



HY463 - Συστήματα Ανάκτησης Πληροφοριών Information Retrieval (IR) Systems

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



Γιάννης Τζίτζικας

Διάλεξη : 22

Ημερομηνία : 8-6-2007

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete, Spring
2007

1



Διάρθρωση Παρουσίασης

- Κίνητρο
- Προφίλ Χρηστών
 - μετα-διήθηση (Post-Filters)
 - προ-διήθηση (Pre-Filters)
 - Πολλαπλά Σημεία Αναφοράς
- Συνεργατική Επιλογή/Διήθηση (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="theory of groups"
 - sociologist: behaviour of a set of people
 - mathematician: a particular type of algebraic structure
- **Γλωσσικές Ικανότητες**
 - Σελίδες στα γαλλικά (οκ για δρομολόγια πλοίων, διασκέδαση, όχι όμως για φιλοσοφικά κείμενα), σελίδες με γιαπωνέζικα (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)

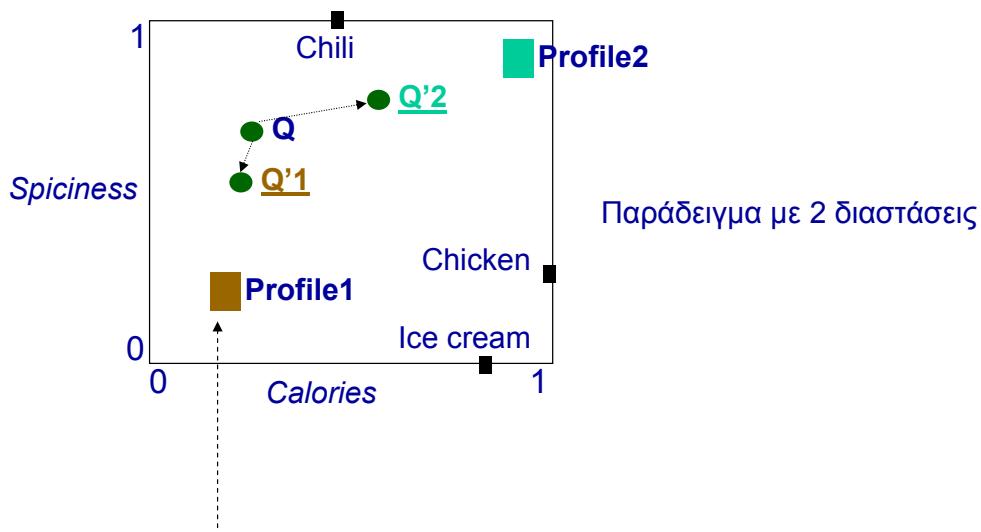


(A) Μετα-διήθηση βάσει Προφίλ (User Profile as a Post-filter)

- **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, εισαγάγει 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, ri 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)

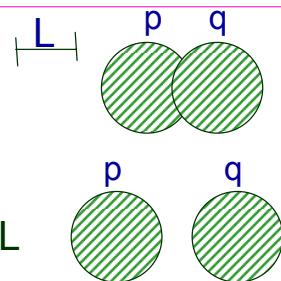
- **Προσέγγιση**
 - Εδώ **δεν τροποποιείται** η αρχική επερώτηση
 - Αντίθετα και η επερώτηση και το προφίλ λαμβάνονται ξεχωριστά υπόψη κατά τη διαδικασία της βαθμολόγησης των εγγράφων
- **Ερωτήματα**
 - Πώς να συνδυάσουμε αυτά τα δυο;
 - Σε ποιο να δώσουμε περισσότερο βάρος και πως;
- **Υπόθεση εργασίας**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



Τρόποι συνδυασμού προφίλ και επερώτησης

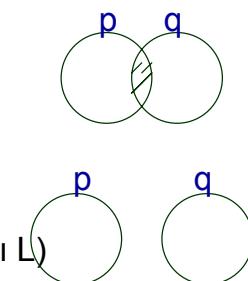
(1) Το διαζευκτικό μοντέλο (το λιγότερο αυστηρό)

- Ένα δ 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)

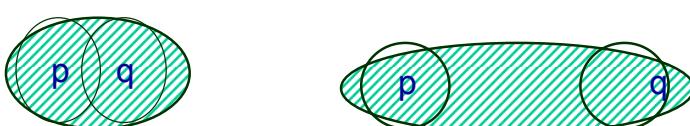
- $(\text{Dist}(d,q) \leq L) \text{ AND } (\text{Dist}(d,p) \leq L)$
- $\max(\text{Dist}(d,q), \text{Dist}(d,p)) \leq L$
- είναι το πιο αυστηρό
- η απάντηση είναι η τομή των $\text{ans}(p)$ και $\text{ans}(q)$ (με κατώφλι L)
 - αν το q απέχει πολύ από το p , τότε η απάντηση θα είναι κενή



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





(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 Cassini δεν είναι πολύ καλό αφού έχει τη μορφή γινομένου. Εδώ είναι προτιμότερο τα βάρη 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 δυο 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



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:
 - $\min(w_1 * \text{Dist}(d, q), w_2 * \text{Dist}(d, p)) \leq L$ //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
- Δηλαδή:
 - $\min(w_1 * \text{Dist}(d, R_1), \dots, w_n * \text{Dist}(d, R_n)) \leq L$ //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
- Τεχνικές Βελτίωσης Απάντησης Επερωτήσεων (ανατροφοδότηση συνάφειας)



Εξατομίκευση μέσω Συνεργατικής Επιλογής/Διέρθησης 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 provides a lock icon and a guarantee of 100% safety. Below the main content, a section titled "Customers who bought this book also bought:" lists three additional books.

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.



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



Παράδειγμα: Επιλογή Εστιατορίου

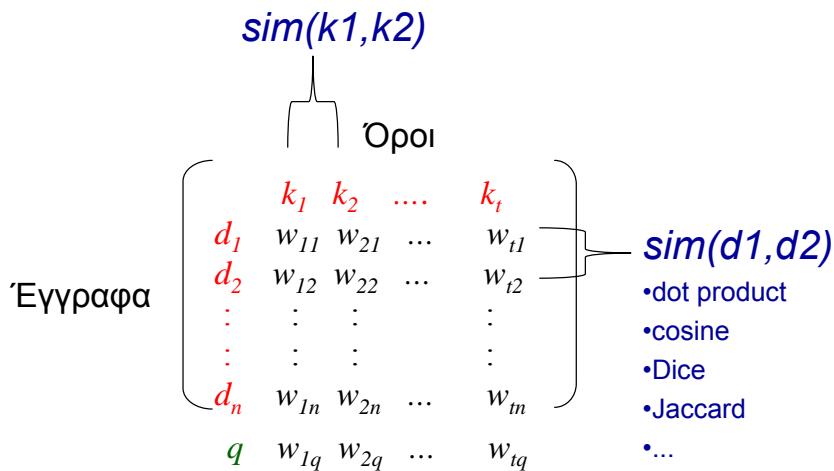
- **Κλασσική Προσέγγιση:**
 - Χαρακτηρίζουμε τα εστιατόρια βάσει ενός πεπερασμένου συνόλου κριτηρίων (κουζίνα, κόστος, τοποθεσία). Οι προτιμήσεις ενός χρήστη εκφράζονται με μια συνάρτηση αξιολόγησης πάνω σε αυτά τα κριτήρια.
- **Μειονεκτήματα**
 - Στην επιλογή όμως ενός εστιατορίου εμπλέκονται και άλλοι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

$$w_{ij} = \{0,1\}$$

$$w_{ij} = tf_{ij} \cdot idf_i$$

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete, Spring
2007

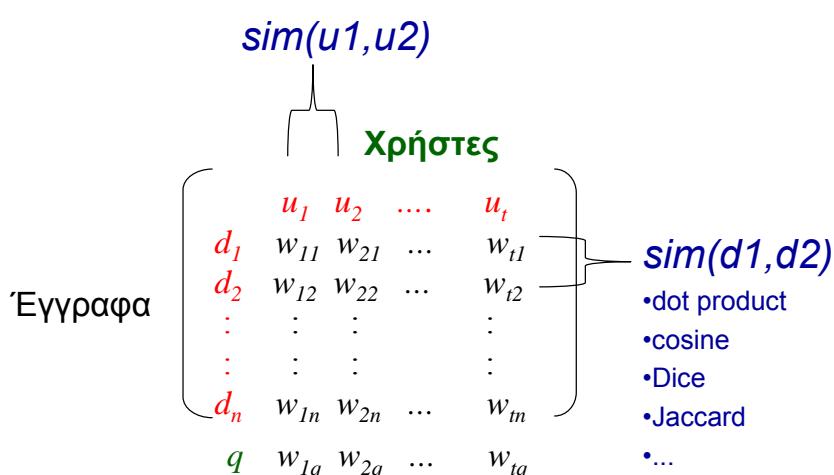
27



Χρήστες αντί Όρων

Ομοιότητα χρηστών

βάσει των προτιμήσεων τους



Ομοιότητα εγγράφων

βάσει των (προτιμήσεων)
των χρηστών

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

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

CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete, Spring
2007

28



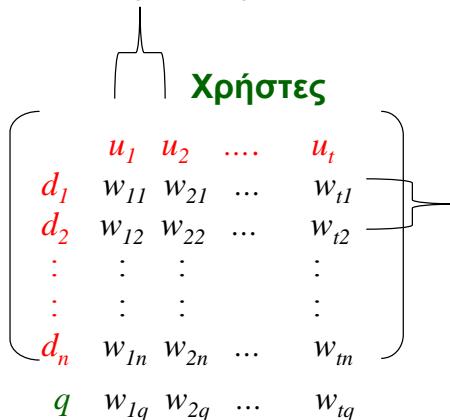
Χρήστες αντί Όρων

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
- ..

$$sim(d1, d2)$$

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

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, Spring
2007

29



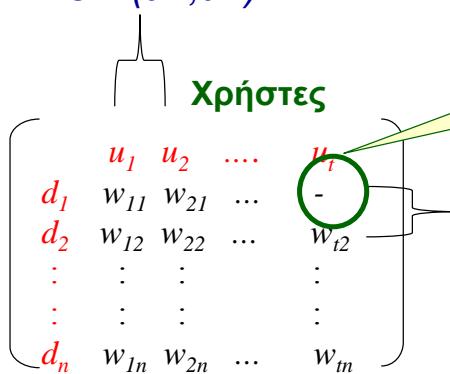
Μαντεύοντας τις προτιμήσεις ενός χρήστη

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;

$$sim(d1, d2)$$

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

Ομοιότητα εγγράφων

βάσει των (προτιμήσεων) των χρηστών

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

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

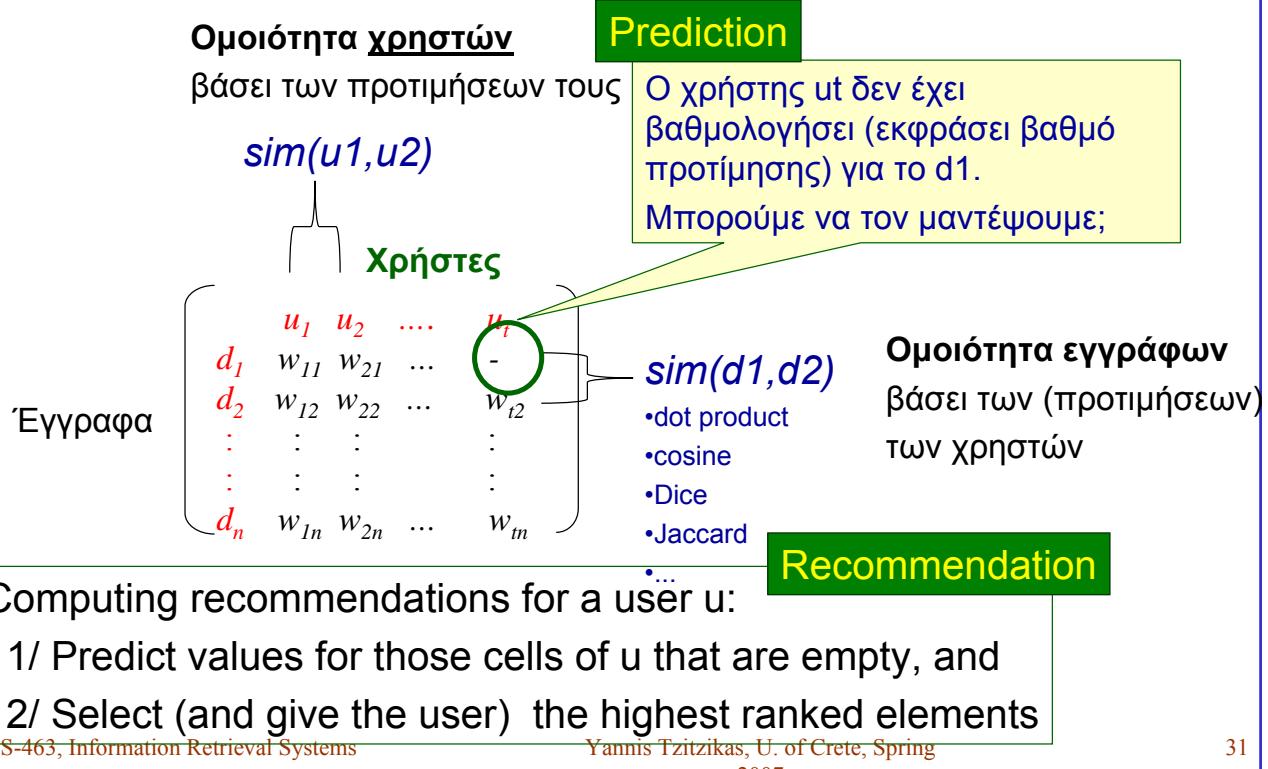
CS-463, Information Retrieval Systems

Yannis Tzitzikas, U. of Crete, Spring
2007

30



Υπολογισμός Προβλέψεων και Συστάσεων



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



How can we compute recommendations?

		Χρήστες		
		u_1	u_2	\dots
Έγγραφα	d_1	w_{11}	w_{21}	\dots
	d_2	w_{12}	w_{22}	\dots
	:	:	:	
	:	:	:	
	d_n	w_{1n}	w_{2n}	\dots

Nearest Users:

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

		u_1	u_2	\dots	u_t
		w_{11}	w_{21}	\dots	-
Έγγραφα	d_1	w_{12}	w_{22}	\dots	w_{t2}
	d_2	w_{13}	w_{23}	\dots	w_{t3}
	:	:	:		:
	:	:	:		:
	d_n	w_{1n}	w_{2n}	\dots	w_{tn}

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 $w(u_t, d_i)$

- **Algorithm Average**

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

- **Algorithm Weighted Average**

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

		Χρήστες		
		u_1	u_2	\dots
Έγγραφα	d_1	w_{11}	w_{21}	\dots
	d_2	w_{12}	w_{22}	\dots
	:	:	:	
	:	:	:	
	d_n	w_{1n}	w_{2n}	\dots



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 => 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

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

– συνημίτονο

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

– Mean Squared Distance

– Pearson Correlation Coefficient

– ...

Στα άδεια κελιά
του πίνακα
θεωρούμε ότι
υπάρχει το 0



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	

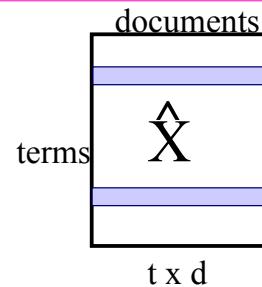
- Various solutions:

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



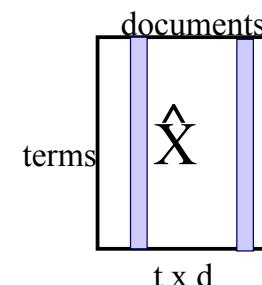
- Τρόπος σύγκρισης 2 όρων:

- the **dot product** between two **row vectors** of \hat{X} 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 \hat{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