



HY463 - Συστήματα Ανάκτησης Πληροφοριών
Information Retrieval (IR) Systems

Μοντέλα Ανάκτησης I (Retrieval Models)

Γιάννης Τζίτζικας

Διάλεξη : 3

Ημερομηνία : 2-3-2006

CS463 - Information Retrieval Systems

Yannis Tzitzikas, U. of Crete, Spring 2006

1



Διάρθρωση

- **Εισαγωγή στα Μοντέλα Άντλησης**
- **Κατηγορίες Μοντέλων**
- **Απόλυτο και Κάλλιστο (ή Βέλτιστο) Ταίριασμα (Exact vs Best Match)**
- **Τα κλασσικά μοντέλα ανάκτησης**
- **To Boolean Μοντέλο**
- **Στατιστικά Μοντέλα - Βάρυνση Όρων**
- **To Διανυσματικό Μοντέλο**
- **To Εκτεταμένο Boolean μοντέλο (Extended Boolean Model)**



Αναπαράσταση Εγγράφων: Πως βλέπουμε ένα έγγραφο;

- Πως βλέπουμε ένα έγγραφο;
 - Ως έχει (full text);
 - Αγνοώντας λέξεις που δεν φέρουν νόημα (π.χ. τα άρθρα) ;
 - Ως σάκο (bag) όρων ευρετηρίου (bag of index terms),
δηλαδή αγνοώντας τη σειρά με την οποία εμφανίζονται οι λέξεις στο κείμενο;
 - Ως σύνολο όρων ευρετηρίου (set of Index terms)
 - Ως δομημένο έγγραφο (π.χ. hypertext, XML)
- Η απάντηση σε αυτό το ερώτημα θα καθορίσει τη μορφή του ευρετηρίου που πρέπει να κατασκευάσουμε.
- Η απάντηση σε αυτό το ερώτημα είναι συνυφασμένη **και** με το μοντέλο ανάκτησης που πρόκειται χρησιμοποιήσουμε.



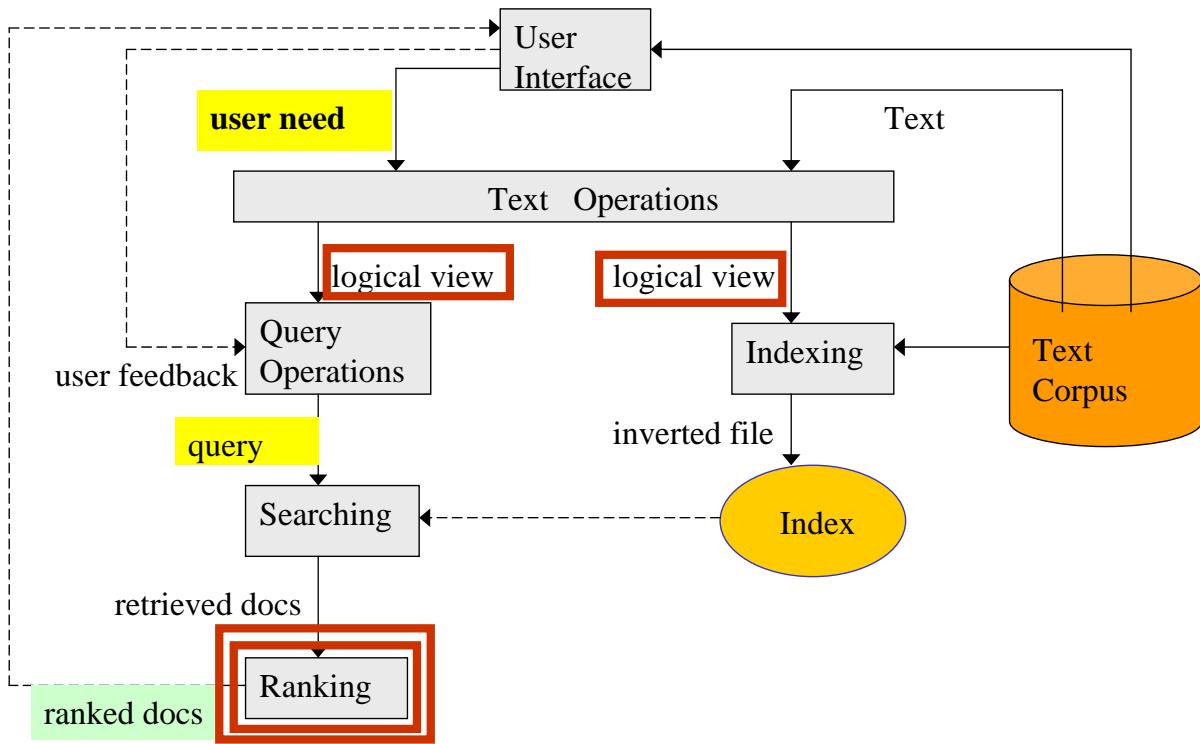
Μοντέλα Ανάκτησης

- Ένα μοντέλο ανάκτησης ορίζει
 - Αναπαράσταση Εγγράφων
 - Αναπαράσταση Επερωτήσεων
 - Καθορίζει και ποσοτικοποιεί την έννοια της συνάφειας
 - ο βαθμός συνάφειας μπορεί να είναι δίτιμος (π.χ. {1,0}), ή συνεχής (π.χ. [0,1])

Έστω **D** η συλλογή εγγράφων και **Q** το σύνολο όλων των πληροφοριακών αναγκών που μπορεί να έχει ένας χρήστης.

Μπορούμε να δούμε ένα **μοντέλο ανάκτησης πληροφορίας** ως μια τετράδα $[F, D, Q, R]$ όπου:

- F: πλαίσιο μοντελοποίησης εγγράφων, επερωτήσεων και των σχέσεων μεταξύ τους
- D: παράσταση εγγράφων $D = \{ F(d) \mid d \in D \}$
- Q: παράσταση επερωτήσεων $Q = \{ F(q) \mid q \in Q \}$
- R: συνάρτηση κατάταξης που αποδίδει μία τιμή σε κάθε ζεύγος $(d, q) \in D \times Q$
 - δίτιμη: $R: D \times Q \rightarrow [\text{True/False}]$
 - συνεχής $R: D \times Q \rightarrow [0, 1]$



Κατηγορίες Μοντέλων Ανάκτησης (I)

- **Κλασσικά Μοντέλα**
 - Boolean Model
 - Διανυσματικό (Vector Space)
 - Πιθανοκρατικό (Probabilistic)
- **Συνολοθεωρητικά (set theoretic)**
 - Εκτεταμένο Boolean (Extended Boolean Model)
 - Fuzzy Model (Ασαφές Μοντέλο)
- **Διανυσματικά (στατιστικά/αλγεβρικά)**
 - Γενικευμένο Διανυσματικό (Generalized Vector Space Model)
 - Latent Semantic Indexing (Λανθάνων/Άδηλος/Υποβόσκων σημασιολογικός ευρετηριασμός)
 - Μοντέλο Νευρωνικού Δικτύου (Neural Network Model)

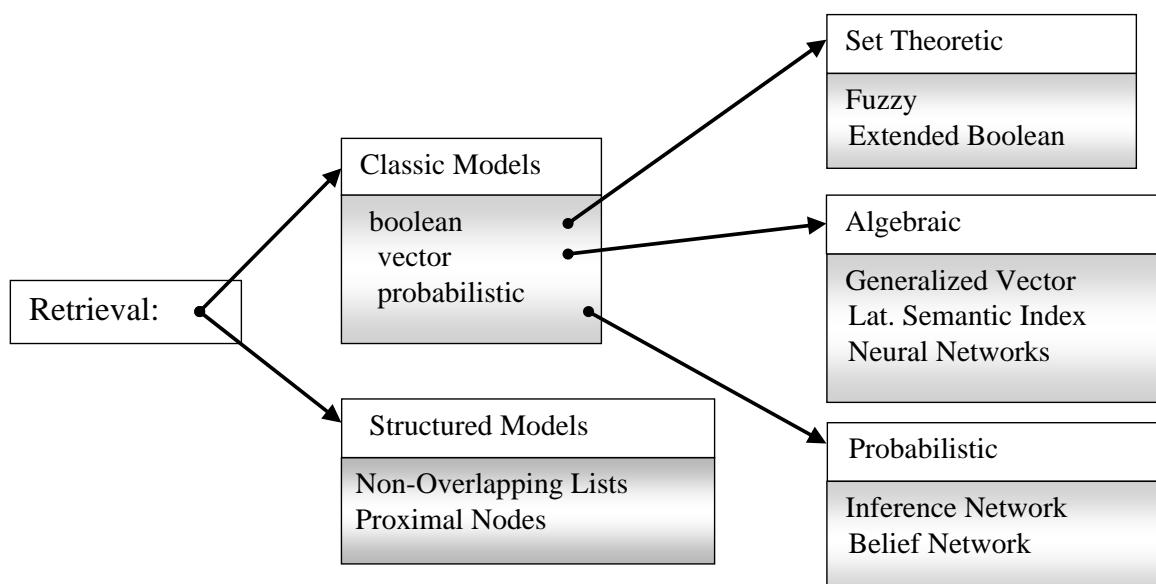


Κατηγορίες Μοντέλων Ανάκτησης (II)

- Πιθανοκρατικά (Probabilistic)
 - Inference Network Model (Μοντέλο Δικτύου Επαγωγών)
 - Belief Network Model (Μοντέλο Δικτύου Πεποιθήσεων)
- Μοντέλα Βασισμένα στη Λογική
- Μοντέλα Δομημένου Κειμένου (Structured Text Retrieval Models)
 - Non-Overlapping Lists
 - Proximal Nodes
 - Μοντέλα Ανάκτησης XML Εγγράφων



Μια Ταξινομία των Μοντέλων Ανάκτησης





Exact vs. Best Match Retrieval Models

- Exact-match (Απόλυτου Ταιριάσματος)
 - μια επερώτηση καθορίζει **αυστηρά (απόλυτα)** κριτήρια ανάκτησης
 - κάθε έγγραφο είτε ταιριάζει είτε όχι με μία επερώτηση
 - το αποτέλεσμα είναι ένα **σύνολο** κειμένων
- Best-match (Κάλλιστου Ταιριάσματος)
 - μια επερώτηση **δεν περιγράφει αυστηρά** κριτήρια ανάκτησης
 - **κάθε** έγγραφο ταιριάζει σε μια επερώτηση **σε ένα βαθμό**
 - το αποτέλεσμα είναι μια **διατεταγμένη λίστα** εγγράφων
 - με ένα κατώφλι (στο βαθμό συνάφειας) μπορούμε να ελέγξουμε το μέγεθος της απάντησης
- «Μικτές προσεγγίσεις»
 - συνδυασμός απόλυτου ταιριάσματος με τρόπους διάταξης του συνόλου της απάντησης
 - E.g., best-match query language that incorporates exact-match operators



Information Retrieval Models

Boolean Retrieval Model



Boolean Retrieval Model

- Έγγραφο = σύνολο λέξεων κλειδιών (keywords)
- Επερώτηση = Boolean έκφραση λέξεων κλειδιών (AND,OR, NOT, παρενθέσεις)
 - πχ επερώτησης
 - ((Crete AND Greece) OR (Oia AND Santorini)) AND Hotel AND-NOT Hilton
 - ((Crete & Greece) | (Oia & Santorini)) & Hotel & ! Hilton
- Απάντηση= σύνολο εγγράφων
 - απουσία διάταξης



Παράσταση εγγράφων κατά το Boolean Model

$$\begin{pmatrix} k_1 & k_2 & \dots & k_t \\ d_1 & w_{11} & w_{21} & \dots & w_{t1} \\ d_2 & w_{12} & w_{22} & \dots & w_{t2} \\ \vdots & \vdots & \vdots & & \vdots \\ \vdots & \vdots & \vdots & & \vdots \\ d_n & w_{1n} & w_{2n} & \dots & w_{tn} \end{pmatrix} \quad w_{i,j} \in \{0,1\}$$

- $K=\{k_1, \dots, k_t\}$: σύνολο όλων των λέξεων ευρετηρίασης
- Κάθε έγγραφο d_j παριστάνεται με το διάνυσμα $d_j=(w_{1,j}, \dots, w_{t,j})$ όπου:
 - $w_{i,j} = 1$ αν η λέξη k_i εμφανίζεται στο κείμενο d_j (αλλιώς $w_{i,j} = 0$)



Boolean Retrieval Model: Formally

- $K = \{k_1, \dots, k_t\}$: σύνολο όλων των λέξεων ευρετηρίασης
- Κάθε έγγραφο d_j παριστάνεται με το διάνυσμα $d_j = (w_{1,j}, \dots, w_{t,j})$ όπου:
 - $w_{i,j} = 1$ αν η λέξη k_i εμφανίζεται στο κείμενο d_j (αλλιώς $w_{i,j} = 0$)
- Μια επερώτηση q είναι μια λογική έκφραση στο K , πχ:
 - $q = "k1 \text{ and } (k2 \text{ or not } k3)"$ δηλαδή $q = "k1 \wedge (k2 \vee \neg k3)"$
 - $q_{DNF} = "(k1 \wedge k2 \wedge k3) \vee (k1 \wedge k2 \wedge \neg k3) \vee (k1 \wedge \neg k2 \wedge \neg k3)"$
 - $q_{DNF} = "(1,1,1) \vee (1,1,0) \vee (1,0,0)"$
- $R(d,q) =$
 - **True** αν υπάρχει συζευκτική συνιστώσα του q με λέξεις των οποίων τα βάρη είναι τα ίδια με αυτά των αντίστοιχων λέξεων του εγγράφου d
 - **False**, αλλιώς



Boolean Retrieval Model: Ισοδύναμος ορισμός

Αποτίμηση επερωτήσεων (με χρήση λογικής)

- ένα κείμενο d είναι μια **σύζευξη όρων**, όπου **όρος** μια λέξη σε θετική ή αρνητική μορφή (σε θετική αν εμφανίζεται στο κείμενο, αλλιώς σε αρνητική)
- μια επερώτηση q είναι μια οποιαδήποτε λογική έκφραση
- **$R(d,q) = True \text{ if and only if } d \models q$**
 - δηλαδή αν κάθε ερμηνεία που αληθεύει το d αληθεύει και το q



Boolean Retrieval Model: Ένας εναλλακτικός τρόπος ορισμού

Μπορούμε να ορίσουμε ως ερμηνεία μιας λέξης (του K) το σύνολο των εγγράφων που την περιέχουν.

Άρα η ερμηνεία είναι μια συνάρτηση $I: K \rightarrow 2^D$ που ορίζεται ως εξής:

$$I(k) = \{ d \mid d \text{ περιέχει τη λέξη } k \}$$

Έστω E το σύνολο των λογικών εκφράσεων με λέξεις από το σύνολο K .

Μπορούμε να επεκτείνουμε μια ερμηνεία I του K σε μια ερμηνεία J του E ως εξής

$$J(t) = I(t)$$

$$J(e \wedge e') = J(e) \cap J(e')$$

$$J(e \vee e') = J(e) \cup J(e')$$

$$J(e \wedge \neg e') = J(e) \setminus J(e')$$

Η απάντηση μιας επερώτησης q (κατά το Boolean μοντέλο) είναι η εξής:

$$\text{ans}(q) = J(q)$$



Οι αδυναμίες του Boolean μοντέλου

Η αδυναμία ελέγχου του μεγέθους της απάντησης

- Παράδειγμα:
 - $|Answer("Cheap \wedge Tickets \wedge Heraklion")| = 1$
 - $|Answer("Cheap \wedge Tickets)| = 1000$
 - $|Answer("Cheap \wedge Heraklion)| = 1000$
 - $|Answer("Tickets \wedge Heraklion")| = 1000$
- Άρα είτε παίρνουμε μια απάντηση με ένα έγγραφο είτε ένα σύνολο 1000 εγγράφων. :(



Οι αδυναμίες του Boolean μοντέλου

- Άκαμπτο: AND σημαίνει όλα, OR σημαίνει οποιοδήποτε
- Δυσκολίες
 - Ο έλεγχος του μεγέθους της απάντησης
 - All matched documents will be returned
 - Ικανοποιητική ακρίβεια (precision) συχνά σημαίνει απαράδεκτη ανάκληση (recall)
 - Η διατύπωση των επερωτήσεων είναι δύσκολη για πολλούς χρήστες
 - Η έκφραση σύνθετων πληροφοριακών αναγκών είναι δύσκολη
 - Δεν μας λέει πώς να διατάξουμε την απάντηση
 - All matched documents logically satisfy the query
 - Τα μοντέλα κατάταξης (ranking models) έχουν αποδειχτεί καλύτερα στην πράξη
 - Η υποστήριξη ανάδρασης συνάφειας δεν είναι εύκολη
 - If a document is identified by the user as relevant or irrelevant, how should the query be modified ? [Τώρα δουλεύουμε σε αυτό]



Τα θετικά του Boolean μοντέλου

- Προβλέψιμο, εύκολα εξηγήσιμο
- Αποτελεσματικό όταν γνωρίζεις ακριβώς τι ψάχνεις και τι περιέχει η συλλογή
- Αποδοτική υλοποίηση



Στατιστικά Μοντέλα



Κοινά χαρακτηριστικά των Στατιστικών Μοντέλων

- **Έγγραφο: σάκος (bag) λέξεων**
 - Bag = set that allows multiple occurrences of the same element
 - So we view a document as an unordered set of words with frequencies
- **Επερώτηση: Σύνολο όρων με προαιρετικά βάρη:**
 - Weighted query terms: **q=<database 0.5, text 0.8, information 0.2>**
 - Unweighted query terms: **q=<database text information >**
 - No Boolean conditions specified in the query
- **Απάντηση: Διατεταγμένο σύνολο συναφών εγγράφων**
 - Υπολογίζεται βάσει των συχνοτήτων εμφάνισης των λέξεων στα έγγραφα και στις επερωτήσεις



Στατιστικά Μοντέλα: Κρίσιμα Ερωτήματα

- Πώς να καθορίζουμε τη σπουδαιότητα ενός όρου σε ένα έγγραφο και στα πλαίσια ολόκληρης της συλλογής;
- Πώς να καθορίζουμε το βαθμό ομοιότητας μεταξύ ενός εγγράφου και μιας επερώτησης;



Information Retrieval Models **Vector Space Model** (Διανυσματικό Μοντέλο)

(το πιο διαδεδομένο μοντέλο ανάκτησης)



Διανυσματικό Μοντέλο: Εισαγωγή

- $K = \{k_1, \dots, k_t\}$: σύνολο όλων των λέξεων ευρετηρίασης
- Κάθε έγγραφο d_j παριστάνεται με ένα διάνυσμα $d_j = (w_{1,j}, \dots, w_{t,j})$ όπου $w_{i,j} \in [0, 1]$ (πχ $w_{i,j}=0.3$)
- Μια επερώτηση q παριστάνεται με ένα διάνυσμα $q = (w_{1,q}, \dots, w_{t,q})$ όπου πάλι $w_{i,q} \in [0, 1]$
- $R(d, q)$ εκφράζει το βαθμό ομοιότητας των διανυσμάτων d και q



Παράσταση εγγράφων στο Διανυσματικό Μοντέλο

$$\begin{pmatrix} & k_1 & k_2 & \dots & k_t \\ d_1 & w_{11} & w_{21} & \dots & w_{t1} \\ d_2 & w_{12} & w_{22} & \dots & w_{t2} \\ \vdots & \vdots & \vdots & & \vdots \\ \vdots & \vdots & \vdots & & \vdots \\ d_n & w_{1n} & w_{2n} & \dots & w_{tn} \end{pmatrix} \quad w_{i,j} \in [0,1]$$

- $K = \{k_1, \dots, k_t\}$: σύνολο όλων των λέξεων ευρετηρίασης
- Κάθε έγγραφο d_j παριστάνεται με το διάνυσμα $d_j = (w_{1,j}, \dots, w_{t,j})$ όπου:
 - $w_{i,j}$ το βάρος της λέξης k_i για το κείμενο d_j



Βάρη Όρων: Συχνότητα όρου (tf)

- Οι πιο συχνοί όροι σε ένα έγγραφο είναι πιο σημαντικοί (υποδηλώνουν το περιεχόμενο του)
 - $freq_{ij}$ = πλήθος εμφανίσεων του όρου i στο έγγραφο j
- Κανονικοποίηση
 - $tf_{ij} = freq_{ij} / \max_k \{ freq_{kj} \}$
 - όπου $\max_k \{ freq_{kj} \}$ το μεγαλύτερο πλήθος εμφανίσεων ενός όρου στο έγγραφο j

Παράδειγμα: Έστω το έγγραφο $d_2 = "a\ a\ a\ b\ b\ b\ c\ c\ c"$

$$freq_{a2} = 4,$$

$$tf_{a2} = 4/4 = 1$$

$$freq_{b2} = 3,$$

$$tf_{b2} = 3/4 = 0.75$$



Παράδειγμα

- $d1 = \{ a\ a\ a\ b\ c \}$
- $d2 = \{ a\ a\ a\ d\ e \}$
- $d3 = \{ a\ a\ a\ f\ g \}$
- Το a λαμβάνει το μεγαλύτερο βάρος (άρα το μεγαλύτερο tf) σε κάθε έγγραφο
- Ας σκεφτούμε ολόκληρη τη συλλογή.
- Μας επιτρέπει το a να διακρίνουμε τα κείμενα;
- Αν όχι μήπως δεν θα έπρεπε να λαμβάνει το μεγαλύτερο βάρος;
- Αν η συλλογή είχε μόνο αυτά τα 3 έγγραφα (και ήταν σταθερή) θα μπορούσαμε ακόμα και να αγνοήσουμε πλήρως τον όρο a από το ευρετήριο.



Βάρη Όρων: Αντίστροφη Συχνότητα Εγγράφων (Inverse Document Frequency)

- Ιδέα: Όροι που εμφανίζονται σε πολλά διαφορετικά έγγραφα έχουν μικρή διακριτική ικανότητα
- df_i = document frequency of term i
 - πλήθος εγγράφων που περιέχουν τον όρο i
- idf_i = inverse document frequency of term i := $\log_2(N/ df_i)$
 - (N: συνολικό πλήθος εγγράφων)
- **Το idf αποτελεί μέτρο της διακριτικής ικανότητας του όρου**
 - ο λογάριθμος ελαφραίνει το βάρος του idf σε σχέση με το tf
- Παράδειγμα:
 - Έστω N=10 και $df_{computer} = 10$, $df_{aristotle} = 2$,
 - Τότε, $N/df_{computer} = 10/10 = 1$, $N/df_{aristotle} = 10/2 = 5$
 - Τότε, $idf_{computer} = \log(1) = 0$, $idf_{aristotle} = \log(5) = 2.3$



TF-IDF Weighting (βάρυνση TF-IDF)

$$\begin{array}{c} k_1 \quad k_2 \quad \dots \quad k_t \\ \textcolor{red}{d_1} \quad w_{11} \quad w_{21} \quad \dots \quad w_{t1} \\ \textcolor{red}{d_2} \quad w_{12} \quad w_{22} \quad \dots \quad w_{t2} \\ \vdots \quad \vdots \quad \vdots \quad \vdots \\ \vdots \quad \vdots \quad \vdots \quad \vdots \\ \textcolor{red}{d_n} \quad w_{1n} \quad w_{2n} \quad \dots \quad w_{tn} \end{array}$$

$$w_{ij} = tf_{ij} idf_i = tf_{ij} \log_2 (N/ df_i)$$

- Ένας όρος που εμφανίζεται **συχνά** στο έγγραφο, αλλά **σπάνια** στην υπόλοιπη συλλογή, λαμβάνει **υψηλό** βάρος.
- Αν και έχουν προταθεί πολλοί άλλοι τρόποι βάρυνσης, το tf-idf δουλεύει πολύ καλά στην πράξη.



Παράδειγμα υπολογισμού TF-IDF

- Έστω ένα έγγραφο που περιέχει όρους με τις εξής συχνότητες:
 - A(3), B(2), C(1), πχ. d="A B A B C A"
- Υποθέστε ότι η συλλογή περιέχει 10.000 έγγραφα και οι συχνότητες κειμένου (document frequencies) αυτών των όρων είναι:
 - A(50), B(1300), C(250)

Τότε:

- A: $tf = 3/3$; $idf = \log(10000/50) = 5.3$; $tf-idf = 5.3$
- B: $tf = 2/3$; $idf = \log(10000/1300) = 2$; $tf-idf = 1.3$
- C: $tf = 1/3$; $idf = \log(10000/250) = 3.7$; $tf-idf = 1.2$



Διάνυσμα Επερώτησης

- Τα διανύσματα των επερωτήσεων θεωρούνται ως έγγραφα και επίσης βαρύνονται με tf-idf
 - Μια επερώτηση δεν συγκροτείται πάντα από λίγες λέξεις. Μια επερώτηση μπορεί να είναι μια παράγραφος κειμένου (ή ένα ολόκληρο έγγραφο)
- Εναλλακτικά, ο χρήστης μπορεί να δώσει τα βάρη των όρων της επερώτησης

$$\begin{matrix} & k_1 & k_2 & \dots & k_t \\ \textcolor{red}{d}_1 & w_{11} & w_{21} & \dots & w_{t1} \\ \textcolor{red}{d}_2 & w_{12} & w_{22} & \dots & w_{t2} \\ \vdots & \vdots & \vdots & & \vdots \\ \vdots & \vdots & \vdots & & \vdots \\ \textcolor{red}{d}_n & w_{1n} & w_{2n} & \dots & w_{tn} \\ \textcolor{red}{q} & w_{1q} & w_{2q} & \dots & w_{tq} \end{matrix} \quad w_{i,j} \in [0,1]$$



Διανυσματικό Μοντέλο:

- $K = \{k_1, \dots, k_t\}$: σύνολο όλων των λέξεων ευρετηρίασης
- Κάθε έγγραφο d_j παριστάνεται με ένα διάνυσμα $d_j = (w_{1,j}, \dots, w_{t,j})$ όπου $w_{i,j} = \text{tf}_{ij} \text{idf}_i$
- Μια επερώτηση q παριστάνεται με ένα διάνυσμα $q = (w_{1,q}, \dots, w_{t,q})$ όπου πάλι $w_{i,q} = \text{tf}_{iq} \text{idf}_i$
- $R(d, q) = ?$



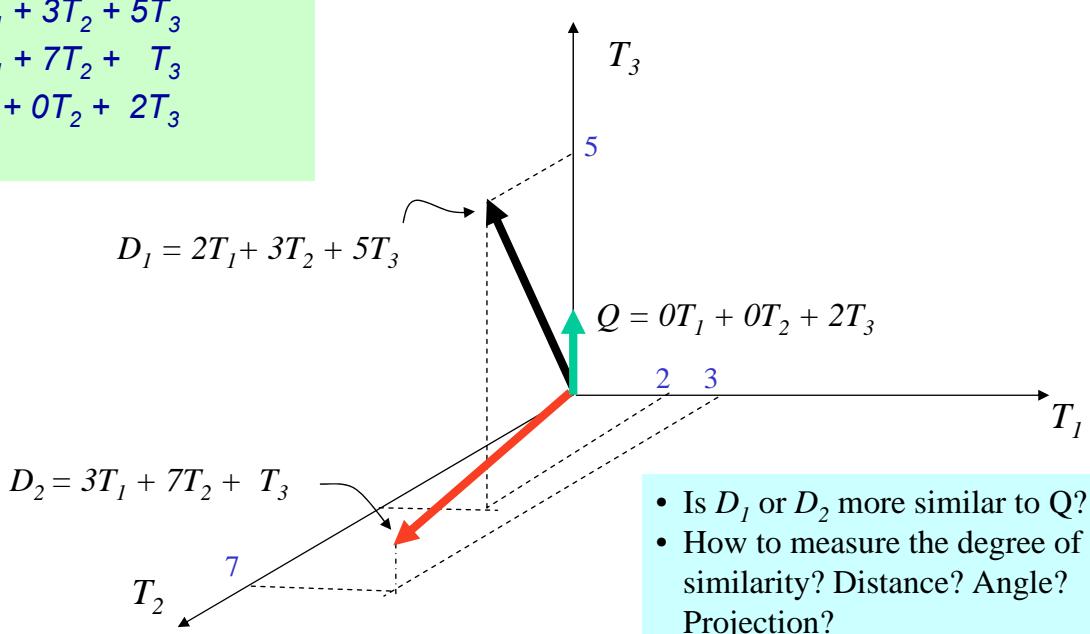
Διανυσματικό Μοντέλο: Μέτρο Ομοιότητας

Example:

$$D_1 = 2T_1 + 3T_2 + 5T_3$$

$$D_2 = 3T_1 + 7T_2 + T_3$$

$$Q = 0T_1 + 0T_2 + 2T_3$$





Μέτρο Ομοιότητας: Εσωτερικό Γινόμενο (inner product)

- Η ομοιότητα μεταξύ των διανυσμάτων d και q ορίζεται ως το εσωτερικό τους γινόμενο:

$$sim(dj, q) = \vec{dj} \cdot \vec{q} = \sum_{i=1}^t w_{ij} \cdot w_{iq}$$

- όπου w_{ij} το βάρος του όρου i στο έγγραφο j και w_{iq} το βάρος του όρου i στην επερώτηση
- Για δυαδικά (0/1) διανύσματα το εσωτερικό γινόμενο είναι ο αριθμός των matched query terms in the document (άρα το μέγεθος της τομής)
- Για βεβαρημένα διανύσματα, είναι το άθροισμα των γινομένων των βαρών των matched terms



Παράδειγμα

Binary:

retrieval
database
architecture
computer
text
management
information

- $d = 1, 1, 1, 0, 1, 1, 0$
- $q = 1, 0, 1, 0, 0, 1, 1$

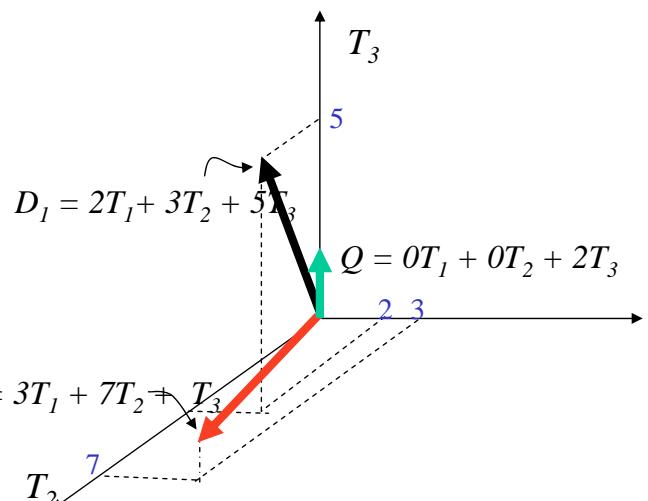
$$sim(d, q) = 3$$

Size of vector = size of vocabulary = 7
0 means corresponding term not found in document or query

Weighted:

$$D_1 = 2T_1 + 3T_2 + 5T_3 \quad D_2 = 3T_1 + 7T_2 + 1T_3 \\ Q = 0T_1 + 0T_2 + 2T_3$$

$$sim(D_1, Q) = 2*0 + 3*0 + 5*2 = 10 \\ sim(D_2, Q) = 3*0 + 7*0 + 1*2 = 2$$





Ιδιότητες του Εσωτερικού Γινόμενου

- Το εσωτερικό γινόμενο

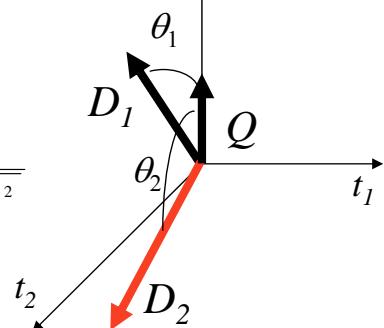
- δεν είναι φραγμένο (unbounded)
- ευνοεί (μεροληπτεί) μεγάλα έγγραφα με μεγάλο πλήθος διαφορετικών όρων
- μετρά το πλήθος των όρων που κάνουν match, αλλά αγνοεί αυτούς που δεν κάνουν match



Μέτρο Ομοιότητας Συνημίτονου (Cosine)

- Μετρά το συνημίτονο της γωνίας μεταξύ των 2 διανυσμάτων
- Εσωτερικό γινόμενο κανονικοποιημένο βάσει του μήκους των διανυσμάτων

$$\text{CosSim}(\vec{d}_j, \vec{q}) = \frac{\vec{d}_j \cdot \vec{q}}{|\vec{d}_j| \cdot |\vec{q}|} = \frac{\sum_{i=1}^t (w_{ij} \cdot w_{iq})}{\sqrt{\sum_{i=1}^t w_{ij}^2} \cdot \sqrt{\sum_{i=1}^t w_{iq}^2}}$$



$D_1 = 2T_1 + 3T_2 + 5T_3$	$\text{CosSim}(D_1, Q) = 10 / \sqrt{(4+9+25)(0+0+4)} = 0.81$
$D_2 = 3T_1 + 7T_2 + 1T_3$	$\text{CosSim}(D_2, Q) = 2 / \sqrt{(9+49+1)(0+0+4)} = 0.13$
$Q = 0T_1 + 0T_2 + 2T_3$	

D_1 is 6 times better than D_2 using cosine similarity but only 5 times better using inner product.



Διανυσματικό Μοντέλο: Παρατηρήσεις

• Πλεονεκτήματα

- Λαμβάνει υπόψη τις **τοπικές** (tf) και **καθολικές** (idf) συχνότητες όρων
- Παρέχει **μερικό ταίριασμα** (partial matching) και **διατεταγμένα** αποτελέσματα
- Τείνει να δουλεύει καλά στην πράξη, παρά τις αδυναμίες του
- Αποδοτική υλοποίηση για μεγάλες συλλογές εγγράφων

• Αδυναμίες

- Απουσία Σημασιολογίας (π.χ. σημασίας λέξεων)
- Απουσία Συντακτικής Πληροφορίας (π.χ. δομή φράσης, σειρά λέξεων, εγγύτητα λέξεων)
- Υπόθεση Ανεξαρτησίας Όρων (π.χ. αγνοεί τα συνώνυμα)
- Έλλειψη ελέγχου ala Boolean model (π.χ. δεν μπορούμε να απαιτήσουμε την παρουσία ενός όρου στο έγγραφο)
 - Given a two-term query $q = "A B"$, may prefer a document containing A frequently but not B, over a document that contains both A and B but both less frequently



Περίληψη του Διανυσματικού Μοντέλου

- $K = \{k_1, \dots, k_t\}$: σύνολο όλων των λέξεων ευρετηρίασης
- Κάθε έγγραφο d_j παριστάνεται με το διάνυσμα $d_j = (w_{1,j}, \dots, w_{t,j})$ όπου $w_{ij} = tf_{ij} idf_i = tf_{ij} \log_2 (N / df_i)$
- Μια επερώτηση q παριστάνεται με το διάνυσμα $q = (w_{1,q}, \dots, w_{t,q})$ όπου $w_{iq} = tf_{iq} idf_i = tf_{iq} \log_2 (N / df_i)$

$$\bullet R(d_j, q) = \text{CosSim}(d_j, q) = \frac{\vec{d}_j \cdot \vec{q}}{|\vec{d}_j| \cdot |\vec{q}|} = \frac{\sum_{i=1}^t (w_{ij} \cdot w_{iq})}{\sqrt{\sum_{i=1}^t w_{ij}^2} \cdot \sqrt{\sum_{i=1}^t w_{iq}^2}}$$



Υπολογισμός του βαθμού συνάφειας

Απλοϊκή Υλοποίηση

- 1) Φτιάξε το *tf-idf* διάνυσμα για κάθε έγγραφο d_j της συλλογής (έστω V το λεξιλόγιο)
2) Φτιάξε το *tf-idf* διάνυσμα q της επερώτησης
3) Για κάθε έγγραφο d_j του D
 Υπολόγισε το σκορ $s_j = \text{cosSim}(d_j, q)$
4) Διέταξε τα έγγραφα σε φθίνουσα σειρά
5) Παρουσίασε τα έγγραφα στο χρήστη

Χρονική πολυπλοκότητα του βήματος (3): $O(|V| \cdot |D|)$

Πολύ ακριβό αν τα V και D είναι μεγάλα!

$|V| = 10,000; |D| = 100,000; |V| \cdot |D| = 1,000,000,000$



Υπολογισμός του βαθμού συνάφειας

Καλύτερη (γρηγορότερη) Υλοποίηση

- Ένας όρος που δεν εμφανίζεται **και** στην επερώτηση **και** στο έγγραφο **δεν επηρεάζει** το βαθμό ομοιότητας συνημίτονου
 - Το γινόμενο των βαρών είναι 0 και άρα δεν συνεισφέρει στο εσωτερικό γινόμενο
- Συνήθως η επερώτηση είναι μικρή, άρα το διάνυσμα της είναι εξαιρετικά «αραιό»
- => Μπορούμε να χρησιμοποιήσουμε ένα ευρετήριο ώστε να υπολογίσουμε το βαθμό ομοιότητας μόνο εκείνων των εγγράφων που περιέχουν τουλάχιστον έναν όρο της επερώτησης.

3) Για κάθε έγγραφο d_j του D
 Υπολόγισε το σκορ $s_j = \text{cosSim}(d_j, q)$

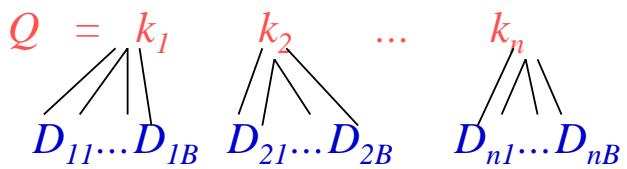
Απλοϊκό

3') Για κάθε έγγραφο d_j **που περιέχει τουλάχιστον έναν όρο του query**
 Υπολόγισε το σκορ $s_j = \text{cosSim}(d_j, q)$

Καλύτερο



Υπολογισμός του βαθμού συνάφειας Καλύτερη (γρηγορότερη) Υλοποίηση (II)



- Ας υποθέσουμε ότι ένας όρος της επερώτησης εμφανίζεται σε B έγγραφα
- Τότε η χρονική πολυπλοκότητα είναι $O(|Q| |B|)$
- Το κόστος αυτό είναι συνήθως πολύ μικρότερο του κόστους του απλοϊκού τρόπου (που είχε πολυπλοκότητα $O(|V||D|)$), διότι:
 - $|Q| \ll |V|$, δηλαδή ο αριθμός των λέξεων στην επερώτησης είναι πολύ μικρότερος του συνολικού αριθμού των λέξεων, και
 - $|B| \ll |D|$, δηλαδή το πλήθος των έγγραφων που έχουν μια λέξη είναι πολύ μικρότερο του πλήθους των εγγράφων της συλλογής.



Information Retrieval Models **Extended Boolean Model**



Extended Boolean Model

- **Κίνητρο**
 - Το Boolean model είναι απλό και κομψό αλλά δεν παρέχει κατάταξη (διαβάθμιση των συναφών εγγράφων)
- **Προσέγγιση**
 - Επέκταση του Boolean model με **βάρυνση όρων** και **μερικό ταίριασμα**
 - Συνδιασμός χαρακτηριστικών του Vector model και ιδιοτήτων της Boolean algebra

[Salton, Fox, and Wu, 1983]



Σκεπτικό / Κίνητρο

Έστω $q = k_x \wedge k_y$.

Σύμφωνα με το Boolean model ένα έγγραφο που περιέχει **μόνο ένα** από τα k_x , k_y είναι **μη-συναφές**, και μάλιστα τόσο μη-συναφές, όσο ένα έγγραφο που δεν περιέχει **κανένα** από τους 2 όρους.



Έστω ότι έχουμε μόνο δύο όρους k_x , k_y

Μπορούμε να θεωρήσουμε κάθε όρο ως μια διάσταση

Άρα έγγραφα και επερωτήσεις απεικονίζονται στο 2D χώρο.

Ένα έγγραφο d_j τοποθετείται βάσει των, βαρών $w_{x,j}$ και $w_{y,j}$.

Έστω ότι τα βάρη αυτά είναι κανονικοποιημένα στο $[0,1]$, π.χ. :

$$w_{x,j} = \text{tf}_{x,j} \text{idf}_x$$

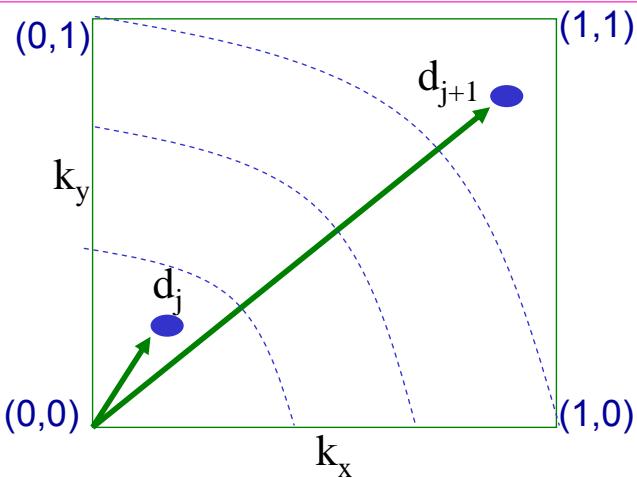
$$w_{y,j} = \text{tf}_{y,j} \text{idf}_y$$

Για συντομία έστω $x = w_{x,j}$ και $y = w_{y,j}$

Άρα οι συντεταγμένες του d_j είναι οι (x,y)



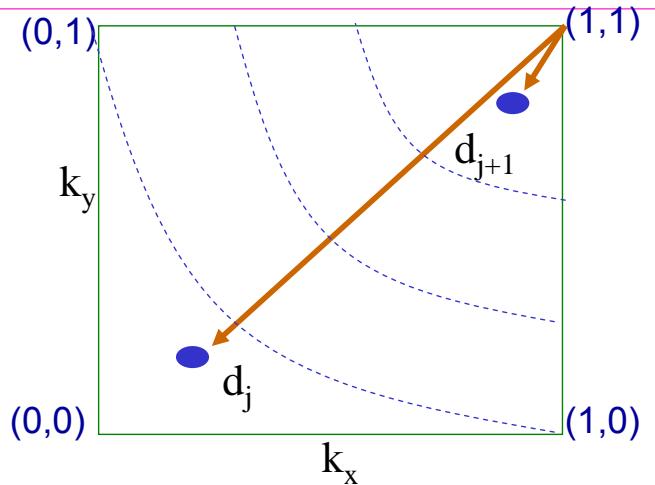
Η γενική ιδεά



Έστω $q_{OR} = k_x \vee k_y$

Το σημείο $(0,0)$ είναι η θέση προς αποφυγή.

Άρα μπορούμε να θεωρήσουμε την απόσταση του d_j από αυτό το σημείο ως το **βαθμό ομοιότητας**



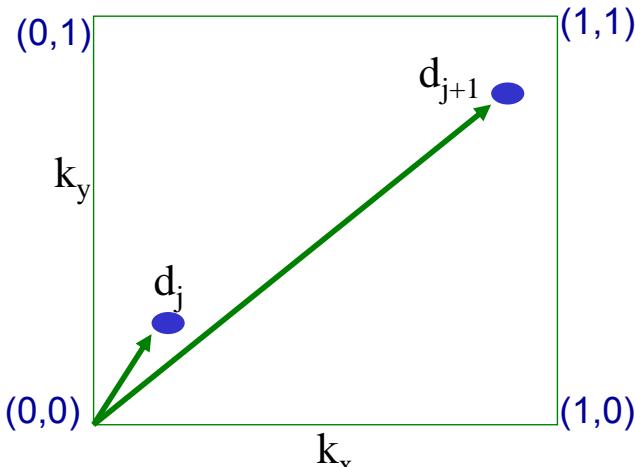
Έστω $q_{AND} = k_x \wedge k_y$

Το σημείο $(1,1)$ είναι η πιο επιθυμητή θέση.

Άρα μπορούμε να θεωρήσουμε το συμπλήρωμα της απόστασης του d_j από αυτό το σημείο ως **βαθμό ομοιότητας**



Η γενική ιδέα (II)



Let $q_{OR} = k_x \vee k_y$

$$sim(q_{OR}, d) = \sqrt{\frac{x^2 + y^2}{2}}$$



Let $q_{AND} = k_x \wedge k_y$

$$sim(q_{AND}, d) = 1 - \sqrt{\frac{(1-x)^2 + (1-y)^2}{2}}$$

("2" for normalisation to [0,1])



Γενικεύοντας την ιδέα (για >2 όρους)

- Μπορούμε να γενικεύσουμε το προηγούμενο μοντέλο χρησιμοποιώντας την Ευκλείδεια απόσταση στον **t-διάστατο χώρο**
- Αυτό μπορεί να γίνει χρησιμοποιώντας **p-norms** που γενικεύουν την έννοια της απόστασης, όπου $1 \leq p \leq \infty$.

- Διαζευκτικές επερωτήσεις**
 - $q_{OR} = k_1 \vee k_2 \vee \dots \vee k_m$

$$sim(q_{OR}, d) = \left(\frac{x_1^p + x_2^p + \dots + x_m^p}{m} \right)^{\frac{1}{p}}$$

- Συζευκτικές επερωτήσεις**
 - $q_{AND} = k_1 \wedge k_2 \wedge \dots \wedge k_m$

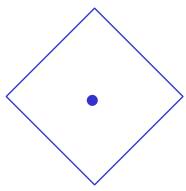
$$sim(q_{AND}, d) = 1 - \left(\frac{(1-x_1)^p + \dots + (1-x_m)^p}{m} \right)^{\frac{1}{p}}$$



Ισομετρικές καμπύλες

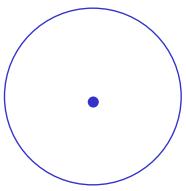
$$\sqrt[p]{(x^p + y^p)}$$

L_1



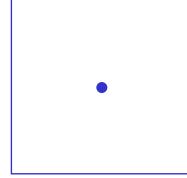
$$x + y = 1$$

L_2

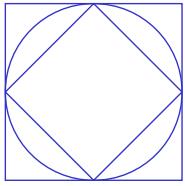


$$\sqrt[2]{(x^2 + y^2)} = 1$$

L_∞



$$\max(x, y) = 1$$



Μερικές ενδιαφέρουσες ιδιότητες

- Μεταβάλλοντας το p , μπορούμε να κάνουμε το μοντέλο να συμπεριφέρεται όπως το Vector, το Fuzzy (που θα δούμε στο επόμενο μάθημα), ή ενδιάμεσα σε αυτά τα δυο.
- Αν $p = 1$ τότε (Vector like)
 - $\text{sim}(q_{\text{OR}}, dj) = \text{sim}(q_{\text{AND}}, dj) = \frac{x_1 + \dots + x_m}{m}$
- Αν $p = \infty$ τότε (Fuzzy like)
 - $\text{sim}(q_{\text{OR}}, dj) = \max(x_i)$
 - $\text{sim}(q_{\text{AND}}, dj) = \min(x_i)$

Ερώτηση: Που πήγαν οι όροι της επερώτησης;



Σύνθετες επερωτήσεις

- Έστω $q = (k_1 \wedge k_2) \vee k_3$
- Εφαρμόζουμε τους ορισμούς σεβόμενοι τη σειρά, εδώ:

$$sim(q, d) = \left(\frac{(1 - (\frac{(1-x_1)^p + (1-x_2)^p}{2})^{1/p})^p + x_3^p}{2} \right)^{\frac{1}{p}}$$

- Έστω $q = (k_1 \vee k_2) \wedge k_3$
 - k_1 and k_2 should be used as in a vector system but the presence of k_3 is required



Μερικές Παρατηρήσεις

- Είναι αρκετά ισχυρό μοντέλο με ενδιαφέρουσες ιδιότητες
- Η επιμεριστική ιδιότητα δεν ισχύει:
 - $q_1 = (k_1 \vee k_2) \wedge k_3$
 - $q_2 = (k_1 \wedge k_3) \vee (k_2 \wedge k_3)$
 - $sim(q_1, d_j) \neq sim(q_2, d_j)$



Διάρθρωση

- Εισαγωγή στα Μοντέλα Άντλησης
- Κατηγορίες Μοντέλων
- Απόλυτο και Κάλλιστο (ή Βέλτιστο) Ταίριασμα (Exact vs Best Match)
- Τα κλασσικά μοντέλα ανάκτησης
- Το Boolean Μοντέλο
- Στατιστικά Μοντέλα - Βάρυνση Όρων
- Το Διανυσματικό Μοντέλο
- Το Εκτεταμένο Boolean μοντέλο (Extended Boolean Model)