέματα Βάσεων Λεδοράδων 1999-2000 Εναγγέλια Πτυχορά 24

Ευρετήρια για XML text

(R5)

```
select X
from *_subpart: {name: X, *_supplier.address: "Philadelphia"}  
  
name child (subpart includes (supplier parent (address intersect "Philadelphia")))
```

Θέματα Βάσεων Λεδοράδων 1999-2000
Επαγγέλμα Πτυχορά 25

Ευρετήρια για XML text

- μόνο ένα περιορισμένο αριθμό από κανονικές εκφράσεις, συγκεκριμένα για τις εκφράσεις R_1, R_2, \dots, R_n όπου R_i label constant or the Kleene closure ($_*$)
- μόνο για ordered trees

Θέματα Βάσεων Λεδοράδων 1999-2000
Επαγγέλμα Πτυχορά 26

Ευρετήρια για κείμενο

Ευρετήρια για κείμενο

ένας σημαντικός τύπος ερώτησης: **keyword search**

- ο πιο συνηθισμένος τύπος ερώτησης στις μηχανές αναζήτησης
- συνήγοροι κρατείται και μια λίστα με συνάντηση (π.χ. ερώτηση για car - επίσης, automobile)
- πιο περίπλοκες ερώτησης που περιλαμβάνουν and, or, not

Θέματα Βάσεων Λεδοράδων 1999-2000
Επαγγέλμα Πτυχορά 27

Ευρετήρια για κείμενο

Δυο βασικοί τύποι ερωτήσεων:

- boolean
- ranked query

1. Boolean query (conjunctive normal form)

$$(t_{11} \vee t_{12} \vee \dots \vee t_{1l}) \wedge \dots \wedge (t_{j1} \vee t_{j2} \vee \dots \vee t_{jl})$$

όπου t_{ij} είναι ανεξάρτητα query terms ή keywords

j conjuncts (που αντιστοιχούν σε διαφορετικές έννοιες (concepts)) - καθεμία από πολλά disjunctions (που αντιστοιχούν σε διαφορετικούς όρους για την ίδια έννοια)

Θέματα Βάσεων Λεδοράδων 1999-2000
Επαγγέλμα Πτυχορά 28

Ευρετήρια για κείμενο

2. Ranked query

Αποτέλεσμα

σύνολο από documents που επιπρόσθετα είναι **ταξινομημένα με βάση τη σχετικότητά τους** (ranked by their relevance)

Information retrieval

Δύο κριτήρια

- **precision (ακρίβεια)**: ποσοστό των ανακαλούμενων (retrieved) documents που είναι σχετικά με την ερώτηση
- **recall**: ποσοστό των σχετικών documents της βάσης δεδομένων που ανακαλούνται ως απάντηση στην ερώτηση

Θέματα Βάσεων Λεδοράδων 1999-2000
Επαγγέλμα Πτυχορά 29

Ευρετήρια

Ευρετήριο

ζεύγη <keyword, documentId>

με πιθανά επιπρόσθετα πεδία όπως πόσες φορές εμφανίζεται το keyword στο document

- Μια μηχανή αναζήτησης δημιουργεί ένα κεντρικό ευρετήριο για documents που είναι αποθηκευμένα σε διάφορα sites

Θέματα Βάσεων Λεδοράδων 1999-2000
Επαγγέλμα Πτυχορά 30

Ευρετήρια για κείμενο

Inverted files

- Για κάθε όρο (term) μια ταξινομημένη λίστα (inverted list) από τα ids των documents που περιέχουν αυτόν το όρο
- Επιπρόσθια, όλοι οι πιθανοί όροι τοποθετώνται σε ένα δευτερεύον ευρετήριο (π.χ., B+δέντρο) -- ευρετήριο λέξικου για την αναζήτηση

Conjunction -- ζεκινώντας από τη συντομότερη λίστα

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 31

Ευρετήρια για κείμενο

Inverted files

Rid	Document	Word	Inverted List
1	agent James Bond	agent	<1,2>
2	agent mobile computer	Bond	<1,4>
3	James Madison movie	computer	<2>
4	James Bond movie	James	<1,3,4>
		Madison	<>
		mobile	<>
		movie	<3,4>

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 32

Ευρετήρια για κείμενο

Signature files

Μια εγγραφή ευρετηρίου (**signature - υπογραφή**) για κάθε document

Κάθε υπογραφή έχει σταθερό μέγεθος b bits - το b ονομάζεται **πλάτος της υπογραφής** (**signature width**)

Ποια bits της υπογραφής ενός κειμένου τίθονται ίσα με 1 εξαρτάται από το ποιες λέξεις εμφανίζονται στο κείμενο

- εφάρμοσε μια συνάρτηση κατακερματισμού σε κάθε λέξη που εμφανίζεται στο κείμενο
- θέσε τα bits που εμφανίζονται στο αποτέλεσμα της συνάρτησης
- ένα bit μπορεί να γίνεται 1 πολλοπλές φορές από διαφορετικές λέξεις

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 33

Ευρετήρια για κείμενο

Rid	Document	Signature	Word	Hash
1	agent James Bond	1100	agent	1000
2	agent mobile computer	1101	Bond	0100
3	James Madison movie	1011	computer	0100
4	James Bond movie	1110	James	1000
			Madison	0001
			mobile	0001
			movie	0010

Πλάτος υπογραφής 4

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 34

Ευρετήρια για κείμενο

Signature files

- Μια υπογραφή S_1 **ταιριάζει** (**matches**) μια άλλη υπογραφή S_2 , αν όλα τα bits που έχουν τεθεί στην S_2 έχουν επίσης τεθεί και στην S_1
- Αν μια υπογραφή S_1 ταιριάζει μια υπογραφή S_2 , τότε η υπογραφή S_1 έχει τουλάχιστον τόσα bits όσα και η υπογραφή S_2

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 35

Ευρετήρια για κείμενο

Rid	Document	Signature
1	agent James Bond	1100 \$2
2	agent mobile computer	1101 \$1
3	James Madison movie	1011
4	James Bond movie	1110

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 36

Ευρετήρια για κείμενο

Signature files

Conjunction (Σύνενξη)

- Δημιουργησε την υπογραφή της ερώτησης εφαρμόζοντας την συνάρτηση κατακερματισμού σε κάθε λέξη στην ερώτηση
- Scan το αρχείο των υπογραφών και ανακάλεσε (retrieve) όλα τα documents των οποίων οι υπογραφές ταιριάζουν με την υπογραφή της ερώτησης
- Ανακάλεσε (retrieve) κάθε πιθανό ταίριασμα και έλεγχε αν πραγματικά περιέχει τις λέξεις της ερώτησης

false positive

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 37

Ευρετήρια για κείμενο

Rid	Document	Signature	Word	Hash
1	agent James Bond	1100	agent	1000
2	agent mobile computer	1101	Bond	0100
3	James Madison movie	1011	computer	0100
4	James Bond movie	1110	James	1000
			Madison	0001
			mobile	0001
			movie	0010

Πλάτος υπογραφής 4

Ερωτήσεις: "James", "James" and "Bond", "movie" and "Madison"

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 38

Ευρετήρια για κείμενο

Signature files

Disjunction (διάσενξη)

- Δημιουργησε μια λίστα από υπογραφές για την ερώτηση μία για κάνε λέξη της ερώτησης
- Scan το αρχείο των υπογραφών αρχείων και ανακάλεσε όλα τα documents των οποίων οι υπογραφές ταιριάζουν τουλάχιστον με μια υπογραφή στη λίστα των υπογραφών της ερώτησης

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 39

Ευρετήρια για κείμενο

Rid	Document	Signature	Word	Hash
1	agent James Bond	1100	agent	1000
2	agent mobile computer	1101	Bond	0100
3	James Madison movie	1011	computer	0100
4	James Bond movie	1110	James	1000
			Madison	0001
			mobile	0001
			movie	0010

Ερωτήσεις: "James" or "Bond", "Bond" or "agent"

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 40

Ευρετήρια για κείμενο

scan the *complete signature file*

Κάθετος διαμερισμός του αρχείου με τις υπογραφές σε σύνολα από b bit slices -- bit sliced signature file

Για μια ερώτηση με q bits - retrieve only q bit slices

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 41

Ερωτήσεις στο www

Διάκριση σελιδών σε

- authorities (αυθεντίες) και
- hubs

Αυθεντία (authority) : μια σελίδα που είναι πολύ σχετική σε ένα συγκεκριμένο θέμα και αναγνωρίζεται από τις άλλες σελίδες ως έγκυρη (authoritative) στο θέμα

Θέματα Βάσεων Λεδοράνων 1999-2000 Εναγγέλια Πτυχορά 42

Ερωτήσεις στο www

Οι άλλες σελίδες (**hubs**) έχουν συνήθως ένα μεγάλο αριθμό αναφορών (hyperlinks) στις αυθεντίες αν και οι ίδιες δεν είναι ιδιαίτερα γνωστές και το περιεχόμενο τους δεν είναι απαραίτητα πολύ σχετικό με το θέμα

Παραδείγματα hubs

συλλογή από πηγές για ένα θέμα σε μια επαγγελματική σελίδα λίστα από σελίδες σχετικές με τα hobbies ενός συγκεκριμένου χρήστη ή και τιμήμα των bookmarks ενός συγκεκριμένου χρήστη

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 43

Ερωτήσεις στο www

- το βασικό χαρακτηριστικό των hubs είναι ότι έχουν πολλά links προς σχετικές σελίδες

- ενώ μπορεί να υπάρχουν πολύ λίγα links που δείχνουν σε ένα hub

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 44

Ερωτήσεις στο www

Ο αλγόριθμος HITS

Είσοδος: ερώτηση χρήστη με έναν αριθμό όρων (terms)

Αποτέλεσμα: ένα σύνολο από καλές αυθεντίες και hubs

www :: κατευθυνόμενο γράφο (κόμβοι: σελίδες, ακμές: hyperlink)

Ο αλγόριθμος προσχωρά σε δύο βήματα:

■ Βήμα Δειγματοληψίας (sampling step): ένα σύνολο σελίδων που καλείται το βασικό σύνολο

■ Δεύτερο Βήμα : ποιες από τις σελίδες στο βασικό σύνολο είναι καλές αυθεντίες και ποιες καλά hubs

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 45

Ερωτήσεις στο www

Βήμα Δειγματοληψίας

I. Retrieve ένα σύνολο web σελίδων που περιέχουν τους όρους της ερώτησης - το σύνολο αυτό καλείται σύνολο ρίζα (root set)

Πως:

για παράδειγμα υπολογίζοντας την ερώτηση ως μια boolean keyword query

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 46

Ερωτήσεις στο www

Αρκεί;

Link page μια σελίδα που είτε περιέχει κάποιο hyperlink σε σελίδα του συνόλου ρίζα ή μια σελίδα του συνόλου ρίζα έχει κάποιο hyperlink σε αυτήν

2. Επέκταση του συνόλου ρίζα με όλες τις link σελίδες → βασικό σύνολο

Βασική σελίδα: σελίδα του βασικού συνόλου

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 47

Ερωτήσεις στο www

Δεύτερο βήμα

Συσχετίζουμε με κάθε σελίδα δύο βάρη:

- hub weight
- authority weight

Υπολογίζουμε τα βάρη με βάση την υπόθεση

- οτι μια σελίδα είναι καλή αυθεντία αν πολλά καλά hubs δείχνουν σε αυτήν
- ενώ ένα hub είναι ένα καλό hub αν έχει πολλά links σε καλές αυθεντίες

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 48

Ερωτήσεις στο www

Αρχικά και τα δύο βάρη είναι ίσα με 1

Έστω μια βασική σελίδα p με hub weight h_p και authority weight a_p

Σε κάθε βήμα

αυξάνουμε το a_p ώστε να είναι ίσο με το άθροισμα των hub weights h_q των σελίδων q που δείχνουν στη p

αυξάνουμε το h_p ώστε να είναι ίσο με το άθροισμα των authority weights a_q όλων των σελίδων q στις οποίες δείχνει η p

Θέματα Βάσεων Λεδοράδων 1999-2000

Εναγγέλια Πτυχορά 49

Ερωτήσεις στο www

Στο βιβλίο (cow book, σελ. 670),

αποδοτική υλοποίηση βασισμένοι σε πίνακες

Θέματα Βάσεων Λεδοράδων 1999-2000

Εναγγέλια Πτυχορά 50

Ερωτήσεις στο www

Απότελεσμα του HITS με ερώτηση Gates -

οι καλύτερες (highest rank) αυθεντίες

<http://www.roadahead.com/>

<http://www.microsoft.com/>

<http://www.microsoft.com/corpinfo/bill-g.htm>

Θέματα Βάσεων Λεδοράδων 1999-2000

Εναγγέλια Πτυχορά 51

Κατανεμημένος Υπολογισμός

- Γνώση των σχήματος (πχ. που βρίσκεται η σχετική πληροφορία) – τεχνικές από κατανεμημένο υπολογισμό ερωτήσεων
- Μη γνώση των σχήματος

Θέματα Βάσεων Λεδοράδων 1999-2000

Εναγγέλια Πτυχορά 52

Κατανεμημένος Υπολογισμός με γνώση του Σχήματος

Θεωρείστε το σχήμα των σελίδων 191--192

Υπάρχει αντιγραφή της πληροφορίας τοπικά (S1) εκτός από την περίπτωση των <rating> που μπορεί να περιέχει link (href) στα πραγματικά δεδομένα στο site S2: www.nhtsa.dot.gov

Θέματα Βάσεων Λεδοράδων 1999-2000

Εναγγέλια Πτυχορά 53

Κατανεμημένος Υπολογισμός με γνώση του Σχήματος

Θεωρείστε την ερώτηση

```
Q = select X.name X.address, Y.make, Y.Model  
where dealer X,  
      X.address.city = "Springfield"  
      X.car Y,  
      Y.Year >= 1996  
      Y._* .ratings R,  
      R._* .driver >= 4, R._* .passenger >= 4
```

Θέματα Βάσεων Λεδοράδων 1999-2000

Εναγγέλια Πτυχορά 54

Κατανεμημένος Υπολογισμός με γνώση του Σχήματος

Ένωση δύο ερωτήσεων Q1 και Q2 όπου η Q1 μπορεί να εκτελεστεί τοπικά

```
Q1 = select X.name X.address, Y.make, Y.Model
      where dealer X,
            X.address.city = "Springfield"
            X.car Y,
            Y.Year >= 1996
            Y.[*href].ratings R,
            R._*.driver >= 4, R._*.passenger >= 4
```

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 55

Κατανεμημένος Υπολογισμός με γνώση του Σχήματος

Q2 = select entry {dealer:X, car:Y, ref:Y.ref}

where dealer X,

X.address.city = "Springfield"

X.car Y,

Y.Year >= 1996

in domain(Y.ref, "www.nhtsa.dot.gov")

Έστω R το αποτέλεσμα

περιέχει τα X, Y που είναι τοπικά (S1) και το Y.ref που βρίσκεται σε άλλο site (S2)

Πώς θα γίνει ο υπολογισμός (*distributed join*)

Εναγγέλια Πτυχορά 56

Κατανεμημένος Υπολογισμός με γνώση του Σχήματος

Semijoin!

1. Αποστολή του R στο site S2
2. Εκτέλεση στο site S2 της ερώτησης



```
select nhtsa: {dealer:X, car:Y}
      from R.entry E, E.dealer X, E.car Y, E.href H
      where H.rating Z, Z._*.driver >= 4, Z._*.passenger >= 4
```
3. Αποστολή του αποτελέσματος στο site S1
4. Υπολογισμός στο S1 της ερώτησης


```
select X.name, X.addr, Y.make, Y.model
      from H.nhtsa N, N.dealer X, N.car Y
```

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 57

Κατανεμημένος Υπολογισμός χωρίς γνώση του Σχήματος




Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 58

Κατανεμημένος Υπολογισμός χωρίς ΓΣ

Κατασκευάζουμε το αυτόματο για την κανονική έκφραση
a.b*c -- Προχωράμε κατασκευάζοντας την Closure



Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 59

Κατανεμημένος Υπολογισμός χωρίς ΓΣ

$(x_1, s1), (x_2, s2), (x_3, s2), [(y_1, s2), (y_2, s2), (y_3, s2), (y_4, s2)], (z_1, s2), (z_2, s2), (z_3, s2), (z_4, s2), [(y_3, s3), (y_4, s3), (z_2, s3), (z_3, s3)]$

Ελαττώνη βημάτων επικονιωνίας;

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 60


Κατανεμημένος Υπολογισμός χωρίς ΓΣ

- Κάθε site αναγνωρίζει τις αναφορές σε μη τοπικούς κόμβους -- αντίγραφα αυτών των κόμβων προστίθενται σε κάθε site: **output nodes**
- Επίσης, κάθε site αναγνωρίζει τους τοπικούς κόμβους που είναι στόχος εξωτερικών αναφορών: **input nodes**
- Η ρίζα του γράφου προστίθεται στους κόμβους εισόδου για το site 1

Θέματα Βάσεων Λεδορένων 1999-2000

Εναγγέλια Πλοπορά 61

Κατανεμημένος Υπολογισμός χωρίς ΓΣ



Εναγγέλια Πλοπορά 62


Κατανεμημένος Υπολογισμός χωρίς ΓΣ

- Κατασκευάζουμε το αντόματο και το στέλνουμε σε κάθε site
- Αρχίζουμε την ίδια διαδικασία σε κάθε site.
- Η διαδικασία "τρέχει" το αντόματο ξεκινώντας από κάθε κόμβο εισόδου του site
- Εάστω η ένας κόμβος εισόδου στο site i και η κατάσταση στη αντόματο, υπολογίζουμε την Closure_i(n, s) μέχρι να μην αλλάξει

Θέματα Βάσεων Λεδορένων 1999-2000

Εναγγέλια Πλοπορά 63

Κατανεμημένος Υπολογισμός χωρίς ΓΣ



Εναγγέλια Πλοπορά 64

Κατανεμημένος Υπολογισμός χωρίς ΓΣ

- Από το Closure_i(n, s) για κάθε η υπολογίζουμε δύο σύνολα:
 - Stop_i(n, s) : το σύνολο των ζευγών (n', s') που ανήκουν στο Closure_i(n, s) και το n' είναι output node
 - Result_i(n, s) : το σύνολο των κόμβων στο Closure_i(n, s) που είναι ζεύγος με τελική κατάσταση
- Closure₃(x2, s1) = { (x2, s1), (x4, s2), (z3, s3) } Closure₃(x2, s2) = { (x2, s2), (x3, s2) }
, (x1, s2), (x4, s2), (z2, s3) }
Stop₃(x2, s1) = {} Stop₃(x2, s2) = { (x4, s2) }
Result₃(x2, s1) = { z3 }, Result₃(x2, s2) = { z2 }

Θέματα Βάσεων Λεδορένων 1999-2000

Εναγγέλια Πλοπορά 65

Κατανεμημένος Υπολογισμός χωρίς ΓΣ

- Σε κάθε site κατασκευάζουμε δύο διαδικασίες σχέσεις για το Stop_i και το Result_i

$$\begin{aligned} & ((n, s), (n', s')) \text{ για } (n', s') \in \text{Stop}_i(n, s) \\ & ((n, s), n') \text{ για } n' \in \text{Result}_i(n, s) \end{aligned}$$

Stop _i (x2, s1)= {} Stop _i (x2, s2) = { (x4, s2) }	Start Stop	Start Result
Result _i (x2, s1)= { z3 }, Result _i (x2, s2) = { z2 }	(x2, s2) (x4, s2)	(x2, s1) z3 (x2, s2) z2

site 3

Θέματα Βάσεων Λεδορένων 1999-2000

Εναγγέλια Πλοπορά 66

Κατανεμημένος Υπολογισμός χωρίς ΓΣ

- Κάθε site στέλνει τις δύο σχέσεις σε ένα κεντρικό site όπου υπολογίζεται η ένωση τους
- Το κεντρικό site υπολογίζει η transitive Closure των σχέσεων Start/Stop και βρίσκει όλα τα Stop ζεύγη που είναι προσπελάσιμα από το (x1, s1).
- Από αυτά τα ζεύγη χρησιμοποιεί τη σχέση Start/Result για να βρει τους κόμβους που είναι προσπελάσιμη από τη πίζα (x1, s1).

κόστος επικοινωνίας:

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 67

Κατανεμημένος Υπολογισμός χωρίς ΓΣ

Start	Stop		
		transitive closure	
(x1,s1)	(y1,s2)	(x1,s1), (y1,s2), (z2,s2),(x4,s2),(y3,s3)	
(x4,s2)	(y3,s3)		
(y1,s2)	(z2,s2)		Start Result
(y3,s2)	(z2,s2)		(x1,s3) x1
(z2,s2)	(x4,s2)		(x4,s2) x3
	(x4,s2)		Result
	(x4,s3)		(x4,s3) x4
	(y1,s2)		y3, z2, x3
	(y1,s3)		
	(z2,s1)		(y1,s3) y1
	(z2,s2)		(z2,s1) z3
	(z2,s3)		(z2,s2) z2
			(z2,s3) z2

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 68

Κατανεμημένα ΣΔΒΔ

Είδη

- Ομοιογένεια
- Επεργένεια

gateway protocols: API that exposes DBMS functionality to external applications (e.g., ODBC, JDBC)

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 69

Κατανεμημένα ΣΔΒΔ

Αρχιτεκτονικές

- Client/server
- clients (user-interface issues)
- servers (manage data and execute transactions)
- (client cache)

Εναγγέλια Πτυχορά 70

Κατανεμημένα ΣΔΒΔ

Αρχιτεκτονικές

- Collaborating server systems

a single query spans multiple servers

a collection of database servers, each capable of running transactions against local data which cooperatively execute transactions spanning multiple servers

Θέματα Βάσεων Λεδοράνων 1999-2000

Εναγγέλια Πτυχορά 71







Κατανεμημένα ΣΔΒΔ

Αρχιτεκτονικές

- Middleware systems

just one special database server (layer of software) that coordinates the execution of queries and transactions across one or more independent database servers

Εναγγέλια Πτυχορά 72



Mediators -- Incremental Maintenance

Αποφυγή υπόλογισμού της δύψης από την αρχή!

Μια αλλαγή θα επηρεάσει ή όχι την όψη