



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

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



Γιάννης Τζίτζικας

Ενότητα : 22

Ημερομηνία :

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

1



## Διάρθρωση Παρουσίασης

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



## 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
  - $q = \text{"theory of groups"}$ 
    - 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-διήθηση** 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-διήθηση** 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)

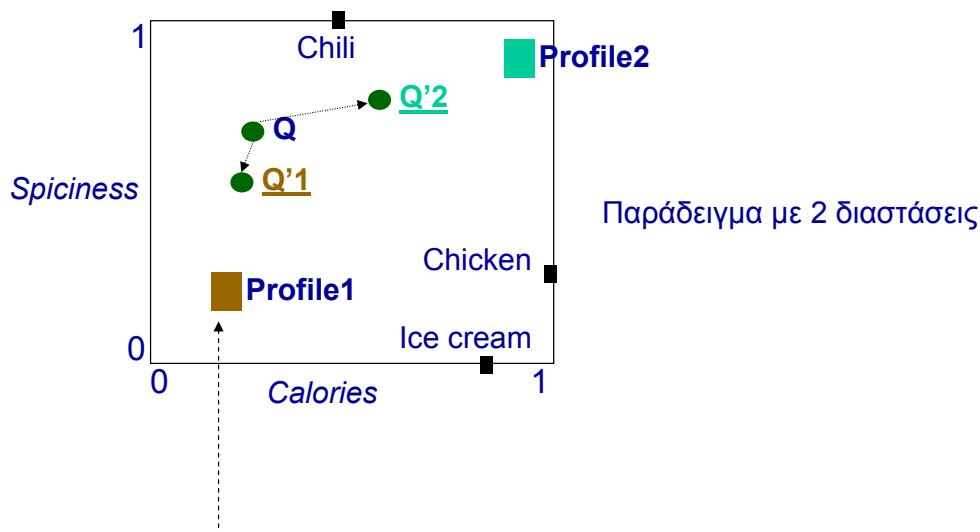


## (A) Μετα-διήθηση βάσει Προφίλ (User Profile as a Post-filter)

- **Μέθοδος:**
  - Η αρχική επερώτηση υπολογίζεται κανονικά
  - Τα αποτελέσματα οργανώνονται βάσει του προφίλ
    - Αναδιάταξη στοιχείων απάντησης
    - 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:



Προφίλ χρήστη που προτιμάει ελαφριά και όχι πικάντικα φαγητά



# 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  $q = \langle q_1, \dots, q_t \rangle$ ,  $p = \langle p_1, \dots, p_t \rangle$  (qi, pi 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
- **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)

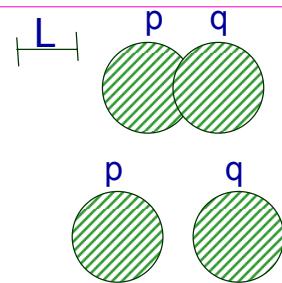
- **Προσέγγιση**
  - Εδώ **δεν τροποποιείται** η αρχική επερώτηση
  - Αντίθετα και η επερώτηση και το προφίλ λαμβάνονται **ξεχωριστά** υπόψη κατά τη διαδικασία της βαθμολόγησης των εγγράφων
- **Ερωτήματα**
  - Πώς να συνδυάσουμε αυτά τα δυο;
  - Σε ποιο να δώσουμε περισσότερο βάρος και πως;
- **Υπόθεση εργασίας**
  - Έστω ότι η ανάκτηση γίνεται βάσει μιας **συνάρτηση απόστασης**  $\text{Dist}$



## Τρόποι συνδυασμού προφίλ και επερώτησης

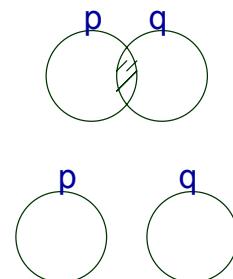
### (1) Το διαζευκτικό μοντέλο (το λιγότερο αυστηρό)

- 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)

- $(\text{Dist}(d,q) \leq L) \text{ AND } (\text{Dist}(d,p) \leq L)$
- $\max(\text{Dist}(d,q), \text{Dist}(d,p)) \leq L$
- 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

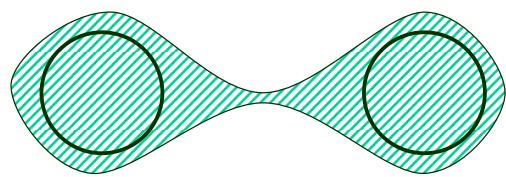
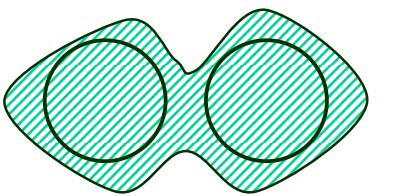




## Τρόποι συνδυασμού προφίλ και επερώτησης (III)

### (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



Πώς μπορούμε καθορίσουμε τη σχετική βαρύτητα επερωτήσεων και προφίλ;

- **Βάρη** μπορούν να προστεθούν στα προηγούμενα μοντέλα:
  - $\min(w1^* \text{Dist}(d,q), w2^* \text{Dist}(d,p)) \leq L$  //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
- Στο μοντέλο Cassini τα βάρη είναι καλύτερ να εκφρασθούν ως εκθέτες:
  - $\text{Dist}(d,q)^{w1} * \text{Dist}(d,p)^{w2} \leq L$  //Cassini



## 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



## 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 of 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

- Πώς 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  $C$



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

- Σημεία αναφοράς: R1, ..., Rn
- Βάρη: w1, ..., wn,  $\sum w_i = 1$
- |||| 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:
  - $\min(w_1 * \text{Dist}(d, q), w_2 * \text{Dist}(d, p)) \leq L$  //διαζευκτικό
  - $\max(w_1 * \text{Dist}(d, q), w_2 * \text{Dist}(d, p)) \leq L$  //συζευκτικό
  - $w_1 * \text{Dist}(d, q) + w_2 * \text{Dist}(d, p) \leq L$  //ελλειψοειδές
  - $\text{Dist}(d, q)^{w_1} * \text{Dist}(d, p)^{w_2} \leq L$  //Cassini
- Συγκεκριμένα:
  - $\min(w_1 * \text{Dist}(d, R_1), \dots, w_n * \text{Dist}(d, R_n)) \leq L$  //διαζευκτικό
  - $\max(w_1 * \text{Dist}(d, R_1), \dots, w_n * \text{Dist}(d, R_n)) \leq L$  //συζευκτικό
  - $w_1 * \text{Dist}(d, R_1) + \dots + w_n * \text{Dist}(d, R_n) \leq L$  //ελλειψοειδές
  - $\text{Dist}(d, R_1)^{w_1} * \dots * \text{Dist}(d, R_n)^{w_n} \leq L$  //Cassini
- ή συνδυασμός των παραπάνω



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

- **Ομαδοποίηση (Clustering):** Θυμηθείτε το μάθημα περί ομαδοποίησης και επιτόπιας ανάλυσης
  - 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/Διέλιθησης Personalization using Collaborative Selection/Filtering



## Παράδειγμα

The screenshot shows a Microsoft Internet Explorer browser window displaying the Amazon.com website. The main content is a product page for "Machine Learning (McGraw-Hill Series in Computer Science)" by Tom M. Mitchell. The page includes a sidebar with recommendations like "Book Information at a glance", reviews, customer comments, and related books. The product image is a blue book cover with the title "MACHINE LEARNING" and the author's name. The price is listed as \$85.15. A sidebar on the right offers an "Add to Shopping Cart" button and a "Shopping with us is 100% safe. Guaranteed." message.

**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



## Product Rating by Users

The screenshot shows a Microsoft Internet Explorer browser window displaying an Amazon.com feedback page titled "Why was I recommended this?". The page asks the user to "Rate this item" and provides a "Thank you for your feedback." message. It lists an item owned by the user: "Machine Learning" by Tom M. Mitchell. To the right is a rating scale from 1 to 5 stars, with radio buttons for each. A green arrow points from the text "Product rating" to the star rating area. There is also a checkbox for "Use for Recommendations" and a "Save changes" button.



## Συνεργατική Επιλογή/Διήθηση

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



## Παράδειγμα: Επιλογή Εστιατορίου

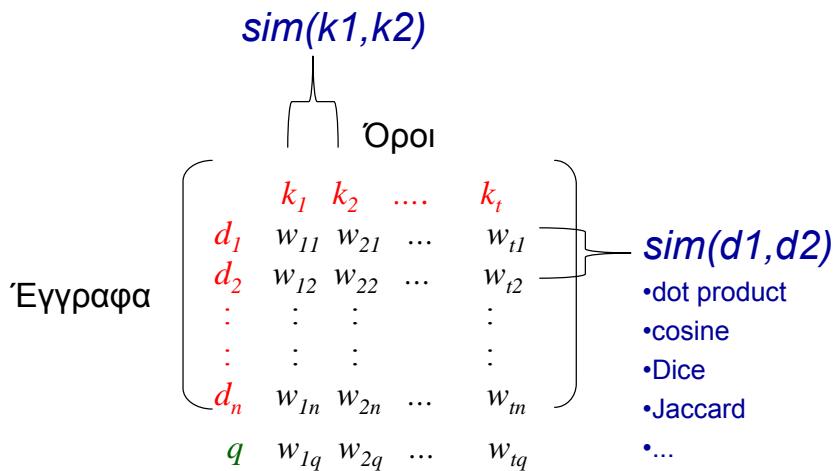
- **Κλασσική Προσέγγιση:**
  - Χαρακτηρίζουμε τα εστιατόρια βάσει ενός πεπερασμένου συνόλου κριτηρίων (κουζίνα, κόστος, τοποθεσία). Οι προτιμήσεις ενός χρήστη εκφράζονται με μια συνάρτηση αξιολόγησης πάνω σε αυτά τα κριτήρια.
- **Μειονεκτήματα**
  - Στην επιλογή όμως ενός εστιατορίου εμπλέκονται και 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 πάρκινγκ
    - 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



## Ομοιότητα εγγράφων

βάσει των λέξεων

$$w_{i,j} = \{0,1\}$$

$$w_{i,j} = tf_{i,j} \cdot idf_i$$

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

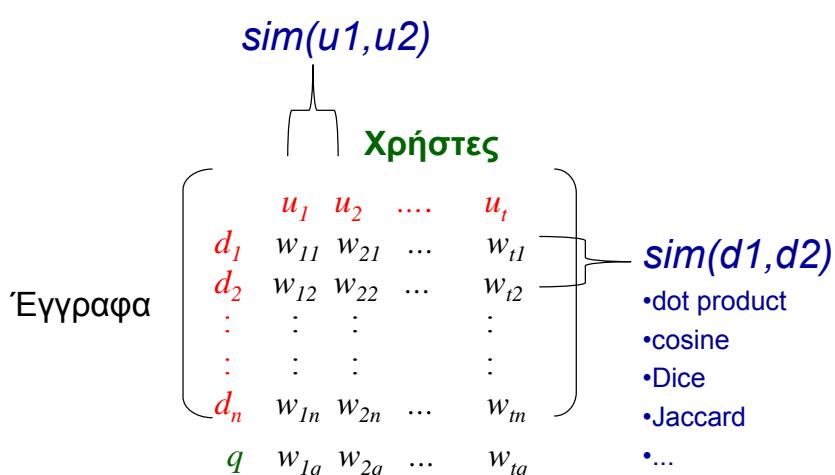
27



## Χρήστες αντί Όρων

## Ομοιότητα χρηστών

βάσει των προτιμήσεων τους



## Ομοιότητα εγγράφων

βάσει των (προτιμήσεων)  
των χρηστών

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

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

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

28



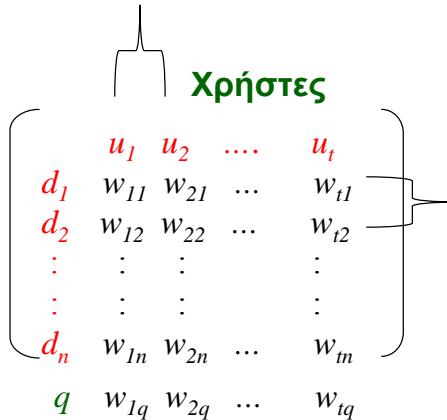
## Χρήστες αντί Όρων

### Ομοιότητα χρηστών

βάσει των προτιμήσεων τους

$$sim(u1, u2)$$

Έγγραφα



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

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

### Ομοιότητα εγγράφων

βάσει των (προτιμήσεων) των χρηστών

$$sim(d1, d2)$$

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

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

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

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

29



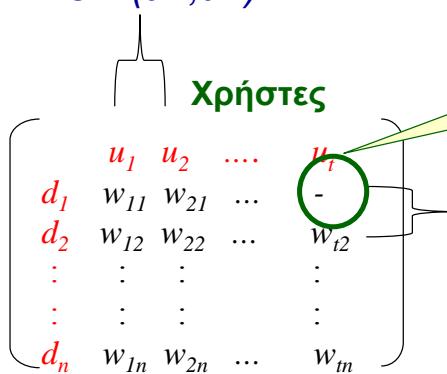
## Μαντεύοντας τις προτιμήσεις ενός χρήστη

### Ομοιότητα χρηστών

βάσει των προτιμήσεων τους

$$sim(u1, u2)$$

Έγγραφα



Ο χρήστης με δεν έχει βαθμολογήσει (εκφράσει βαθμό προτίμησης) για το d1.  
Μπορούμε να τον μαντέψουμε;

### Ομοιότητα εγγράφων

βάσει των (προτιμήσεων) των χρηστών

$$sim(d1, d2)$$

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

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

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

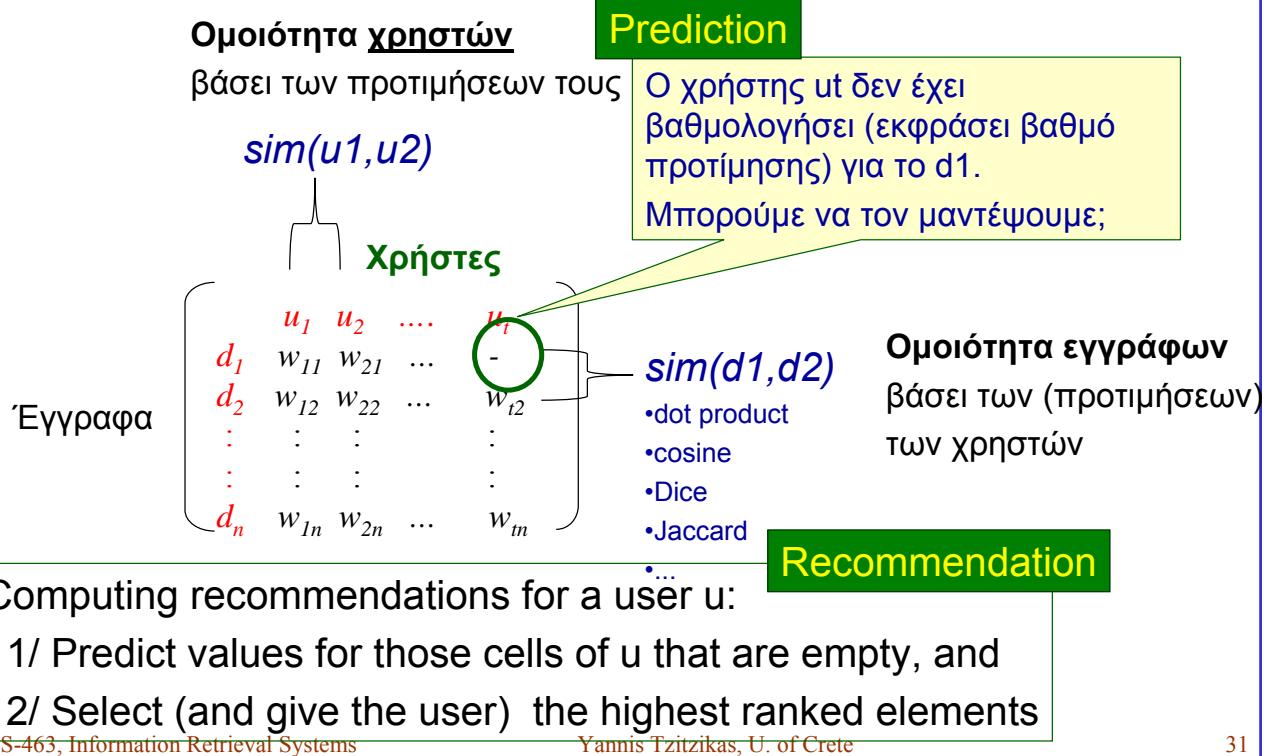
CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete

30



## Υπολογισμός Προβλέψεων και Συστάσεων

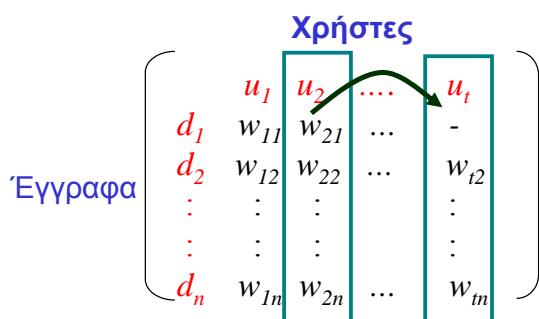


## Παράδειγμα της διαφοράς μεταξύ Πρόβλεψης και Σύστασης

- 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

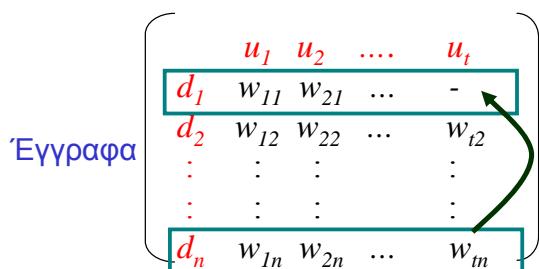


## How can we compute recommendations?



### Nearest Users:

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



### Nearest Items:

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

(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

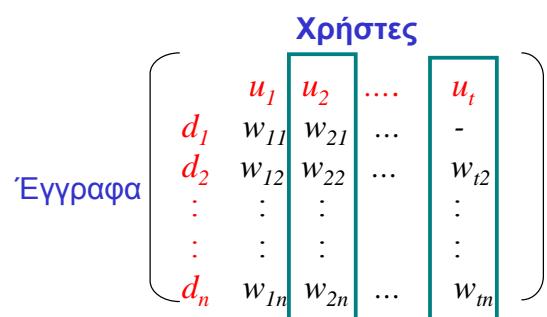
Objective: Compute  $w(u_t, di)$

### • Algorithm Average

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

### • Algorithm Weighted Average

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





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

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



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	?

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

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

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

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 τίποτα (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 => πιοτέ 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

- Mean Squared Distance

- Pearson Correlation Coefficient

- ...

Στα άδεια κελιά  
του πίνακα  
θεωρούμε ότι  
υπάρχει το 0

$$sim(u1, u2) = \sum_{i=1}^t w_{1i} \cdot w_{2i}$$

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



## Ομοιότητα/Απόσταση Χρηστών

- Problem: Not every User rates every Item
- A solution: Determine similarity of customers u1 and u2 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	



## Ομοιότητα/Απόσταση Χρηστών: Mean Squared Difference

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

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

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



## Ομοιότητα/Απόσταση Χρηστών: Pearson correlation

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

$\bar{u1}$  = 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.



## Ομοιότητα/Απόσταση Items

- Τρόποι υπολογισμού ομοιότητας/απόστασης:
  - εσωτερικό γινόμενο
  - συνημίτονο
  - Pearson Correlation Coefficient

$$C_{Pearson}(x1, x2) = \frac{\sum_{u \in U} (u(x1) - \bar{x1})(u(x2) - \bar{x2})}{\sqrt{\sum_{u \in U} (u(x1) - \bar{x1})^2} \cdot \sqrt{\sum_{u \in U} (u(x2) - \bar{x2})^2}}$$

– Adjusted Pearson Correlation Coefficient

To handle the differences  
in rating scales of the users

$$C_{Pearson}(x1, x2) = \frac{\sum_{u \in U} (u(x1) - \bar{u1})(u(x2) - \bar{u2})}{\sqrt{\sum_{u \in U} (u(x1) - \bar{u1})^2} \cdot \sqrt{\sum_{u \in U} (u(x2) - \bar{u2})^2}}$$



## Ομοιότητα/Απόσταση Items

- Τρόποι υπολογισμού ομοιότητας/απόστασης:
  - εσωτερικό γινόμενο
  - συνημίτονο
  - Pearson Correlation Coefficient

$$C_{Pearson}(x1, x2) = \frac{\sum_{u \in U} (u(x1) - \bar{x1})(u(x2) - \bar{x2})}{\sqrt{\sum_{u \in U} (u(x1) - \bar{x1})^2 \cdot \sum_{u \in U} (u(x2) - \bar{x2})^2}}$$

– Adjusted Pearson Correlation Coefficient

To handle the differences  
in rating scales of the users

$$C_{Pearson}(x1, x2) = \frac{\sum_{u \in U} (u(x1) - \bar{u1})(u(x2) - \bar{u2})}{\sqrt{\sum_{u \in U} (u(x1) - \bar{u1})^2 \cdot \sum_{u \in U} (u(x2) - \bar{u2})^2}}$$



## 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

In Books: Your Favorites Edit  
Science  
Computers & Internet  
Parenting & Families  
Professional & Technical  
  
More Categories Accessories  
Arts & Photography  
Audio CDs  
Audiotapes  
Bargain Books  
Biographies & Memoirs  
Business & Investing  
Calendars  
Catálogo de libros en español  
  
1. LOOK INSIDE! Data Mining by Ian H. Witten, Eibe Frank Average Customer Review: ★★★★☆ October 11, 1999  
  
Amazon.com Data mining techniques are used to power intelligent software, both on and off the Internet. *Data Mining: Practical Machine Learning Tools* explains the magic behind information extraction in a book that succeeds at bringing the latest in computer science research to any IS manager or developer. In... [Read more](#)  
  
Our Price: \$49.95 Used & new from \$34.52  
  
I own it Not interested Why was I recommended this?  
  
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	

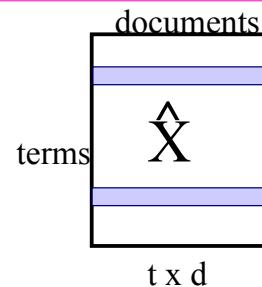
- Various solutions:
  - View CF as a classification task
    - build a classifier for each user
    - employ training examples
  - Reduce Dimensions
    - e.g. LSI (Latent Semantic Indexing)



## LSI:

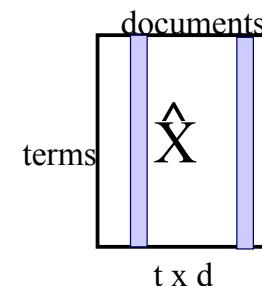
- Τρόπος σύγκρισης 2 όρων:

- the **dot product** between two **row vectors** of  $X^T$  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  $X$



## 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 άπομακρυσμένα 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, μεζεδοπωλείων, ...
- **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