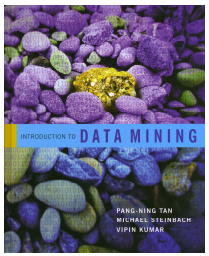
Ανάλυση Συσχέτισης Ι

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



Εισαγωγή



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

συναλλαγή

- Προώθηση προϊόντων
- Τοποθέτηση προϊόντων στα ράφια
- Διαχείριση αποθεμάτων

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

Παραδείγματα κανόνων συσχέτισης

{Diaper} → {Beer},
{Milk, Bread} → {Eggs, Coke},
{Beer, Bread} → {Milk}

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 διάταξης)



Δυαδική αναπαράσταση

Γραμμές: συναλλαγές

Στήλες: Στοιχεία

1 αν το στοιχείο εμφανίζεται στη σχετική δοσοληψία

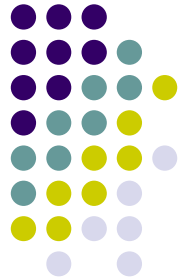
Μη συμμετρική δυαδική μεταβλητή (1 πιο σημαντικό από το 0)

- *Ένας περιορισμός είναι ότι χάνουμε πληροφορία για τις ποσότητες*

Παράδειγμα

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

Ορισμοί



- $I = \{i_1, i_2, .., i_k\}$ ένα σύνολο από διακριτά **στοιχεία (items)**

Παράδειγμα: {Bread, Milk, Diapers, Beer, Eggs, Coke}

- **Στοιχειοσύνολο (Itemset):** Ένα υποσύνολο του *I*

Παράδειγμα: {Milk, Bread, Diaper}

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

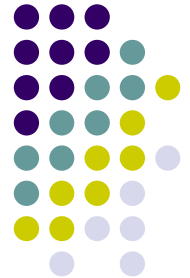
- $T = \{t_1, t_2, .., t_N\}$ ένα σύνολο από **συναλλαγές**, όπου κάθε t_i είναι ένα στοιχειοσύνολο

  Πλάτος (width) συναλλαγής: αριθμός στοιχείων

  t_i **περιέχει** ένα στοιχειοσύνολο X, αν το X είναι υποσύνολο της t_i

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

Ορισμοί



- **support count (σ) ενός στοιχειοσυνόλου**

Η συχνότητα εμφάνισης του στοιχειοσυνόλου

Παράδειγμα: σ({Milk, Bread, Diaper}) = 2

$\sigma(X) = |\{ t_i \mid X \subseteq t_i, t_i \in T\}|$

- **Υποστήριξη (Support (s)) ενός στοιχειοσυνόλου**

Το ποσοστό των συναλλαγών που περιέχουν ένα στοιχειοσύνολο

Παράδειγμα: s({Milk, Bread, Diaper}) = 2/5

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

- **Frequent Itemset – Συχνό Στοιχειοσύνολο**

Ένα στοιχειοσύνολο του οποίου η υποστήριξη είναι μεγαλύτερη ή ίση από κάποια τιμή κατωφλίου *minsup*

Ορισμοί

Κανόνας Συσχέτισης (Association Rule)

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

Παράδειγμα: {Milk, Diaper} → {Beer}

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

Υποστήριξη Κανόνα Support (s)

Το ποσοστό των συναλλαγών που περιέχουν και το X και το Y ($X \cup Y$)
$\sigma(X \cup Y)/|T|$ ($|T|$ ο αριθμός των δοσοληψιών)

Εμπιστοσύνη - Confidence (c)

Πόσες από τις συναλλαγές (ποσοστό) που περιέχουν το X περιέχουν και το Y
$\sigma(X \cup Y)/\sigma(X)$

$$s = \frac{\sigma\{\text{Milk, Diaper, Beer}\}}{|T|} = \frac{2}{5} = 0.4 \qquad \{\text{Milk, Diaper}\} \rightarrow \text{Beer}$$

$$c = \frac{\sigma\{\text{Milk, Diaper, Beer}\}}{\sigma\{\text{Milk, Diaper}\}} = \frac{2}{3} = 0.67$$

Εξόρυξη Κανόνων Συσχέτισης



Παρατηρήσεις

- $s(X \rightarrow Y) = s(X \cup Y) = \sigma(X \cup Y)/N$

Ένας κανόνας με μικρή υποστήριξη μπορεί να εμφανίζεται τυχαία

Λιγότερη *σημασία/χρησιμότητα*, γιατί αφορά μικρό αριθμό από συναλλαγές

Το κατώφλι minsup εξαιρεί κανόνες που δεν έχουν ενδιαφέρον

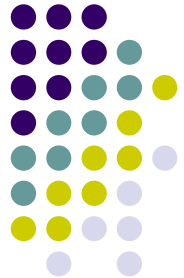
- $c(X \rightarrow Y) = \sigma(X \cup Y)/\sigma(X)$

$c(X \rightarrow Y) = P(Y|X)$ δεσμευμένη πιθανότητα να εμφανίζεται το Y όταν εμφανίζεται το X

Εμπιστοσύνη μετρά την *αξιοπιστία*, βεβαιότητα της εξάρτησης

Όσο μεγαλύτερη εμπιστοσύνη τόσο μεγαλύτερη η πιθανότητα εμφάνισης του Y σε κανόνες που περιέχουν το X

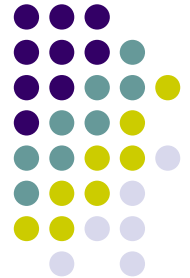
Εξόρυξη Κανόνων Συσχέτισης



Εύρεση Κανόνων Συσχέτισης

Είσοδος: Ένα σύνολο από συναλλαγές T
Έξοδος: Όλοι οι κανόνες με
support ≥ *minsup*
confidence ≥ *minconf*

Εξόρυξη Κανόνων Συσχέτισης

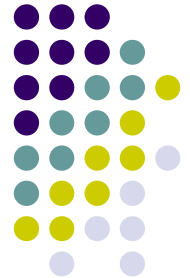


Brute-force προσέγγιση:

- Παρήγαγε όλους τους πιθανούς κανόνες συσχέτισης
- Υπολόγισε την υποστήριξη και την εμπιστοσύνη για τον καθένα
- Prune τους κανόνες που δεν ικανοποιούν το κατώφλι εμπιστοσύνης και υποστήριξης

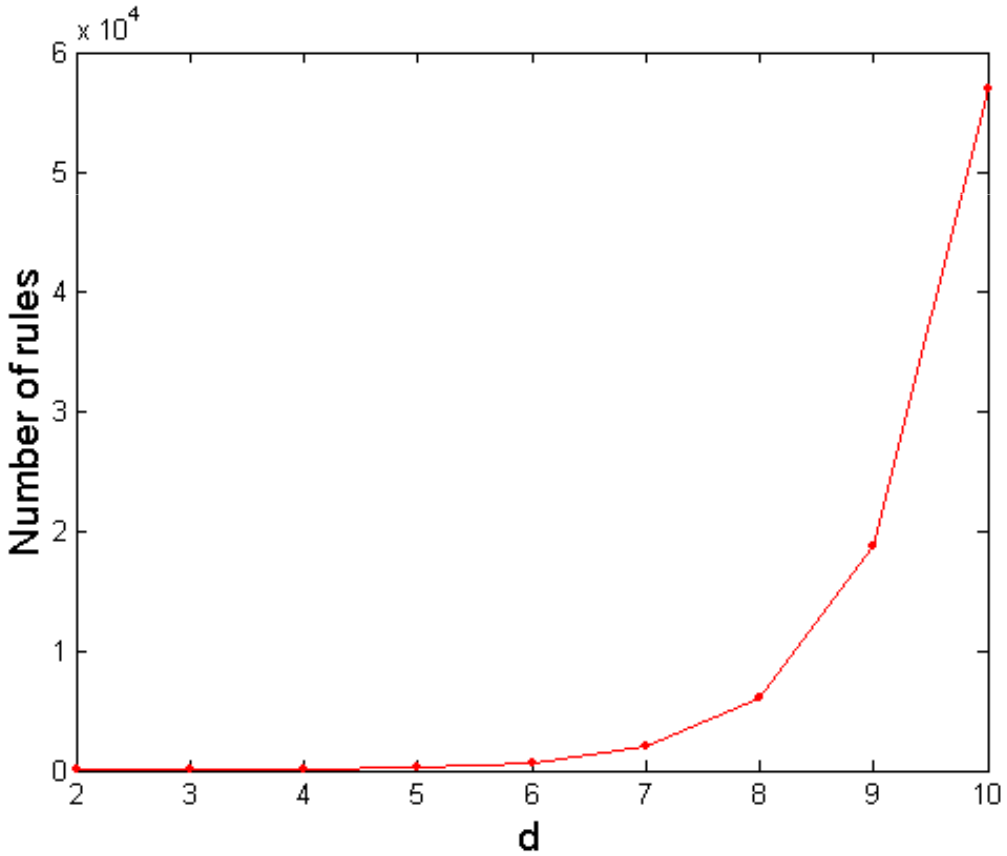
$\Rightarrow$ Υπολογιστικά ακριβό!

Εύρεση Συχνών Στοιχειοσυνόλων



Υπολογιστική Πολυπλοκότητα

- Έστω d διαφορετικά στοιχεία:
  - Συνολικός αριθμός στοιχειοσυνόλων = 2^d (δυναμοσύνολο)
  - Συνολικός αριθμός πιθανών κανόνων συσχέτισης:



$$R = \sum_{k=1}^{d-1}\left[\binom{d}{k} \times \sum_{j=1}^{d-k}\binom{d-k}{j}\right]$$

$$= 3^d - 2^{d+1} + 1$$

If d = 6, R = 602 rules

Εξόρυξη Κανόνων Συσχέτισης



Μια σημαντική παρατήρηση

Η υποστήριξη ενός κανόνα $X \rightarrow Y$ εξαρτάται μόνο από την υποστήριξη του $X \cup Y$
Άρα κανόνες που ξεκινούν από το ίδιο στοιχειοσύνολο έχουν την ίδια υποστήριξη (αλλά πιθανών διαφορετική εμπιστοσύνη)

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

Πιθανοί κανόνες με τα στοιχεία Milk, Diaper και Beer (στοιχειοσύνολο {Milk, Diaper, Beer})

{Milk,Diaper} → {Beer} (s=0.4, c=0.67)
{Milk,Beer} → {Diaper} (s=0.4, c=1.0)
{Diaper,Beer} → {Milk} (s=0.4, c=0.67)
{Beer} → {Milk,Diaper} (s=0.4, c=0.67)
{Diaper} → {Milk,Beer} (s=0.4, c=0.5)
{Milk} → {Diaper,Beer} (s=0.4, c=0.5)

Αν είχαμε minsup = 0.5, θα αποκλείαμε και τους έξη κανόνες

Άρα μπορούμε να εξετάσουμε τους περιορισμούς για την υποστήριξη και την εμπιστοσύνη ξεχωριστά

Εξόρυξη Κανόνων Συσχέτισης

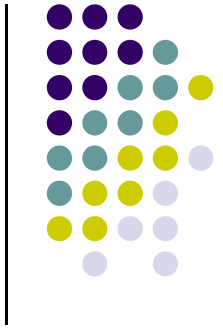


Χωρισμός του προβλήματος σε δύο υπο-προβλήματα:

- Εύρεση όλων των συχνών στοιχειοσυνόλων (Frequent Itemset Generation)
  Εύρεση όλων των στοιχειοσυνόλων με υποστήριξη $\geq$ minsup

- Δημιουργία Κανόνων (Rule Generation)
  Για κάθε στοιχειοσύνολο, δημιούργησε κανόνες με μεγάλη υποστήριξη, όπου κάθε κανόνες είναι μια δυαδική διαμέριση του συχνού στοιχειοσυνόλου

Η δημιουργία των συχνών στοιχειοσυνόλων είναι επίσης υπολογιστικά ακριβή

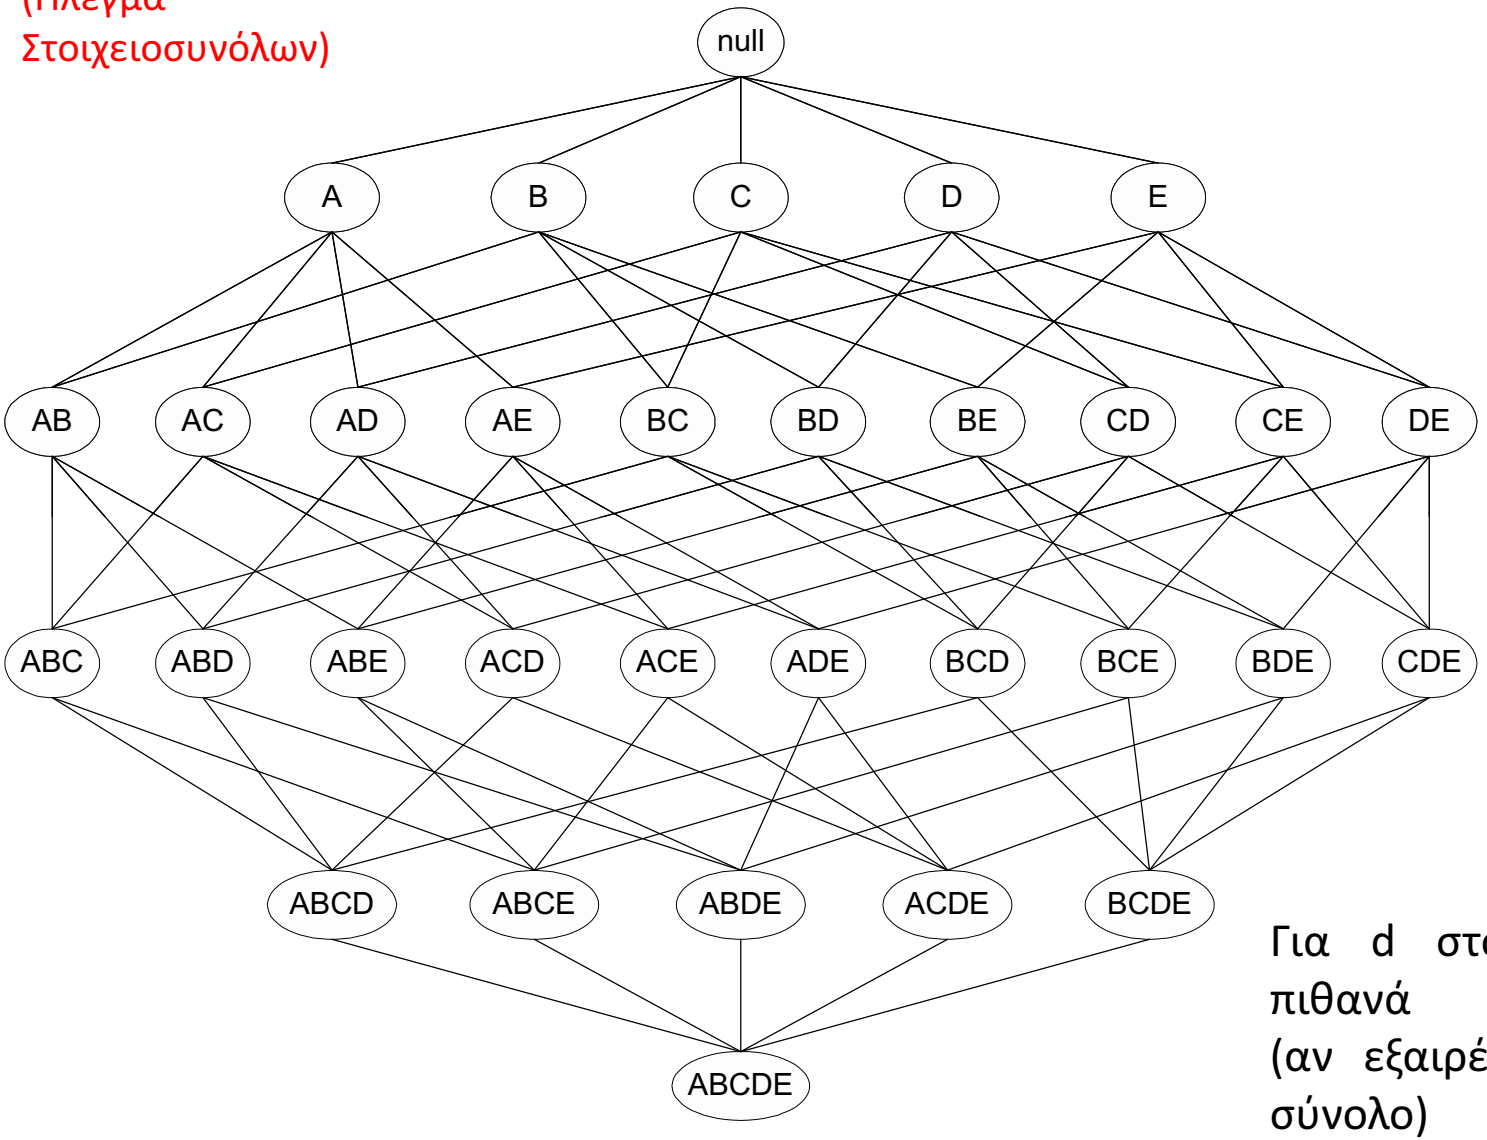


Εύρεση Συχνών Στοιχειοσυνόλων

Εύρεση Συχνών Στοιχειοσυνόλων

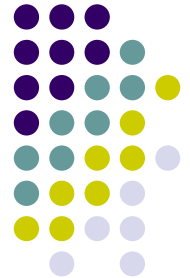
Itemset (Πλέγμα Στοιχειοσυνόλων)

Lattice



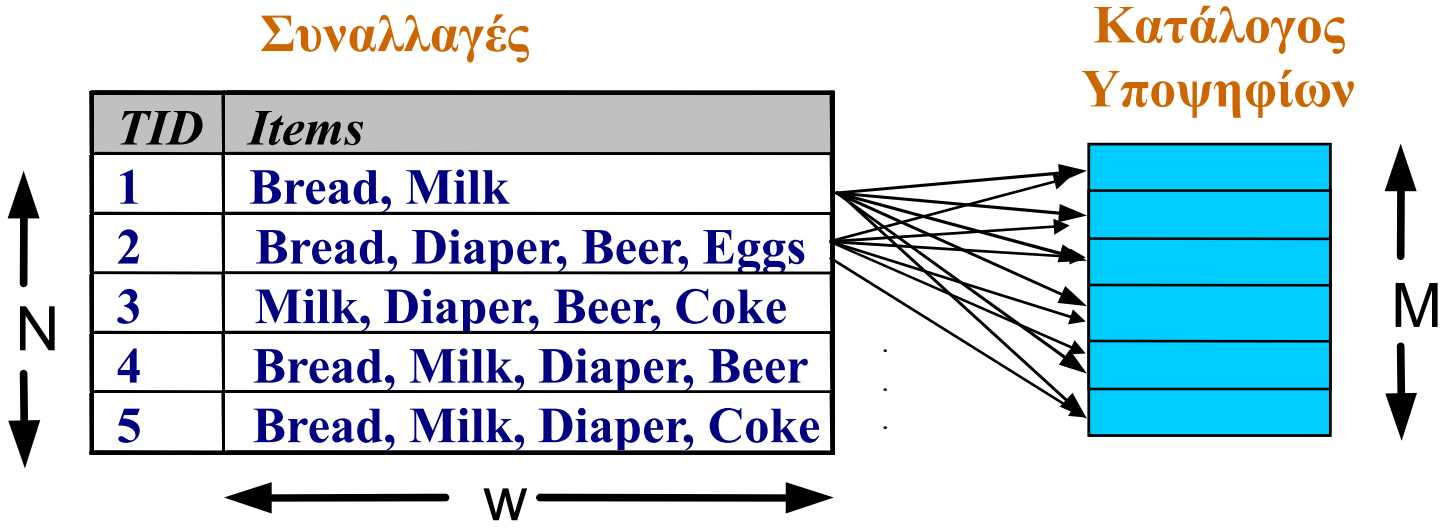
Για d στοιχεία, 2^d - 1 πιθανά στοιχειοσύνολα (αν εξαιρέσουμε το κενό σύνολο)

Εύρεση Συχνών Στοιχειοσυνόλων



Brute-force approach:

- Κάθε στοιχειοσύνολο στο πλέγμα είναι ένα υποψήφιο συχνό στοιχειοσύνολο
- Υπολόγισε την υποστήριξη κάθε υποψήφιου στοιχειοσυνόλου διατρέχοντας (scanning) τη βάση δεδομένων με τις συναλλαγές



Ταίριαξε κάθε συναλλαγή με κάθε υποψήφιο
Πολυπλοκότητα ~ O(NMw) => Μεγάλη γιατί M = 2^d !!!

N: αριθμός συναλλαγών

w: μέγιστο πλάτος δοσοληψίας

Εύρεση Συχνών Στοιχειοσυνόλων



Διαφορετικές Στρατηγικές

Ελάττωση του αριθμού των υποψηφίων στοιχειοσυνόλων (M)

Πλήρης αναζήτηση: $M=2^d$

Χρησιμοποίησε κάποια τεχνική pruning (κλαδέματος - ελάττωσης) για να ελαττωθεί το M (πχ *apriori*)

Ελάττωση του αριθμού των συναλλαγών (N)

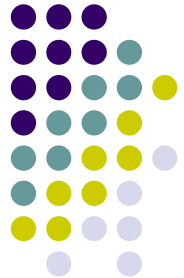
Ελάττωση του μεγέθους του N καθώς το μέγεθος του στοιχειοσυνόλου αυξάνεται (κάποιοι αλγόριθμοι βασισμένοι σε κατακερματισμό)

Ελάττωση του αριθμού των συγκρίσεων (NM)

Στόχος να αποφύγουμε να ταιριάξουμε κάθε υποψήφιο στοιχειοσύνολο με κάθε συναλλαγή

Χρήση *αποδοτικών δομών δεδομένων* για την αποθήκευση των υποψηφίων στοιχειοσυνόλων ή των συναλλαγών

Αρχή apriori



Ελάττωση συχνών στοιχειοσυνόλων

Αρχή Apriori

Αν ένα στοιχειοσύνολο είναι συχνό, τότε όλα τα υποσύνολα του είναι συχνά

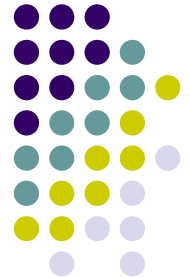
Αντιθετοαντιστροφή: Αν ένα στοιχειοσύνολο δεν είναι συχνό, όλα τα υπερσύνολα του δεν είναι συχνά

Η αρχή Apriori ισχύει λόγω της παρακάτω ιδιότητας της υποστήριξης:

$$\forall X, Y : (X \subseteq Y) \Rightarrow s(X) \geq s(Y)$$

Η υποστήριξη ενός στοιχεισύνολου είναι *μικρότερη* ή *ίση* της υποστήριξης οποιουδήποτε υποσυνόλου του

Αρχή apriori



Αντι-μονότονη (anti-monotone) ιδιότητα της υποστήριξης

$$\forall X, Y : (X \subseteq Y) \Rightarrow s(X) \geq s(Y)$$

s: downwards closed

Μονότονη ιδιότητα ή upwards closed

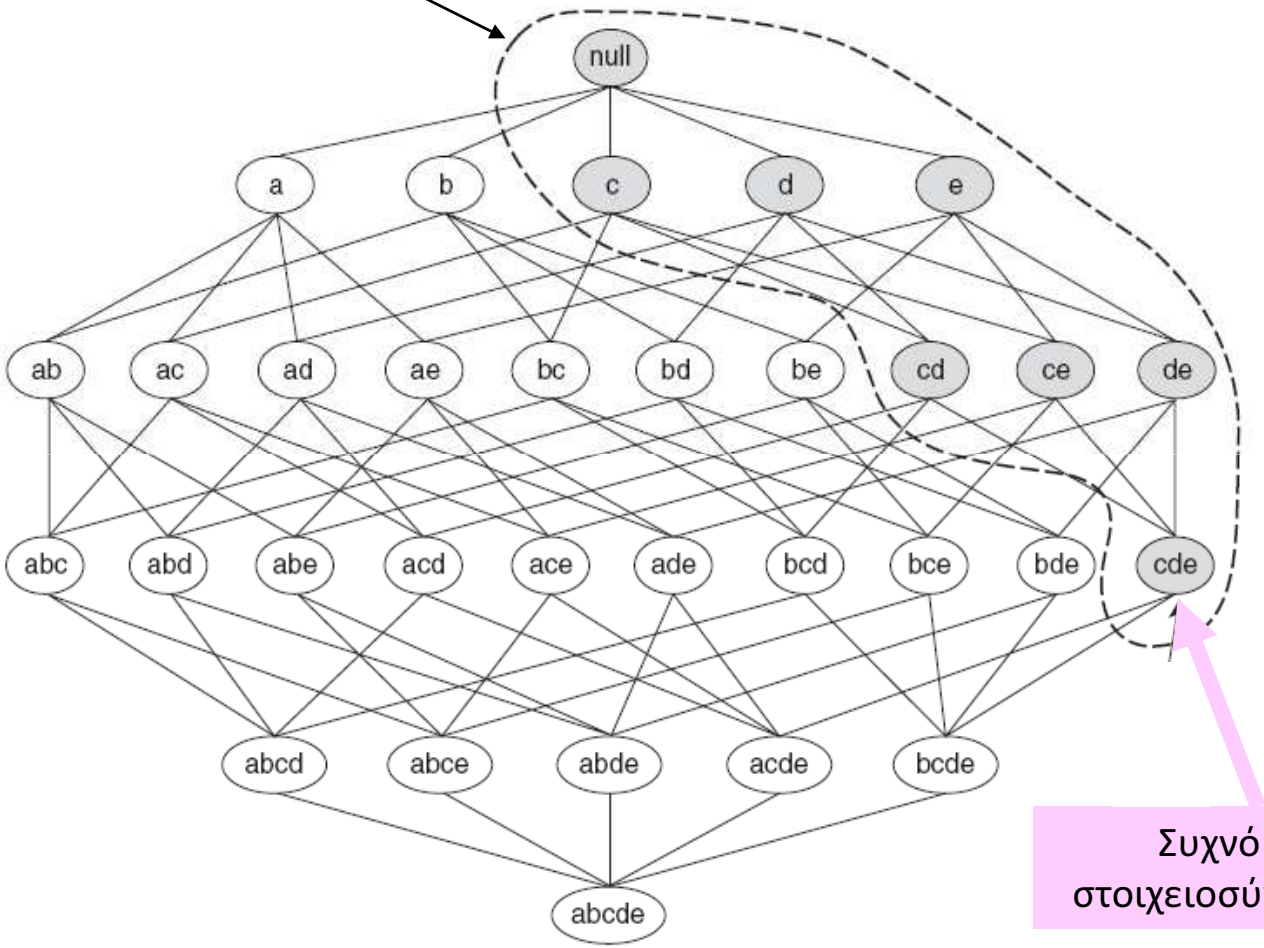
$$\forall X, Y : (X \subseteq Y) \Rightarrow f(X) \leq f(Y)$$

Σημείωση: τι ισχύει για τα ιδιότητα του κλειδιού στις βάσεις δεδομένων;

Αρχή apriori



Όλα τα υποσύνολα του συχνά

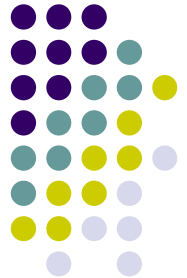


Κλειστό προς τα κάτω

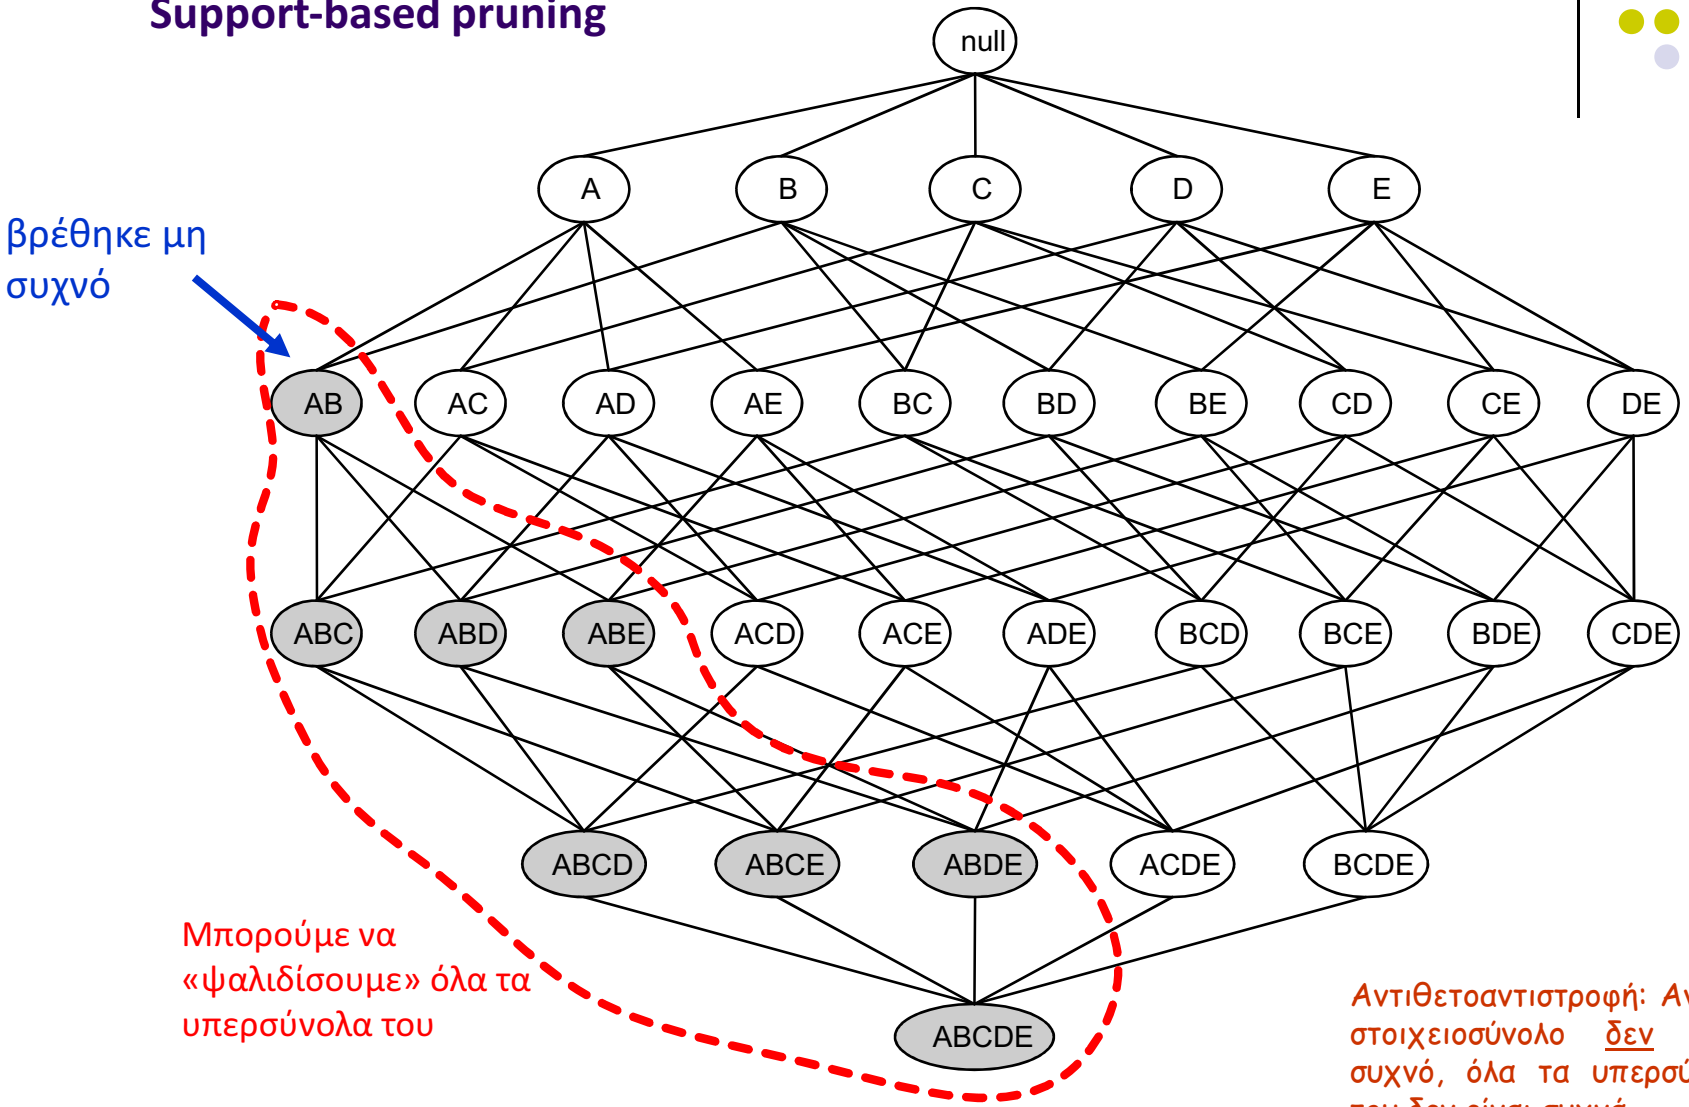
Συχνό στοιχειοσύνολο

Αν το {c, d, e} είναι συχνό, όλα τα υποσύνολα του είναι συχνά

Στρατηγική apriori

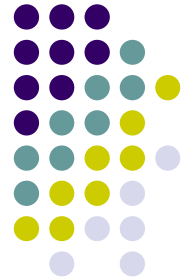


Support-based pruning



Αντιθετοαντιστροφή: Αν ένα στοιχειοσύνολο δεν είναι συχνό, όλα τα υπερσύνολα του δεν είναι συχνά

Στρατηγική apriori



Παράδειγμα

Minimum Support = 3

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

Στοιχεία (1-στοιχειοσύνολα)

Item	Count
Bread	4
Coke	2
Milk	4
Beer	3
Diaper	4
Eggs	1

Ζεύγη (2-στοιχειοσύνολα)

Itemset	Count
{Bread,Milk}	3
{Bread,Beer}	2
{Bread,Diaper}	3
{Milk,Beer}	2
{Milk,Diaper}	3
{Beer,Diaper}	3

(Δε χρειάζεται να παραχθούν υποψήφιοι με Coke
ή Eggs)

Αν όλα τα δυνατά στοιχειοσύνολα:

$$\binom{6}{1}+\binom{6}{2}+\binom{6}{3}=6+15+20=41$$

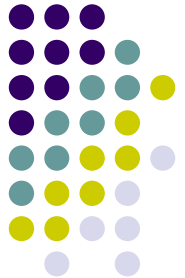
Μετά την ελάττωση με βάση την υποστήριξη:

$$\binom{6}{1}+\binom{4}{2}+1=6+6+1=13$$

Τριάδες (3-στοιχειοσύνολα)

Itemset	Count
{Bread,Milk,Diaper}	3

Στρατηγική apriori



Γενικός Αλγόριθμος

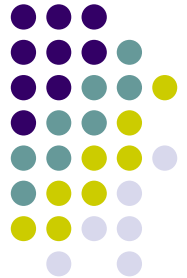
$k = 1$

Δημιούργησε όλα τα συχνά στοιχειοσύνολα μήκους 1

Repeat until δεν δημιουργούνται νέα στοιχειοσύνολα

- Δημιούργησε υποψήφια στοιχειοσύνολα μήκους (k+1) από τα συχνά στοιχειοσύνολα μήκους k
- Prune τα υποψήφια στοιχειοσύνολα που περιέχουν υποσύνολα μήκους k που δεν είναι συχνά
- Υπολόγισε την υποστήριξη (support) κάθε υποψηφίου στοιχειοσύνολου διαβάζοντας από τη βάση δεδομένων
- Σβήσε τα υποψήφια στοιχειοσύνολα που δεν είναι συχνά, αφήνοντας μόνο τα συχνά

Στρατηγική apriori



Γενικός Αλγόριθμος

- Διατρέχει το πλέγμα ανά επίπεδο
- Generate-and-Test στρατηγική

  Σε κάθε βήμα *k*:

  Δημιουργία υποψήφιων *k*-στοιχειοσυνόλων με βάση τα συχνά *k*-1 στοιχειοσύνολα

  Υπολογισμός της υποστήριξής τους και pruning όσων έχουν μικρή υποστήριξη

- k_{max} περάσματα, όπου k_{max} μέγεθος (αριθμός στοιχείων) του μεγαλύτερου στοιχειοσυνόλου

Στρατηγική apriori: Δημιουργία Στοιχειοσυνόλων



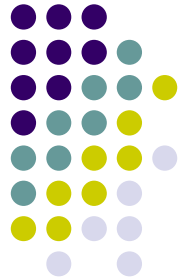
Σε κάθε βήμα *k*:

Δημιουργία υποψήφιων *k*-στοιχειοσυνόλων με βάση τα συχνά *k*-1 στοιχειοσύνολα

- **Όλα** τα υποσύνολα του πρέπει να είναι συχνά
- Δεν πρέπει να δημιουργούμε ένα στοιχειοσύνολο πολλές φορές
- complete – δεν πρέπει να χάνουμε κάποιο συχνό

Πως;

Στρατηγική apriori: Δημιουργία Στοιχειοσυνόλων

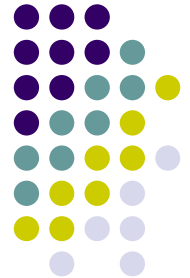


Θα δούμε δύο τρόπους:

- Μέθοδος F_{k-1} x F_1
- Μέθοδος F_{k-1} x F_{k-1}

Για να αποφύγουμε τη δημιουργία του ίδιου στοιχειοσυνόλου, κρατάμε κάθε στοιχειοσύνολο (λεξικογραφικά) ταξινομημένο

Και στις δύο περιπτώσεις, έλεγχος αν τα παραγόμενα στοιχειοσύνολα είναι συχνά με βάση τα υποσύνολά τους.



Μέθοδος F_{k-1} x F_1

Επέκταση κάθε συχνού (k-1) στοιχειοσυνόλου με άλλα συχνά στοιχεία

Itemset	Count
{Bread,Milk}	3
{Beer,Bread}	2
{Bread,Diaper}	3
{Beer, Milk}	2
{Diaper,Milk}	3
{Beer,Diaper}	3

Item	Count
Bread	4
Coke	2
Milk	4
Beer	3
Diaper	4
Eggs	1

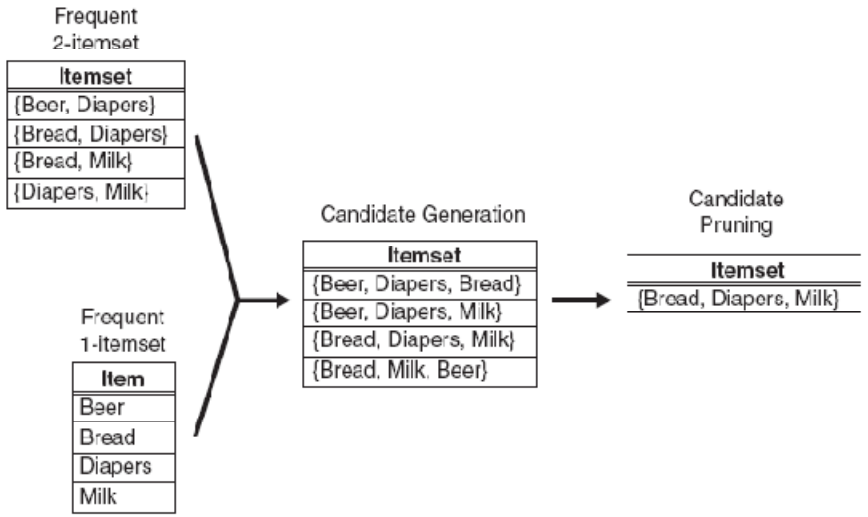


Figure 6.7. Generating and pruning candidate k-itemsets by merging a frequent $(k-1)$-itemset with a frequent item. Note that some of the candidates are unnecessary because their subsets are infrequent.

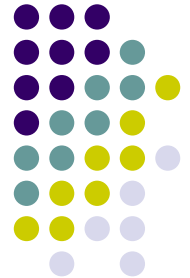
Κάθε στοιχειοσύνολο (λεξικογραφικά) ταξινομημένο – κάθε (k-1) συχνό στοιχεισύνολο επεκτείνεται με συχνά στοιχεία που είναι λεξικογραφικά μεγαλύτερα του

$O(|F_{k-1}| \times |F_1|)$

{Beer, Diaper, Milk}

Δημιουργεί και κάποια *περιττά*, πχ το παραπάνω δεν είναι συχνό, γιατί το {Beer, Milk} δεν είναι συχνό

Στρατηγική apriori: Δημιουργία Στοιχειοσυνόλων



F_{k-1} x F_1

Επέκταση κάθε συχνού (*k*-1) στοιχειοσυνόλου με άλλα συχνά στοιχεία

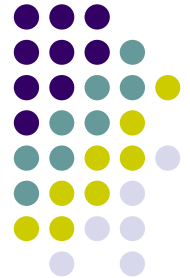
Διάφοροι ευριστικοί για να μειωθεί ο αριθμός των στοιχειοσυνόλων που δημιουργούνται και δεν είναι συχνά

Πχ έστω το $\{i_1, i_2, i_3, i_4\}$ για να είναι συχνό πρέπει όλα τα 3-στοιχειοσύνολα που είναι υποσύνολα του να είναι συχνά,

Πχ θα πρέπει να υπάρχουν τουλάχιστον 3 3-στοιχειοσύνολα που περιέχουν πχ το i_4 ($\{i_1, i_2, i_4\}$, $\{i_1, i_3, i_4\}$ και $\{i_2, i_3, i_4\}$

Γενικά, κάθε στοιχείο ενός *k*-στοιχειοσυνόλου θα πρέπει να περιέχεται σε τουλάχιστον *k*-1 από το συχνά (*k*-1)-στοιχειοσύνολα

Παράδειγμα Beer στο 3-στοιχειοσύνολο σε τουλάχιστον 2 από τα συχνά 2-στοιχειοσύνολα



Μέθοδος F_{k-1} x F_{k-1}

Συγχώνευση δύο συχνών (k-1) στοιχειοσυνόλου αν τα πρώτα k-2 στοιχεία τους είναι τα ίδια

Itemset	Count
{Bread,Milk}	3
{Beer,Bread}	2
{Bread,Diaper}	3
{Beer, Milk}	2
{Diaper,Milk}	3
{Beer,Diaper}	3

Itemset	Count
{Bread,Milk}	3
{Beer,Bread}	2
{Bread,Diaper}	3
{Beer, Milk}	2
{Diaper,Milk}	3
{Beer,Diaper}	3

Συγχώνευση δύο συχνών (*k*-1)-στοιχειοσυνόλων αλλά πρέπει *επιπρόσθετα να ελέγξουμε* ότι και τα υπόλοιπα *k*-2 υποσύνολα είναι συχνά

Στρατηγική apriori



Γενικός Αλγόριθμος

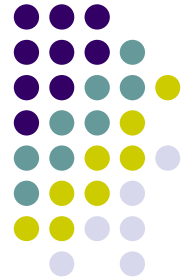
k = 1

Δημιούργησε όλα τα συχνά στοιχειοσύνολα μήκους 1

Repeat until δεν δημιουργούνται νέα στοιχειοσύνολα

- Δημιούργησε υποψήφια στοιχειοσύνολα μήκους (k+1) από τα συχνά στοιχειοσύνολα μήκους k
- Prune τα υποψήφια στοιχειοσύνολα που περιέχουν υποσύνολα μήκους k που δεν είναι συχνά
- Υπολόγισε την υποστήριξη (support) κάθε υποψηφίου στοιχειοσύνολου διαβάζοντας από τη βάση δεδομένων
- Σβήσε τα υποψήφια στοιχειοσύνολα που δεν είναι συχνά, αφήνοντας μόνο τα συχνά

Στρατηγική apriori: Υπολογισμός Υποστήριξης



Υπολογισμός υποστήριξης: για κάθε νέο υποψήφιο συχνό στοιχειοσύνολο, πρέπει να υπολογίσουμε την υποστήριξή του

Brute Force:

- Διαπέρασε τη βάση των συναλλαγών για τον υπολογισμό της υποστήριξης κάθε υποψήφιου στοιχειοσυνόλου

Αν σε ένα βήμα έχουμε *m* συχνά στοιχειοσύνολα, τότε διαπέραση της βάσης *m* φορές

For each item

for i = 1 to N

if t_i περιέχει το item

c(item)++

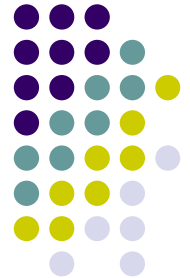
Πχ έστω
item = {Beer, Bread}

Συναλλαγές

N

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

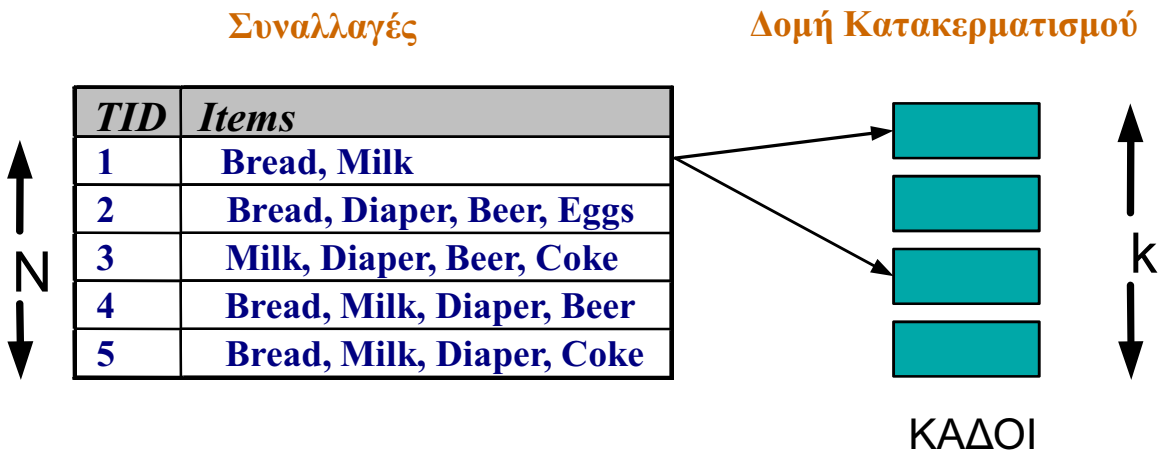
Στρατηγική apriori: Υπολογισμός Υποστήριξης



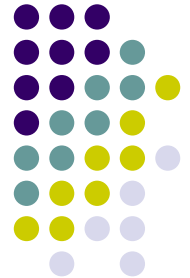
Ελάττωση του αριθμού των συγκρίσεων

Για να *μειώσουμε* τον αριθμό των συγκρίσεων, αποθήκευση των υποψηφίων στοιχειοσυνόλων σε μια δομή κατακερματισμού

- Αντί να ταιριάζουμε κάθε συναλλαγή με κάθε υποψήφιο στοιχειοσύνολο, **ταίριαξε κάθε συναλλαγή με τα υποψήφια στοιχειοσύνολα που περιέχονται σε κάδους κατακερματισμού**



Στρατηγική apriori: Υπολογισμός Υποστήριξης



Απαρίθμηση Στοιχειοσυνόλων

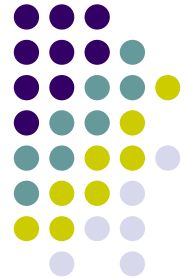
Βασική ιδέα του κατακερματισμού

1. Κατά τη διάρκεια του apriori τα συχνά στοιχειοσύνολα που παράγονται κατακερματίζονται σε κάδους και αποθηκεύονται σε ένα δέντρο κατακερματισμού

2. Στη συνέχεια, κάθε συναλλαγή (για την ακρίβεια, κάθε στοιχειοσύνολο που περιέχει) κατακερματίζεται με την ίδια συνάρτηση και τη συγκρίνουμε όχι με όλα τα πιθανά στοιχειοσύνολα, *αλλά μόνο με τα στοιχειοσύνολα στους αντίστοιχους κάδους*

Ας δούμε πως

Στρατηγική apriori: Υπολογισμός Υποστήριξης



1. Δημιουργία του δέντρου κατακερματισμού υποψηφίων στοιχειοσυνόλων

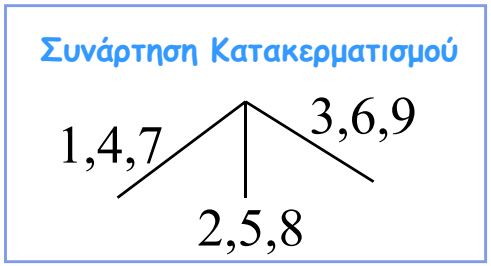
Έστω ότι έχουμε 15 υποψήφια 3-στοιχειοσύνολα:

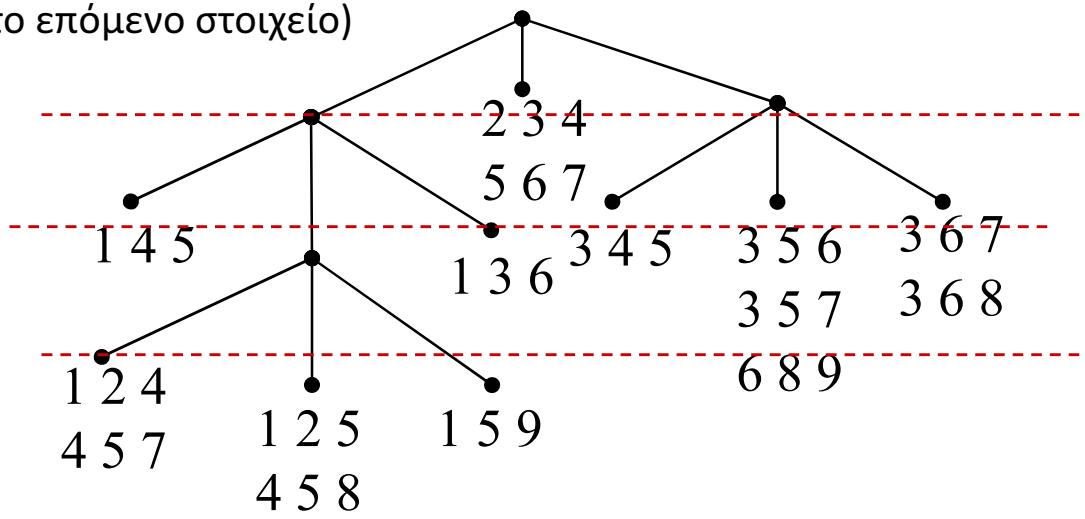
{1 4 5}, {1 2 4}, {4 5 7}, {1 2 5}, {4 5 8}, {1 5 9}, {1 3 6}, {2 3 4}, {5 6 7}, {3 4 5}, {3 5 6}, {3 5 7}, {6 8 9}, {3 6 7}, {3 6 8}

Στο δέντρο κατακερματίζουμε τα υποψήφια στοιχειοσύνολα

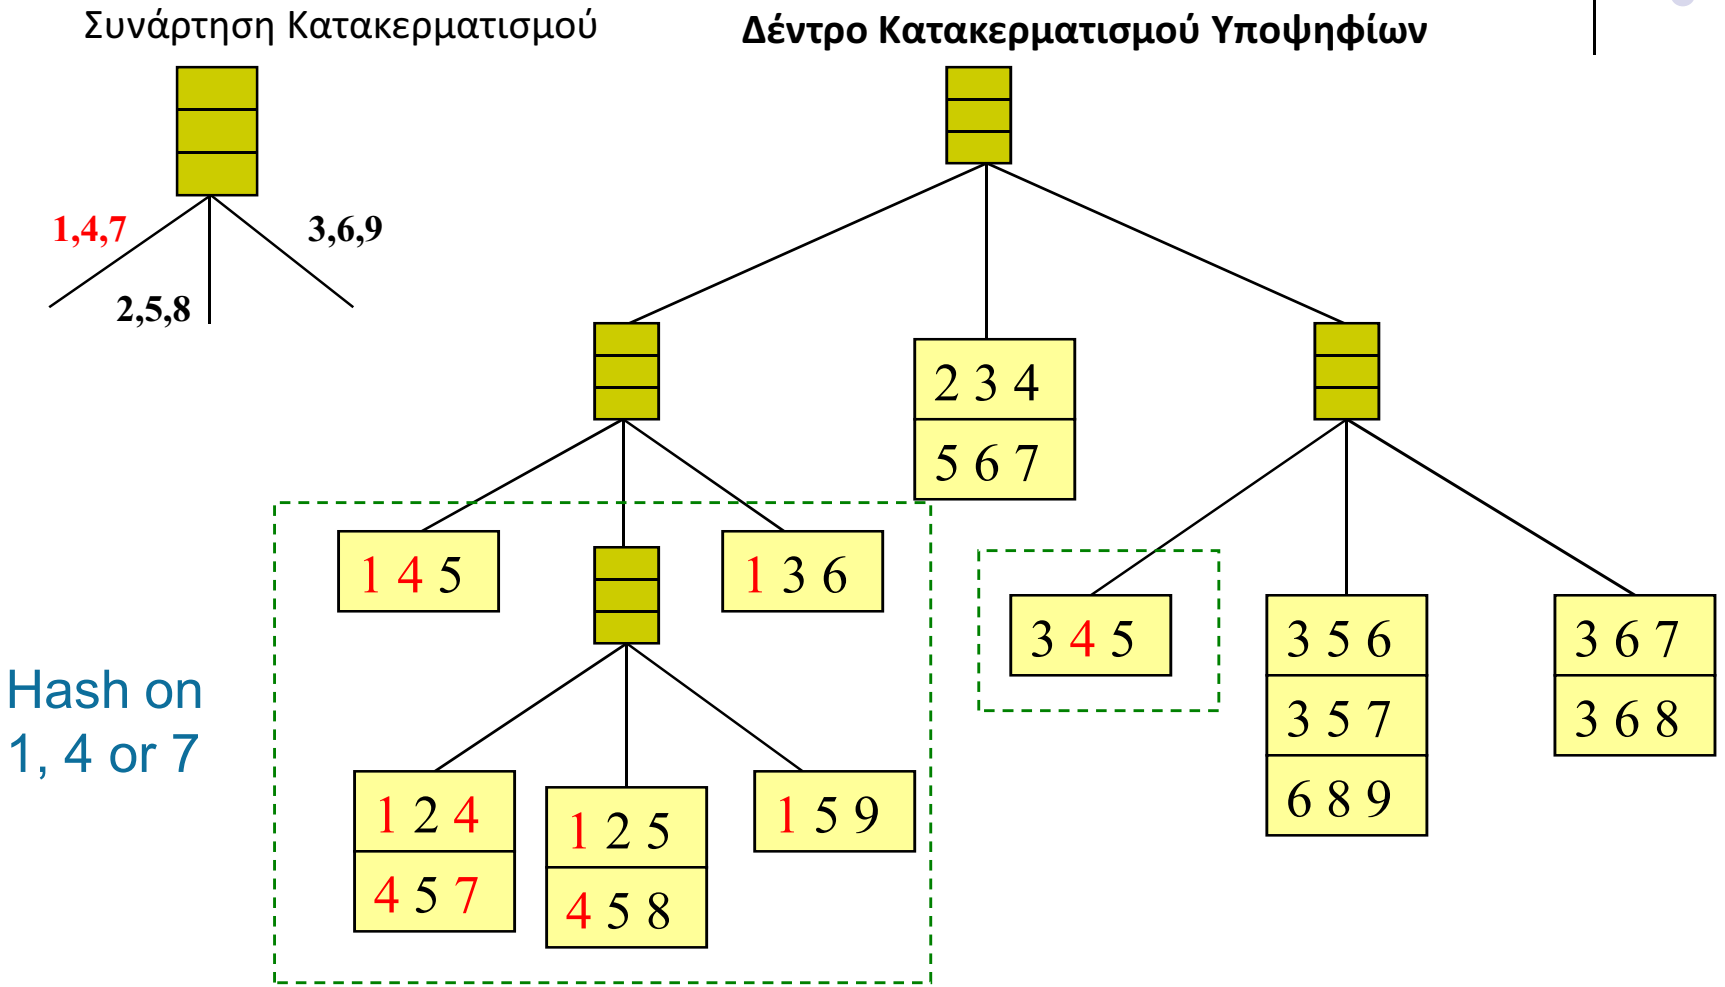
Τα αποθηκεύουμε στα φύλλα (κάδους) του δέντρου

- Συνάρτηση κατακερματισμού (ποιο κλαδί θα ακολουθήσουμε σε κάθε επίπεδο)
- Μέγιστο Μήκος Φύλλου: μέγιστος αριθμός στοιχειοσυνόλων που θα αποθηκευτούν σε κάθε φύλλο (αν ο αριθμός των στοιχειοσυνόλων υπερβεί το μέγιστο μέγεθος του φύλλου, διαχώρισε τον κόμβο – χρήση κατακερματισμού στο επόμενο στοιχείο)

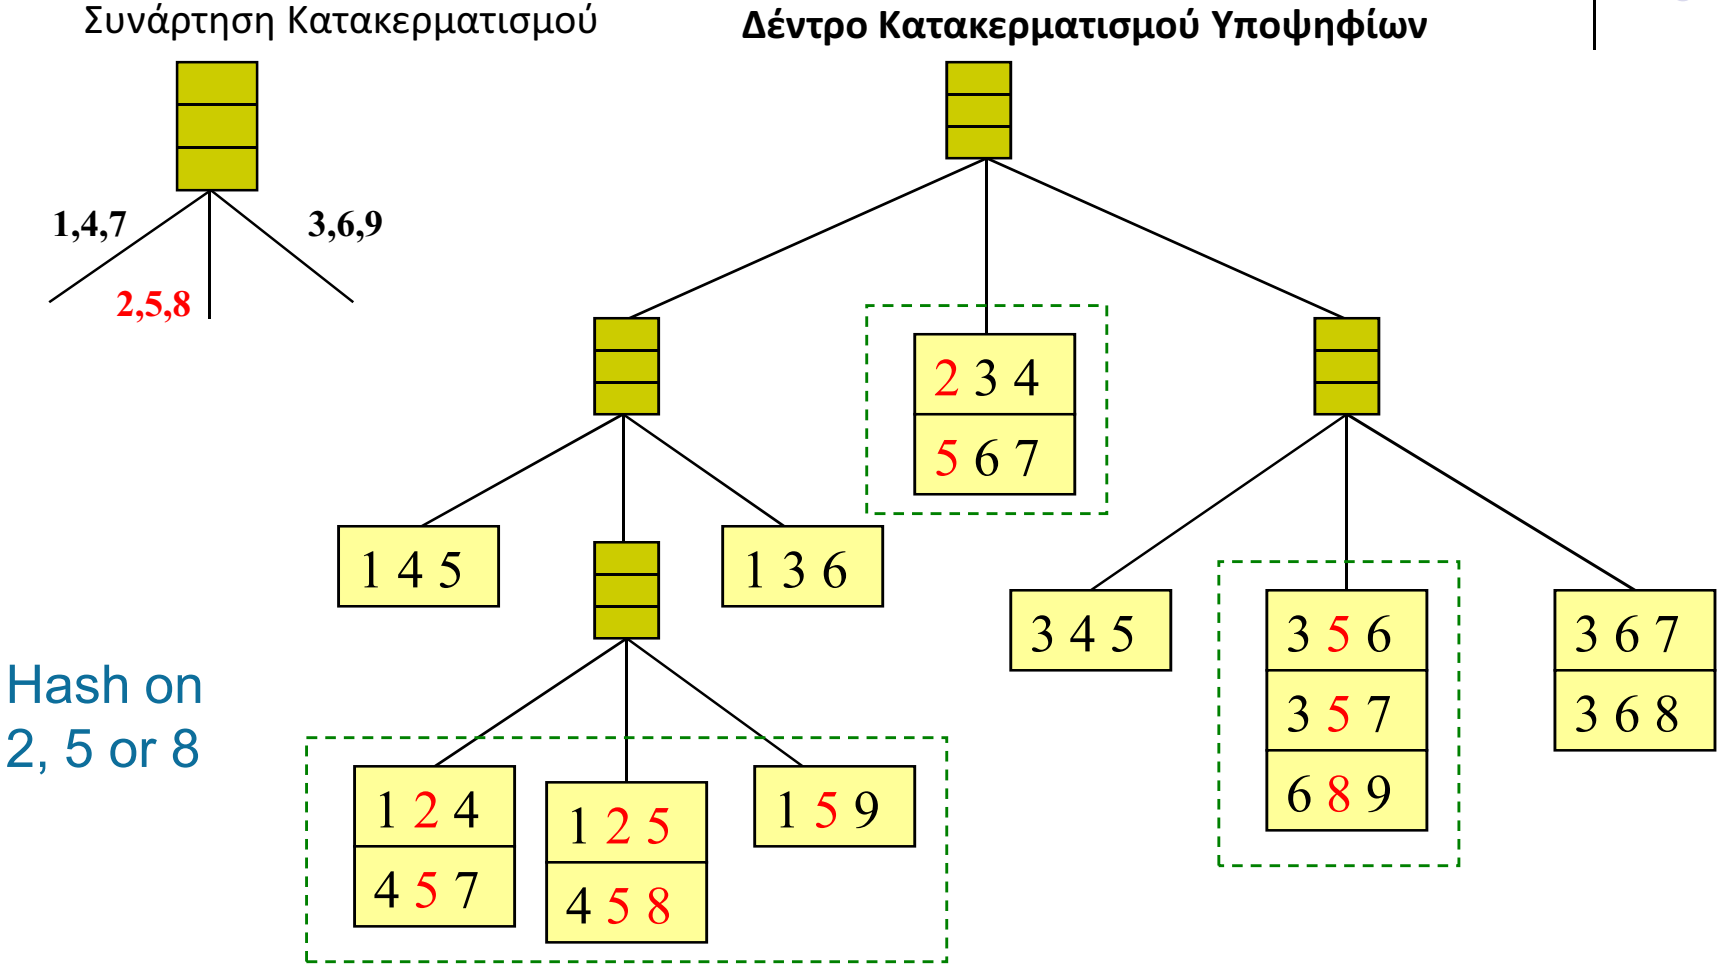




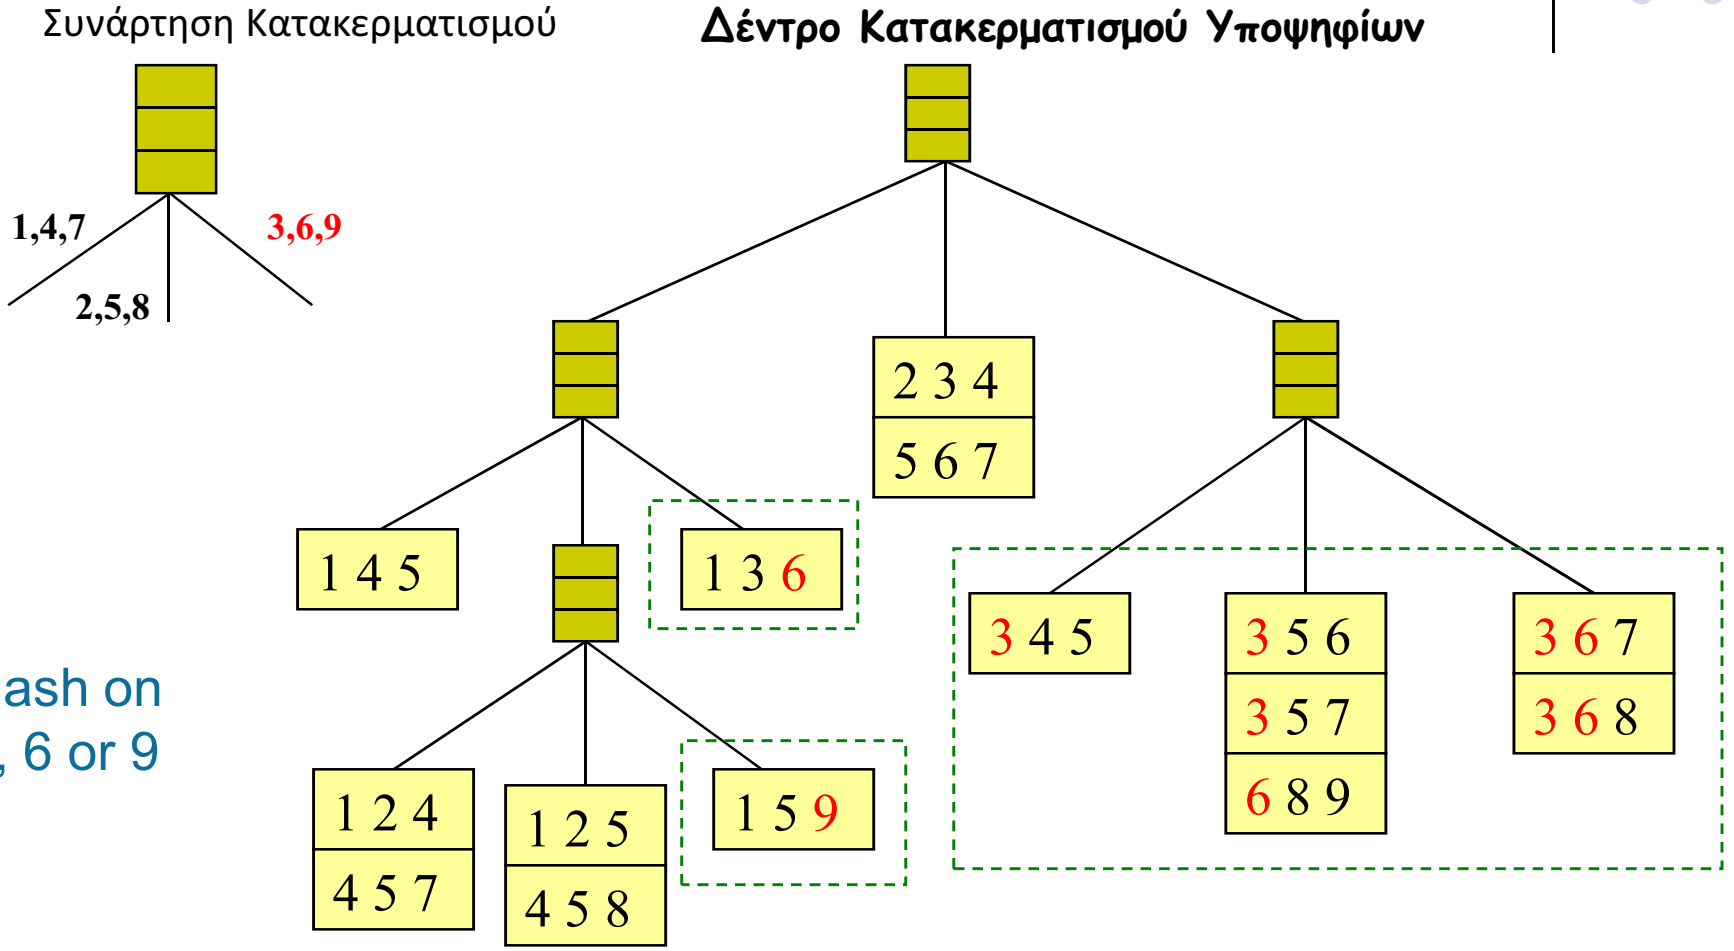
Στρατηγική apriori: Υπολογισμός Υποστήριξης



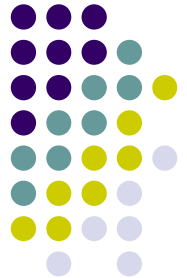
Στρατηγική apriori: Υπολογισμός Υποστήριξης



Στρατηγική apriori: Υπολογισμός Υποστήριξης



Στρατηγική apriori: Υπολογισμός Υποστήριξης



2. Απαρίθμηση Υποσυνόλων με χρήση του Δέντρου Κατακερματισμού

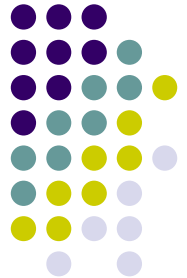
Έχοντας κατασκευάσει το δέντρο κατακερματισμού (π.χ., για τα 3-στοιχειοσύνολα),

Για κάθε συναλλαγή,

κατακερματίζουμε όλα τα 3-στοιχειοσύνολα της συναλλαγής στο δέντρο

και αυξάνουμε τον αντίστοιχο μετρητή

Στρατηγική apriori: Υπολογισμός Υποστήριξης



Απαρίθμηση Στοιχειοσυνόλων

Πχ έστω ότι είμαστε στο 3 βήμα και έχουμε δημιουργήσει όλα τα πιθανά 3-στοιχειοσύνολα

Έστω μια συναλλαγή t με 5 στοιχεία {1, 2, 3, 5, 6}

Θα πρέπει να ελέγξουμε για καθένα από τα πιθανά στοιχειοσύνολα αν το περιέχει η t

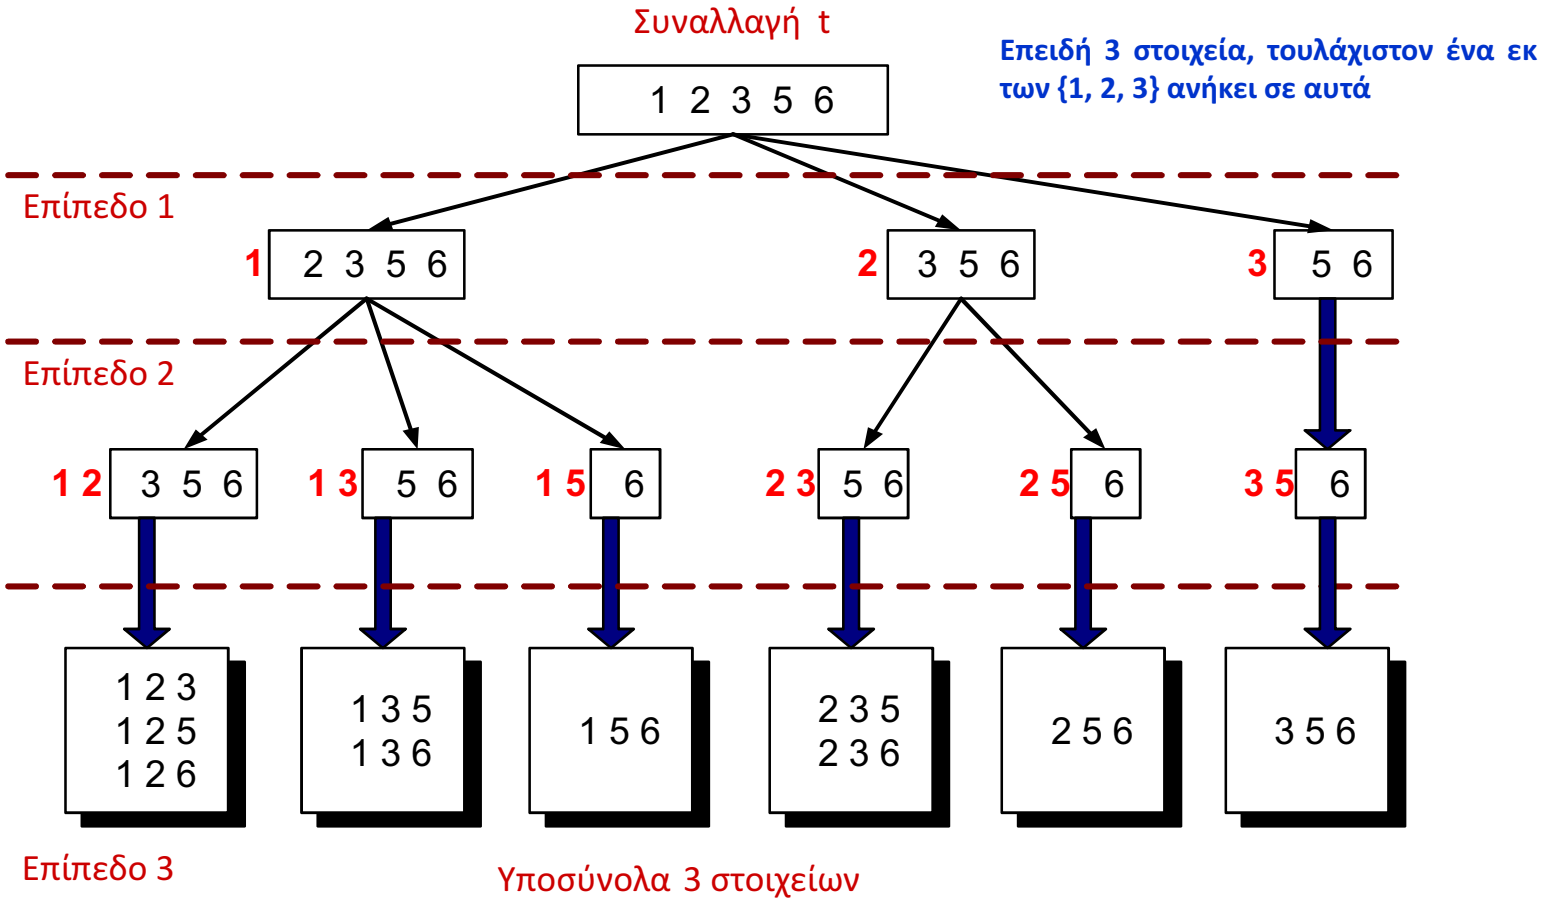
Αν το περιέχει η t θα πρέπει να αυξήσουμε την υποστήριξη του κατά 1

Ας δούμε πρώτα ένα συστηματικό τρόπο για την απαρίθμηση όλων των 3-στοιχειοσυνόλων της t

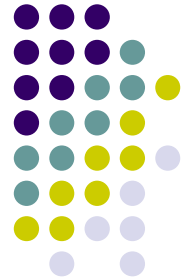
Στρατηγική apriori: Υπολογισμός Υποστήριξης

Απαρίθμηση Στοιχειοσυνόλων

Έστω μια συναλλαγή t με 5 στοιχεία {1, 2, 3, 5, 6} - Απαρίθμηση όλων των πιθανών υποσυνόλων της με τρία στοιχεία (3-στοιχειοσύνολα) με λεξικογραφική διάταξη

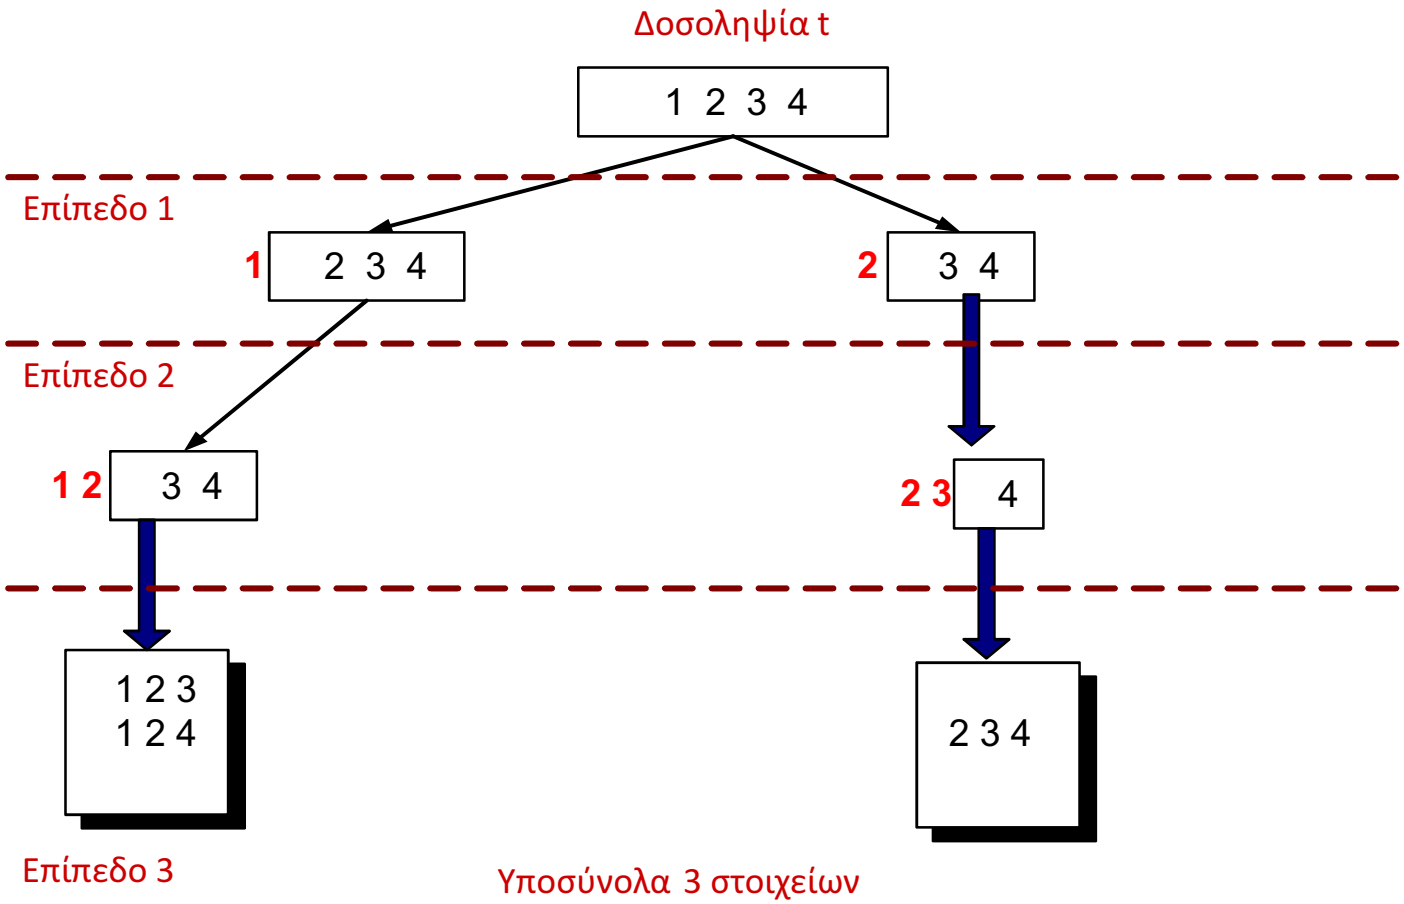


Στρατηγική apriori: Υπολογισμός Υποστήριξης



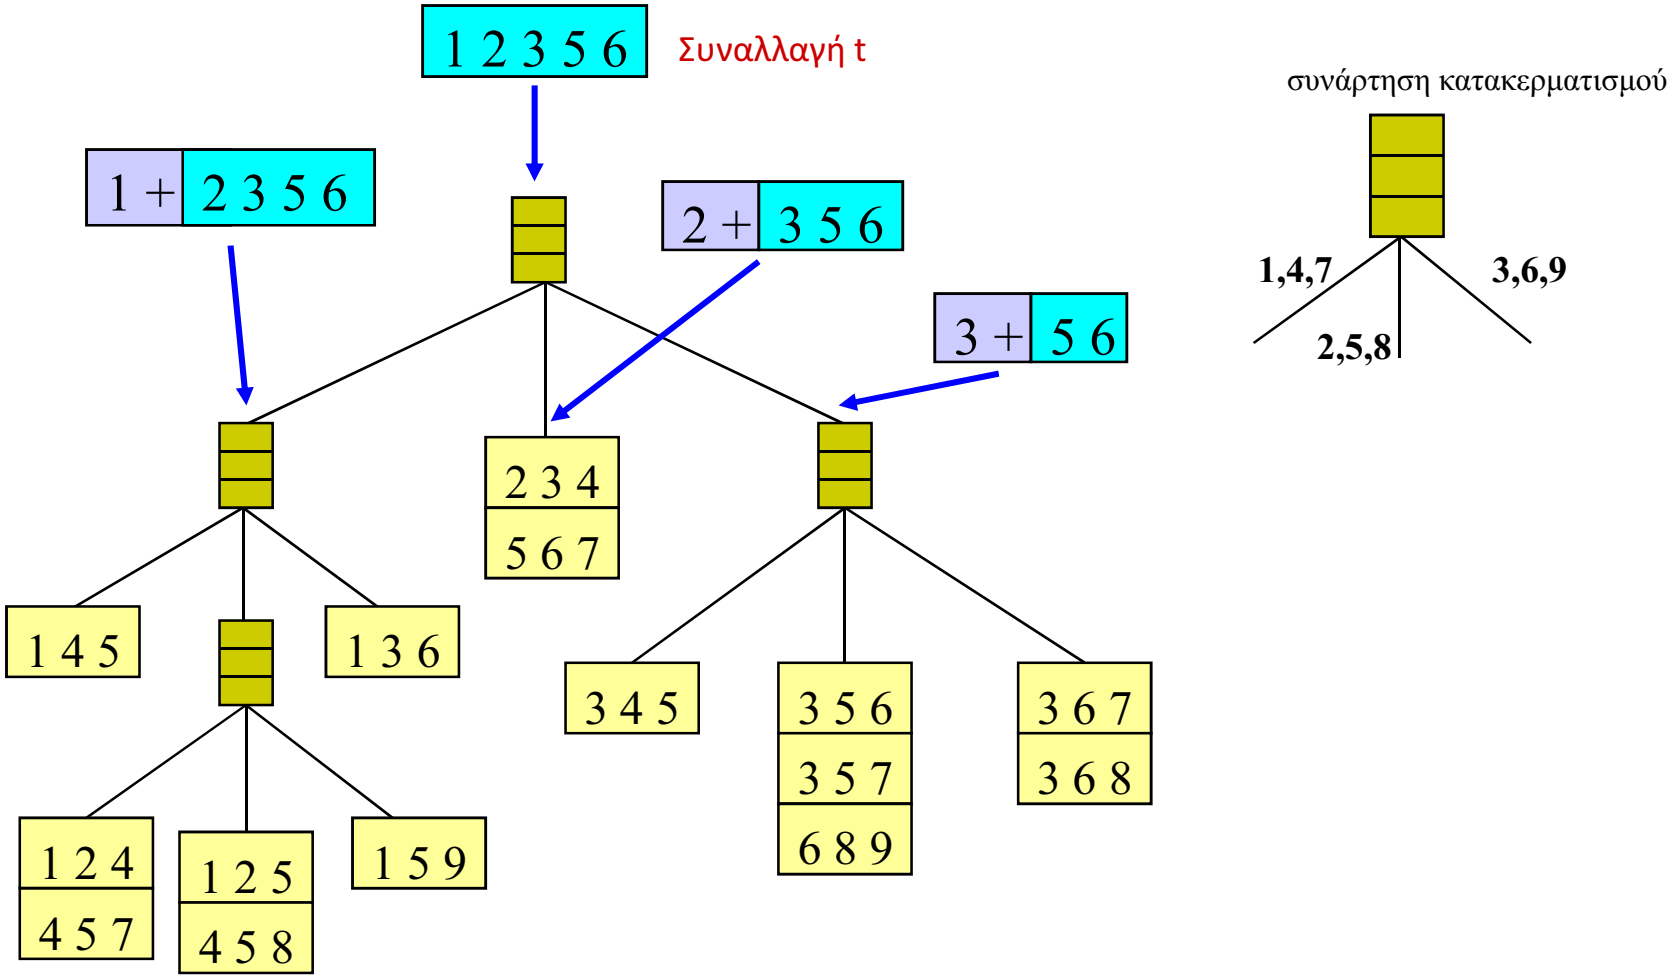
Απαρίθμηση Στοιχειοσυνόλων

Έστω μια συναλλαγή t με 4 στοιχεία {1, 2, 3, 4} - Απαρίθμηση όλων των πιθανών υποσυνόλων της με τρία στοιχεία (3-στοιχειοσύνολα) με λεξικογραφική διάταξη



Στρατηγική apriori: Υπολογισμός Υποστήριξης

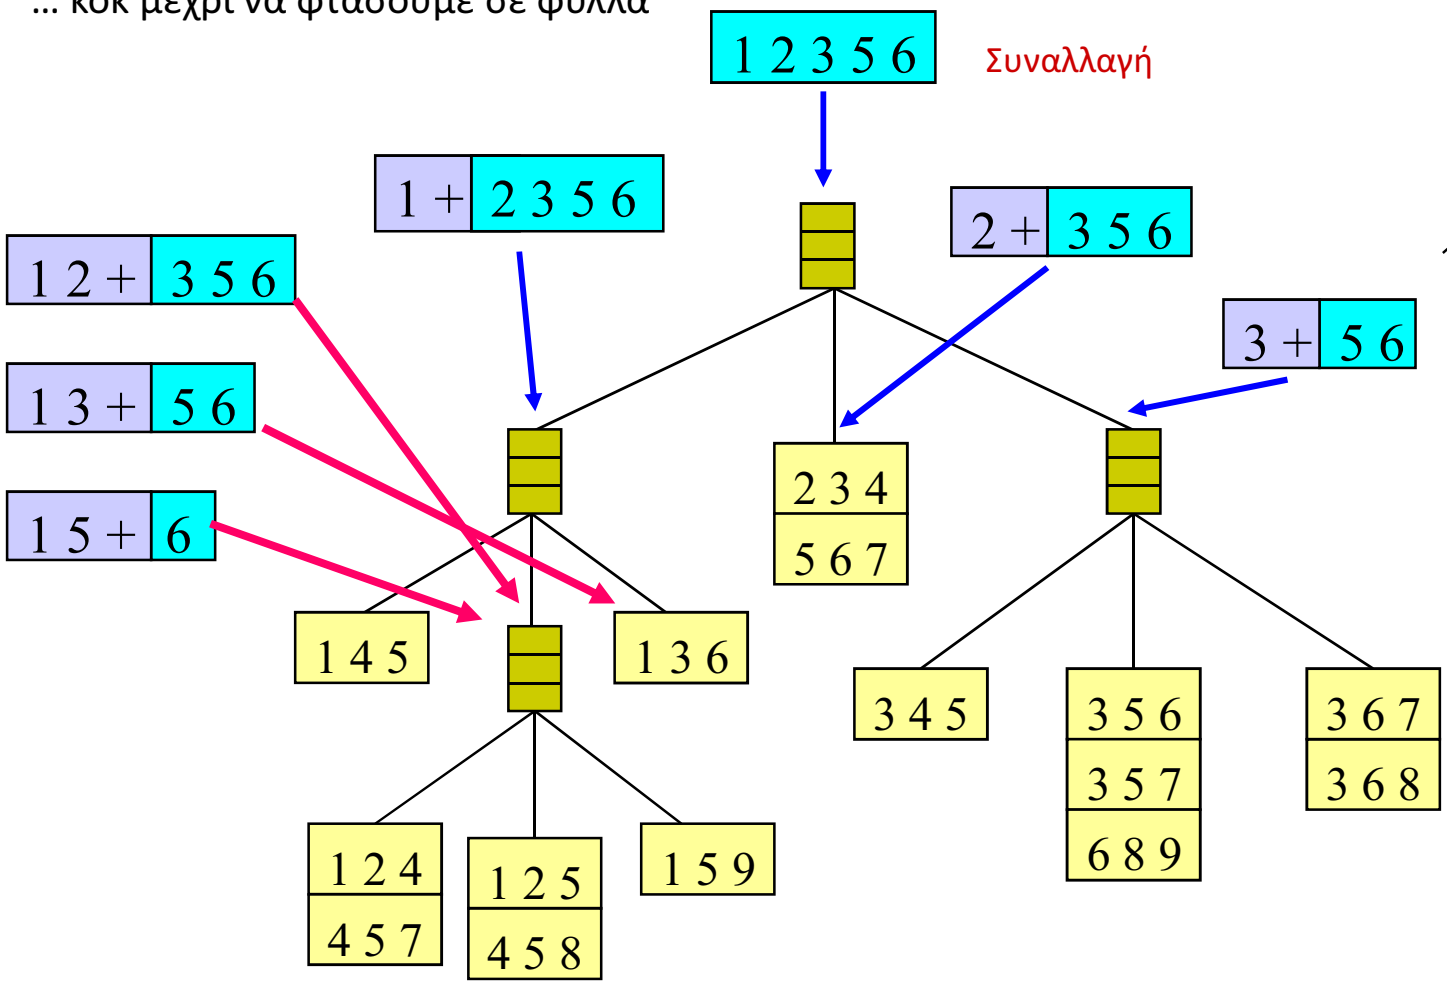
Με βάση το δέντρο απαρίθμησης για την t = {1, 2, 3, 5, 6} όλα τα δυνατά στοχειοσύνολα αρχίζουν από 1, 2 ή 3 => στη ρίζα κατακερματίζουμε χωριστά τα 1, 2 και 3 – δηλαδή με βάση τα στοιχεία του πρώτου επιπέδου

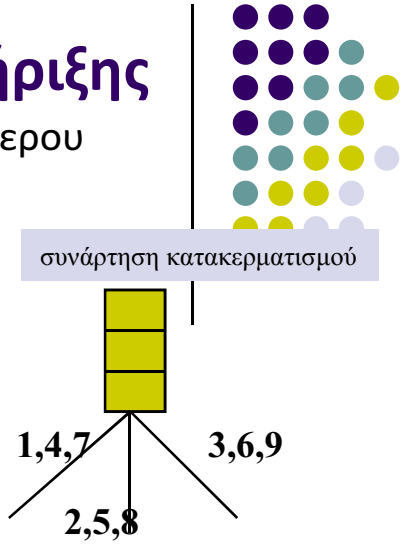


Στρατηγική apriori: Υπολογισμός Υποστήριξης

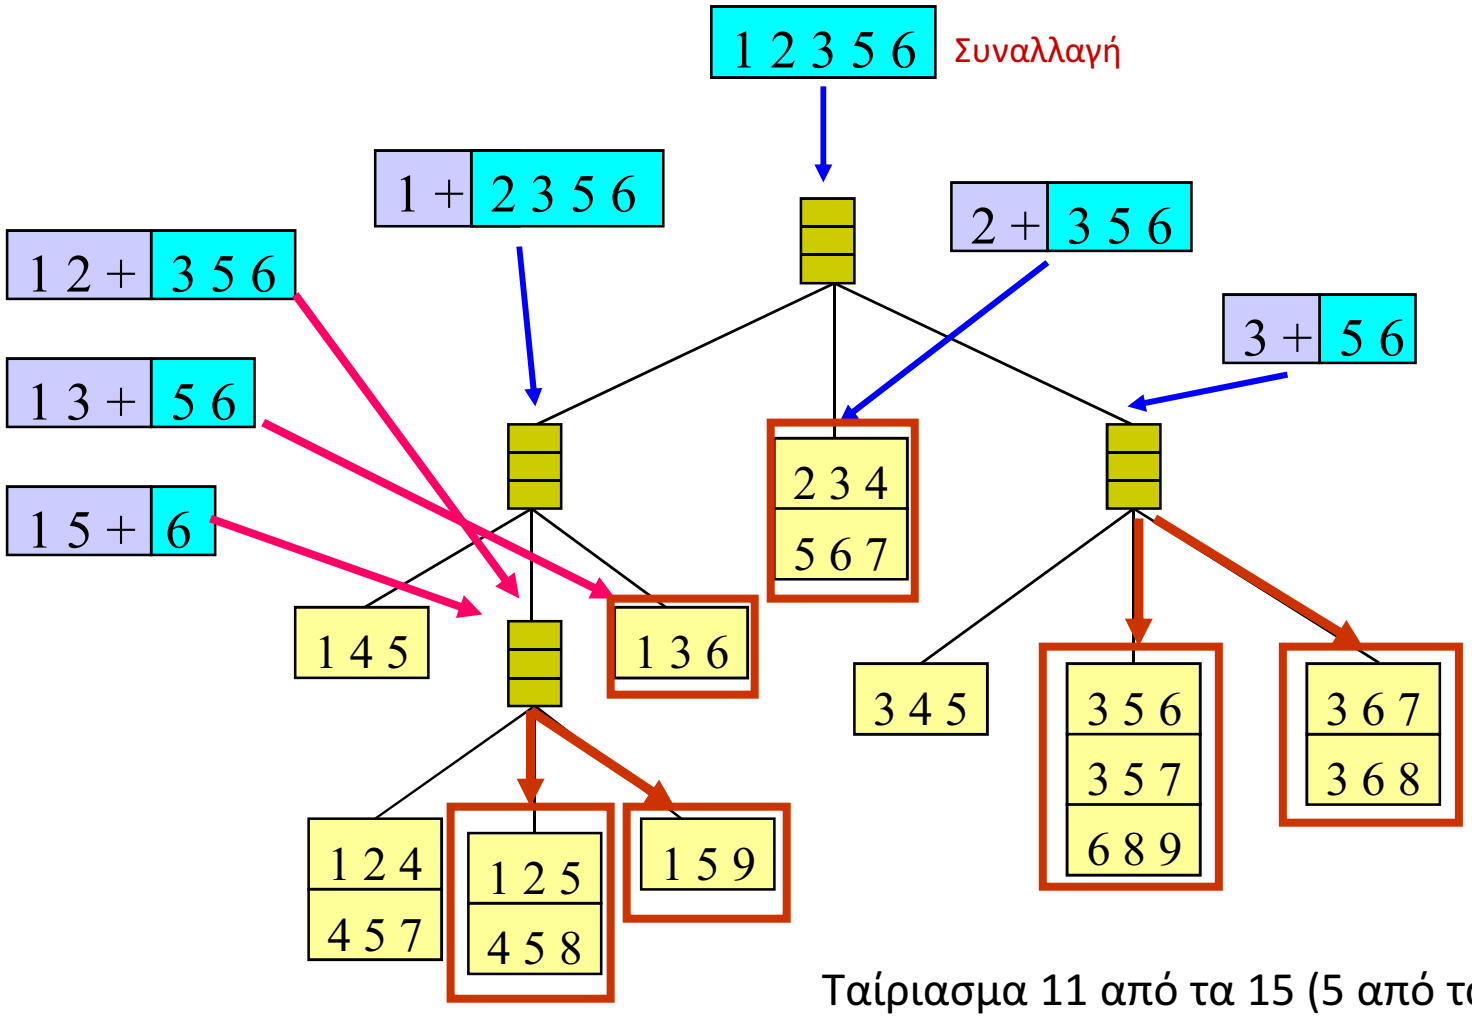
στη συνέχεια κατακερματίζουμε με βάση τα αντίστοιχα στοιχεία του δεύτερου επιπέδου: 2, 3, 5 (για το 1) 3, 5 (για το 2) 5 (για το 3)

... κοκ μέχρι να φτάσουμε σε φύλλα





Στρατηγική apriori: Υπολογισμός Υποστήριξης



Ταίριασμα 11 από τα 15 (5 από τα 9 φύλλα)

Στρατηγική apriori



Γενικός Αλγόριθμος (ξανά)

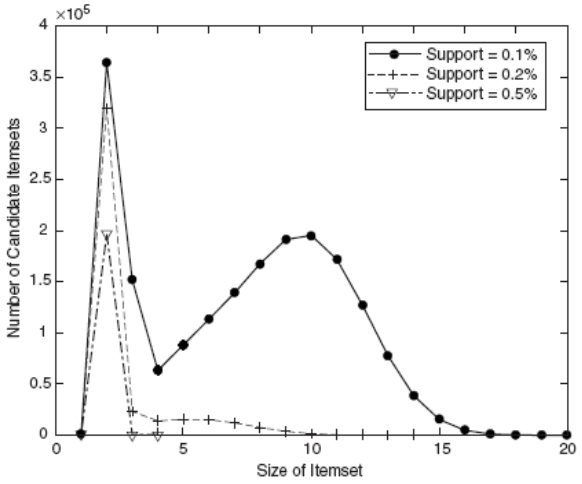
k = 1

Δημιούργησε όλα τα συχνά στοιχειοσύνολα μήκους 1

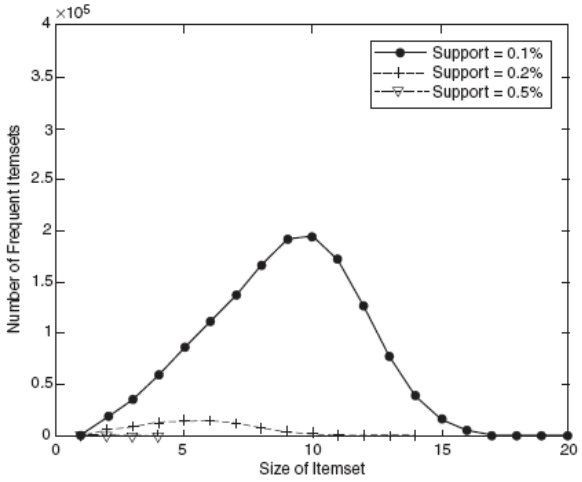
Repeat until δεν δημιουργούνται νέα στοιχειοσύνολα

- Δημιούργησε υποψήφια στοιχειοσύνολα μήκους (k+1) από τα συχνά στοιχειοσύνολα μήκους k (είτε $F_{k-1} \times F_1$ είτε $F_{k-1} \times F_{k-1}$)
- Prune τα υποψήφια στοιχειοσύνολα που περιέχουν υποσύνολα μήκους k που δεν είναι συχνά
- Υπολόγισε την υποστήριξη (support) κάθε υποψηφίου στοιχειοσύνολου διαβάζοντας από τη βάση δεδομένων (πχ χρησιμοποίησε το δέντρο κατακερματισμού)
- Σβήσε τα υποψήφια στοιχειοσύνολα που δεν είναι συχνά, αφήνοντας μόνο τα συχνά

Στρατηγική apriori: Πολυπλοκότητα



(a) Number of candidate itemsets.

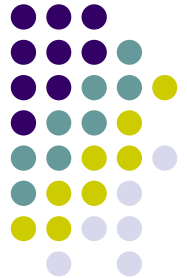


(b) Number of frequent itemsets.

Figure 6.13. Effect of support threshold on the number of candidate and frequent itemsets.

- Επιλογή της τιμής του κατωφλιού για την ελάχιστη υποστήριξη
  - Μικρή τιμή =>
  - πολλά συχνά στοιχειοσύνολα
  - Αύξηση υποψήφιων στοιχειοσυνόλων (πολυπλοκότητα) και το μέγιστο μήκος των συχνών στοιχειοσυνόλων (περισσότερα περάσματα στα δεδομένα για τον υπολογισμό της υποστήριξης)

Στρατηγική apriori: Πολυπλοκότητα



Πλήθος διαστάσεων - Dimensionality (αριθμός στοιχείων) του συνόλου δεδομένων

- Περισσότερος χώρος για την αποθήκευση της υποστήριξης κάθε στοιχείου
- Αύξηση του αριθμού των συχνών στοιχείων, αύξηση του υπολογιστικού κόστους και του κόστους I/O

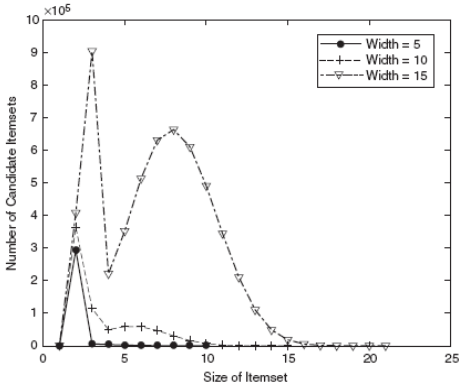
Μέγεθος της βάσης (πλήθος συναλλαγών)

Επειδή ο Apriori κάνει πολλαπλά περάσματα, ο χρόνος εκτέλεσης μπορεί να αυξηθεί

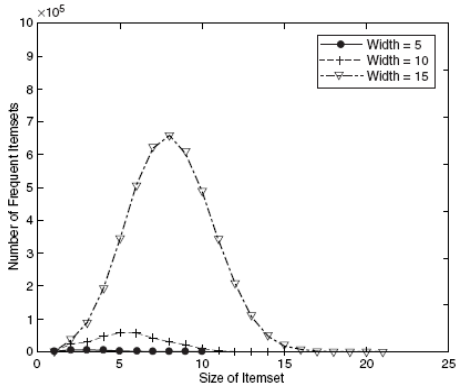
Στρατηγική apriori: Πολυπλοκότητα



- Μέσο πλάτος συναλλαγής (πυκνά σύνολα δεδομένων – πολλά στοιχεία ανά συναλλαγή)
  - Το μέγιστο μήκος των συχνών στοιχειοσύνολων τείνει να αυξηθεί με την αύξηση του μέσου πλάτους των συναλλαγών, άρα και ο αριθμός των υποψηφίων σε κάθε βήμα
  - Επίσης, αύξηση των περασμάτων του δέντρου κατακερματισμού



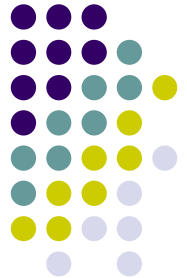
(a) Number of candidate itemsets.



(b) Number of Frequent Itemsets.

Figure 6.14. Effect of average transaction width on the number of candidate and frequent itemsets.

Στρατηγική apriori: Πολυπλοκότητα



N = #συναλλαγών, w = μέσο πλάτος συναλλαγής

1. Δημιουργία συχνών 1-στοχειοσυνόλων

O(Nw) (για κάθε συναλλαγή, πρέπει να ενημερώνεται η υποστήριξη για κάθε στοιχείο που έχει)

2. Δημιουργία υποψήφιων στοιχειοσυνόλων

Έστω F_{k-1} x F_{k-1}

k-2 συγκρίσεις για κοινό prefix

Στη χειρότερη περίπτωση, ταιριάζουν όλα $\Sigma_{k=2,w}|F_{k-1}|^2$

Επίσης κατασκευάζουμε το δέντρο, μέγιστο ύψος k, άρα $\Sigma_{k=2,w}k|F_{k-1}|^2$

Έλεγχος, ότι τα k-2 υποσύνολα είναι συχνά με χρήση του δέντρου

3. Υπολογισμός της Υποστήριξης

Κάθε συναλλαγή έχει k από |t| k-στοιχειοσύνολα

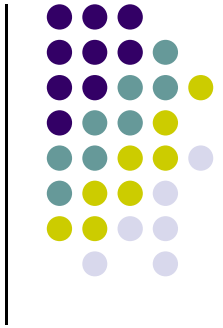
Εξόρυξη Κανόνων Συσχέτισης



Χωρισμός του προβλήματος σε <u>δύο υπο-προβλήματα</u>:

- Εύρεση όλων των συχνών στοιχειοσυνόλων (Frequent Itemset Generation)
  Εύρεση όλων των στοιχειοσυνόλων με υποστήριξη $\geq$ minsup

- Δημιουργία Κανόνων (Rule Generation)
  Για κάθε στοιχειοσύνολο, δημιούργησε κανόνες με μεγάλη υποστήριξη, όπου κάθε κανόνες είναι μια δυαδική διαμέριση του συχνού στοιχειοσυνόλου



Δημιουργία Κανόνων



Παραγωγή Κανόνων (Rule Generation)

- Δοθέντος ενός συχνού στοιχειοσυνόλου L, βρες όλα τα μη κενά υποσύνολα $f \subset L$ τέτοια ώστε ο κανόνας $f \rightarrow L - f$ ικανοποιεί τον περιορισμό της ελάχιστης εμπιστοσύνης
- Παράδειγμα αν {A,B,C,D} είναι ένα συχνό στοιχειοσύνολο, υποψήφιοι κανόνες:
  - ABC →D, ABD →C, ACD →B, BCD →A,
    A →BCD, B →ACD, C →ABD, D →ABC
    AB →CD, AC → BD, AD → BC, BC →AD,
    BD →AC, CD →AB,

  Όλοι έχουν την ίδια υποστήριξη, πρέπει να ελέγξουμε την εμπιστοσύνη
- Αν |L| = k, τότε υπάρχουν $2^k - 2$ υποψήφιοι κανόνες συσχέτισης (εξαιρώντας τον $L \rightarrow \varnothing$ και τον $\varnothing \rightarrow L$)

Υπενθύμιση: Εμπιστοσύνη του $X \rightarrow Y$
Πόσες από τις συναλλαγές που περιέχουν το X περιέχουν και το Y
$\sigma(X \cup Y)/\sigma(X)$



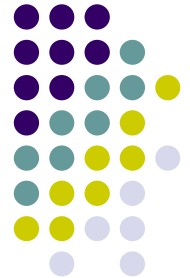
Υπολογισμός Εμπιστοσύνης

- Παρατήρηση: Δε χρειάζεται να διαπεράσουμε πάλι τα δεδομένα για να υπολογίσουμε την εμπιστοσύνη ενός κανόνα που προκύπτει από ένα συχνό στοιχειοσύνολο:
  - ABC →D, ABD →C, ACD →B, BCD →A,
    A →BCD, B →ACD, C →ABD, D →ABC
    AB →CD, AC → BD, AD → BC, BC →AD,
    BD →AC, CD →AB

Γιατί; Πχ c(CD →AB) = σ{A, B, C, D}/σ{C, D}

Από την αντι-μονότονη ιδιότητα της υποστήριξης, το {C, D} είναι συχνό στοιχειοσύνολο άρα έχουμε ήδη υπολογίζει την υποστήριξή του

Παραγωγή Κανόνων



Πως μπορούν να παραχθούν αποδοτικά οι κανόνες από τα συχνά στοιχειοσύνολα;

- Γενικά, η αντι-μονότονη ιδιότητα δεν ισχύει για την εμπιστοσύνη

$$\forall X, Y : (X \subseteq Y) \not\Rightarrow s(X) \geq s(Y)$$

Δηλαδή, η εμπιστοσύνη του X $\rightarrow$ Y μπορεί να είναι μεγαλύτερη, μικρότερη ή ίση της εμπιστοσύνης ενός κανόνα X' $\rightarrow$Y' όπου X' $\subseteq$ X και Y' $\subseteq$ Y

Γενικά έστω {p} $\rightarrow$ {q} με εμπιστοσύνη c_1

- Και {p, r} $\rightarrow$ {q} με εμπιστοσύνη c_2 (το αριστερό μέρος – LHS - υπερσύνολο)

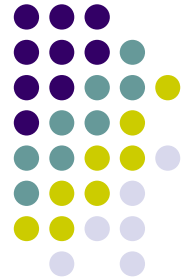
  Μπορεί $c_2 > c_1$, $c_2 < c_1$ ή $c_2 = c_1$

- Έστω {p} $\rightarrow$ {q, r} με εμπιστοσύνη c_3 (το δεξί μέρος – RHS - υπερσύνολο)

  $c_3 \leq c_1$

- Επίσης, $c_3 \leq c_2$

Παραγωγή Κανόνων



Υπενθύμιση: Εμπιστοσύνη του $X \rightarrow Y$
Πόσες από τις συναλλαγές που περιέχουν το X περιέχουν και το Y
$\sigma(X \cup Y)/\sigma(X)$

Η εμπιστοσύνη για τους κανόνες που παράγονται από το ίδιο στοιχειοσύνολο έχει μια αντι-μονότονη ιδιότητα

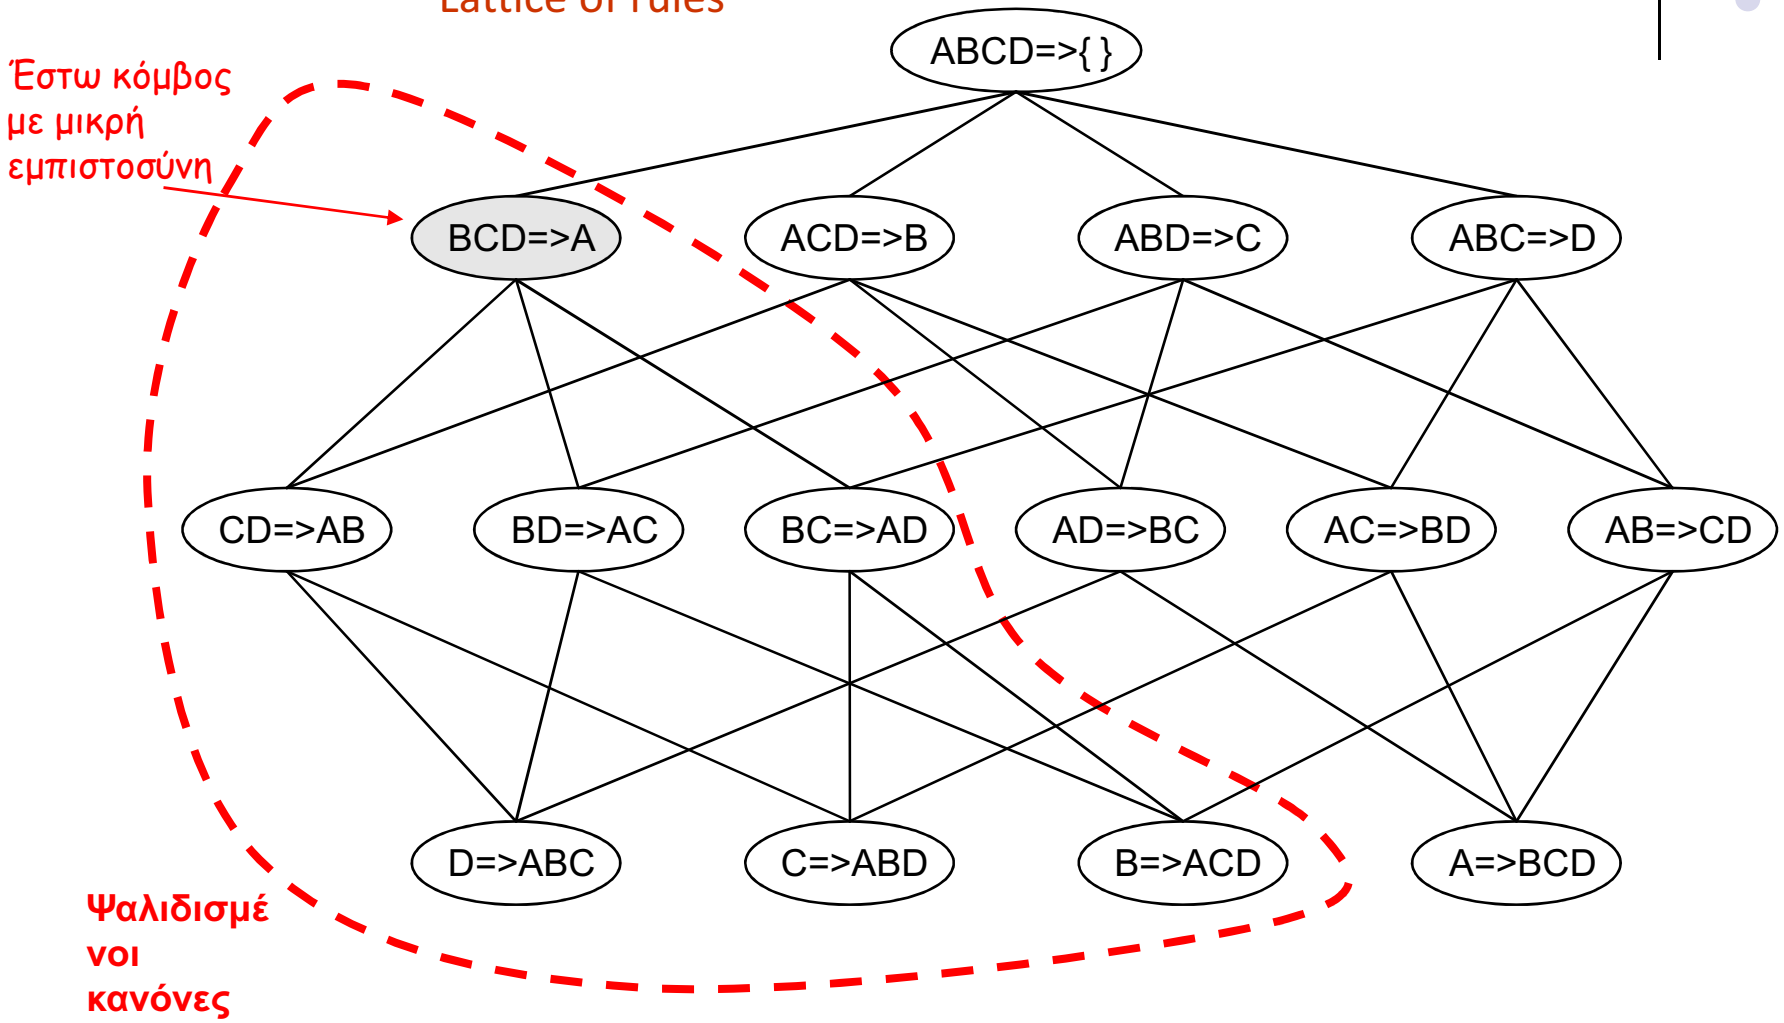
Για παράδειγμα L = {A,B,C,D}:

$$c(ABC \rightarrow \mathbf{D}) \geq c(AB \rightarrow C\mathbf{D}) \geq c(A \rightarrow BC\mathbf{D})$$

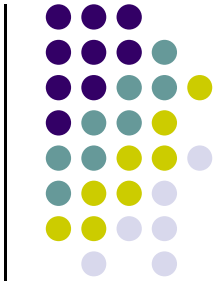
- Η εμπιστοσύνη είναι αντι-μονότονη σε σχέση με των αριθμό των στοιχείων στο RHS του κανόνα (ή ισοδύναμα μονότονη στον αριθμό των στοιχείων στο LHS)

Pruning Rule:
Αν ο κανόνας $X \rightarrow Y - X$ δεν ικανοποιεί το κατώφλι εμπιστοσύνης, τότε και ο κανόνας $X' \rightarrow Y - X'$ ($X' \subseteq X$) δεν τον ικανοποιεί

Παραγωγή Κανόνων για τον Αλγόριθμο apriori



Παραγωγή Κανόνων για τον Αλγόριθμο apriori



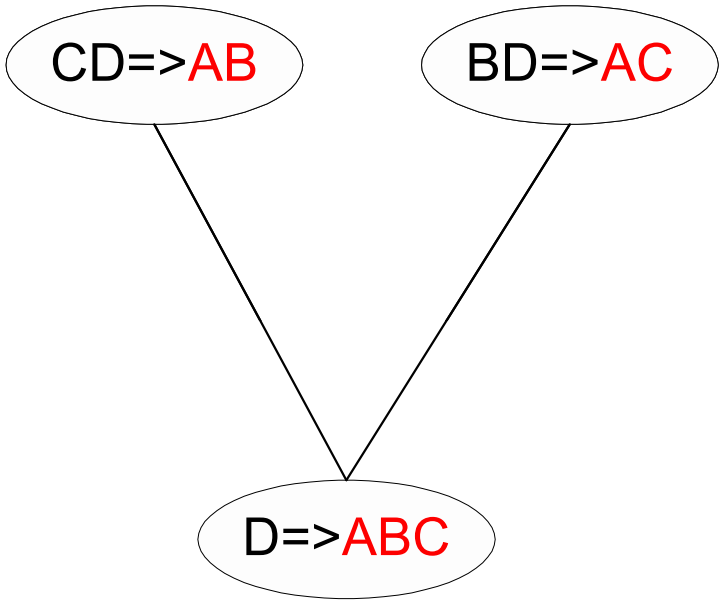
Οι κανόνες παράγονται σε επίπεδα με βάση τα στοιχεία στο RHS

Αρχικά, θεωρούμε όλους τους κανόνες **με ένα στοιχείο** στο RHS

Στη συνέχεια, οι υποψήφιοι κανόνες παράγονται συγχωνεύοντας το RHS δυο υποψηφίων κανόνων
Πχ
Συγχώνευση(ACD=>B, ABD=>C) μας δίνει AD=>BC

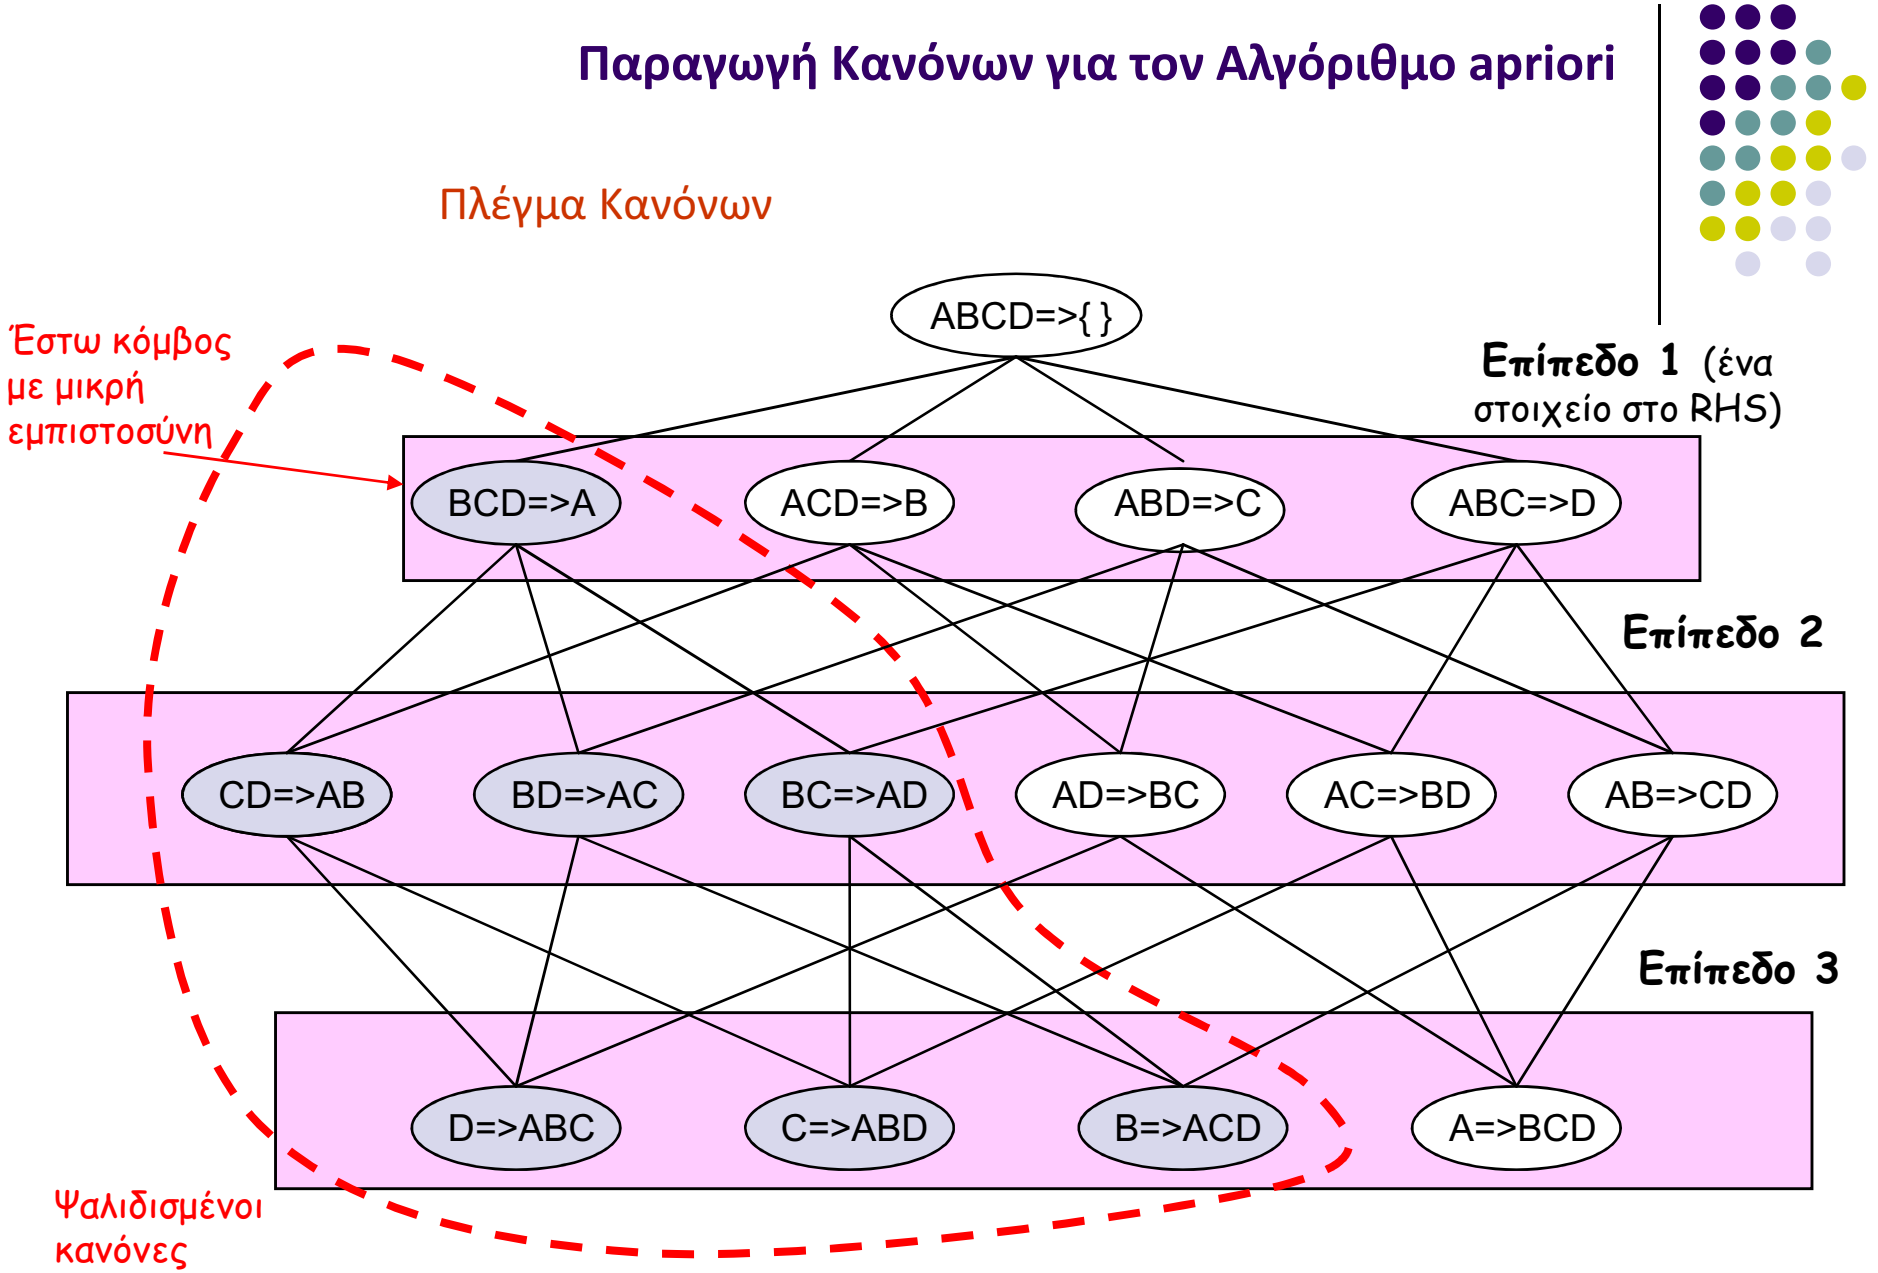
Όπως και στα συχνά στοιχειοσύνολα, στη συνέχεια, με το ίδιο prefix στο RHS
Συγχώνευση(CD=>AB, BD=>AC) μας δίνει D => ABC

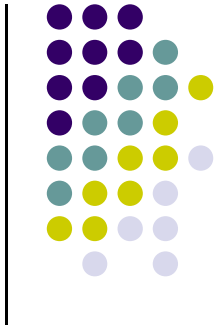
Prune τον κανόνα D=>ABC, αν το υποσύνολο AD=>BC δεν έχει επαρκή εμπιστοσύνη



- Σε αντίθεση με την περίπτωση των συχνών στοιχειοσυνόλων, δε χρειάζεται να διαβάσουμε τις δοσοληψίες για να υπολογίσουμε την εμπιστοσύνη

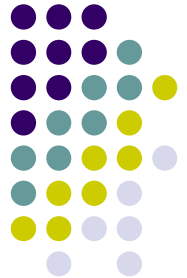
Παραγωγή Κανόνων για τον Αλγόριθμο apriori





Αναπαράσταση Κανόνων Συσχέτισης

Αναπαράσταση Στοιχειοσυνόλων

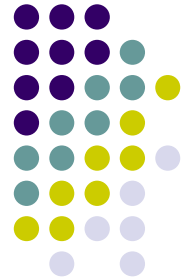


Τα στοιχειοσύνολα που παράγονται είναι πολλά, κάποια ίσως περιττά

Ποια να κρατήσουμε;

Αντιπροσωπευτικά συχνά στοιχειοσύνολα

Αναπαράσταση Στοιχειοσυνόλων



Έστω οι παρακάτω 15 δοσοληψίες με 30 στοιχεία

Έστω, υποστήριξη 20%

TID	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10
1	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1

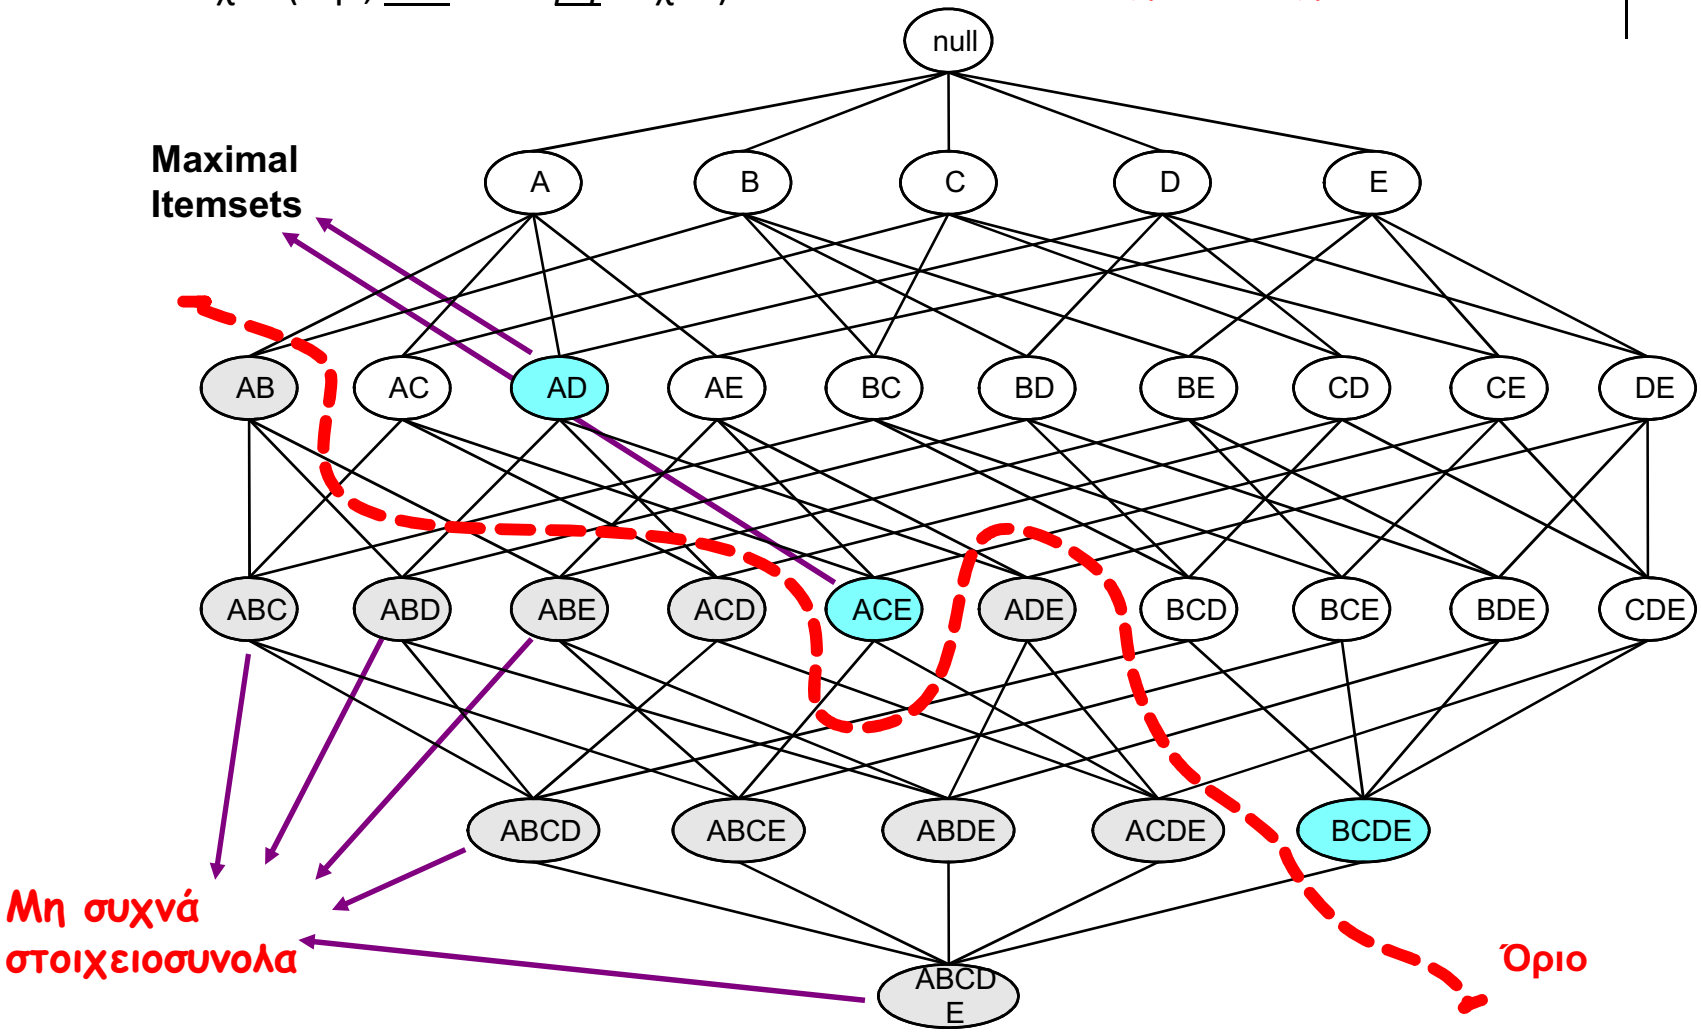
Αριθμός συχνών στοιχειοσυνόλων $= 3 \times \sum_{k=1}^{10} \binom{10}{k}$

Μερικά στοιχειοσύνολα είναι πλεονάζοντα, έχουν την ίδια υποστήριξη με το τα υπερσύνολα τους

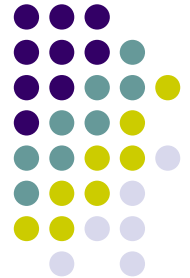
Πιθανή συνοπτική αναπαράσταση {A1, A2, A3, A4, A5, A6. A7, A8, A9, A10}, {B1, B2, B3, B4, B5, B6, B7, B8, B9, B10}, {C1, C2, C3, C4, C5, C6, C7, C8, C9, C10}

Αναπαράσταση Στοιχειοσυνόλων

Ένα στοιχειοσύνολο είναι maximal συχνό (μέγιστο συχνό) αν κανένα από τα άμεσα υπερσύνολά του δεν είναι συχνό (δηλ, όλα είναι *μη* συχνά)



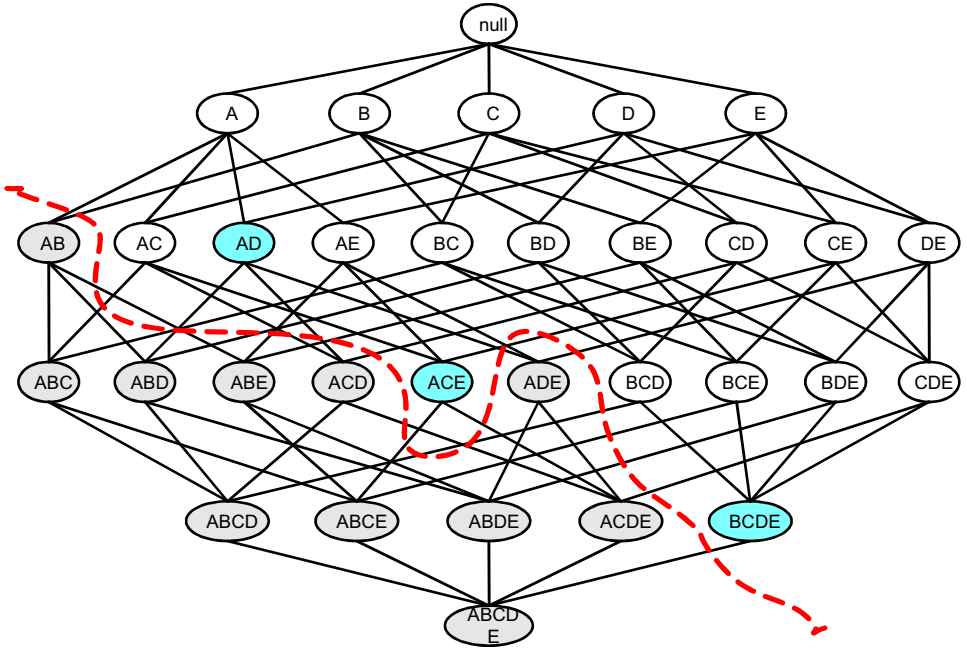
Αναπαράσταση Στοιχειοσυνόλων



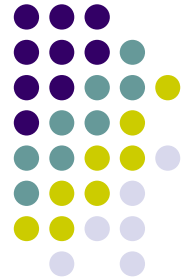
Προσφέρουν μια συνοπτική αναπαράσταση των συχνών στοιχειοσυνόλων: το μικρότερο σύνολο στοιχειοσυνόλων από το οποίο μπορούμε να πάρουμε όλα τα συχνά στοιχειοσύνολα (είναι όλα τα υποσύνολά τους)

Βέβαια, αυτό έχει νόημα μόνο αν έχουμε έναν αποδοτικό αλγόριθμο για τον υπολογισμό τους που δεν παράγει όλα τα δυνατά υποσύνολά τους

ΜΕΙΟΝΕΚΤΗΜΑ: Δεν προσφέρουν *καμιά πληροφορία για την υποστήριξη των υποσυνόλων τους*



Αναπαράσταση Στοιχειοσυνόλων



Ένα στοιχειοσύνολο είναι **κλειστό (closed)** αν κανένα από τα άμεσα υπερσύνολα του δεν έχει την ίδια υποστήριξη με αυτό

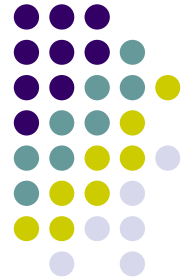
Δεν είναι κλειστό αν κάποιο άμεσο υπερσύνολό του έχει την ίδια υποστήριξη

TID	Items
1	{A,B}
2	{B,C,D}
3	{A,B,C,D}
4	{A,B,D}
5	{A,B,C,D}

Itemset	Support
{A}	4
{B}	5
{C}	3
{D}	4
{A,B}	4
{A,C}	2
{A,D}	3
{B,C}	3
{B,D}	4
{C,D}	3

Itemset	Support
{A,B,C}	2
{A,B,D}	3
{A,C,D}	2
{B,C,D}	3
{A,B,C,D}	2

Αναπαράσταση Στοιχειοσυνόλων



Ένα στοιχειοσύνολο είναι **κλειστό συχνό στοιχειοσύνολο** αν είναι κλειστό και η υποστήριξη του είναι μεγαλύτερη ή ίση με minsup

Ο αλγόριθμος υπολογισμού της υποστήριξης βασίζεται στο ότι:

Η υποστήριξη ενός μη κλειστού στοιχειοσυνόλου πρέπει να είναι ίση με την μεγαλύτερη υποστήριξη ανάμεσα στα υπερσύνολά του

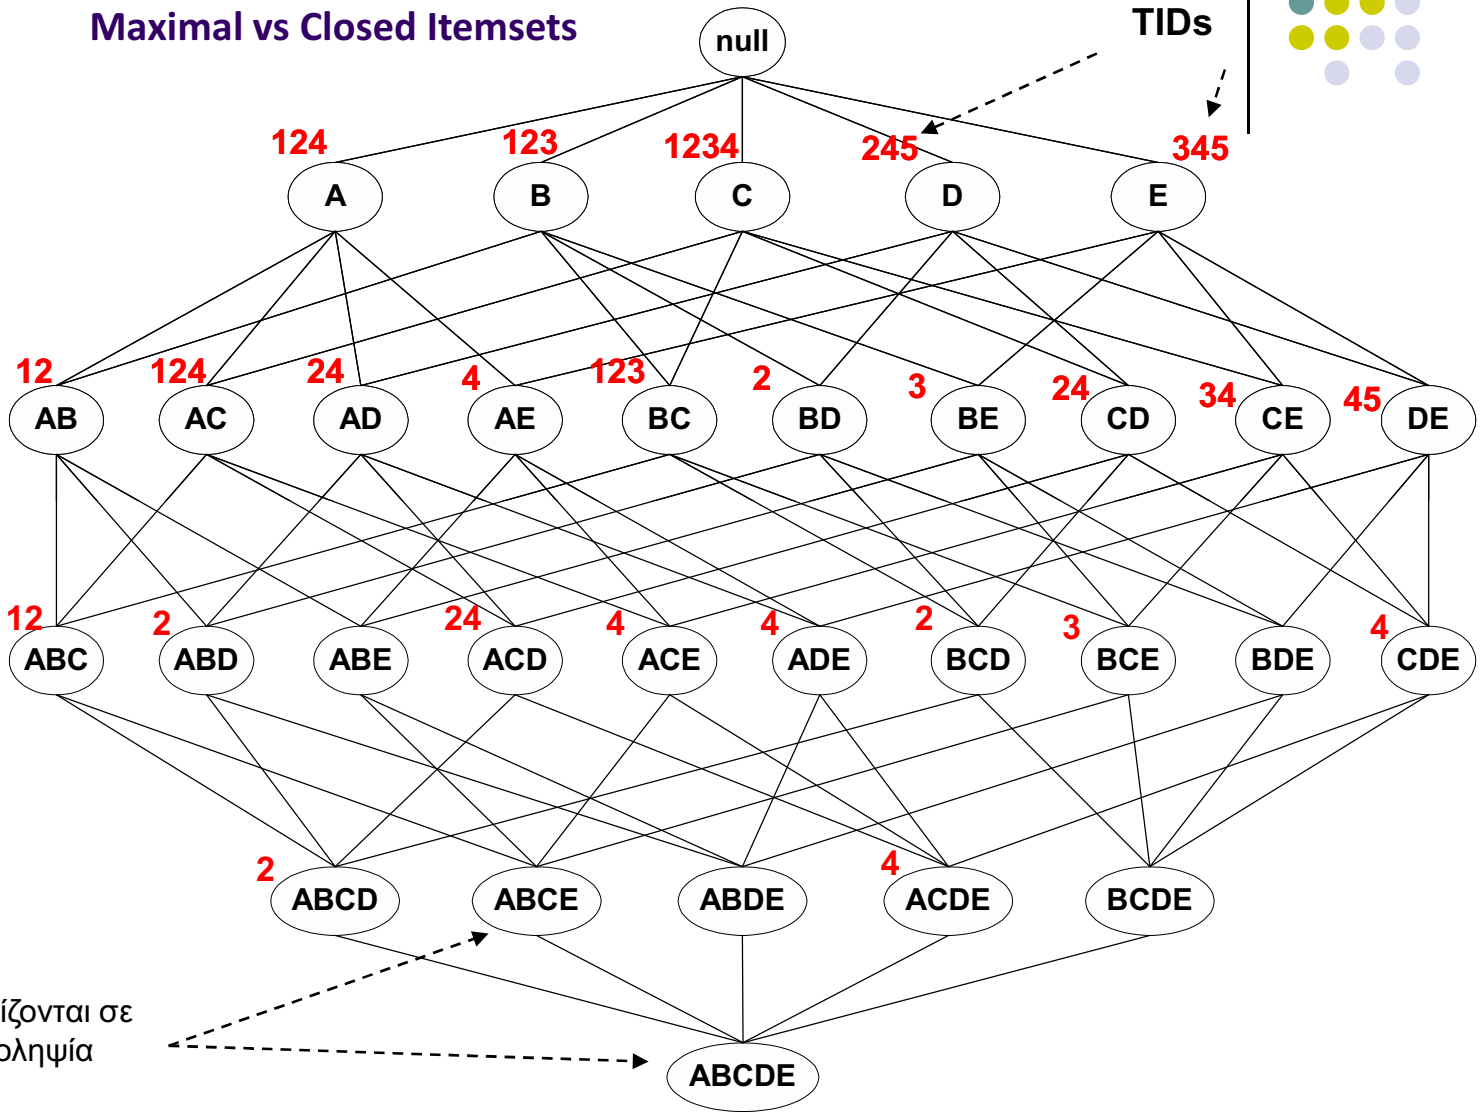
TID	Items
1	{A,B}
2	{B,C,D}
3	{A,B,C,D}
4	{A,B,D}
5	{A,B,C,D}

Itemset	Support
{A}	4
{B}	5
{C}	3
{D}	4
{A,B}	4
{A,C}	2
{A,D}	3
{B,C}	3
{B,D}	4
{C,D}	3

Itemset	Support
{A,B,C}	2
{A,B,D}	3
{A,C,D}	2
{B,C,D}	3
{A,B,C,D}	2

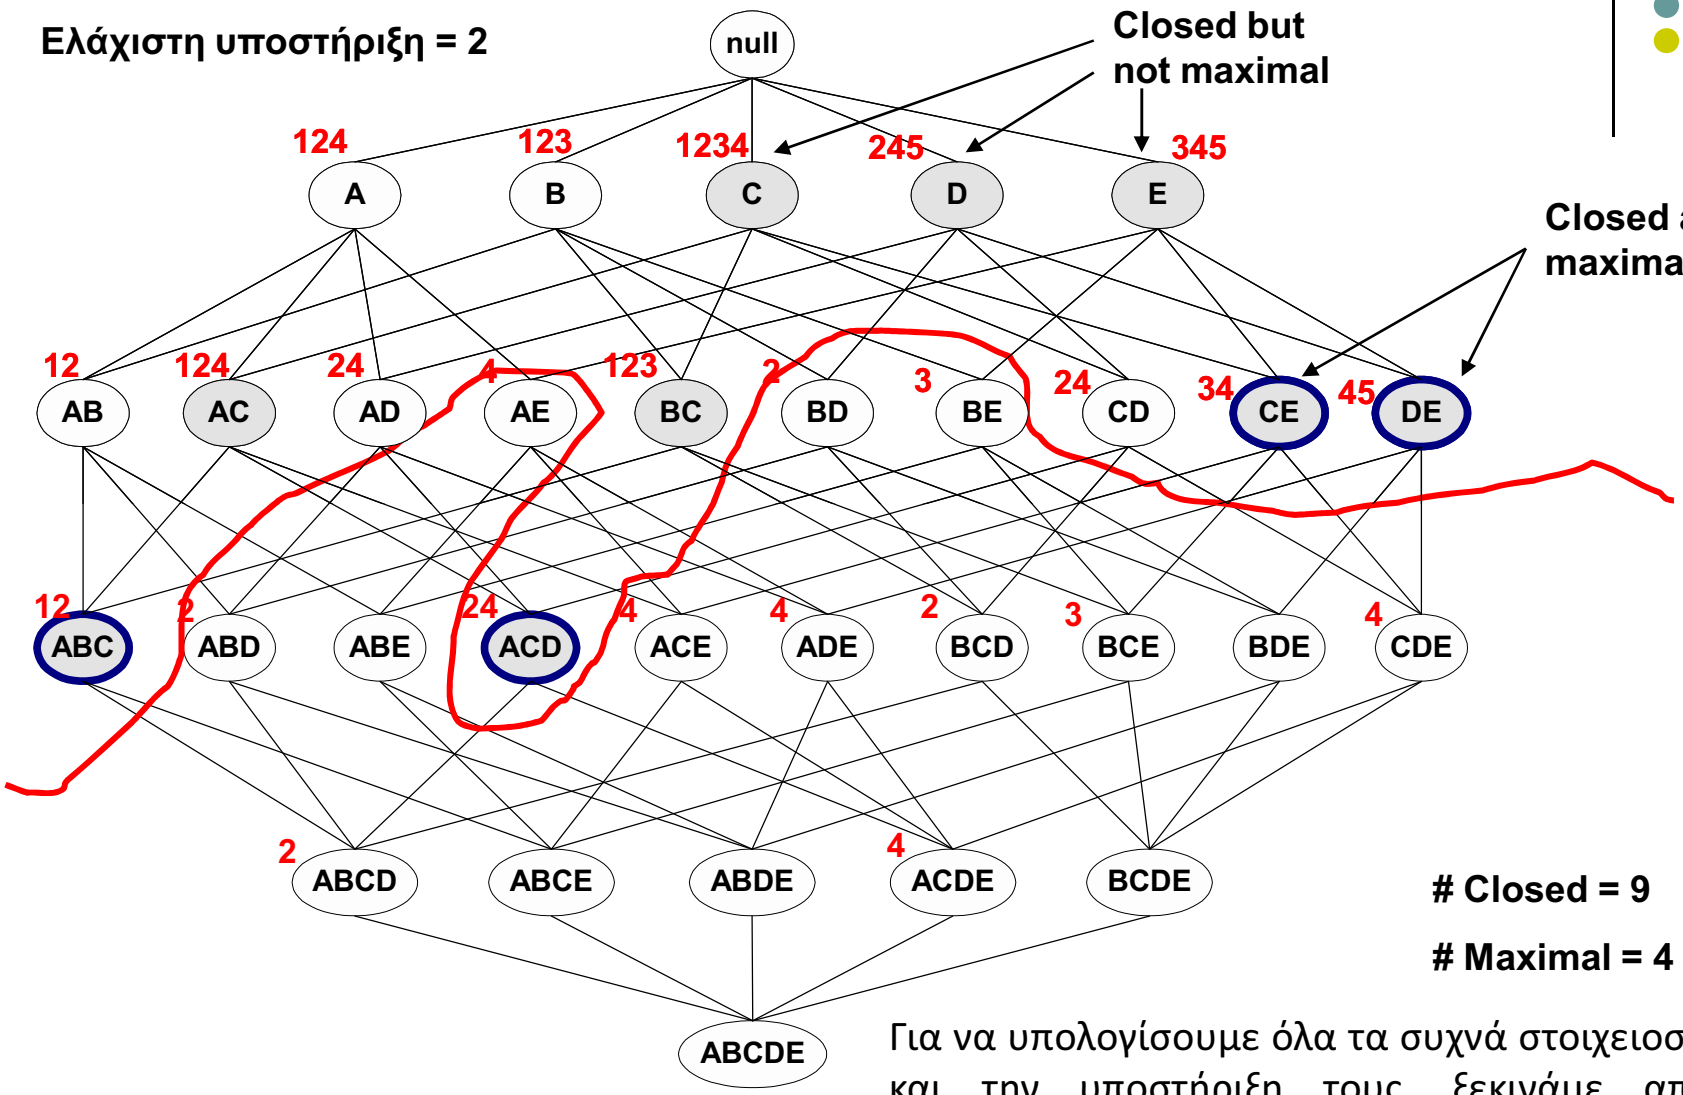
Αναπαράσταση Στοιχειοσυνόλων

TID	Items
1	ABC
2	ABCD
3	BCE
4	ACDE
5	DE



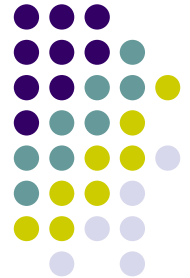
Αναπαράσταση Στοιχειοσυνόλων

Maximal vs Closed Itemsets



Για να υπολογίσουμε όλα τα συχνά στοιχειοσύνολα και την υποστήριξη τους, ξεκινάμε από τα μεγαλύτερα κλειστά και προχωράμε

Αναπαράσταση Στοιχειοσυνόλων



Περιττός κανόνας

$X \rightarrow Y$, αν υπάρχει ένας κανόνας $X' \rightarrow Y'$, όπου $X \subseteq X'$ και $Y \subseteq Y'$ με την ίδια υποστήριξη και εμπιστοσύνη

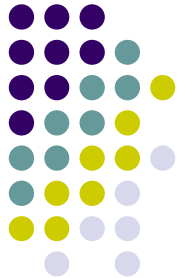
$\{b\} \rightarrow \{d, e\}$ περιττός

$\{b, c\} \rightarrow \{d, e\}$

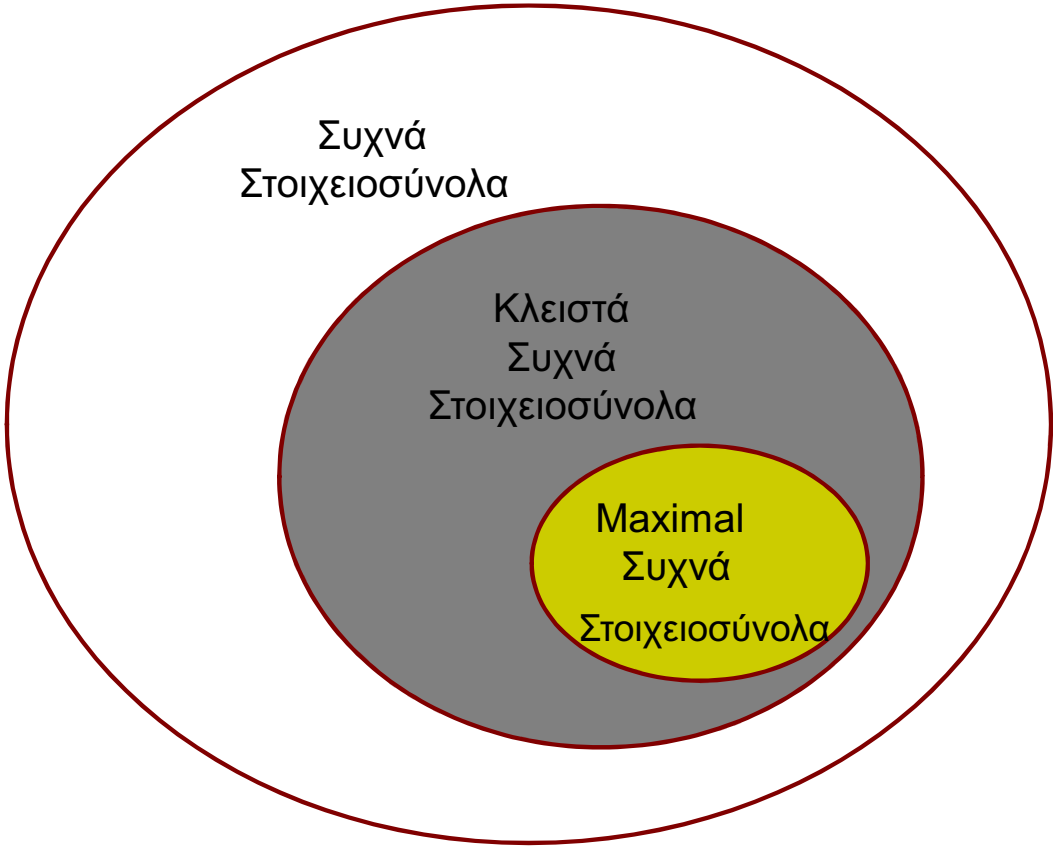
Παρατήρηση: θα κρατήσουμε μόνο το {b, c, d, e}

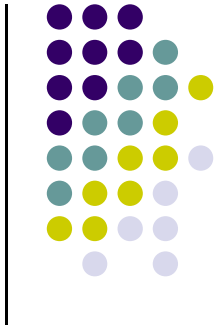
b δεν είναι κλειστό συχνό, ενώ το {b, c} είναι

Αναπαράσταση Στοιχειοσυνόλων



Maximal vs Closed Itemsets





Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων

Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων



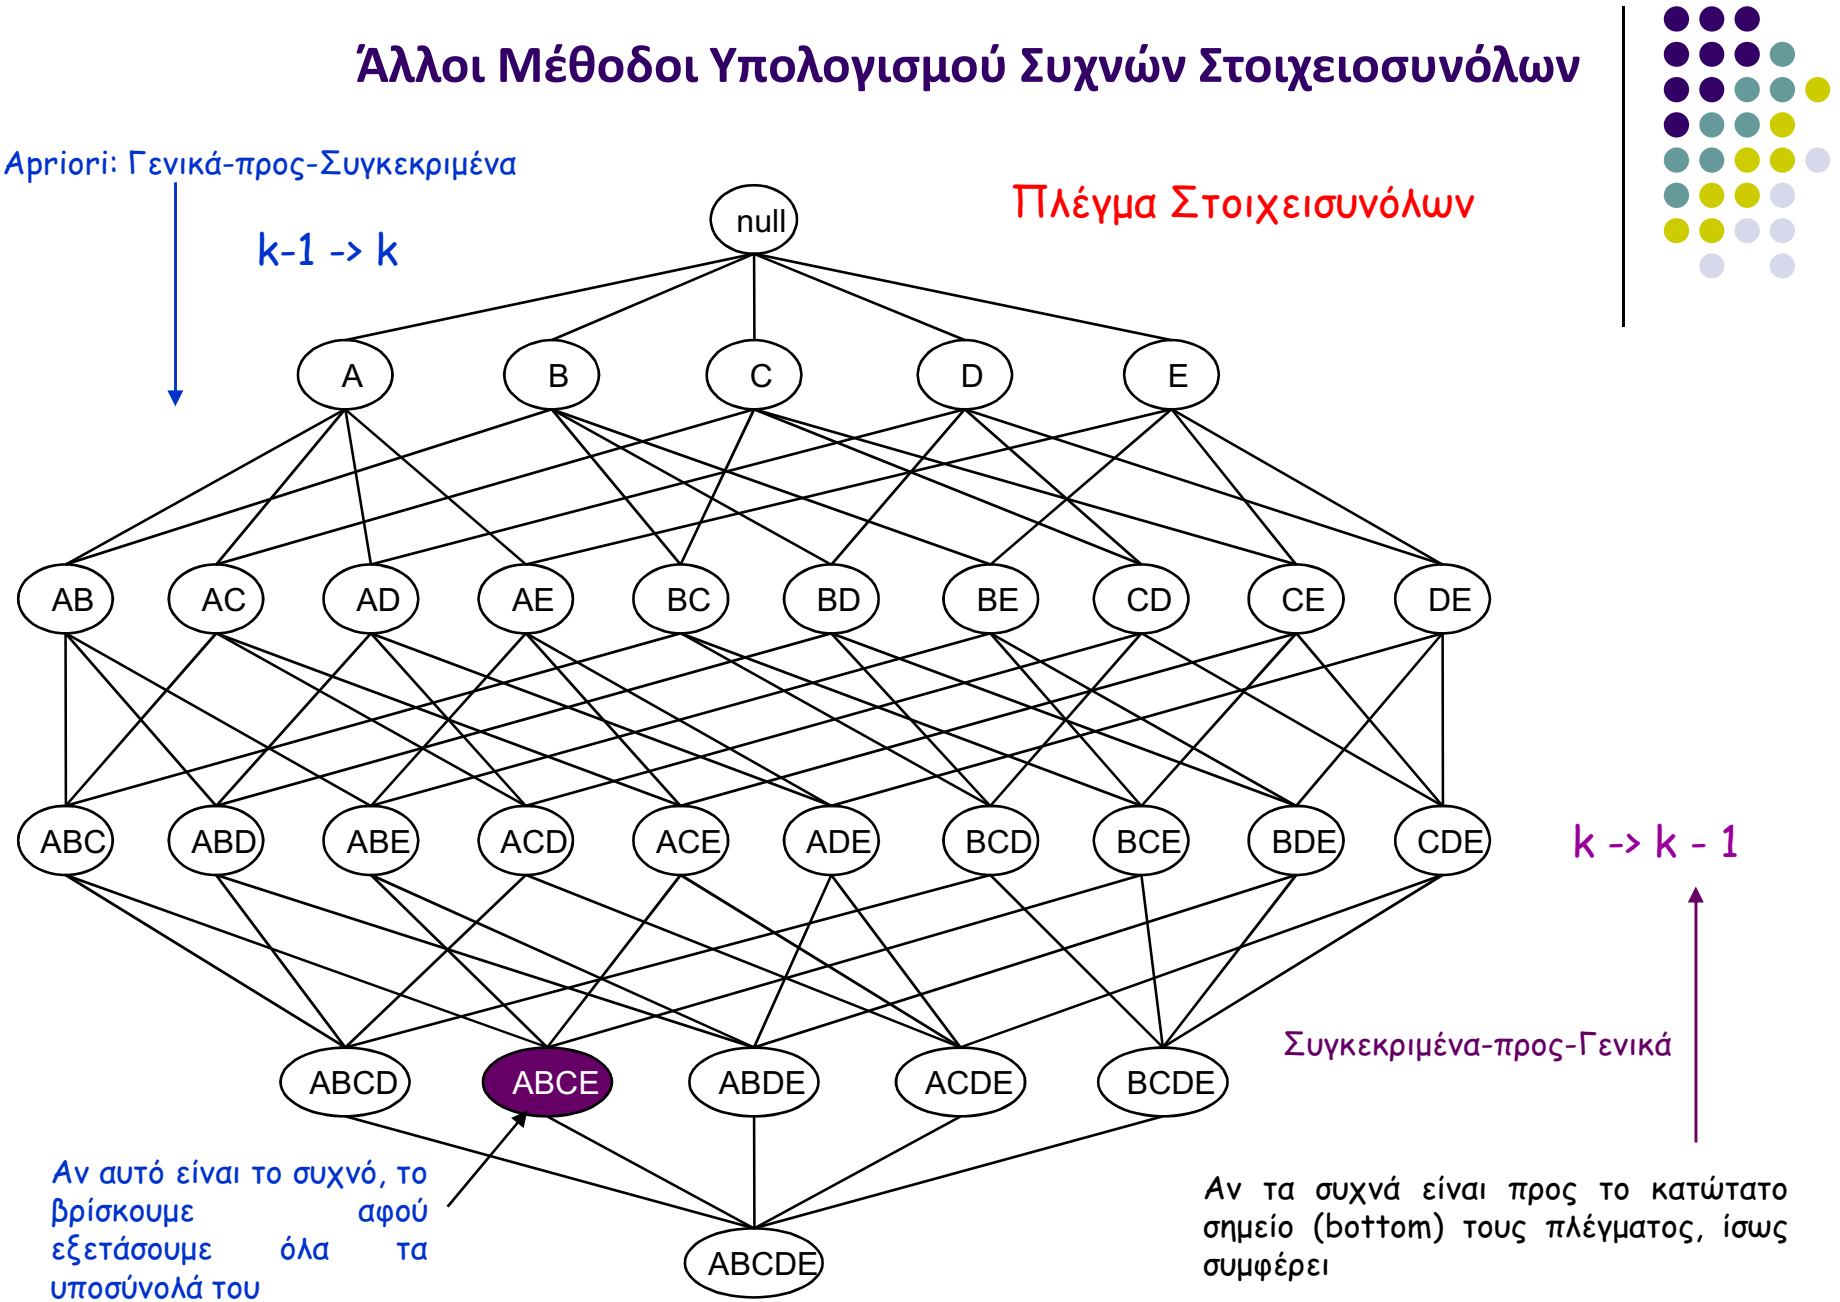
Ο Apriori από τους παλιότερους, αλλά:

- Συχνά μεγάλο I/O επειδή κάνει πολλαπλά περάσματα στη βάση των συναλλαγών
- Κακή απόδοση όταν οι συναλλαγές έχουν μεγάλο πλάτος

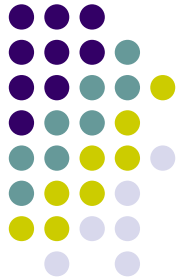
Άλλες μέθοδοι:

- Διαφορετικές διασχίσεις του πλέγματος των στοιχειοσυνόλων
- Αναπαράσταση Συνόλου Συναλλαγών

Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων



Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων

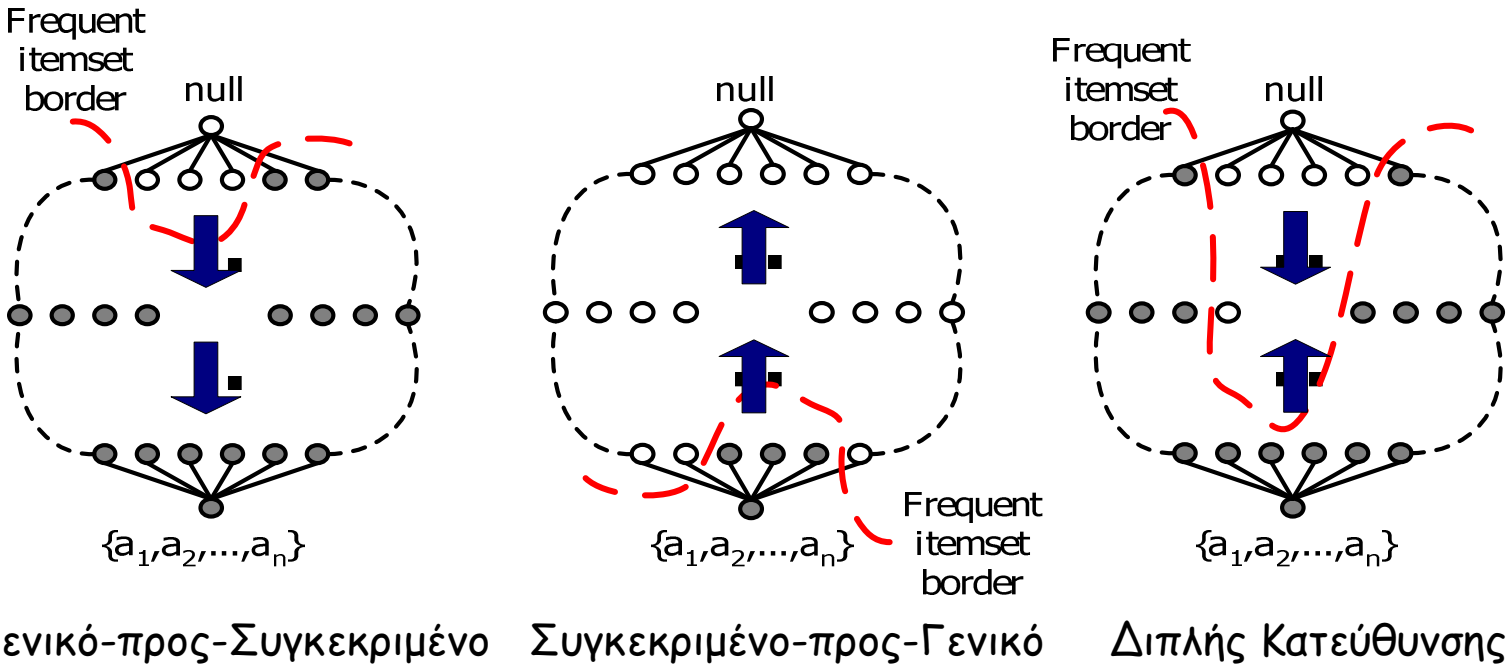


Διάσχιση του Πλέγματος των Στοιχειοσυνόλων: Συγκεκριμένα-προς-Γενικά vs Γενικά-προς-Συγκεκριμένα

k -> k – 1 (συγκεκριμένο-προς-γενικό)

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

Αν συχνό, δε χρειάζεται να ελέγξουμε κανένα από τα υποσύνολά του



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

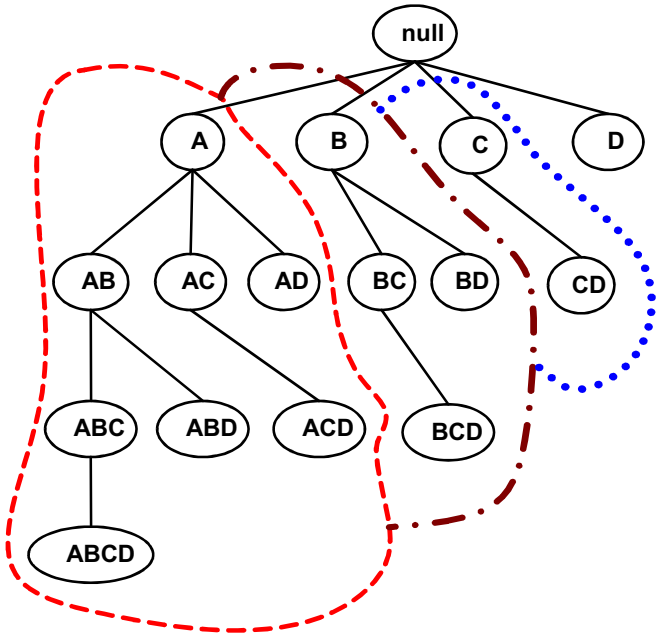
Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων

Διάσχιση του Πλέγματος των Στοιχειοσυνόλων: Κλάσεις Ισοδυναμίας

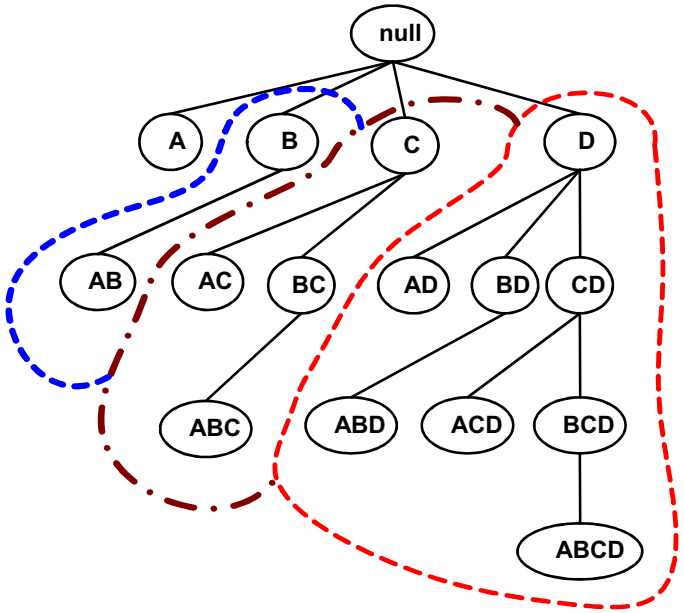
Χωρισμός των στοιχειοσυνόλων του πλέγματος σε ξένες μεταξύ τους ομάδες (κλάσεις ισοδυναμίας) και εξέταση των στοιχειοσυνόλων ανά κλάσεις

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 επίθεμα-κατάληξη) μήκους k



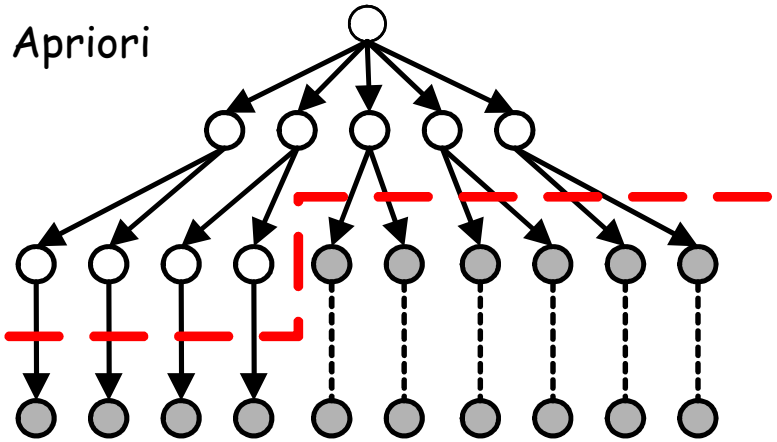
(a) Prefix tree



(b) Suffix tree

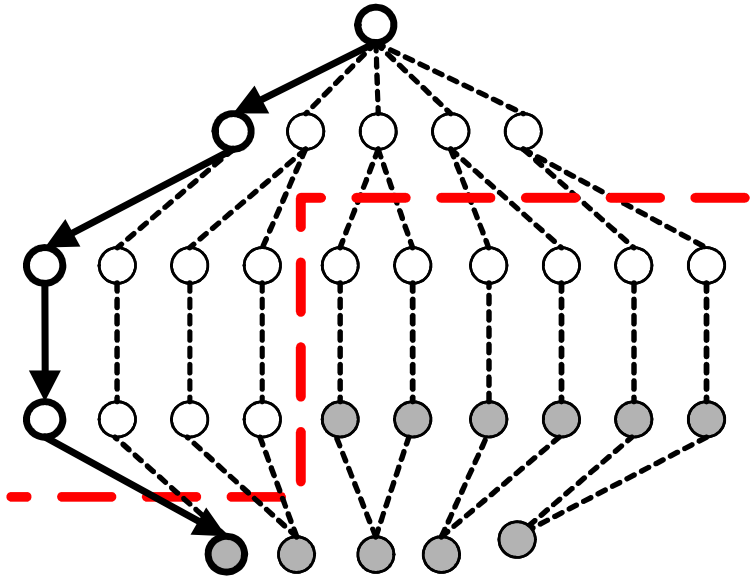
Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων

Διάσχιση του Πλέγματος των Στοιχειοσυνόλων: BFS vs DFS



BFS: Breadth-First-Search
Διάσχιση κατά Πλάτος

DFS: Depth-First-Search
Διάσχιση κατά Βάθος

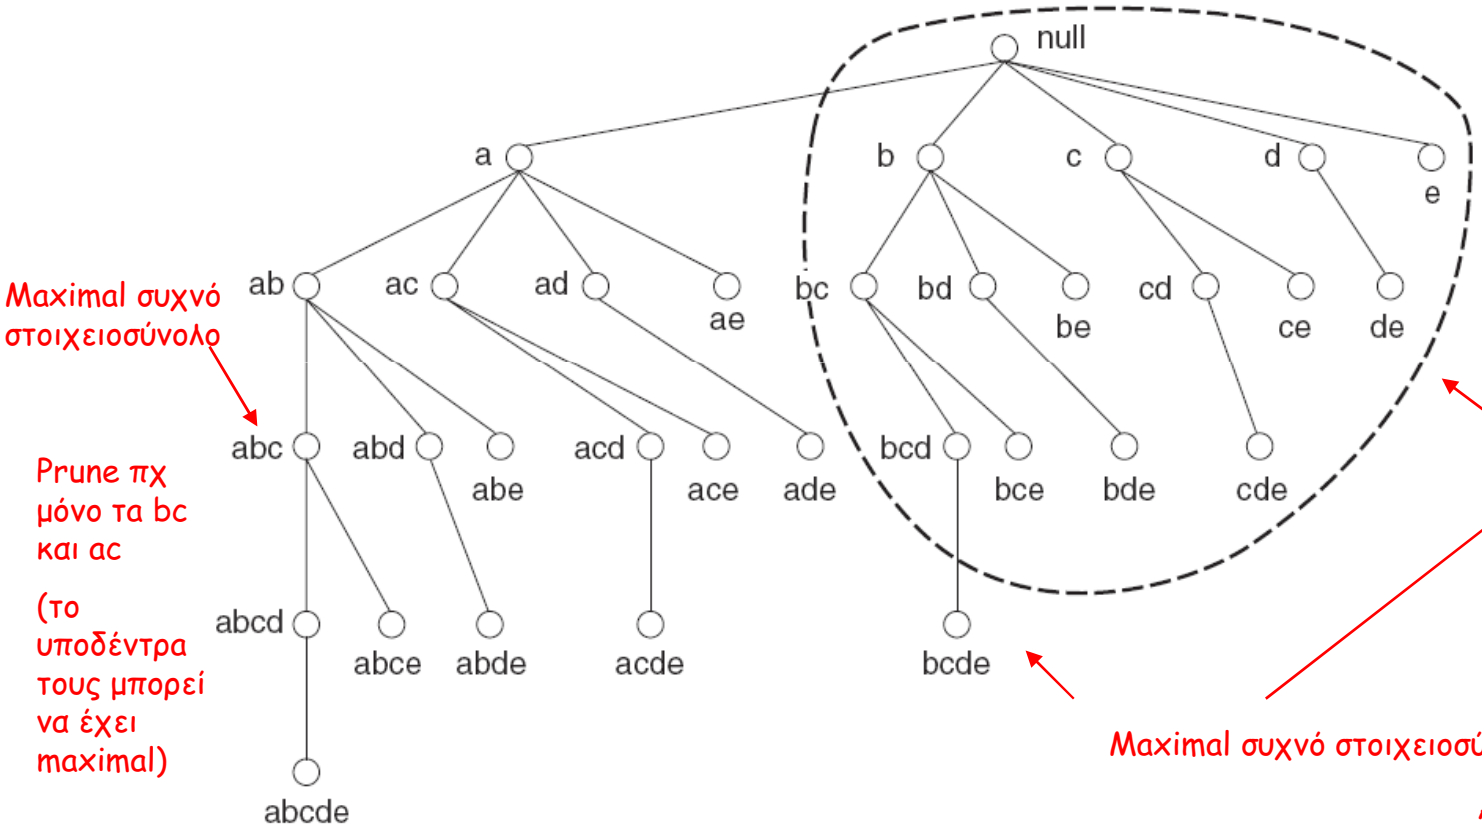


Χρήσιμο για την εύρεση maximal συχνών στοιχειοσυνόλων γιατί τα εντοπίζει πιο γρήγορα από το BFS

Μόλις εντοπιστεί το maximal, είναι δυνατόν να κλαδευτούν πολλά υποσύνολα του

Άλλοι Μέθοδοι Υπολογισμού Συχνών Στοιχειοσυνόλων

Διάσχιση του Πλέγματος των Στοιχειοσυνόλων: BFS vs DFS



Maximal συχνό στοιχειοσύνολο

Prune πχ μόνο τα bc και ac

(το υποδέντρα τους μπορεί να έχει maximal)

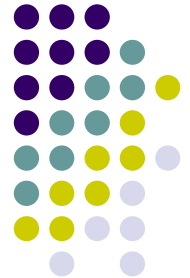
Μπορούμε να κάνουμε prune όλο το υποδέντρο

Maximal συχνό στοιχειοσύνολο

Αν ο abc ίδια υποστήριξη με ab τότε τα υποδέντρα στο abd και abe pruned – δεν έχουν maximal συχνό

Figure 6.22. Generating candidate itemsets using the depth-first approach.

Άλλοι Τρόποι Υπολογισμού



Αναπαράσταση της Βάσης Δεδομένων των Συναλλαγών: Οριζόντια vs Κάθετη

Αυτό χρησιμοποιεί ο apriori

↓

Οριζόντια Διάρθρωση Δεδομένων

TID	Items
1	A,B,E
2	B,C,D
3	C,E
4	A,C,D
5	A,B,C,D
6	A,E
7	A,B
8	A,B,C
9	A,C,D
10	B

Εναλλακτικά:

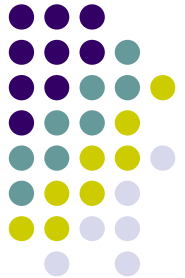
Για κάθε στοιχείο σε ποιες συναλλαγές εμφανίζεται

Κάθετη Διάρθρωση Δεδομένων

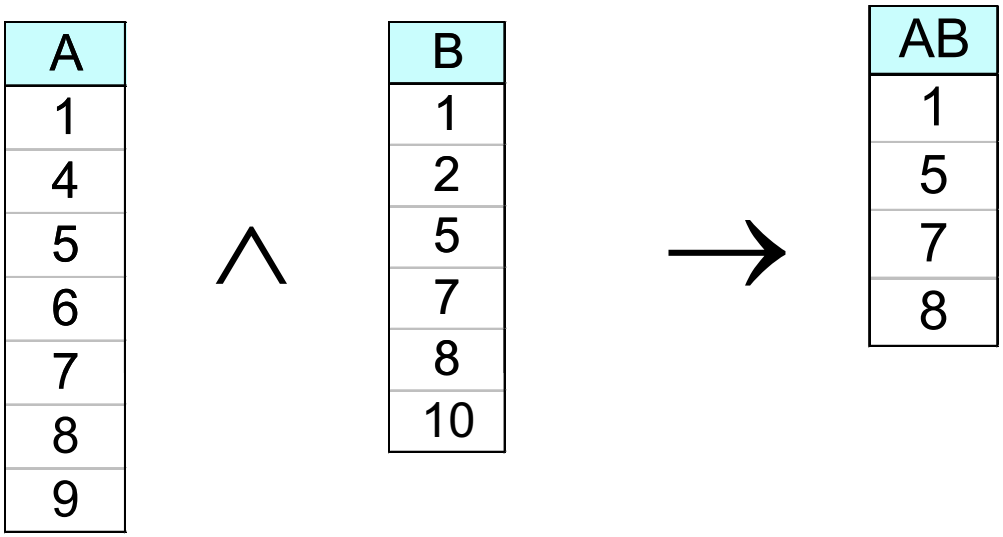
A	B	C	D	E
1	1	2	2	1
4	2	3	4	3
5	5	4	5	6
6	7	8	9	
7	8	9		
8	10			
9				

Η υποστήριξη υπολογίζεται παίρνοντας τις τομές των TID-λιστών

Άλλοι Τρόποι Υπολογισμού



Η υποστήριξη υπολογίζεται παίρνοντας τις τομές των TID-λιστών



- Η υποστήριξη ενός k-στοιχειοσυνόλου υπολογίζεται παίρνοντας τις τομές των TID-λιστών δύο από τα (k-1)-ύπο-στοιχειοσύνολα του.

- Πλεονέκτημα: πολύ γρήγορος υπολογισμός της υποστήριξης
- Πρόβλημα, αν οι TID-λίστες είναι μεγάλες και δε χωρούν στη μνήμη

Θα δούμε τον FP-Growth που χρησιμοποιεί μια prefix-based αναπαράσταση των συναλλαγών