

## Κανόνες Συσχέτισης II



Οι διαφάνειες στηρίζονται στο P.-N. Tan, M. Steinbach, V. Kumar, «Introduction to Data Mining», Addison Wesley, 2006



### Σύντομη Ανακεφαλαίωση

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008      ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II      2

**Market-Basket transactions  
(Το καλάθι της νοικοκυράς!)**

TID	Items
1	Bread, Milk
2	Bread, Diaper, Beer, Eggs
3	Milk, Diaper, Beer, Coke
4	Bread, Milk, Diaper, Beer
5	Bread, Milk, Diaper, Coke

**Εισαγωγή**

Το πρόβλημα: Δεδομένου ενός συνόλου δοσοληψιών (transactions), βρες κανόνες που προβέπουν την εμφάνιση στοιχείων (item) με βάση την εμφάνιση άλλων στοιχείων στις συναλλαγές

**Παραδείγματα κανόνων συσχέτισης**

$\{Diaper\} \rightarrow \{Beer\}$ ,  
 $\{Milk, Bread\} \rightarrow \{Eggs, Coke\}$ ,  
 $\{Beer, Bread\} \rightarrow \{Milk\}$

**δοσοληψία (transaction)**      **στοιχείο (item)**

- Πρωθητική προϊόντων
- Τοποθέτηση προϊόντων στα ράφια
- Διαχείριση αποθεμάτων

Σημαίνει ότι εμφανίζονται μαζί, όχι ότι η εμφάνιση του ενός είναι η αιτία της εμφάνισης του άλλου (co-occurrence, not causality όχι έννοια χρόνου ή ίση από κάποια τιμή καταφύλου *minsup*)

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008      ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II      3

**Ορισμοί**

**στοιχειοσύνολο (itemset):** Ένα υποσύνολο του συνόλου των στοιχείων

**k-στοιχειοσύνολο (k-itemset):** ένα στοιχειοσύνολο με k στοιχεία

**support count (σ) ενός στοιχειοσύνολου:** ο αριθμός εμφανίσεων του στοιχείου

**Υποστήριξη (Support (s)) ενός στοιχειοσύνολου** Το ποσοστό των δοσοληψιών που περιέχουν ένα στοιχειοσύνολο

**Συνόλο Στοιχειοσύνολο (Frequent Itemset)** Ένα στοιχειοσύνολο του οποίου η υποστήριξη είναι μεγαλύτερη ή ίση από κάποια τιμή καταφύλου *minsup*

TID	Items
1	Bread, Milk
2	Bread, Diaper, Beer, Eggs
3	Milk, Diaper, Beer, Coke
4	Bread, Milk, Diaper, Beer
5	Bread, Milk, Diaper, Coke

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008      ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II      4

**Κανόνας Συσχέτισης (Association Rule)**

Είναι μια έκφραση της μορφής  $X \rightarrow Y$ , όπου  $X$  και  $Y$  είναι στοιχειοσύνολα  $X \subseteq I$ ,  $Y \subseteq I$ ,  $X \cap Y = \emptyset$

Παράδειγμα:  $\{Milk, Diaper\} \rightarrow \{Beer\}$

**Υποστήριξη Kanōva Support (s)**  
Το ποσοστό των δοσοληψιών που περιέχουν και το X και το Y ( $X \cup Y$ )

**Εμπιστοσύνη - Confidence (c)**  
Τόσος από τις δοσοληψιές (ποσοστό) που περιέχουν το X περιέχουν και το Y

**Πρόβλημα**

Εύρεση Κανόνων Συσχέτισης

Εισόδος: Ένα σύνολο από δοσοληψίες T  
Έξοδος: Όλοι οι κανόνες με  
 $support \geq minsup$   
 $confidence \geq minconf$







Εξόριη Διδούμενων: Ακ. Έτος 2007-2008      ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II      5







**Εξόρυξη Κανόνων Συσχέτισης**

Χωρισμός του προβλήματος σε δύο υπο-προβλήματα:

- **Εύρεση όλων των συχνών στοιχειοσύνολων (Frequent Itemset Generation)**  
Εύρεση όλων των στοιχειοσύνολων με υποστήριξη  $\geq minsup$
- **Δημιουργία Κανόνων (Rule Generation)**  
Για κάθε (συχνό) στοιχειοσύνολο, δημιουργησε κανόνες με μεγάλη υποστήριξη, όπου κάθε κανόνες είναι μια δυαδική διαμέριση (δηλ. χωρισμός στα δύο) του συχνού στοιχειοσύνολου

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008      ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II      6





**Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων**

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008  
ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II  
19

**Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων**

O Apriori από τους παλιότερους, αλλά:

Συχνά μεγάλο I/O επειδή κάνει πολλαπλά περάσματα στη βάση των δοσοληψών

Κακή απόδοση όταν οι δοσοληψίες έχουν μεγάλο πλάτος

Άλλες μέθοδοι:

- Διαφορετικές διασχίσεις του πλέγματος των στοιχειοσυνόλων
- Αναπαράσταση Συνόλου Δοσοληψών

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008  
ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II  
20

**Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων**

Apriori: Γενικά-προς-Συγκεκριμένα

$k-1 \rightarrow k$

Πλέγμα Στοιχειοσυνόλων

An autó είναι το συχνό, το δρισίουμε όταν αφού εξέτασμος όλα τα υποσύνολα του

An τα συχνά είναι προς το καπύταστο σημείο (βάση) τους πλέγματος, ίσως συμφέρει

Συγκεκριμένα-προς-Γενικά

$k \rightarrow k-1$

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008  
ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II  
21

**Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων**

Διάσχιση του Πλέγματος των Στοιχειοσυνόλων: Συγκεκριμένα-προς-Γενικά vs Γενικά-προς-Συγκεκριμένα

$k \rightarrow k-1$  (συγκεκριμένο-προς-γενικό)

Πιο χρήσιμο για τον εντοπισμό μακριών συχνών στοιχειοσυνόλων σε πυκνές (δηλ., με μεγάλο πλάτος δοσοληψίες) όπου το συχνό στοιχειοσύνολο βρίσκεται κοντά στο κατώτατο σημείο του πλέγματος

Αν συχνό, δε χρειάζεται να ελέγχουμε κανένα από τα υποσύνολα του

Γενικό-προς-Συγκεκριμένα Συγκεκριμένο-προς-Γενικό Διπλής Κατεύθυνσης

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008  
ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II  
22

**Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων**

Διάσχιση του Πλέγματος των Στοιχειοσυνόλων: Κλάσεις Ισοδυναμίας

Χωρισμός των στοιχειοσυνόλων του πλέγματος σε ζένες μεταξύ τους ομάδες (κλάσεις ισοδυναμίας) και εξέταση των στοιχειοσυνόλων ανά κλάση

Apriori: ορίζει τις κλάσεις με βάση το μήκος  $k$  των στοιχειοσυνόλων, πρώτα αυτά μήκους 1, μετά μήκους 2 κοκ

Prefix (Suffix): Δύο στοιχειοσύνολα ανήκουν στην ίδια κλάση αν έχουν κοινό πρόθεμα (ή επίθημα-κατάλληλη) μήκους  $k$

(a) Prefix tree  
(b) Suffix tree

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008  
ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II  
23

**Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων**

Διάσχιση του Πλέγματος των Στοιχειοσυνόλων: BFS vs DFS


BFS: Breadth-First-Search Διάσχιση κατά Πλάτος

DFS: Depth-First-Search Διάσχιση κατά Βάθος

Xρήσιμο για την εύρεση μακριών συχνών στοιχειοσύνολων γιατί τα εντοπίζει πιο γρήγορα από το BFS

Μόλις εντοπιστεί το μακρινό, είναι δυνατόν να κλαδεύσουν πολλά υποσύνολα του


Εξόριη Διδούμενη: Ακ. Έτος 2007-2008  
ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II  
24



Εξόριη Δεδουλων: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II


25



Εξόριη Δεδουλων: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II


26



Εξόριη Δεδουλων: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II


27



Εξόριη Δεδουλων: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II

29



Εξόριη Δεδουλων: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II

30

**Αλγόριθμος FP-Growth**

**Κατασκευή FP-δέντρου**

Διάβασμα TID=1:

Διάβασμα TID=2:

Κάθε κόμβος έχει μια **ΕΤΙΚΕΤΑ**: ποιο στοιχείο και τη συχνότητα εμφάνισης (υποστήριξη) - πόσες δοσοληψίες φτάνουν σε αυτόν

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II 31

**Αλγόριθμος FP-Growth**

**Κατασκευή FP-δέντρου**

Διάβασμα TID=1:

Διάβασμα TID=2:

Κάθε κόμβος ετικέτα, ποιο στοιχείο και τη συχνότητα εμφάνισης (υποστήριξη) - πόσες δοσοληψίες φτάνουν σε αυτόν

Επίσης, **δείκτες μεταξύ των κόμβων** που αναφέρονται στο ίδιο στοιχείο

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II 32

**Αλγόριθμος FP-Growth**

**Κατασκευή FP-δέντρου**

Διάβασμα TID=1, 2:

Πίνακας Δεικτών

Item	Pointer
A	-----
B	-----
C	-----
D	-----
E	-----

Επίσης, κρατάμε **πίνακα δεικτών** για να βοηθήσουν στον υπολογισμό των συχνών στοιχεισυνώλων

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II 33

**Αλγόριθμος FP-Growth**

**Κατασκευή FP-δέντρου**

Διάβασμα TID=1, 2:

Διάβασμα TID=3:

Πίνακας Δεικτών

Item	Pointer
A	-----
B	-----
C	-----
D	-----
E	-----

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II 34

**Αλγόριθμος FP-Growth**

**Κατασκευή FP-δέντρου**

Διάβασμα TID=1, 2:

Διάβασμα TID=3:

Πίνακας Δεικτών

Item	Pointer
A	-----
B	-----
C	-----
D	-----
E	-----

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II 35

**Αλγόριθμος FP-Growth**

**Κατασκευή FP-δέντρου**







Διάβασμα TID=1, 2:







Διάβασμα TID=3:







Πίνακας Δεικτών







Item	Pointer
A	-----
B	-----
C	-----
D	-----
E	-----







Εξόριη Διδούμενων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II 36































Επόμενη Διδούμενη: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II


79



Επόμενη Διδούμενη: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II


80



Επόμενη Διδούμενη: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II


81



Επόμενη Διδούμενη: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II


82



Επόμενη Διδούμενη: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II






83















Επόμενη Διδούμενη: Ακ. Έτος 2007-2008



ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II

84









**Αλγόριθμος FP-Growth**

**Παρατηρήσεις**

Παραδείγμα τεχνικής διαίρει-και-βασίλευς

Σε κάθε αναδρομικό βήμα, λύνεται και ένα υπο-πρόβλημα:

- Κατασκευάζεται το προθεματικό δέντρο
- Υπολογίζεται η νέα υποστήριξη για τους κόμβους του
- Περικόβονται οι κόμβοι με μικρή υποστήριξη

Επειδή τα υποπροβλήματα είναι ξένα μεταξύ τους, δεν δημιουργούνται τα ίδια συχνά στοιχείοσυνόλα δύο φορές

Ο υπολογισμός της υποστήριξης είναι αποδοτικός – γίνεται ταυτόχρονα με τη δημιουργία των συχνών στοιχείοσυνώλων

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008    ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II    105

**Αλγόριθμος FP-Growth**

**Παρατηρήσεις**

Η απόδοση του FP-Growth εξαρτάται από τον παράγοντα συμπίεσης του συνόλου των δεδομένων (*compaction factor*)

Αν τα τελικά δέντρα είναι «θαμνώδη» (bushy) τότε δε δουλεύει καλά, αυξάνεται ο αριθμός των υποπροβλημάτων (οι αναδρομικές κλήσεις)

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008    ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II    106

**Αποτίμηση Κανόνων Συσχέτισης**

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008    ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II    107

**Αποτίμηση Κανόνων Συσχέτισης**


Παράγουν πάρα πολλούς κανόνες που συχνά είναι μη ενδιαφέροντες ή πλεονάζοντες (territto)

Πλεονάζοντες αν  $\{A, B, C\} \rightarrow \{D\}$  και  $\{A, B\} \rightarrow \{D\}$  έχουν την ίδια υποστήριξη & εμπιστοσύνη

Μέτρα ενδιαφέροντος (interestingness) χρησιμοποιούνται για να ελαττώσουν (prune) ή να ιεραρχίσουν (rank) τα παραγόμενα πρότυπα

Χρησιμοποιούνται σε διάφορα στάδια της διαδικασίας ανάκτησης γνώσης

Εξόριη Διδούμενων: Ακ. Έτος 2007-2008    ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II    108



**Αποτίμηση Κανόνων Συσχέτισης**

Γενικά: αντικειμενικά (objective) και υποκειμενικά (subjective) μέτρα ενδιαφέροντος

Ας δούμε πρώτα μερικά αντικειμενικά κριτήρια:

Στην αρχική διατύπωση του προβλήματος της εξόρυξης κανόνων συσχέτισης χρησιμοποιήθηκαν ως μέτρα μόνο η υποστήριξη και η εμπιστοσύνη

Γενικά συνήθως βασίζονται σε μετρήσεις της συχνότητας εμφάνισης που δίνονται μέσω ενός πίνακα "contingency" (συνάφειας)

110

**Μέτρηση Ενδιαφέροντος**

Υπολογισμός του Μέτρου Ενδιαφέροντος (αντικειμενικά μέτρα)

Contingency table (πίνακας συνάφειας)

Μέτρηση συχνότητας εμφάνισης

	Y	$\bar{Y}$	
X	$f_{11}$	$f_{10}$	$f_{1+}$
$\bar{X}$	$f_{01}$	$f_{00}$	$f_{0+}$
	$f_{+1}$	$f_{+0}$	$ T $

$f_{11}$ : support of X and Y  
 $f_{10}$ : support of X and  $\bar{Y}$   
 $f_{01}$ : support of  $\bar{X}$  and Y  
 $f_{00}$ : support of  $\bar{X}$  and  $\bar{Y}$

$f_{11}$  πόσο συχνά εμφανίζεται το X και το Y (support count)  
 $f_{+1}$  μετρήτης υποστήριξης (support count) του Y  
Χρησιμοποιείται για τον ορισμό διαφόρων μέτρων  
Έστω ένας κανόνας,  $X \rightarrow Y$ , η πληροφορία που χρειάζεται για τον υπολογισμό της εμπιστοσύνης και υποστήριξης του κανόνα μπορεί να υπολογιστεί από τον contingency table

Επόμενη Δεδουλύνων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II 111

**Μέτρηση Ενδιαφέροντος**

Μειονεκτήματα της Εμπιστοσύνης

Μεγάλες τιμές υποστήριξης μπορεί να «διώξουν» ενδιαφέροντες κανόνες. Τι γίνεται με την εμπιστοσύνη;

	Coffee	$\bar{\text{Coffee}}$	
Tea	15	5	20
$\bar{\text{Tea}}$	75	5	80
	90	10	100

Ενδιαφέρομαστε για τη σχέση μεταξύ αυτών που πίνουν καφέ και αυτών που πίνουν τσάι  
Κανόνας Συσχέτισης: Tea  $\rightarrow$  Coffee

Εμπιστοσύνη =  $P(\text{Coffee} | \text{Tea}) = 0.75$   
Ενώ ο κανόνας έχει υψηλή εμπιστοσύνη, ο κανόνας είναι παραπλανητικός  
 $P(\text{Coffee} | \bar{\text{Tea}}) = 0.9375$   
 $P(\text{Coffee}) = 0.9$   
Αγνοεί την υποστήριξη του RHS

Επόμενη Δεδουλύνων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II 112

**Μέτρηση Ενδιαφέροντος**

Εξαιτίας τέτοιων προβλημάτων της υποστήριξης/εμπιστοσύνης,

Έχουν προταθεί πολλά αντικειμενικά μέτρα για τη μέτρηση του ενδιαφέροντος των κανόνων, που στηρίζονται κυρίως στην έννοια της στατιστικής ανεξαρτησίας

Ας δούμε ένα παράδειγμα

Επόμενη Δεδουλύνων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II 113

**Μέτρα βασισμένα στη Στατιστική**

**Στατιστική Ανεξαρτησία**

Πληθυσμός 1000 σπουδαστών

- 600 σπουδαστές ξέρουν κολύμπι (S)
- 700 σπουδαστές ξέρουν ποδήλατο (B)
- 420 σπουδαστές ξέρουν κολύμπι και ποδήλατο (S,B)
- $P(S \wedge B) = 420/1000 = 0.42$
- $P(S) \times P(B) = 0.6 \times 0.7 = 0.42$
- $P(S \wedge B) = P(S) \times P(B) \Rightarrow$  Στατιστική ανεξαρτησία
- $P(S \wedge B) > P(S) \times P(B) \Rightarrow$  Positively correlated (Θετική συσχέτιση)
- $P(S \wedge B) < P(S) \times P(B) \Rightarrow$  Negatively correlated (αρνητική συσχέτιση)

Επόμενη Δεδουλύνων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II 114

**Μέτρα βασισμένα στη Στατιστική**

Μέτρα που λαμβάνουν υπ' όψιν τους τη στατιστική εξάρτηση  
Για τη συσχέτιση:  $X \rightarrow Y$

$Lift = \frac{P(Y|X)}{P(Y)} = \frac{f_{11}}{f_{+1}}$

$Interest = \frac{P(X,Y)}{P(X)P(Y)} = \frac{Nf_{11}}{f_{++}f_{+1}}$

$PS = P(X,Y) - P(X)P(Y)$

$\phi-coefficient = \frac{P(X,Y) - P(X)P(Y)}{\sqrt{P(X)[1-P(X)]P(Y)[1-P(Y)]}} = \frac{f_{11}f_{00} - f_{01}f_{10}}{\sqrt{f_{1+}f_{+1}f_{0+}f_{+0}}}$



Εξόριη Δεδουλώνων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II 115

**Μέτρα βασισμένα στη Στατιστική**

Παράδειγμα: Lift/Interest

	Coffee	<u>Coffee</u>	
Tea	15	5	20
<u>Tea</u>	75	5	80
	90	10	100

Κανόνας συσχέτιση: Tea → Coffee

Εμπιστοσύνη:  $P(Coffee|Tea) = 0.75$   
αλλά  $P(Coffee) = 0.9$   
 $\Rightarrow Interest = 0.15/(0.9*0.2) = 0.8333 (< 1, άρα αρνητικά συσχετιζόμενα)$



Εξόριη Δεδουλώνων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II 116

**Μέτρα βασισμένα στη Στατιστική**

Μειονεκτήματα του Lift & Interest

	Y	$\bar{Y}$	
X	10	0	10
$\bar{X}$	0	90	90
	10	90	100

	Y	$\bar{Y}$	
X	90	0	90
$\bar{X}$	0	10	10
	90	10	100

$I = \frac{0.1}{(0.1)(0.1)} = 10$        $I = \frac{0.9}{(0.9)(0.9)} = 1.11$

Μεγαλύτερο αν και σπάνια εμφανίζονται μαζί

$c = 10/100 = 0.1$        $c = 90/100 = 0.9$   
 $s = 1$        $s = 1$



Εξόριη Δεδουλώνων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II 117

**Μέτρα βασισμένα στη Στατιστική**

$\phi$ -Coefficient

$\phi-coefficient = \frac{P(X,Y) - P(X)P(Y)}{\sqrt{P(X)[1-P(X)]P(Y)[1-P(Y)]}} = \frac{f_{11}f_{00} - f_{01}f_{10}}{\sqrt{f_{1+}f_{+1}f_{0+}f_{+0}}}$

Κανονικοποιημένη τιμή μεταξύ του -1 και 1  
Δυαδική εκδοχή του Pearson's coefficient  
0: στατιστική ανεξαρτησία  
-1: τέλεια αρνητική συσχέτιση  
1: τέλεια θετική συσχέτιση



Εξόριη Δεδουλώνων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II 118

**Μέτρα βασισμένα στη Στατιστική**

$\phi$ -Coefficient

	Y	$\bar{Y}$	
X	60	10	70
$\bar{X}$	10	20	30
	70	30	100

	Y	$\bar{Y}$	
X	20	10	30
$\bar{X}$	10	60	70
	30	70	100

$\phi = \frac{0.6 - 0.7 \times 0.7}{\sqrt{0.7 \times 0.3 \times 0.7 \times 0.3}} = 0.5238$        $\phi = \frac{0.2 - 0.3 \times 0.3}{\sqrt{0.7 \times 0.3 \times 0.7 \times 0.3}} = 0.5238$

$\phi$  Coefficient ιδιος και για τους δύο πίνακες



Εξόριη Δεδουλώνων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II 119

**Μέτρα βασισμένα στη Στατιστική**

$\phi$ -Coefficient

$\phi-coefficient = \frac{P(X,Y) - P(X)P(Y)}{\sqrt{P(X)[1-P(X)]P(Y)[1-P(Y)]}} = \frac{f_{11}f_{00} - f_{01}f_{10}}{\sqrt{f_{1+}f_{+1}f_{0+}f_{+0}}}$

- Είναι κατάλληλο για μη συμμετρικές (η απουσία και η παρουσία μετρούν το ίδιο)
- Λόγω κανονικοποίησης, αγνοεί το μέγεθος του δειγματος



Εξόριη Δεδουλώνων: Ακ. Έτος 2007-2008 ΚΑΝΟΝΕΣ ΣΥΣΧΕΤΙΣΗΣ II 120

**Μέτρα βασισμένα στη Στατιστική**

**IS-measure**

$$IS(X, Y) = \frac{s(X, Y)}{\sqrt{s(X)s(Y)}} = \frac{f_{11}}{\sqrt{f_{11} + f_{+1}}} = \sqrt{J(X, Y)s(x, y)}$$

▪ είναι το συνημίτονο αν θεωρηθούν δυαδικές μεταβλητές  
▪ γεωμετρικός μέσος της εμπιστοσύνης του  $X \rightarrow Y$  και  $Y \rightarrow X$

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008      ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II      121

#	Measure	Formula
1	$\phi$ -coefficient	$\frac{ P(A,B)-P(A)P(B) }{\sqrt{P(A)P(\bar{A})P(B)P(\bar{B})}}$
2	Goodman-Kruskal's ( $\lambda$ )	$\lambda = \frac{\sum_{i,j} P(A_iB_j)(1-P(A_i)(1-P(B_j)))}{\sum_{i,j} P(A_iB_j) + \sum_{i,j} \max_{k,l} P(A_kB_l) - \max_{i,j} P(A_i) - \max_{k,l} P(B_k)}$
3	Odd ratio ( $\alpha$ )	$\alpha = \frac{P(A,B)P(\bar{A},\bar{B})}{P(A,\bar{B})P(\bar{A},B)}$
4	Yule's $Q$	$Q = \frac{P(A,B)P(\bar{A},\bar{B}) - P(A,\bar{B})P(\bar{A},B)}{P(A,B)P(\bar{A},\bar{B}) + P(A,\bar{B})P(\bar{A},B)} = \frac{\alpha-1}{\alpha+1}$
5	Yule's $Y$	$Y = \frac{\sqrt{P(A,B)P(\bar{A},\bar{B})} - \sqrt{P(A,\bar{B})P(\bar{A},B)}}{\sqrt{P(A,B)P(\bar{A},\bar{B})} + \sqrt{P(A,\bar{B})P(\bar{A},B)}} = \frac{\sqrt{\alpha}-1}{\sqrt{\alpha}+1}$
6	Kappa ( $\kappa$ )	$\kappa = \frac{P(A,B)P(\bar{A},\bar{B}) - P(A,\bar{B})P(\bar{A},B)}{1 - P(A)P(\bar{B}) - P(\bar{A})P(\bar{B})}$
7	Mutual Information ( $M$ )	$M = \sum_{i,j} P(A_iB_j) \log \left( \frac{P(A_iB_j)}{P(A_i)P(B_j)} \right)$
8	J-Measure ( $J$ )	$J = \max \left( P(A,B) \log^2 \frac{P(A,B)}{P(A)P(B)}, P(\bar{A},\bar{B}) \log^2 \frac{P(\bar{A},\bar{B})}{P(\bar{A})P(\bar{B})} \right)$
9	Gini index ( $G$ )	$G = \max \left( P(A)[P(B A)^2 + P(\bar{B} A)^2] + P(\bar{A})[P(B \bar{A})^2 + P(\bar{B} \bar{A})^2] - P(B)^2 - P(\bar{B})^2, P(B)[P(A B)^2 + P(\bar{A} B)^2] + P(\bar{B})[P(A \bar{B})^2 + P(\bar{A} \bar{B})^2] - P(A)^2 - P(\bar{A})^2 \right)$
10	Support ( $s$ )	$s = P(A,B)$
11	Confidence ( $c$ )	$c = \max(P(A B), P(A \bar{B}))$
12	Laplace ( $L$ )	$L = \max \left( \frac{N(A)+1}{N(A)+2}, \frac{N(\bar{A})+1}{N(\bar{A})+2} \right)$
13	Conviction ( $V$ )	$V = \frac{P(A)P(\bar{B})}{P(\bar{A})P(B)}$
14	Interest ( $I$ )	$I = \frac{P(A B)P(\bar{A} \bar{B})}{P(\bar{A})P(\bar{B})}$
15	cosine ( $IS$ )	$IS = \frac{\sqrt{P(A)P(\bar{B})}}{\sqrt{P(\bar{A})P(\bar{B})}}$
16	Piatetsky-Shapiro's ( $PS$ )	$PS = P(A,B) - P(A)P(B)$
17	Certainty factor ( $F$ )	$F = \frac{P(A B)P(\bar{A} \bar{B})}{P(A B)P(\bar{A} \bar{B}) + P(\bar{A} B)P(\bar{A} \bar{B})}$
18	Added Value ( $AV$ )	$AV = P(B A) - P(B)$
19	Collective strength ( $S$ )	$S = \frac{P(A,B) + P(\bar{A},\bar{B})}{P(A) + P(\bar{A})} \times \frac{1 - P(A)P(\bar{B}) - P(\bar{A})P(\bar{B})}{1 - P(A,B) - P(\bar{A},\bar{B})}$
20	Jaccard ( $\zeta$ )	$\zeta = \frac{P(A) + P(B) - P(A,B)}{\sqrt{P(A)P(B)}} = \frac{P(A) + P(B) - P(A,B)}{\sqrt{P(A)P(B)P(\bar{A})P(\bar{B})}}$
21	Klosgen ( $K$ )	$K = \sqrt{P(A,B) \max(P(B A) - P(B), P(A \bar{B}) - P(A))}$

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008

**Αποτίμηση Κανόνων Συσχέτισης**

**Σύγκριση Μέτρων**

10 παραδείγματα contingency πινάκων:

Ιεράρχηση των πινάκων με βάση τα διάφορα μέτρα (1 ο πιο ενδιαφέρον, 10 ο λιγότερο ενδιαφέρον):

Example	f <sub>11</sub>	f <sub>10</sub>	f <sub>01</sub>	f <sub>00</sub>
E1	8123	83	424	1370
E2	8330	2	622	1046
E3	9481	94	127	298
E4	3954	3080	5	2961
E5	2886	1363	1320	4431
E6	1500	2000	500	6000
E7	4000	2000	1000	3000
E8	4000	2000	2000	2000
E9	1720	7121	5	1154
E10	61	2483	4	7452

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008      ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II      123

**Αποτίμηση Κανόνων Συσχέτισης**

**Ιδιότητες ενός Καλού Μέτρου**

Piatetsky-Shapiro:

3 γενικές ιδιότητες που πρέπει να ικανοποιεί ένα καλό μέτρο  $M$ :

- $M(A, B) = 0$  αν τα  $A$  και  $B$  είναι στατιστικά ανεξάρτητα
- $M(A, B)$  αυξάνεται μονότονα με το  $P(A, B)$  όταν τα  $P(A)$  και  $P(B)$  παραμένουν αμετάβλητα
- $M(A, B)$  μειώνεται μονότονα με το  $P(A)$  [ή το  $P(B)$ ] όταν τα  $P(A, B)$  και  $P(B)$  [ή  $P(A)$ ] παραμένουν αμετάβλητα

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008      ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II      124

**Ιδιότητες Μέτρων Αποτίμησης**

**Αλλαγή Διάταξης Μεταβλητών (variable permutation)**

<b>B</b>	<b>Ā</b>
<b>A</b>	p    q
<b>Ā</b>	r    s

$\Rightarrow$

<b>B</b>	<b>A</b>
<b>Ā</b>	p    r
<b>B</b>	q    s

$\text{Ίσχυει } M(A, B) = M(B, A)$

Γενικά συμμετρικά μέτρα για στοιχειοσύνολα και μη συμμετρικά για κανόνες

Συμμετρικά (symmetric) μέτρα:

- ♦ support (υποστήριξη), lift, collective strength, cosine, Jaccard, κλπ

Μη συμμετρικά (asymmetric) μέτρα:

- ♦ confidence (εμπιστοσύνη), conviction, Laplace, J-measure, κλπ

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008      ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II      125

**Ιδιότητες Μέτρων Αποτίμησης**

**Κλιμάκωση Γραμμής/Στήλης (Row/Column Scaling)**

Παράδειγμα Βαθμός-Φύλο (Mosteller, 1968):

	K <sub>3</sub>	K <sub>4</sub>	
K <sub>1</sub>	Male	Female	
High	2	3	5
Low	1	4	5
	3	7	10

	Male	Female	
High	4	30	34
Low	2	40	42
	6	70	76

2x      10x

Mosteller:  
Η συσχέτιση πρέπει να είναι ανεξάρτητη από το σχετικό αριθμό αγοριών-κοριτσιών στο δύναμα

Invariant under the row/column scaling operation αν  $M(T) = M(T')$  όπου  $T'$  ο πίνακας contingency με μετρητές συχνότητας  $[f_{11}, f_{10}, f_{01}, f_{00}]$  και  $T'$  ο πίνακας contingency με μετρητές συχνότητας  $[K_1K_3f_{11}, K_2K_3f_{10}; K_1K_4f_{01}; K_2K_4f_{00}]$  όπου  $K_1, K_2, K_3, K_4$  θετικές σταθερές

Εξόριη Διδούμενη: Ακ. Έτος 2007-2008      ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II      126

### Ιδιότητες Μέτρων Αποτίμησης

**Αντιστροφή (Inversion Operation)**

Δοσοληψία 1 → (a) (b) (c)

Δοσοληψία N → (d) (e) (f)

Invariant under the inversion operation αν η τιμή της παραμένει η ίδια αν ανταλλάσουμε τις τιμές  $f_{11}$  και  $f_{00}$  και τις τιμές  $f_{10}$  και  $f_{01}$ .  
Χρήσιμο για συμμετρικές μεταβλητές

Εξόρια Διδούμενα: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II

127

### Ιδιότητες Μέτρων Αποτίμησης

**Null Addition (προσθήκη μη σχετιζόμενων στοιχείων)**

Δεν επηρεάζονται από την αύξηση του  $f_{00}$  όταν οι άλλες τιμές παραμένουν αμετάβλητες

**Invariant measures:**  
◆ support, cosine, Jaccard, κλπ

**Non-invariant measures:**  
◆ correlation, Gini, mutual information, odds ratio, κλπ

Εξόρια Διδούμενα: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II

128

### Αποτίμηση Κανόνων Συσχέτισης

**Παράδοξο του Simpson**

		Buy HDTV		Buy Exercise Machine	
		Yes	No		
Buy HDTV	Yes	99	81	180	
	No	54	66	120	
	153	147	300		

$c((HTVS=Yes) \rightarrow (EM=Yes)) = 99/180 = 55\%$   
 $c((HTVS=No) \rightarrow (EM=Yes)) = 54/120 = 45\%$

$c((HTVS=Yes) \rightarrow (EM=Yes)) = 98/170 = 57.7\%$   
 $c((HTVS=No) \rightarrow (EM=Yes)) = 50/86 = 58.1\%$

**Working adults**

		Buy HDTV		Buy Exercise Machine	
		Yes	No		
Buy HDTV	Yes	98	72	170	
	No	50	36	86	
	148	108	256		

$c((HTVS=Yes) \rightarrow (EM=Yes)) = 98/170 = 57.7\%$   
 $c((HTVS=No) \rightarrow (EM=Yes)) = 50/86 = 58.1\%$

Εξόρια Διδούμενα: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II

129

### Αποτίμηση Κανόνων Συσχέτισης

**Παράδοξο του Simpson**

		Buy HDTV		Buy Exercise Machine	
		Yes	No		
Buy HDTV	Yes	99 <b>a+p</b>	81	180 <b>b+q</b>	
	No	54 <b>c+r</b>	66	120 <b>d+s</b>	
	153	147	300		

$c((HTVS=Yes) \rightarrow (EM=Yes)) = 99/180 = 55\%$   
 $c((HTVS=No) \rightarrow (EM=Yes)) = 54/120 = 45\%$

$a/b < c/d$   
 $p/q + r/s \text{ δεν συνεπάγεται ότι}$   
 $(a+p)/(b+q) < (c+r)/(d+s)!$

**Working adults**

		Buy HDTV		Buy Exercise Machine	
		Yes	No		
Buy HDTV	Yes	98 <b>p</b>	72	170 <b>q</b>	
	No	50 <b>r</b>	36	86 <b>s</b>	
	148	108	256		

$c((HTVS=Yes) \rightarrow (EM=Yes)) = 98/170 = 57.7\%$   
 $c((HTVS=No) \rightarrow (EM=Yes)) = 50/86 = 58.1\%$

Είναι σημαντικό πως θα γίνει διαχωρισμός (stratification) των δεδομένων

Εξόρια Διδούμενα: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II

130

### Υποκειμενικά Μέτρα Ενδιαφέροντος

- Αντικειμενικά Μέτρα:**
  - Ιεραρχούν τα αποτελέσματα με βάση στατιστικά στοιχεία που υπολογίζονται από τα δεδομένα
  - π.χ., 21 μετρήσεις συσχέτισης (support, confidence, Laplace, Gini, mutual information, Jaccard, etc.).
- Υποκειμενικά Μέτρα:**
  - Ιεράρχηση των προτύπων με βάση την ερμηνεία του χρήστη
    - Ένα πρότυπο είναι υποκειμενικά ενδιαφέροντον αν είναι σε αντίθεση με αυτό που αναμένει ο χρήστης (Silberschatz & Tuzhilin)
    - Ένα πρότυπο είναι υποκειμενικά ενδιαφέροντον αν μπορεί να χρησιμοποιηθεί (Silberschatz & Tuzhilin)

Εξόρια Διδούμενα: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II

131

### Υποκειμενικά Μέτρα Ενδιαφέροντος

**Interestingness (ενδιαφέρον) via Unexpectedness (μη αναμονή)**

+ Pattern expected to be frequent  
- Pattern expected to be infrequent  
□ Pattern found to be frequent  
○ Pattern found to be infrequent

+ ○ Expected Patterns  
- □ Unexpected Patterns

Χρειάζεται να μοντελοποιήσουμε τι αναμένει ο χρήστης (domain knowledge)  
Χρειάζεται να συνδυάσουμε το τι αναμένεται από τους χρήστες με το τι δίνουν τα δεδομένα (δηλαδή τα πρότυπα που παίρνουμε - evidence)

Εξόρια Διδούμενα: Ακ. Έτος 2007-2008

ΚΑΝΟΝΕΣ ΣΥΧΕΤΙΣΗΣ II

132

