



Πανεπιστήμιο Κρήτης, Τμήμα Επιστήμης Υπολογιστών  
Άνοιξη 2008

## HY463 - Συστήματα Ανάκτησης Πληροφοριών Information Retrieval (IR) Systems

Εξατομίκευση: Προφίλ Χρηστών και Συνεργατική Επιλογή/Διήθηση  
(Personalization: User Profiles and Collaborative Selection/Filtering)



Γιάννης Τζίτζικας

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

1



## Διάρθρωση Παρουσίασης

- Κίνητρο
- Προφίλ Χρηστών
  - μετα-διήθηση (Post-Filters)
  - προ-διήθηση (Pre-Filters)
  - Πολλαπλά Σημεία Αναφοράς
- Συνεργατική Επιλογή/Διήθηση (Collaborative Selection/Filtering)

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

2



## Κίνητρο

- Διαπιστώσεις
  - Δεν έχουν όλοι οι χρήστες τα ίδια χαρακτηριστικά
  - Άρα δεν έχουν ούτε τις ίδιες πληροφοριακές ανάγκες
- Σκοπός: *Προσαρμογή της λειτουργικότητας στα χαρακτηριστικά και τις ανάγκες διαφορετικών χρηστών*



## Παραδείγματα Κριτηρίων Διάκρισης Χρηστών

- Εξοικείωση με την περιοχή της επερώτησης
  - Χρήστης με ΔΔ στην Πληροφορική ψάχνει για ιατρικές πληροφορίες
  - q="theory of groups"
    - sociologist: behaviour of a set of people
    - mathematician: a particular type of algebraic structure
- Γλωσσικές Ικανότητες
  - Ιστοσελίδες στη γαλλική γλώσσα (οκ για εύρεση δρομολογίων πλοίων, όχι όμως για φιλοσοφικά κείμενα), σελίδες στην ιαπωνική (τίποτα)
- Συγκεκριμένες προτιμήσεις
  - εγγραφή σε περιοδικό
  - παρακολούθηση δουλειάς συγκεκριμένων συγγραφέων (π.χ. Salton)
- Μορφωτικό επίπεδο
  - Χρήστης με Παν/κό Πτυχίο έναντι Χρήστη με Γνώσεις Δημοτικού



## Προφίλ Χρηστών

### Προφίλ Χρηστών:

- μέσο διάκρισης των χρηστών βάσει των χαρακτηριστικών και προτιμήσεών τους

#### Μορφή

- Δεν υπάρχει κάποια τυποποιημένη μορφή
- Μπορούμε να θεωρήσουμε ότι έχει τη μορφή μιας επερώτησης

### Προφίλ Χρηστών και Ηθική

- (α) Είναι «օρθό» να περιορίζουμε τα αποτελέσματα;
- (β) Ιδιωτικότητα και προστασία προσωπικών δεδομένων (Privacy)

- Αν έχουμε πολύ λεπτομερή προφίλ
  - Ποιος έχει δικαίωμα να βλέπει τα προφίλ;
  - Ποιος μπορεί να ελέγχει και να αλλάζει τα προφίλ;



## Γενικοί Τρόποι Αξιοποίησης των Προφίλ κατά την Ανάκτηση Πληροφοριών

### A) Μετα-διάθηση βάσει προφίλ (User Profile as a post-filter)

- Εδώ το προφίλ χρησιμοποιείται **κατόπιν** της αποτίμησης της αρχικής επερώτησης
- Η χρήση προφίλ αυξάνει το υπολογιστικό κόστος της ανάκτησης

### B) Προ-διάθηση βάσει προφίλ (User Profile as a pre-filter)

- Εδώ το προφίλ χρησιμοποιείται για να **τροποποιήσει** την αρχική επερώτηση του χρήστη
- Η χρήση προφίλ και η τροποποίηση επερωτήσεων δεν αυξάνει κατά ανάγκη το υπολογιστικό κόστος της ανάκτησης

### C) Επερώτηση και Προφίλ ως **ξεχωριστά σημεία αναφοράς**

- (Query and Profile as Separate Reference Points)



## (A) Μετα-διήθηση βάσει Προφίλ (User Profile as a Post-filter)

### ■ Μέθοδος:

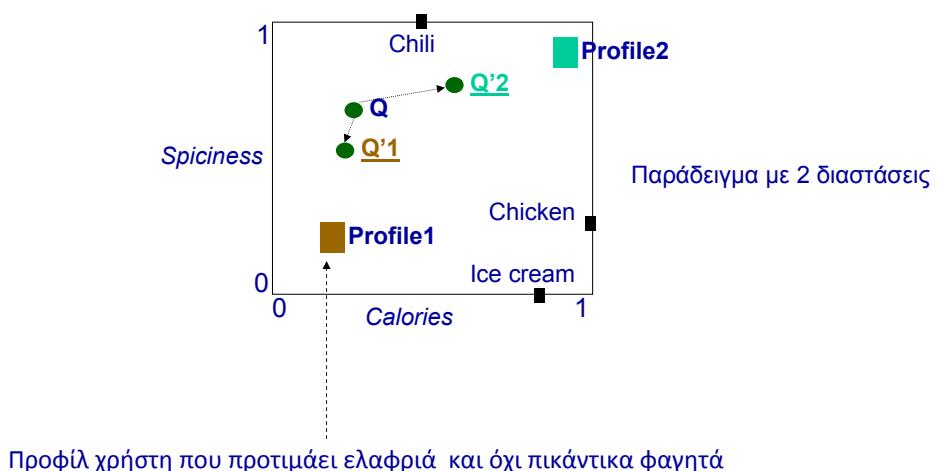
- Η αρχική επερώτηση υπολογίζεται κανονικά
- Τα αποτελέσματα οργανώνονται βάσει του προφίλ
  - ο Αναδιάταξη στοιχείων απάντησης
  - ο Αποκλεισμός ορισμένων εγγράφων

### ■ Υπολογιστικό κόστος

- Η χρήση προφίλ δεν μειώνει το υπολογιστικό κόστος
- Αντίθετα, προσθέτει ένα παραπάνω υπολογιστικό στάδιο



## B) Προ-διήθηση βάσει Προφίλ (User Profile as a Pre-filter) Παράδειγμα Τροποποίησης Επερωτήσεων:





## Τεχνικές τροποποίησης επερωτήσεων

### (B.1) Simple Linear Transformation

- Μετακινεί το διάνυσμα προς την κατεύθυνση του προφίλ

### (B.2) Piecewise Linear Transformation

- Μετακινεί το διάνυσμα προς την κατεύθυνση του προφίλ βάσει περιπτώσεων



### (B.1) Simple Linear Transformation (απλός γραμμικός μετασχηματισμός)

Έστω  $q = \langle q_1, \dots, q_t \rangle$ ,  $p = \langle p_1, \dots, p_t \rangle$  ( $q_i, p_i$  τα βάρη των διανυσμάτων)

Τροποποίηση επερώτησης  $q$  (και ορισμός της  $q'$ ) :

$$q'_i = k p_i + (1-k) q_i \quad \text{για } 0 \leq k \leq 1$$

Περιπτώσεις

- Αν  $k=0$  τότε  $q' = q$  (η επερώτηση μένει αναλλοίωτη)
- Αν  $k=1$  τότε  $q' = p$  (η νέα επερώτηση ταυτίζεται με το προφίλ)
- Οι ενδιάμεσες τιμές του  $k$  είναι ενδιαφέρουσες



## (B.2) Piecewise Linear Transformation

Εδώ η τροποποίηση των βαρών προσδιορίζεται με ένα σύνολο περιπτώσεων  
(διαφορετική συμπεριφορά με βάση αν ο όρος εμφανίζεται ή όχι στην επερώτηση και στο προφίλ)

### Περιπτώσεις:

- (1) όρος που εμφανίζεται **και** στην επερώτηση **και** στο προφίλ
  - εφαρμόζουμε τον απλό γραμμικό μετασχηματισμό
- (2) όρος που εμφανίζεται **μόνο στην επερώτηση**
  - αφήνουμε το βάρος του όρου αμετάβλητο ή το μειώνουμε ελαφρά (πχ 5%)
- (3) όρος που εμφανίζεται **μόνο στο προφίλ**
  - δεν κάνουμε τίποτα, ή εισαγάγουμε τον όρο στην επερώτηση αλλά με μικρό βάρος
- (4) όρος που δεν εμφανίζεται **ούτε στην επερώτηση ούτε στο προφίλ**
  - δεν κάνουμε τίποτα

### Παράδειγμα

- $p = \langle 5, 0, 0, 3 \rangle$
- $q = \langle 0, 2, 0, 7 \rangle$
- $q' = \langle 1.25, 1.5, 0, 6 \rangle$



## (C) Επερώτηση και Προφίλ ως ξεχωριστά σημεία αναφοράς (Query and Profile as Separate Reference Points)

### Προσέγγιση

- Εδώ **δεν τροποποιείται** η αρχική επερώτηση
- Αντίθετα και η επερώτηση και το προφίλ λαμβάνονται ξεχωριστά υπόψη κατά τη διαδικασία της βαθμολόγησης των εγγράφων

### Ερωτήματα

- Πώς να συνδυάσουμε αυτά τα δυο;
- Σε ποιο να δώσουμε περισσότερο βάρος και πως;

### Υπόθεση εργασίας

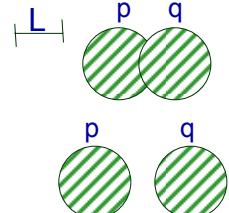
- Έστω ότι η ανάκτηση γίνεται βάσει μιας **συνάρτηση απόστασης**  $Dist$



## Τρόποι συνδυασμού προφίλ και επερώτησης

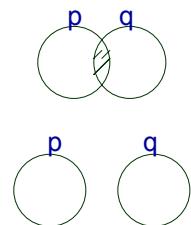
### (1) Το διαζευκτικό μοντέλο (το λιγότερο αυστηρό)

- Ένα  $d$  ανήκει στην απάντηση αν:
  - $(\text{Dist}(d, q) \leq L) \text{ OR } (\text{Dist}(d, p) \leq L)$
  - Εναλλακτική διατύπωση:  $\min(\text{Dist}(d, q), \text{Dist}(d, p)) \leq L$
- είναι το λιγότερο αυστηρό



### (2) Το συζευκτικό μοντέλο (το αυστηρότερο)

- Ένα  $d$  ανήκει στην απάντηση αν:
  - $(\text{Dist}(d, q) \leq L) \text{ AND } (\text{Dist}(d, p) \leq L)$
  - $\max(\text{Dist}(d, q), \text{Dist}(d, p)) \leq L$
- είναι το πιο αυστηρό
- η απάντηση είναι η τομή των  $\text{ans}(p)$  και  $\text{ans}(q)$  (με κατώφλι  $L$ )
  - αν το  $q$  απέχει πολύ από το  $p$ , τότε η απάντηση θα είναι κενή



## Τρόποι συνδυασμού προφίλ και επερώτησης (II)

### (3) Το ελλειψοειδές μοντέλο

- $\text{Dist}(d, q) + \text{Dist}(d, p) \leq L$
- καλό αν το  $d$  και το  $p$  δεν απέχουν πολύ
  - αν απέχουν πολύ τότε μπορεί να ανακτηθούν πολλά μη συναφή με κανένα

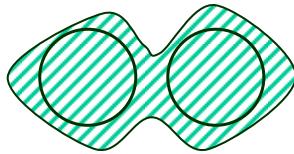




### Τρόποι συνδυασμού προφίλ και επερώτησης (III)

#### (4) Το οβάλ μοντέλο του Casini

- $\text{Dist}(d, q) * \text{Dist}(d, p) \leq L$
- αν το  $d$  και το  $p$  είναι κοντά, τότε ομοιάζει με το ελλειψοειδές
- αν απέχουν λίγο τότε μοιάζει με φυστίκι
- αν απέχουν πολύ τότε έχει τη μορφή του 8



CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

15



Πώς μπορούμε καθορίσουμε τη σχετική βαρύτητα επερωτήσεων και προφίλ;

- **Βάρη** μπορούν να προστεθούν στα προηγούμενα μοντέλα:

- $\min (\text{w1} * \text{Dist}(d, q), \text{w2} * \text{Dist}(d, p)) \leq L$  //διαζευκτικό
- $\max (\text{w1} * \text{Dist}(d, q), \text{w2} * \text{Dist}(d, p)) \leq L$  //συζευκτικό
- $\text{w1} * \text{Dist}(d, q) + \text{w2} * \text{Dist}(d, p) \leq L$  //ελλειψοειδές

- Στο μοντέλο Cassini τα βάρη είναι καλύτερα να εκφρασθούν ως εκθέτες:

- $\text{Dist}(d,q)^{\text{w1}} * \text{Dist}(d,p)^{\text{w2}} \leq L$  //Cassini

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

16



## Προφίλ Χρηστών και Αξιολόγηση Αποτελεσματικότητας Ανάκτησης

- Μόνο πειραματικά μπορούμε να αποφανθούμε για το ποια προσέγγιση είναι καλύτερη, ή για το αν αυτές οι τεχνικές βελτιώνουν την αποτελεσματικότητα της ανάκτησης
- Η πειραματική αξιολόγηση [Sung Myaeng] απέδειξε ότι οι τεχνικές αυτές βελτιώνουν την αποτελεσματικότητα

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

17



## Συστήματα Πολλαπλών Σημείων Αναφοράς (Multiple Reference Point Systems)

### Κίνητρο

- Δυνατότητα χρήσης περισσότερων των 2 σημείων αναφοράς
  - Στην προηγούμενη συζήτηση είχαμε δύο σημεία αναφοράς: την επερώτηση και το προφίλ.

### Ορισμός:

- **Σημείο Αναφοράς (reference point or point of interest) = Ένα ορισμένο σημείο ή έννοια ως προς την οποία μπορούμε να κρίνουμε ένα έγγραφο**

### Παραδείγματα σημείων αναφοράς:

- ένα γνωστό έγγραφο
- ένα σύνολο γνωστών εγγράφων
- ένας συγγραφέας ή ένα σύνολο συγγραφέων
- ένα γνωστό περιοδικό
- μια χρονική περίοδος

- Πως μπορούμε να ορίσουμε ένα σημείο αναφοράς από ένα σύνολο εγγράφων  $C \subseteq D$ ;
- Απάντηση: Θεωρούμε ότι υπάρχει ένα τεχνητό έγγραφο, το centroid document
  - το βάρη του διανύσματος του προκύπτουν παίρνοντας τον μέσο όρο των βαρών των εγγράφων του  $C$

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

18



## Συστήματα Πολλαπλών Σημείων Αναφοράς (Multiple Reference Point Systems)

Σημεία αναφοράς:  $R_1, \dots, R_n$

Βάρη:  $w_1, \dots, w_n, \sum w_i = 1$

||| μετρική (συνάρτηση απόστασης)

### Παρατηρήσεις

- Τα παρακάτω είναι ανεξάρτητα της μετρικής που χρησιμοποιούμε
- μπορούμε να χρησιμοποιήσουμε οποιαδήποτε μετρική απόστασης ή ομοιότητας επιθυμούμε
- **Διαισθητικά:** Είναι σαν να κάνουμε Ανάκτηση Πληροφορίας χρησιμοποιώντας ΠΟΛΛΕΣ επερωτήσεις ταυτόχρονα



## Multiple Reference Points: Mathematical Basis

Θα γενικεύσουμε τα μοντέλα του δισδιάστατου χώρου που έχουμε ήδη δει:

- $\min(w1 * \text{Dist}(d, q), w2 * \text{Dist}(d, p)) \leq L$  //διαζευκτικό
- $\max(w1 * \text{Dist}(d, q), w2 * \text{Dist}(d, p)) \leq L$  //συζευκτικό
- $w1 * \text{Dist}(d, q) + w2 * \text{Dist}(d, p) \leq L$  //ελλειψοειδές
- $\text{Dist}(d, q)^{w1} * \text{Dist}(d, p)^{w2} \leq L$  //Cassini

Συγκεκριμένα:

- $\min(w1 * \text{Dist}(d, R_1), \dots, wn * \text{Dist}(d, R_n)) \leq L$  //διαζευκτικό
- $\max(w1 * \text{Dist}(d, R_1), \dots, wn * \text{Dist}(d, R_n)) \leq L$  //συζευκτικό
- $w1 * \text{Dist}(d, R_1) + \dots + wn * \text{Dist}(d, R_n) \leq L$  //ελλειψοειδές
- $\text{Dist}(d, R_1)^{w1} * \dots * \text{Dist}(d, R_n)^{wn} \leq L$  //Cassini

ή συνδυασμός των παραπάνω



Άλλες τεχνικές (που έχουμε ήδη δει) που βοηθούν την εξατομίκευση

- **Ομαδοποίηση (Clustering):** Θα το δούμε και στο μάθημα περί ομαδοποίησης και επιτόπιας ανάλυσης
  - *Ομαδοποιούμε τα αποτελέσματα της ερώτησης*

Μπορεί να δώσει λύση στο παράδειγμα:

q="theory of groups"

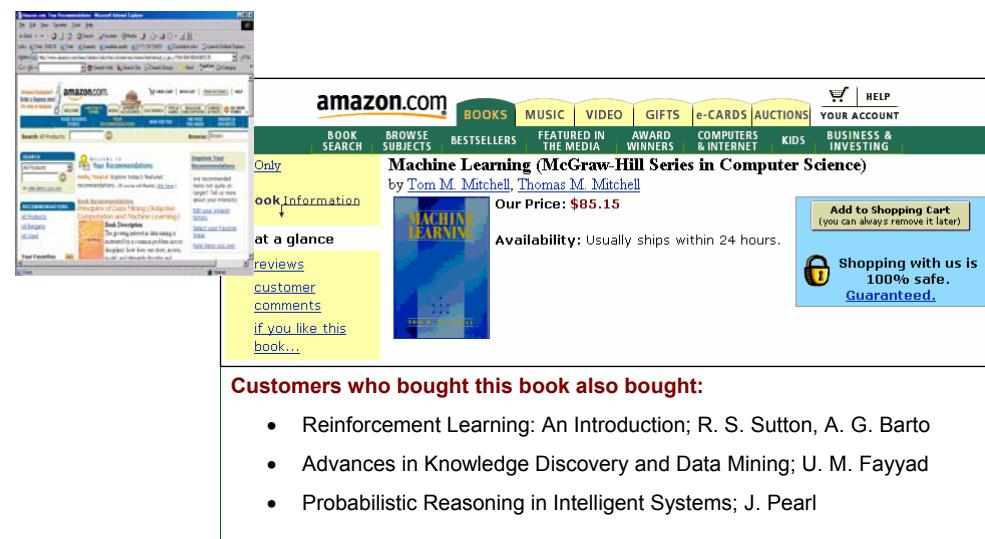
- sociologist: behaviour of a set of people
- mathematician: a particular type of algebraic structure
- υπό την έννοια ότι η διαδικασία της ομαδοποίησης θα μας δώσει διαφορετικές ομάδες και ο εκάστοτε χρήστης θα μπορεί επιλέξει την κατάλληλη

- Τεχνικές Βελτίωσης Απάντησης Επερωτήσεων (**ανατροφοδότηση συνάφειας**)



**Εξατομίκευση μέσω Συνεργατικής Επιλογής/Διήθησης**  
Personalization using Collaborative Selection/Filtering

 Παράδειγμα



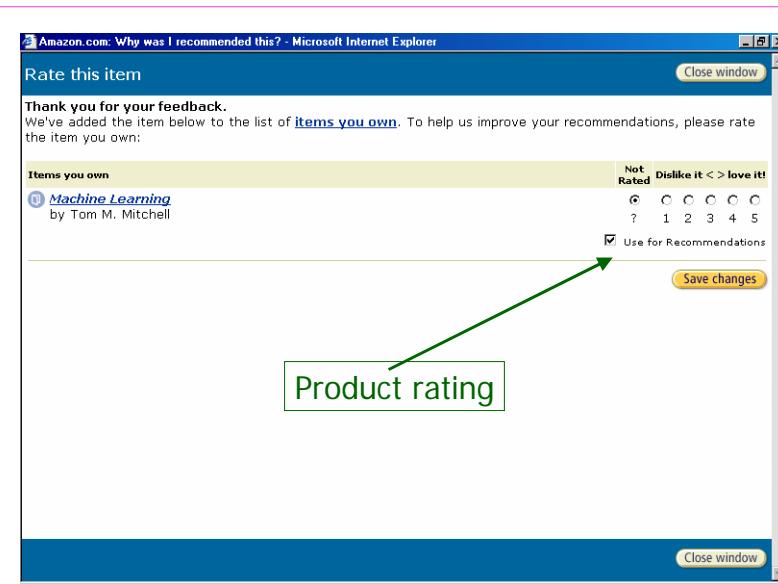
Only book information at a glance  
reviews  
customer comments  
if you like this book...

**Customers who bought this book also bought:**

- Reinforcement Learning: An Introduction; R. S. Sutton, A. G. Barto
- Advances in Knowledge Discovery and Data Mining; U. M. Fayyad
- Probabilistic Reasoning in Intelligent Systems; J. Pearl

CS-463, Information Retrieval Systems      Yannis Tzitzikas, U. of Crete      23

 Product Rating by Users



Rate this item

Thank you for your feedback.  
We've added the item below to the list of **Items you own**. To help us improve your recommendations, please rate the item you own:

**Items you own**

**Machine Learning**  
by Tom M. Mitchell

Not Rated	Dislike it	<	?	1	2	3	4	5	love it!
<input type="radio"/>									

Use for Recommendations

**Product rating**

Save changes

Close window

CS-463, Information Retrieval Systems      Yannis Tzitzikas, U. of Crete      24



## Συνεργατική Επιλογή/Διήθηση

Πρόβλεψη προτιμήσεως ενός χρήστη βάσει των καταγεγραμμένων προτιμήσεων του ιδίου και άλλων χρηστών.



## Παράδειγμα: Επιλογή Εστιατορίου

### Κλασσική Προσέγγιση:

- Χαρακτηρίζουμε τα εστιατόρια βάσει ενός πεπερασμένου συνόλου κριτηρίων (κουζίνα, κόστος, τοποθεσία). Οι προτιμήσεις ενός χρήστη εκφράζονται με μια συνάρτηση αξιολόγησης πάνω σε αυτά τα κριτήρια.

### Μειονεκτήματα

- Στην επιλογή όμως ενός εστιατορίου εμπλέκονται και άλλοι παράγοντες (απεριόριστοι στον αριθμό) που δύσκολα θα μπορούσαν να εκφραστούν με σαφήνεια, όπως:
  - το στυλ και η ατμόσφαιρα, η διακόσμηση
  - η υπόλοιπη πελατεία, το πάρκιν
  - η γειτονιά, η διαδρομή προς το εστιατόριο
  - η εξυπηρέτηση, οι ώρες λειτουργίας, τα ... σερβίτσια

Θα θέλαμε να μπορούμε να προβλέψουμε τις προτιμήσεις χωρίς να περιοριζόμαστε σε ένα σταθερό σύνολο κριτηρίων

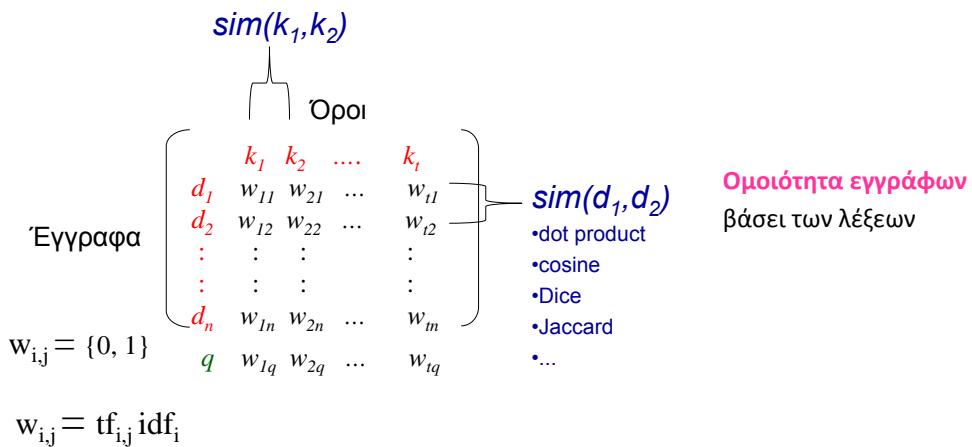
- χωρίς καν να χρειαστεί να αναλύσουμε τον τρόπο που σκέφτεται ο χρήστης



## Η Κλασσική Ανάκτηση Κειμένων

### Ομοιότητα όρων

βάσει των εγγράφων



CS-463, Information Retrieval Systems

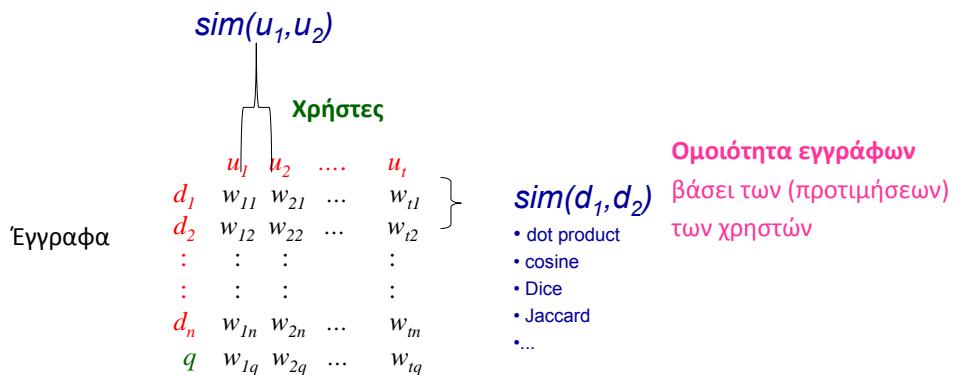
Yannis Tzitzikas, U. of Crete

27



## Χρήστες αντί Όρων

### Ομοιότητα χρηστών βάσει των προτιμήσεων τους



$w_{i,j} = \{0, 1\} \implies 0: \text{Bad}, 1: \text{Good}$

$w_{i,j} = tf_{i,j} \cdot idf_i \implies w_{i,j}: \text{βαθμός προτίμησης του χρήστη } i \text{ στο έγγραφο } j, \pi \in \{1, 2, 3, 4, 5\}$

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

28



## Χρήστες αντί Όρων

### Ομοιότητα χρηστών

βάσει των προτιμήσεων τους

$$sim(u_1, u_2)$$

χρήστες

Έγγραφα

$$\begin{array}{c} \left( \begin{array}{cccc} u_1 & u_2 & \dots & u_t \\ d_1 & w_{11} & w_{21} & \dots & w_{t1} \\ d_2 & w_{12} & w_{22} & \dots & w_{t2} \\ \vdots & \vdots & \vdots & & \vdots \\ d_n & w_{1n} & w_{2n} & \dots & w_{tn} \end{array} \right) \\ q \quad w_{1q} \quad w_{2q} \quad \dots \quad w_{tq} \end{array}$$

Αφού δεν χρησιμοποιούμε λέξεις, τα «έγγραφα» μπορεί να είναι στιδήποτε:

- Φωτογραφίες, Βιβλία
- Ηλεκτρικές Συσκευές
- Εστιατόρια, Μεζεδοπωλεία
- Κινηματογραφικές ταινίες
- Τηλεοπτικά Προγράμματα
- ..

$$sim(d_1, d_2)$$

- dot product
- cosine
- Dice
- Jaccard
- ...

### Ομοιότητα εγγράφων

βάσει των (προτιμήσεων)  
των χρηστών

$w_{ij} = \{0, 1\} \implies 0: \text{Bad}, 1: \text{Good}$

$w_{ij} = tf_{ij} \cdot idf_i \implies w_{ij}$ : βαθμός προτίμησης του χρήστη i στο έγγραφο j, πχ {1,2,3,4,5}

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

29



## Μαντεύοντας τις προτιμήσεις ενός χρήστη

### Ομοιότητα χρηστών

βάσει των προτιμήσεων τους

### Prediction

Ο χρήστης  $u_t$  δεν έχει βαθμολογήσει (εκφράσει βαθμό προτίμησης) για το  $d_1$ .

Μπορούμε να τον μαντέψουμε;

$$sim(u_1, u_2)$$

χρήστες

Έγγραφα

$$\begin{array}{c} \left( \begin{array}{cccc} u_1 & u_2 & \dots & u_t \\ d_1 & w_{11} & w_{21} & \dots & w_{t1} \\ d_2 & w_{12} & w_{22} & \dots & w_{t2} \\ \vdots & \vdots & \vdots & & \vdots \\ d_n & w_{1n} & w_{2n} & \dots & w_{tn} \end{array} \right) \\ - \quad w_{t2} \end{array}$$

### Ομοιότητα εγγράφων

βάσει των (προτιμήσεων)  
των χρηστών

$w_{ij} = \{0, 1\} \implies 0: \text{Bad}, 1: \text{Good}$

$w_{ij} = tf_{ij} \cdot idf_i \implies w_{ij}$ : βαθμός προτίμησης του χρήστη i στο έγγραφο j, πχ {0,1,2,3,4,5}

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

30



## Υπολογισμός Προβλέψεων και Συστάσεων

Ομοιότητα χρηστών  
βάσει των προτιμήσεων τους

Prediction

$sim(u_1, u_2)$

χρήστες

Ο χρήστης  $u_i$  δεν έχει βαθμολογήσει (εκφράσει βαθμό προτίμησης) για το  $d_1$ .  
Μπορούμε να τον μαντέψουμε;

Έγγραφα

	$u_1$	$u_2$	...	$u_r$	
$d_1$	$w_{11}$	$w_{21}$	...	$w_{r1}$	
$d_2$	$w_{12}$	$w_{22}$	...	$w_{r2}$	
:	:	:		:	
$d_n$	$w_{1n}$	$w_{2n}$	...	$w_{rn}$	

Ομοιότητα εγγράφων  
βάσει των (προτιμήσεων)  
των χρηστών

Recommendation

Computing recommendations for a user  $u$ :

- 1/ Predict values for those cells of  $u$  that are empty, and
- 2/ Select (and give the user) the highest ranked elements

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

31



## Παράδειγμα της διαφοράς μεταξύ Πρόβλεψης και Σύστασης

- Prediction
  - e.g.: ET3 channel has tonight the movie "MATRIX", would I like it?
- Recommendation
  - e.g. recommend me what movies to rent from a Video Club

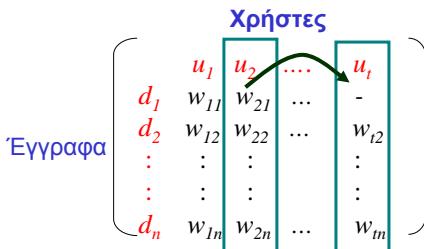
CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

32



## How can we compute recommendations?



Με ποιον χρήστη έχω παρόμοιες προτιμήσεις;

Τι λέει αυτός ο χρήστης για το  $d_1$ ;

### Nearest Users:

find the nearest (most similar) users and from their ratings infer  $w(u_t, d_i)$  (or compute recommendations).



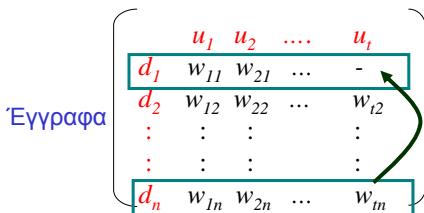
## How can we compute recommendations?

### Nearest Items:

find the nearest (most similar) item and from its rating infer  $w(u_t, d_i)$ .

(compute recommendations):

find the items that are similar to other items the user has liked in the past





## How we can compute recommendations.

### Nearest Users

Objective: Compute  $w(u_t, di)$

#### ■ Algorithm Average

- Let  $\text{Sim}(u_t) = \text{the users that are similar to } u_t$ 
  - E.g. k-nearest neighbours
- $w(u_t, di) = \text{average}(\{w(u, di) \mid u \in \text{Sim}(u_t)\})$

		Χρήστες			
		$u_1$	$u_2$	...	$u_t$
$d_1$		$w_{11}$	$w_{21}$	...	-
$d_2$		$w_{12}$	$w_{22}$	...	$w_{t2}$
:		:	:	⋮	⋮
$d_n$		$w_{1n}$	$w_{2n}$	...	$w_m$

Έγγραφα

#### ■ Algorithm Weighted Average

- As some close neighbors are closer than others, we can assign higher weights to ratings of closer neighbors
- $w(u_t, di) = \sum \text{sim}(u_t, u) * w(u, di) \quad \text{where } u \in \text{Sim}(u_t)$

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

35



Παράδειγμα πρόβλεψης βάσει των 3 κοντινότερων **χρήστων** και μέτρο απόστασης τη μετρική  $L_2$

	Tony	Manos	Tom	Nick	Titos	Yannis
PizzaRoma	4	5	1	2	5	4
PizzaNapoli	3	3	1	1	4	3
PizzaHut	1	2	5	4	1	2
PizzaToscana	5	4	2	1	5	?

$$D(Tony, Yannis) = \sqrt{(4-4)^2 + (3-3)^2 + (1-2)^2} = 1$$

$$D(Manos, Yannis) = \sqrt{(5-4)^2 + (3-3)^2 + (2-2)^2} = 1$$

$$D(Tom, Yannis) = \sqrt{(1-4)^2 + (1-3)^2 + (5-2)^2} = 4.69$$

$$D(Nick, Yannis) = \sqrt{(2-4)^2 + (1-3)^2 + (4-2)^2} = 3.46$$

$$D(Titos, Yannis) = \sqrt{(5-4)^2 + (4-3)^2 + (1-2)^2} = 1.73$$

Nearest 3 = Tony, Manos, Titos

$$(5+4+5)/3 = 4.66$$

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

36



Παράδειγμα πρόβλεψης με βάση τις 2 κοντινότερες πιτσαρίες και μέτρο απόστασης τη μετρική  $L_2$

	Tony	Manos	Tom	Nick	Titos	Yannis
PizzaRoma	4	5	1	2	5	4
PizzaNapoli	3	3	1	1	4	3
PizzaHut	1	2	5	4	1	2
PizzaToscana	5	4	2	1	5	?

$$D(\text{Roma}, \text{Toscana}) = \sqrt{[(4-5)^2 + (5-4)^2 + (1-2)^2 + (2-1)^2 + (5-5)^2]} = 2$$

$$D(\text{Napoli}, \text{Toscana}) = \sqrt{[(3-5)^2 + (3-4)^2 + (1-2)^2 + (1-1)^2 + (4-5)^2]} = 2.65$$

$$D(\text{Hut}, \text{Toscana}) = \sqrt{[(1-5)^2 + (2-4)^2 + (5-2)^2 + (4-1)^2 + (1-5)^2]} = 7.34$$

Nearest 2 = Roma, Napoli

$$(4+3)/2 = 3.5$$



## Προβλήματα Εκκίνησης (I) Nearest Users

Εισαγωγή νέου χρήστη:

- δεν έχει εκφράσει καμιά προτίμηση => δεν μπορούμε να του προτείνουμε τύποτα (δεν μπορούμε να εντοπίσουμε κοντινούς χρήστες)

	Tony	Manos	Tom	Nick	Titos	Yannis
PizzaRoma	4	5	1	2	5	-
PizzaNapoli	3	3	1	1	4	-
PizzaHut	1	2	5	4	1	-
PizzaToscana	5	4	2	1	5	?



## Προβλήματα Εκκίνησης (II) Nearest Items

Εισαγωγή νέου αντικειμένου (new item):

- δεν έχουμε προτιμήσεις για αυτό => ποτέ δεν θα προταθεί σε κάποιον χρήστη

	Tony	Manos	Tom	Nick	Titos	Yannis
PizzaRoma	4	5	1	2	5	4
PizzaNapoli	3	3	1	1	4	3
PizzaHut	1	2	5	4	1	2
PizzaToscana	-	-	-	-	-	?



## Προβλήματα Εκκίνησης (III)

Σε κάθε περίπτωση ποτέ δεν θα προταθεί ένα νέο στοιχείο σε ένα νέο χρήστη

	Tony	Manos	Tom	Nick	Titos	Yannis
PizzaRoma	4	5	1	2	5	-
PizzaNapoli	3	3	1	1	4	-
PizzaHut	1	2	5	4	1	-
PizzaToscana	-	-	-	-	-	?



## Ομοιότητα/Απόσταση Χρηστών

Τρόποι υπολογισμού:

- εσωτερικό γινόμενο
- συνημίτονο

$$sim(u_1, u_2) = \sum_{i=1}^t w_{1i} \cdot w_{2i}$$

Στα άδεια κελιά του πίνακα θεωρούμε ότι υπάρχει το 0

$$\cos(\vec{u}_1, \vec{u}_2) = \frac{\vec{u}_1 \cdot \vec{u}_2}{|\vec{u}_1| \cdot |\vec{u}_2|} = \frac{\sum_{i=1}^t (w_{1i} \cdot w_{2i})}{\sqrt{\sum_{i=1}^t w_{1i}^2} \cdot \sqrt{\sum_{i=1}^t w_{2i}^2}}$$

- Mean Squared Distance

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

41



## Ομοιότητα/Απόσταση Χρηστών

Problem: Not every User rates every Item

A solution: Determine similarity of customers  $u_1$  and  $u_2$  based on the similarity of ratings of those items that both have rated, i.e.,  $D_{u1 \cap u2}$ .

	Tony	Manos	Tom	Nick	Titos	Yannis
PizzaRoma	5		2			
PizzaNapoli	3	1		4	3	
PizzaHut	1		5			2
PizzaToscana	5		2	1	5	

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

42



## Ομοιότητα/Απόσταση Χρηστών: Mean Squared Difference

$$u1(x) \equiv w_{1x}$$

$$u2(x) \equiv w_{2x}$$

$$d_{MSD}(u1, u2) = \frac{1}{|D_{u1 \cap u2}|} \cdot \sum_{x \in D_{u1 \cap u2}} (u1(x) - u2(x))^2$$

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

43



## Ομοιότητα/Απόσταση Χρηστών: Pearson correlation

$$C_{Pearson}(u1, u2) = \frac{\sum_{x \in D_{u1 \cap u2}} (u1(x) - \bar{u1})(u2(x) - \bar{u2})}{\sqrt{\sum_{x \in D_{u1 \cap u2}} (u1(x) - \bar{u1})^2 \cdot \sum_{x \in D_{u1 \cap u2}} (u2(x) - \bar{u2})^2}}$$

$\bar{u1}$  = mean of  $u1$

$C(u1, u2) > 0$  θετική σχέση

$\bar{u2}$  = mean of  $u2$

$C(u1, u2) = 0$  ουδέτερη σχέση

$C(u1, u2) < 0$  αρνητική σχέση

The correlation coefficient measures the strength of a linear relationship between two variables.

The correlation coefficient is always between -1 and +1. The closer the correlation is to +/-1, the closer to a perfect linear relationship. Here is an example of interpretation:

- 1.0 to -0.7 strong negative association.
- 0.7 to -0.3 weak negative association.
- 0.3 to +0.3 little or no association.
- +0.3 to +0.7 weak positive association.
- +0.7 to +1.0 strong positive association.

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

44



## Ομοιότητα/Απόσταση Items

Τρόποι υπολογισμού ομοιότητας/απόστασης:

- εσωτερικό γινόμενο
- συνημίτονο
- Pearson Correlation Coefficient

$$C_{Pearson}(x_1, x_2) = \frac{\sum_{u \in U} (u(x_1) - \bar{x}_1)(u(x_2) - \bar{x}_2)}{\sqrt{\sum_{u \in U} (u(x_1) - \bar{x}_1)^2 \cdot \sum_{u \in U} (u(x_2) - \bar{x}_2)^2}}$$

- Adjusted Pearson Correlation Coefficient

To handle the differences  
in rating scales of the users

$$C_{Pearson}(x_1, x_2) = \frac{\sum_{u \in U} (u(x_1) - \bar{u}_1)(u(x_2) - \bar{u}_2)}{\sqrt{\sum_{u \in U} (u(x_1) - \bar{u}_1)^2 \cdot \sum_{u \in U} (u(x_2) - \bar{u}_2)^2}}$$



## Ομοιότητα/Απόσταση Items

Τρόποι υπολογισμού ομοιότητας/απόστασης:

- εσωτερικό γινόμενο
- συνημίτονο
- Pearson Correlation Coefficient

$$C_{Pearson}(x_1, x_2) = \frac{\sum_{u \in U} (u(x_1) - \bar{x}_1)(u(x_2) - \bar{x}_2)}{\sqrt{\sum_{u \in U} (u(x_1) - \bar{x}_1)^2 \cdot \sum_{u \in U} (u(x_2) - \bar{x}_2)^2}}$$

- Adjusted Pearson Correlation Coefficient

To handle the differences  
in rating scales of the users

$$C_{Pearson}(x_1, x_2) = \frac{\sum_{u \in U} (u(x_1) - \bar{u}_1)(u(x_2) - \bar{u}_2)}{\sqrt{\sum_{u \in U} (u(x_1) - \bar{u}_1)^2 \cdot \sum_{u \in U} (u(x_2) - \bar{u}_2)^2}}$$



## Obtaining User Input

User (consumer) input is **difficult to get**

A solution:

- identify preferences that are **implicit** in *people's actions*
  - Purchase records
    - For example, people who order a book implicitly express their preference for that book (over other books)
  - Timing logs
- Works quite well (but results are not as good as with the use of rating)



## Obtaining User Input: An Example of **Implicit Rating**

The screenshot shows a Microsoft Internet Explorer window displaying an Amazon.com product page for the book "Data Mining". The page includes the book cover, a "LOOK INSIDE!" button, and a brief description. At the bottom, there are two buttons: "I own it" and "Not interested". Three green arrows point from these buttons to a green box at the bottom center labeled "Implicit rating".



Παρά ταύτα,

Πολύ συχνά  $|D_{u_1 \cap u_2}|=0$

When thousands of items available only little overlap!

=> Recommendations based on only a few observations

	Tony	Manos	Tom	Nick	Titos	Yannis
PizzaRoma		5		2		
PizzaNapoli		3	1		4	3
PizzaHut	1		5			2
PizzaToscana	5		2	1	5	

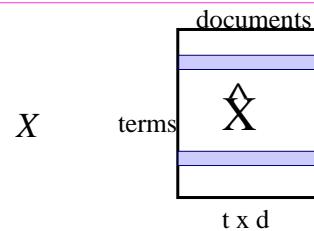
Various solutions:

- View CF as a classification task
  - build a classifier for each user
  - employ training examples
- Reduce Dimensions
  - e.g. LSI (Latent Semantic Indexing)

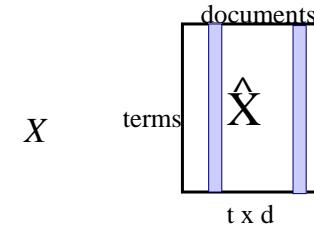


LSI:

- Τρόπος σύγκρισης 2 όρων:
  - the **dot product** between two **row vectors of** reflects the extent to which two terms have a similar pattern of occurrence across the set of document.



- Τρόπος σύγκρισης δύο εγγράφων:
  - **dot product** between two **column vectors of**





## Performance Issues

- Depends on  $|U|$  vs.  $|D|$  and their “stability”
  - Typical setting
    - $D$  stable (e.g. 5.000 movies)
    - $U$  dynamic and  $|U| \gg |D|$  (e.g. 100.000 users)
    - A fast Item-based approach
- Precompute similarities of items:
- Requires  $O(|D|^2)$  space (very big)
  - One solution: Store only the  $k$ -nearest items of an item (this is what we need for computing recommendations)



## Evaluation Metrics

A method to evaluate a method for collaborative selection/filtering is the following:

- Data is divided into 2 sets
  - training set
  - test set
- Evaluation Metrics
  - Then we compare the results of the techniques on the test set using the Mean Absolute Error (MAE)

$$MAE = \frac{\sum_{i=1}^N |p_i - q_i|}{N}$$

$p_i$  : predicted rating

$q_i$  : actual rating



## Συναφή Ζητήματα που έχουμε ήδη μελετήσει

- **Ενοποίηση Διατάξεων**
  - Borda, Condorcet, Arrow's Impossibility Theorem
  - Αν οι προτιμήσεις των χρηστών είναι ένα διατεταγμένο σύνολο επιλογών
    - Υπολογισμός συστάσεων = εύρεση ενοποιημένης διάταξης
- **Γρήγορη αποτίμηση top-k queries**
  - Αλγόριθμος FA (Fagin's Algorithm) και TA (Threshold Algorithm). Αν οι προτιμήσεις των χρηστών εκφράζονται με σκορ και είναι αποθηκευμένες σε απομακρυσμένα συστήματα.



## Συνεργατική Επιλογή/Διήθηση: Σύνοψη

- **Ιδιαίτερο χαρακτηριστικό:** δεν χρειάζεται να έχουμε περιγραφή του περιεχομένου των στοιχείων
  - μπορούμε να την χρησιμοποιήσουμε για την επιλογή/διήθηση ποιημάτων, φιλοσοφικών ιδεών, mp3, μεζεδοπαλείων, ...
- **Θα μπορούσε να αξιοποιηθεί και στα πλαίσια της κλασσικής ΑΠ**
  - Διάταξη στοιχείων απάντησης βάσει συνάφειας ΚΑΙ του εκτιμούμενου βαθμού τους (βάσει των αξιολογήσεων των άλλων χρηστών)
- **Έχει αποδειχθεί χρήσιμη και για τους αγοραστές και για τους πωλητές (e-commerce)**
- **Αδυναμίες: Sparseness & Cold Start**
  - Works well only once a "critical mass" of preference has been obtained
  - Need a very large number of consumers to express their preferences about a relatively large number of products.
  - Users' profiles don't overlap -> similarity not computable
  - Doesn't help the community forming
  - Difficult or impossible for users to control the recommendation process
- **Επεκτάσεις/Βελτιώσεις**
  - **Trust** = explicit rating of user on user



## Διάρθρωση Παρουσίασης

- Motivation
- User Profiles
  - as Post-Filters
  - as Pre-Filters (query modification)
    - Linear and Piecewise Transformations
  - as Separate Reference Points
- Collaborative Selection/Filtering



CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

55



## User Profiles: Bibliography

- [4] Korfhage's Book Chapter 6 and 7

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

56