

ΣΧΕΔΙΑΣΜΟΣ ΒΑΣΕΩΝ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΚΑΝΟΝΙΚΟΠΟΙΗΣΗ

Α' μέρος

Σύνοψη

- Σχεσιακός Σχεδιασμός - Στόχοι
- Κριτήρια / Οδηγίες για ένα “καλό” Σχεδιασμό
- Συναρτησιακές Εξαρτήσεις - Οι Κανονικές Μορφές ΒΔ
- Αποσυνθέσεις Σχέσεων (Decompositions)
- Συνθήκη Διατήρησης Εξαρτήσεων (dependency preservation) και Συνενώσεις άνευ απωλειών (lossless-joins)
- Άλλες Συναρτησιακές Εξαρτήσεις (Multivalued, Join)

Σχεσιακές Βάσεις – Λογικός Σχεδιασμός

- Σχεδιασμός Σχέσεων:

Ομαδοποίηση Γνωρισμάτων έτσι ώστε να επιτευχθούν “καλά” σχήματα Σχέσεων

- Άτυπα κριτήρια:

- Προσπάθεια για εννοιολογική καθαρότητα
- Προσπάθεια για αποδοτικότητα χώρου (αποφυγή πλεονασμού)
- Προσπάθεια για ακεραιότητα (αποφυγή ανωμαλιών ενημέρωσης)
- Προσπάθεια για πληρότητα (αποφυγή NULL τιμών σε πλειάδες)
- Προσπάθεια για γλωσσολογική αποδοτικότητα
- Προσπάθεια για καλή επίδοση (performance)

Εννοιολογική καθαρότητα

- Ανεπίσημα (και στην ιδανική περίπτωση), **κάθε πλειάδα** πρέπει να παριστά **ακριβώς μια** οντότητα ή **ένα** στιγμιότυπο συσχέτισης
- Με άλλα λόγια, οι πλειάδες δεν πρέπει να είναι **υπερφορτωμένες** με εννοιολογική πληροφορία (δηλαδή, δεν πρέπει να παριστούν περισσότερα του ενός γεγονότα)
- Διακριτές οντότητες δεν πρέπει να αναμιγνύονται – ο **μόνος** τρόπος για **ένδο-αναφορές** μεταξύ Σχέσεων πρέπει να είναι το “**εξωτερικό κλειδί**”

Αποδοτικότητα χώρου

- Αποφυγή πλεονασμού
- Πλεονασμός χώρου (redundancy) σημαίνει χάσιμο χώρου
- Ο πλεονασμός φέρνει **ανωμαλίες**
(ονομάζονται, ανωμαλίες ενημέρωσης - *update anomalies*)

Προσπάθεια για ακεραιότητα

- Αποφυγή ανωμαλιών ενημέρωσης
- Η ακεραιότητα της Βάσης φθείρεται όταν συμβαίνουν ανωμαλίες εισαγωγής, διαγραφής και τροποποίησης
- Έχουμε ανωμαλία όταν μια ενημέρωση σε ένα σημείο επιφέρει έναν μη-προσδιορίσιμο αριθμό ενημερώσεων σε άλλα σημεία της Βάσης.

Προσπάθεια για πληρότητα

- Αποφυγή NULL τιμών σε πλειάδες
- Οι τιμές Null σημαίνουν “έλλειψη γνώσης” ή “μη-εφαρμοσιμότητα” και συχνά προκαλούν λάθη σε ερωτήσεις
- Για να γίνει σωστή η εκτέλεση των ερωτήσεων απαιτείται διαφορετική λογική από αυτή που χρησιμοποιούμε σε πρακτικά/εμπορικά συστήματα – λογική δύο τιμών αληθείας (true /false)

Προσπάθεια για γλωσσολογική αποδοτικότητα

- Όσο πιο απλά μπορούν να εκφραστούν οι ερωτήσεις στην εφαρμογή – τόσο το καλύτερο για τον προγραμματιστή / χρήστη και (συνήθως) για τον Βελτιστοποιητή Ερωτήσεων του συστήματος
- Οι Ερωτήσεις γίνονται πιο εύκολα σε Σχέσεις που έχουν πολλές πληροφορίες / γνωρίσματα (π.χ., δεν χρειάζονται πολλές συνενώσεις)

Προσπάθεια για καλή επίδοση

- Απόδοση: Αριθμός ερωτημάτων ή ενημερώσεων που μπορούν να υποστούν επεξεργασία ανά μονάδα χρόνου
- Χρόνος απόκρισης: Ο χρόνος που χρειάζεται για να ολοκληρωθεί μια μόνο συναλλαγή από την αρχή ως το τέλος της (στη μέση ή στη χειρότερη περίπτωση)
- Όπως και στην προηγούμενη περίπτωση, Σχέσεις με λίγα Γνωρίσματα (π.χ., δυαδικές), επιφέρουν ένα μεγάλο αριθμό συνενώσεων για την εκτέλεση ερωτήσεων – χειρότερη απόδοση

Παράδειγμα «Κακού» Σχεδιασμού

- Έστω η Βάση με ένα Σχήμα Σχέσης:

ED(SSN, EName, Salary, DNumber, DName, Location, MgrSSN)

Q1: *Βρες όλους τους Υπαλλήλους που βγάζουν πιο πολλά από τον Προϊστάμενό τους*

```
select e.EName
from   ED e, ED m
where  e.MgrSSN = m.SSN and e.Salary > m.Salary
```

Q2: *Για κάθε Τμήμα, Βρες τον μέγιστο μισθό*

```
select      DName, max(Salary)
from        ED
group by    DNumber
```

Παράδειγμα «Κακού» Σχεδιασμού (2)

ED(SSN, EName, Salary, DNumber, DName, Location, MgrSSN)

■ ΣΧΟΛΙΑ

- Οι παραπάνω ερωτήσεις γίνονται με απλό τρόπο (**linguistic efficiency**)
ΑΛΛΑ:

(α) **Πλεονασμοί**: Οι πληροφορίες ενός Τμήματος επαναλαμβάνονται για κάθε **υπάλληλο** του Τμήματος

(β) **Ανωμαλίες Τροποποιήσεων**: Σε μια απλή τροποποίηση (π.χ., αλλάζοντας τον Προϊστάμενο ενός Τμήματος) ένας **ανεξέλεγκτος αριθμός πλειάδων πρέπει να τροποποιηθεί**

(γ) **Ανωμαλίες Εισαγωγής**: Πληροφορίες για ένα νέο Τμήμα **δεν είναι δυνατό να εισαχθούν** στη Βάση αν δεν υπάρχει κάποιος Υπάλληλος που (ήδη) εργάζεται στο Τμήμα.

(δ) **Ανωμαλίες Διαγραφής**: Όταν διαγράφεται και ο τελευταίος υπάλληλος που εργάζεται σε ένα Τμήμα, **χάνουμε τις πληροφορίες για το ίδιο το Τμήμα**

Παράδειγμα «Καλύτερου» Σχεδιασμού

- Μπορούμε να επιλέξουμε έναν **ισοδύναμο** (του προηγούμενου) Σχεδιασμό με δύο Σχέσεις:

EMPLOYEE(SSN, EName, Salary, DNumber)

DEPARTMENT(DNumber, DName, Location, MgrSSN)

Q1: *Βρες όλους τους Υπαλλήλους που βγάζουν πιο πολλά από τον Προϊστάμενό τους*

```
select  e.EName
from    EMPLOYEE e, EMPLOYEE m, DEPARTMENT d
where   e.DNumber = d.DNumber and e.MgrSSN = m.SSN
and     e.Salary > m.Salary
```

Παράδειγμα «Καλύτερου» Σχεδιασμού (2)

Q2: *Για κάθε Τμήμα, Βρες τον μέγιστο μισθό*

```
select    d.DName, max(e.Salary)
from      EMPLOYEE e, DEPARTMENT d
where     d.DNumber = e.DNumber
group by  d.DNumber
```

- Αυτές οι ερωτήσεις είναι σύνθετες (**linguistic inefficiency**) και απαιτούν περισσότερες συνενώσεις (**performance**), **ΑΛΛΑ ΑΠΟΦΕΥΓΟΥΝ ΟΛΕΣ ΤΙΣ ανωμαλίες τροποποίησης (update anomalies)**
- *Ο Στόχος μας στη συνέχεια είναι να δούμε ΠΩΣ η κατάληξη σε καλούς Σχεδιασμούς μπορεί να γίνει **ΤΥΠΙΚΑ** και **ΣΥΣΤΗΜΑΤΙΚΑ***

Μια Απλή περίπτωση Κανονικοποίησης (α)

- Έστω μια Σχέση για EMPLOYEES
- Μερικοί Υπάλληλοι έχουν περισσότερα του ενός γραφεία
- ΠΩΣ το παρουσιάζουμε αυτό???

EID	LastName	FirstName	Salary	Office
1	Long	Mark	10k	Austin
2	Smith	Lisa	45K	Boston
3	Harris	Dave	60K	Atlanta
4	Davis	James	42K	Dallas
5	Jackson	Harold	35K	Denver

Μια Απλή περίπτωση Κανονικοποίησης (β)

- Μερικοί Υπάλληλοι έχουν περισσότερα του ενός γραφεία
- ΠΩΣ το παρουσιάζουμε αυτό???
- ΛΥΣΗ με πολλές στήλες
(δαπανά χώρο, κάνει δύσκολα μερικά ερωτήματα, κλπ)

EID	LastName	FirstName	Salary	Office1	Office2
1	Long	Mark	10k	Austin	
2	Smith	Lisa	45K	Boston	Seattle
3	Harris	Dave	60K	Atlanta	
4	Davis	James	42K	Dallas	
5	Jackson	Harold	35K	Denver	Miami

Μια Απλή περίπτωση Κανονικοποίησης (γ)

- Μερικοί Υπάλληλοι έχουν περισσότερα του ενός γραφεία
- ΛΥΣΗ με Κανονικοποίηση σε 2 Σχέσεις

Συχνά αποκαλείται: «Σχέσεις με Κύριο / Εξωτερικό Κλειδί»

EID	LastName	FirstName	Salary
1	Long	Mark	10k
2	Smith	Lisa	45K
3	Harris	Dave	60K
4	Davis	James	42K
5	Jackson	Harold	35K

EID	Office
1	Austin
2	Boston
2	Seattle
3	Atlanta
4	Dallas
5	Denver
5	Miami

ΣΥΝΑΡΤΗΣΙΑΚΕΣ ΕΞΑΡΤΗΣΕΙΣ

- Οι Συναρτησιακές Εξαρτήσεις (Functional Dependencies – FD) είναι το πιο κοινό **τυπικό** μέτρο του “καλού” για Σχεσιακούς Σχεδιασμούς
- Χρησιμοποιούνται για τον ορισμό των **Κανονικών Μορφών** για Σχέσεις
- Μια FD αποτελεί έναν *περιορισμό* για όλα τα στιγμιότυπα της Σχέσης $r(\mathbf{R})$, αλλά είναι *μια ιδιότητα* των γνωρισμάτων στο Σχήμα \mathbf{R}
- *ΤΥΠΙΚΟΣ ΟΡΙΣΜΟΣ:* Έστω X, Y σύνολα Γνωρισμάτων στο Σχήμα Σχέσης R . Λέμε ότι η Συναρτησιακή Εξάρτηση (FD):
$$X \rightarrow Y$$
ισχύει αν η X-τιμή καθορίζει μοναδικά την Y-τιμή.

FD Ορισμοί

- *ΕΝΑΛΛΑΚΤΙΚΟΣ ΟΡΙΣΜΟΣ*: Έστω X, Y σύνολα Γνωρισμάτων στο Σχήμα Σχέσης R . Λέμε ότι η Συναρτησιακή Εξάρτηση (FD):

$$X \rightarrow Y$$

ισχύει αν, όποτε δύο πλειάδες σε ένα στιγμιότυπο $r(R)$ έχουν την ίδια τιμή για το X , τότε *πρέπει να έχουν* την ίδια τιμή για το Y

Δηλαδή:

για οποιεσδήποτε δύο πλειάδες t_1, t_2 σε κάθε σχέση $r(R)$:

$$\text{Αν } t_1[X] = t_2[X] \text{ τότε } t_1[Y] = t_2[Y]$$

- Αν το K είναι **Κλειδί στην R** , τότε το K εξαρτά συναρτησιακά ΟΛΑ τα Γνωρίσματα στην R (μια και δεν μπορούμε ποτέ να έχουμε διακριτές πλειάδες t_1, t_2 με $t_1[K] = t_2[K]$)

Ιδιότητες των FD

- **Τετριμμένη Συναρτησιακή Εξάρτηση:**

Όποτε $Y \subseteq X$, τότε $X \rightarrow Y$

Παράδειγμα: $SSN, Salary \rightarrow Salary$

- **Πλήρης Συναρτησιακή Εξάρτηση:**

Λέμε ότι ένα σύνολο γνωρισμάτων Y είναι **πλήρως εξαρτώμενο συναρτησιακά** από ένα σύνολο X , αν είναι συναρτησιακά εξαρτώμενο από το X και **δεν είναι** συναρτησιακά εξαρτώμενο από κάποιο υποσύνολο του X ,

Δηλαδή, το Y είναι **πλήρως εξαρτώμενο συναρτησιακά** από το X , αν $X \rightarrow Y$ και **δεν υπάρχει** W έτσι ώστε $W \subset X$ and $W \rightarrow Y$

Παράδειγμα: $SSN, PNumber \rightarrow HoursPW$

Ιδιότητες των FD (2)

- **Μερική Εξάρτηση:** Σαν συνέπεια του παραπάνω ορισμού, λέμε ότι το Y είναι **μερικό εξαρτώμενο** από το X , αν $X \rightarrow Y$ και δεν υπάρχει κάποιο W έτσι ώστε $W \subset X$ και $W \rightarrow Y$

Παράδειγμα: $SSN, Salary \rightarrow Address$ (αλλά και, $SSN \rightarrow Address$)

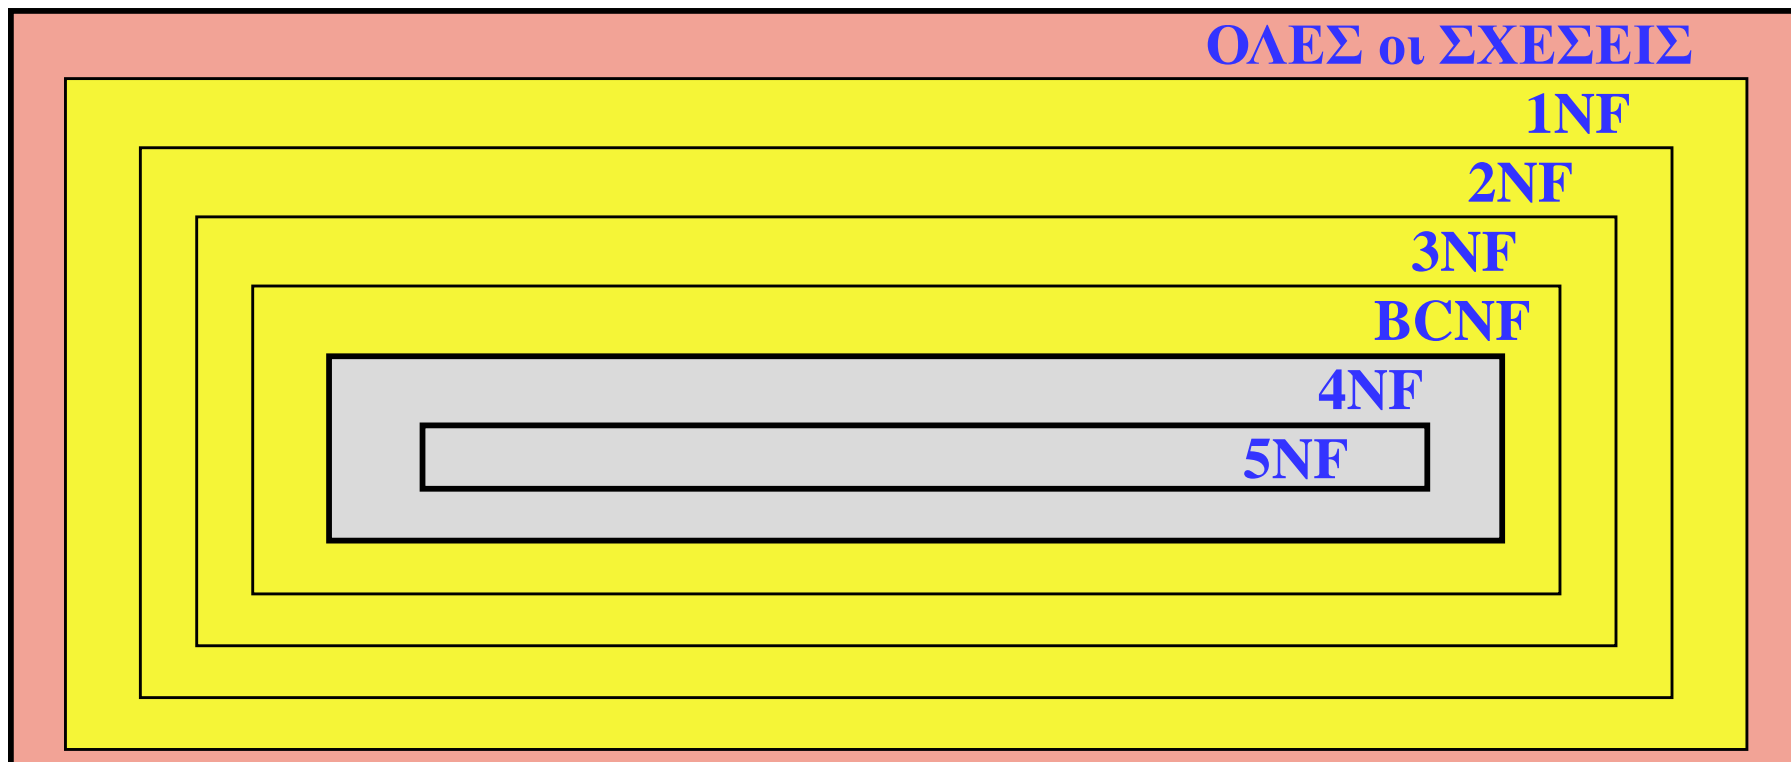
- **Μεταβατική Εξάρτηση:** Μια συναρτησιακή εξάρτηση $X \rightarrow Z$ είναι **μεταβατική** αν μπορεί να προέλθει / απορρέει από δύο άλλες FD με μεταβατικότητα ($X \rightarrow Y$ και $Y \rightarrow Z$)

Παράδειγμα: $SSN \rightarrow DNumber$ και $DNumber \rightarrow MgrSSN$,
συνεπάγονται: $SSN \rightarrow MgrSSN$

- **Πρωτεύον Γνώρισμα:** Ένα Γνώρισμα που είναι μέλος κάποιου υποψήφιου κλειδιού

ΚΑΝΟΝΙΚΟΠΟΙΗΣΗ

- Η διαδικασία της Κανονικοποίησης *ενσωματώνει* την εννοιολογική έννοια της FD στα **Σχήματα Σχέσεων**.
- Υπάρχουν **Κανονικές Μορφές Σχημάτων**, όπου τα παρακάτω αποδεικνύονται:



Κανονικές Μορφές (1)

- **Πρώτη Κανονική Μορφή (1NF):** Η R είναι σε 1NF αν κάθε Γνώρισμα παίρνει ατομικές / αδιαίρετες τιμές. Θεωρούμε ότι οι Σχέσεις που δουλεύουμε είναι τουλάχιστον σε 1NF (αυτό σε σύγχρονα DBMS δεν ισχύει – π.χ., πολυμέσα, γεωγραφικές πληροφορίες, κλπ).

Παράδειγμα: **R(ENumber, ChildrenNames)** ΔΕΝ ΕΙΝΑΙ σε 1NF

- **Δεύτερη Κανονική Μορφή (2NF):** Η R είναι σε 2NF αν είναι σε 1NF και κανένα μη-πρωτεύον Γνώρισμα δεν είναι μερικώς εξαρτώμενο από ένα υποψήφιο κλειδί.

Παράδειγμα : **SUPPLIER(SNumber, SName, ItemNumber, Price)**
ΔΕΝ ΕΙΝΑΙ σε 2NF, γιατί ο συνδυασμός SNumber, ItemNumber είναι υποψήφιο κλειδί, αλλά επίσης SNumber → SName ισχύει

Κανονικές Μορφές (2)

- **Τρίτη Κανονική Μορφή (3NF):** Η R είναι σε 3NF αν είναι σε 2NF και κανένα μη-πρωτεύον Γνώρισμα δεν είναι μεταβατικά εξαρτώμενο από ένα υποψήφιο κλειδί

Παράδειγμα: Η Σχέση:

ED(SSN, EName, Salary, DNumber, DName, Location, MgrSSN)

είναι σε 2NF ΑΛΛΑ ΔΕΝ ΕΙΝΑΙ σε 3NF, διότι

Το SSN είναι (το μόνο) υποψήφιο κλειδί και έχουμε:

SSN → Dnumber και DNumber → MgrSSN

(δηλαδή, το MgrSSN είναι μεταβατικά εξαρτώμενο από το SSN)

Κανονικές Μορφές (3)

- **Ισοδύναμος Ορισμός της ΤΡΙΤΗΣ ΚΑΝΟΝΙΚΗΣ ΜΟΡΦΗΣ (3NF):** Η R είναι σε 3NF αν και μόνο εάν για κάθε FD $X \rightarrow A$, όπου X είναι ένα σύνολο γνωρισμάτων της R και A είναι απλό Γνώρισμα, **τουλάχιστο ένα από τα παρακάτω τρία ισχύει**

- 1.- $A \subseteq X$ (η FD είναι τετριμμένη)
- 2.- $K \subseteq X$ (με το K υποψήφιο κλειδί του R)
- 3.- $A \subseteq K$ (με το K υποψήφιο κλειδί του R)

Κανονικές Μορφές (4)

- **Κανονική Μορφή BOYCE-CODD (BCNF):** Η R είναι σε BCNF αν και μόνο εάν όποτε μια **FD** $X \rightarrow Y$ ισχύει τότε το X είναι υποψήφιο κλειδί (όπου X, Y είναι σύνολα Γνωρισμάτων του R)
- **Ισοδύναμος Ορισμός του BOYCE-CODD NORMAL FORM (BCNF):** Η R είναι σε BCNF αν και μόνο εάν για κάθε **FD** $X \rightarrow A$, όπου το X είναι σύνολο γνωρισμάτων του R και A είναι απλό γνώρισμα, τουλάχιστον ένα από τα παρακάτω ισχύει:

1.- $A \subseteq X$ (η FD είναι τετριμμένη)

2.- $K \subseteq X$ (με το K υποψήφιο κλειδί του R)

Σημείωση: Ακριβώς όπως η 3NF χωρίς την επιλογή 3., που άμεσα δείχνει ότι η **BCNF** συνεπάγεται την 3NF

Κανονικές Μορφές (5)

Παράδειγμα: Η Σχέση:

RESTAURANT(Client, Food, ReceiptNumber)

είναι σε 3NF **ΑΛΛΑ ΔΕΝ ΕΙΝΑΙ** σε BCNF, διότι ισχύουν:

Client, Food \rightarrow ReceiptNumber, και

ReceiptNumber \rightarrow Food (αυτή δεν είναι εξάρτηση από κλειδί)

- Κάθε Σχέση είναι δυνατόν να μετασχηματιστεί σε **ισοδύναμες** σχέσεις σε 3NF (χρησιμοποιώντας καλά ορισμένους αλγορίθμους). Η διαδικασία αυτή ονομάζεται **Αποσύνθεση** ή **3NF Κανονικοποίηση**.
- Δυστυχώς, υπάρχουν κάποιες 3NF σχέσεις που **δεν είναι δυνατόν να** μετασχηματιστούν σε BCNF (όπως το χαρακτηριστικό παράδειγμα παραπάνω)

Κανονικές Μορφές Πέραν της Τρίτης

■ 4^η Κανονική Μορφή (4NF)

Απομόνωση των ανεξάρτητων πολλαπλών σχέσεων μεταξύ δεδομένων

■ 5^η Κανονική Μορφή (5NF)

Απομόνωση των εννοιολογικά σχετιζόμενων πολλαπλών σχέσεων μεταξύ δεδομένων

Παράδειγμα 4^{ης} Κανονικής Μορφής (α)

Έστω η Σχέση (για Πωλήσεις Προϊόντων) σε 3 NF

ΠΡΟΙΟΝ	ΧΡΩΜΑ	ΜΕΓΕΘΟΣ
Footer	Κόκκινο	Small
Footer	Κόκκινο	Medium
Footer	Κόκκινο	Large
Footer	Πράσινο	Small
Footer	Πράσινο	Medium
Footer	Πράσινο	Large

Παράδειγμα 4^{ης} Κανονικής Μορφής (β)

σε 4^η NF με ΔΥΟ ΠΙΝΑΚΕΣ

ΠΡΟΙΟΝ	ΧΡΩΜΑ
Footer	Κόκκινο
Footer	Πράσινο

ΠΡΟΙΟΝ	ΜΕΓΕΘΟΣ
Footer	Small
Footer	Medium
Footer	Large

Παράδειγμα 5^{ης} Κανονικής Μορφής (α)

Έστω η Σχέση (για Πωλήσεις Προϊόντων) σε 3 NF

ΠΡΟΙΟΝ	ΧΡΩΜΑ	ΜΕΓΕΘΟΣ
Footer	Κόκκινο	Small
Footer	Κόκκινο	Medium
Footer	Κόκκινο	Large
Footer	Πράσινο	Small
Footer	Πράσινο	Medium

Παράδειγμα 5^{ης} Κανονικής Μορφής (β)

Σε 5^η NF με ΤΡΕΙΣ ΠΙΝΑΚΕΣ

ΠΡΟΙΟΝ	ΧΡΩΜΑ
Footer	Κόκκινο
Footer	Πράσινο

ΧΡΩΜΑ	ΜΕΓΕΘΟΣ
Κόκκινο	Small
Κόκκινο	Medium
Κόκκινο	Large
Πράσινο	Small
Πράσινο	Medium

ΠΡΟΙΟΝ	ΜΕΓΕΘΟΣ
Footer	Small
Footer	Medium
Footer	Large

Θεωρία Κανονικοποίησης - Κανόνες

- Δοθέντος ενός συνόλου από FD F μπορούμε να προσδιορίσουμε άλλες FD που ισχύουν όποτε οι FD στην F ισχύουν - για να προσδιορίσουμε τέτοιες FD χρειαζόμαστε **κανόνες συμπερασμού**.
- A1.** Αν $Y \subseteq X$ τότε $X \rightarrow Y$ (Ανακλαστικός - *Reflexivity*)
- A2.** Αν $X \rightarrow Y$ τότε $XZ \rightarrow YZ$ (Επαυξητικός - *Augmentation*)
- A3.** Αν $X \rightarrow Y$ και $Y \rightarrow Z$ τότε $X \rightarrow Z$ (Μεταβατικός - *Transitivity*)

Ο *Armstrong* απέδειξε ότι: $\{A1, A2, A3\}$ είναι ένα **βάσιμο και πλήρες σύνολο** κανόνων συμπερασμού

δηλαδή, οι κανόνες δημιουργούν μόνο **βάσιμες** FD και επίσης, όλες οι FD που μπορούμε να συμπεράνουμε, **δημιουργούνται με αυτούς τους κανόνες**.

Κανόνες Συμπερασμού

- Επιπλέον Κανόνες Συμπερασμού ισχύουν :

A4. Αν $X \rightarrow YZ$ τότε $X \rightarrow Y$ και $X \rightarrow Z$

(Διασπαστικός - *Decomposition*)

A5. Αν $X \rightarrow Y$ και $X \rightarrow Z$ τότε $X \rightarrow YZ$ (Ενωτικός - *Union*)

A6. Αν $X \rightarrow Y$ και $WY \rightarrow Z$ τότε $WX \rightarrow Z$

(Ψευδομεταβατικός - *Pseudotransitivity*)

- Το **κλείσιμο - closure** F^+ ενός συνόλου FD F είναι το σύνολο όλων των FD που συμπεραίνονται από το F (με την εφαρμογή των κανόνων Armstrong)

- Το **κλείσιμο - closure** X^+ ενός συνόλου γνωρισμάτων X σε σχέση με ένα σύνολο FD F είναι το σύνολο όλων των γνωρισμάτων που εξαρτώνται συναρτησιακά από το X (με την εφαρμογή των κανόνων Armstrong)

Παραδείγματα

- $R = (A, B, C, G, H, I)$
 $F = \{$
 - $A \rightarrow B$
 - $A \rightarrow C$
 - $CG \rightarrow H$
 - $CG \rightarrow I$
 - $B \rightarrow H\}$
- Συναρτησιακές εξαρτήσεις στην F^+
 - $A \rightarrow H$
 - » Με μεταβατικότητα $A \rightarrow B$ και $B \rightarrow H$
 - $AG \rightarrow I$
 - » Επαυξητικά από το $A \rightarrow C$ με το G , παίρνουμε το $AG \rightarrow CG$ και μετά με μεταβατικότητα με το $CG \rightarrow I$
 - $CG \rightarrow HI$
 - » Από το $CG \rightarrow H$ και το $CG \rightarrow I$: “κανόνας ένωσης”

Υπολογισμός του F^+

- Αλγόριθμος:

$F^+ = F$

repeat

for each functional dependency f in F^+

 apply reflexivity and augmentation rules on f

 add the resulting functional dependencies to F^+

for each pair of functional dependencies f_1 and f_2 in F^+

if f_1 and f_2 can be combined using transitivity

then add the resulting functional dependency to F^+

until F^+ does not change any further

«ΑΡΓΟΣ» Αλγόριθμος

Υπολογισμός Κλεισίματος Συνόλου Γνωρισμάτων (α^+)

- Αλγόριθμος υπολογισμού α^+ , με την ύπαρξη της F

result := α ;

while (changes to *result*) **do**

for each $\beta \rightarrow \gamma$ **in** F **do**

begin

if $\beta \subseteq \textit{result}$ **then** *result* := *result* \cup γ

end

«ΓΡΗΓΟΡΟΣ» Αλγόριθμος

Παραδείγματα του Κλεισίματος Συνόλου Γνωρισμάτων (α^+)

- $R = (A, B, C, G, H, I)$
- $F = \{A \rightarrow B$
 $A \rightarrow C$
 $CG \rightarrow H$
 $CG \rightarrow I$
 $B \rightarrow H\}$
- $(AG)^+$
 1. $result = AG$
 2. $result = ABCG$ ($A \rightarrow C$ and $A \rightarrow B$)
 3. $result = ABCGH$ ($CG \rightarrow H$ and $CG \subseteq AGBC$)
 4. $result = ABCGHI$ ($CG \rightarrow I$ and $CG \subseteq AGBCH$)
- Είναι το AG υποψήφιο κλειδί?
 1. Είναι το AG κλειδί?
 1. Η Ερώτηση $AG \rightarrow R$? Είναι ισοδύναμη με την « είναι το $(AG)^+ \supseteq R$ »?
 2. Είναι κάποιο υποσύνολο του AG κλειδί?
 1. Είναι το $A \rightarrow R$? \equiv Είναι το $(A)^+ \supseteq R$
 2. Είναι το $G \rightarrow R$? \equiv Είναι το $(G)^+ \supseteq R$

Χρήσεις του Κλεισίματος Συνόλου Γνωρισμάτων (α^+)

- ΕΛΕΓΧΟΣ ΚΛΕΙΔΙΟΥ:
 - Για τον έλεγχο αν το α είναι κλειδί, υπολογίζουμε το α^+ , και ελέγχουμε αν το α^+ περιέχει όλα τα γνωρίσματα του R .
- ΕΛΕΓΧΟΣ ΣΥΝΑΡΤΗΣΙΑΚΩΝ ΕΞΑΡΤΗΣΕΩΝ
 - Για τον έλεγχο αν η συναρτησιακή εξάρτηση $\alpha \rightarrow \beta$ ισχύει (με άλλα λόγια, αν είναι στο F^+), έλεγξε αν $\beta \subseteq \alpha^+$.
 - Δηλαδή, υπολογίζουμε το α^+ με το γνωστό αλγόριθμο, και ελέγχουμε αν περιέχει το β .
 - Είναι ένα εύκολος και γρήγορος έλεγχος
- ΥΠΟΛΟΓΙΣΜΟΣ ΤΟΥ ΚΛΕΙΣΙΜΑΤΟΣ ΤΟΥ F
 - Για κάθε $\gamma \subseteq R$, υπολογίζουμε το γ^+ , και για κάθε $S \subseteq \gamma^+$, παίρνουμε μια συναρτησιακή εξάρτηση $\gamma \rightarrow S$.

Ισοδυναμία Συνόλων από FD

- Δύο σύνολα από FD F και G είναι *ισοδύναμα* αν κάθε FD στο F είναι δυνατόν να παραχθεί από το G και κάθε FD στο G είναι δυνατόν να παραχθεί από το F (δηλαδή, F και G είναι ισοδύναμα αν ισχύει: $F^+ = G^+$)
- Το F *καλύπτει το* G αν κάθε FD στο G είναι δυνατόν να παραχθεί από το F (δηλαδή ισχύει: $G^+ \subseteq F^+$)
- Ένα σύνολο F από FD είναι *ελάχιστη κάλυψη* αν ικανοποιεί τα παρακάτω:
 - (1)Κάθε εξάρτηση στο F είναι της μορφής: $X \rightarrow A$, όπου A είναι ένα απλό γνώρισμα
 - (2)Δεν μπορούμε να αποσύρουμε μια FD από το F και να εξακολουθούμε να έχουμε ένα σύνολο ισοδύναμο του F
 - (3)Δεν μπορούμε να αντικαταστήσουμε μια FD $X \rightarrow A$ από το F με μια FD $Y \rightarrow A$, όπου $Y \subset X$ και να εξακολουθούμε να έχουμε ένα σύνολο ισοδύναμο του F

Υπολογισμός Ελάχιστης Κάλυψης του F

- Αλγόριθμος:

repeat

Use the union rule to replace any dependencies in F

$\alpha_1 \rightarrow \beta_1$ and $\alpha_1 \rightarrow \beta_2$ with $\alpha_1 \rightarrow \beta_1 \beta_2$

Find a functional dependency $\alpha \rightarrow \beta$ with an
extraneous attribute either in α or in β

If an extraneous attribute is found, delete it from $\alpha \rightarrow \beta$

until F does not change

Παράδειγμα

- $R = (A, B, C)$
 $F = \{A \rightarrow BC$
 $B \rightarrow C$
 $A \rightarrow B$
 $AB \rightarrow C\}$
- Combine $A \rightarrow BC$ and $A \rightarrow B$ into $A \rightarrow BC$
 - Set is now $\{A \rightarrow BC, B \rightarrow C, AB \rightarrow C\}$
- A is extraneous in $AB \rightarrow C$
 - Check if the result of deleting A from $AB \rightarrow C$ is implied by the other dependencies
 - » Yes: in fact, $B \rightarrow C$ is already present!
 - Set is now $\{A \rightarrow BC, A \rightarrow B, B \rightarrow C\}$
- C is extraneous in $A \rightarrow BC$
 - Check if $A \rightarrow C$ is logically implied by $A \rightarrow B$ and the other dependencies
 - » Yes: using transitivity on $A \rightarrow B$ and $B \rightarrow C$.
 - Can use attribute closure of A in more complex cases
- Η ελάχιστη κάλυψη είναι:
 $A \rightarrow B$
 $B \rightarrow C$

Αποτελέσματα Θεωρίας Συναρτησιακών Εξαρτήσεων

- Υπάρχει απλός αλγόριθμος για να ελέγχει την ισοδυναμία μεταξύ συνόλων από FD
- Κάθε σύνολο από FD έχει ένα **ελάχιστο ισοδύναμο** σύνολο
- Δεν υπάρχει απλός (efficient) αλγόριθμος για να υπολογίζει το ελάχιστο ισοδύναμο σύνολο από FD που είναι ισοδύναμο με ένα σύνολο F από FD
- Η ύπαρξη (και υπολογισμός) ενός ελάχιστου ισοδύναμου συνόλου είναι **σημαντική** για κάθε αλγόριθμο σχεδιασμού
- Επιπλέον κριτήρια απαιτούνται για να επιτύχουμε έναν «καλό» λογικό σχεδιασμό σχέσεων (*ιδιότητα συνενώσεων άνευ απωλειών - lossless join property, ιδιότητα διατήρησης εξαρτήσεων - dependency preserving property*).
- Οι αλγόριθμοι σχεδιασμού πληρούν τέτοιες ιδιότητες

Σχεσιακή Αποσύνθεση

- ΤΟ ΑΡΧΙΚΟ ΣΗΜΕΙΟ όλων των αλγορίθμων είναι ένα *σχήμα καθολικής σχέσης* R που περιέχει *όλα* τα γνωρίσματα της Βάσης
- ΣΤΟΧΟΣ του σχεδιασμού είναι μια αποσύνθεση (decomposition) D του R σε m Σχήματα Σχέσεων $R_1, R_2, R_3, \dots, R_m$ όπου κάθε R_i περιέχει ένα υποσύνολο γνωρισμάτων του R και κάθε γνώρισμα του R πρέπει να παρουσιάζεται σε **τουλάχιστον ένα Σχήμα Σχέσης** R_i (ιδιότητα διατήρησης Γνωρισμάτων)
- Στην ουσία, όταν κάνουμε αποσύνθεση του R , σκοπεύουμε να αποθηκεύσουμε στιγμιότυπα των Σχέσεων που προκύπτουν από την αποσύνθεση, αντί για στιγμιότυπα του R .

Προβλήματα με Αποσυνθέσεις

- **Αν η αποσύνθεση γίνει με τυχαίο τρόπο, παρουσιάζονται προβλήματα:**
 - ☆ Μερικές ερωτήσεις καθίστανται πιο ακριβές (μη-αποδοτικές) .
 - » Π.χ., Οι ερωτήσεις πιθανόν να απαιτούν πολλές Συνενώσεις
 - 🕒 Δοθέντων στιγμιότυπων των αποσυνθεμένων Σχέσεων, είναι πιθανόν να μη μπορούμε να ανακατασκευάσουμε το στιγμιότυπο της αρχικής Σχέσης!
 - » Η περίπτωση των "πλασματικών" πλειάδων
 - 🕒 Για τον έλεγχο κάποιων εξαρτήσεων, πιθανόν να χρειάζεται η Συνένωση των αποσυνθεμένων στιγμιότυπων.
 - » Τα γνωρίσματα στις FD είναι τώρα σε περισσότερες της μιας Σχέσεις

Διατήρηση Εξαρτήσεων (1)

- **ΙΔΙΟΤΗΤΑ ΔΙΑΤΗΡΗΣΗΣ ΕΞΑΡΤΗΣΕΩΝ:** Η αποσύνθεση D πρέπει να διατηρεί τις συναρτησιακές εξαρτήσεις; δηλαδή, η συλλογή όλων των εξαρτήσεων που ισχύουν για τις σχέσεις R_i πρέπει να είναι **ισοδύναμη με την F** (οι FD που ισχύουν στην R)
- **ΤΥΠΙΚΑ:**

Ορισμός: Η **ΠΡΟΒΟΛΗ** του F στο R_i , η $\Pi_F(R_i)$, είναι το σύνολο των FD $X \rightarrow Y$ στο F^+ έτσι ώστε: $(X \cup Y) \subseteq R_i$

Μια αποσύνθεση D ικανοποιεί την **ιδιότητα διατήρησης εξαρτήσεων** αν:

$$(\Pi_F(R_1) \cup \Pi_F(R_2) \dots \cup \Pi_F(R_m))^+ = F^+$$

Διατήρηση Εξαρτήσεων (2)

- Υπάρχει αλγόριθμος, ο οποίος ονομάζεται *αλγόριθμος σχεσιακής σύνθεσης*, που αποσυνθέτει την καθολική σχέση R σε ένα σύνολο σχέσεων $D = \{R_1, R_2, R_3, \dots R_m\}$ διατηρώντας τις εξαρτήσεις σε σχέση με το F , έτσι ώστε κάθε R_i είναι σε 3NF
- Ο Αλγόριθμος βασίζεται σε **Ελάχιστες Καλύψεις** και, όπως έχει ειπωθεί και νωρίτερα, ΔΕΝ υπάρχουν αποδοτικοί τρόποι για να βρεθούν ελάχιστες καλύψεις.

Συνενώσεις Άνευ Απωλειών

- **ΙΔΙΟΤΗΤΑ ΣΥΝΕΝΩΣΕΩΝ ΑΝΕΥ ΑΠΩΛΕΙΩΝ:** Η ιδιότητα αυτή φροντίζει ώστε να μη παρουσιάζονται μη-υπαρκτές (πλασματικές) πλειάδες σε Σχέσεις, όταν συνενώνονται αποσυνθεμένες Σχέσεις

Τυπικά, Μια αποσύνθεση $D = \{R_1, R_2, R_3, \dots R_m\}$ του R έχει την *ιδιότητα συνενώσεων άνευ απωλειών* σε σχέση με ένα σύνολο από FD F , αν *για κάθε* στιγμιότυπο $r(R)$ του οποίου οι πλειάδες ικανοποιούν όλες τις FD στο F , έχουμε:

$$(\Pi_{R_1}(r(R)) \bowtie \Pi_{R_2}(r(R)) \bowtie \dots \bowtie \Pi_{R_m}(r(R))) = r(R)$$

- Αυτή είναι πολύ σημαντική ιδιότητα για Αποσυνθέσεις, διότι επηρεάζει τον τρόπο που Ερωτήσεις με ΝΟΗΜΑ γίνονται στα Σχεσιακά Σχήματα

Παράδειγμα Πλασματικών Πλειάδων

- Έστω η Βάση Δεδομένων COMPANY και μια Σχέση $E_P(\underline{SSN}, \underline{PNumber}, HoursPW, EName, PName, Location)$ που δημιουργείται με την Συνένωση των EMPLOYEE, PROJECT και WORKS_ON (σε στιγμιότυπα) και στην συνέχεια με την Προβολή στα παραπάνω Γνωρίσματα

Πεισθείτε ότι η αποσύνθεση της E_P στις:

$R_1(\underline{EName}, \underline{Location})$

$R_2(\underline{SSN}, \underline{PNumber}, HoursPW, PName, Location)$

ΔΕΝ ΙΚΑΝΟΠΟΙΕΙ την ιδιότητα συνένωσης άνευ απωλειών

ΠΩΣ?: Κάντε προβολές σε στιγμιότυπα του E_P (για R_1, R_2) και συνενώστε τις Προβολές. ΔΕΝ θα πάρετε πίσω το E_P !


Περισσότερα για Lossless Joins

- Η αποσύνθεση του R στα X και Y είναι lossless-join σε σχέση με το F αν και μόνο εάν το κλείσιμο του F περιέχει την:

- $X \cap Y \rightarrow X$, ή την
- $X \cap Y \rightarrow Y$

- Συγκεκριμένα, η αποσύνθεση της R σε UV και $R - V$ είναι lossless-join αν η $U \rightarrow V$ ισχύει στην R .


A	B	C
1	2	3
4	5	6
7	2	8



A	B
1	2
4	5
7	2

B	C
2	3
5	6
2	8

A	B	C
1	2	3
4	5	6
7	2	8
1	2	8
7	2	3



Θεωρητικά Αποτελέσματα

- Υπάρχει απλός αλγόριθμος για να ελέγχει αν μια αποσύνθεση D ικανοποιεί την ιδιότητα *lossless join* σε σχέση με ένα σύνολο F από FD.
- Υπάρχει απλός αλγόριθμος για Αποσύνθεση του R σε BCNF Σχέσεις έτσι ώστε η αποσύνθεση D να ικανοποιεί την ιδιότητα *lossless join* σε σχέση με ένα σύνολο F από FD στο R
- **ΔΕΝ ΥΠΑΡΧΕΙ αλγόριθμος για Αποσύνθεση σε BCNF Σχέσεις που ικανοποιούν την ιδιότητα διατήρησης εξαρτήσεων**
- Υπάρχει απλός αλγόριθμος (τροποποίηση του αλγορίθμου σχεσιακής σύνθεσης) για αποσυνθέσεις σε 3NF (όχι BCNF) Σχέσεις που ικανοποιούν και τις δύο ιδιότητες (διατήρηση εξαρτήσεων και *lossless join*)

Αποσύνθεση σε 3NF

ΑΛΓΟΡΙΘΜΟΣ:

- 1.- Βρες ένα **ελάχιστο σύνολο** G από FD ισοδύναμο του F
- 2.- Για κάθε X μιας FD $X \rightarrow Y$ στο G
Δημιούργησε ένα Σχήμα Σχέσης R_i στο D με τα γνωρίσματα $\{X \cup A_1 \cup A_2 \cup \dots, \cup A_k\}$, όπου κάθε A_j είναι ένα γνώρισμα που υπάρχει σε μια FD του G με το X στα αριστερά
- 3.- Αν γνωρίσματα του R δεν έχουν μπει σε κάποιο R_i τότε **δημιούργησε** μια νέα Σχέση στο D για αυτά τα γνωρίσματα
- 4.- Αν καμία σχέση στο D δεν περιέχει ένα κλειδί του R , **δημιούργησε** μια σχέση που περιέχει ένα κλειδί του R και **πρόσθεσέ** την στο D

- Ο Αλγόριθμος δημιουργεί Σχέσεις σε 3NF που ικανοποιούν και τις δύο ιδιότητες.

Επιπρόσθετες Εξαρτήσεις

- Με τη χρήση των FD μπορούμε να φτάσουμε μέχρι 3NF και BCNF
- Άλλες εξαρτήσεις: *πλειότιμες εξαρτήσεις (Multivalued) (MVD), εξαρτήσεις συνένωσης (Join Dependencies), εξαρτήσεις εγκλεισμού (Inclusion Dependencies), ...*
Αυτές οι εξαρτήσεις μας πάνε σε κανονικές μορφές πέραν των 3NF και BCNF (δηλαδή, 4NF και 5NF)
- *Πλειότιμες Συναρτήσεις:* (άτυπος ορισμός) Ένα σύνολο γνωρισμάτων X καθορίζει πολλαπλά ένα σύνολο Y αν η τιμή του X καθορίζει ένα σύνολο τιμών για το Y (ανεξάρτητα από τα άλλα γνωρίσματα στη Σχέση)

Πλειότιμες Εξαρτήσεις

- Μια MVD παρουσιάζεται ως $X \twoheadrightarrow Y$
- Υπάρχουν **βάσιμα και πλήρη** σύνολα κανόνων συμπερασμού για MVDs
- Μια FD είναι ειδική περίπτωση των MVD
- Ένα Σχεσιακό Σχήμα R είναι στην **τέταρτη κανονική μορφή (4NF)** σε σχέση με ένα σύνολο συναρτησιακών και πλειότιμων εξαρτήσεων F αν για κάθε μη τετριμμένη πλειότιμη εξάρτηση $X \twoheadrightarrow Y$ στην F^+ , το X είναι υποψήφιο κλειδί του R
- Δεν υπάρχει **αποδοτικός αλγόριθμος** για την αποσύνθεση του R σε 4NF Σχέσεις, έτσι ώστε η αποσύνθεση να έχει την ιδιότητα **lossless join** σε σχέση με ένα σύνολο F από FD και MVD στο R

Εξαρτήσεις Συνένωσης

- Μια *εξάρτηση συνένωσης* $JD(R_1, R_2, R_3, \dots R_m)$ είναι ένας δομικός περιορισμός στην R που προσδιορίζει ότι *κάθε νόμιμο στιγμιότυπο* $r(R)$ **πρέπει να έχει μια lossless join αποσύνθεση** στα $R_1, R_2, R_3, \dots R_m$
- Μια *MVD* είναι ειδική περίπτωση των *JD* (όπου $m=2$)
- Ένα Σχεσιακό Σχήμα R είναι στην *πέμπτη κανονική μορφή (5NF)* σε σχέση με ένα σύνολο συναρτησιακών, πλειότιμων και εξαρτήσεων συνένωσης F αν για κάθε μη τετριμμένη $JD(R_1, R_2, \dots R_m)$ στην F^+ , κάθε R_i είναι υπέρ-κλειδί του R
- Η *5NF* ονομάζεται επίσης *PJNF (Project-Join Normal Form)*

Εξαρτήσεις Εγκλεισμού

- FD, MVD και JD ορίζονται εντός του ιδίου Σχεσιακού Σχήματος R (δεν συσχετίζουν γνωρίσματα που βρίσκονται σε διαφορετικές σχέσεις)
- Υπάρχουν και άλλες εξαρτήσεις, όπως οι εξαρτήσεις εγκλεισμού που χρησιμοποιούνται για την παράσταση της αναφορικής ακεραιότητας και των ιεραρχιών class / subclass μεταξύ δύο σχέσεων R και S
- Μια εξάρτηση εγκλεισμού $R.X < S.Y$ προσδιορίζει ότι σε κάθε χρονικό σημείο, αν τα $r(R)$ και $s(S)$ είναι στιγμιότυπα σχέσεων των R και S, τότε $\Pi_X(r(R)) \subseteq \Pi_Y(s(S))$

Πρακτικά Θέματα για την Κανονικοποίηση

- Ένας μεγάλος αριθμός από εμπορικά εργαλεία, δοθέντων ενός συνόλου Σχημάτων Σχέσεων / Γνωρισμάτων και ενός συνόλου συναρτησιακών εξαρτήσεων **δημιουργούν αυτόματα Σχήματα Σχέσεων σε μορφή 3NF** (σπάνια πάνε σε BCNF, 4NF και 5NF)
- Μια άλλη χρήση τέτοιων εργαλείων είναι να **ελέγχουν το επίπεδο Κανονικοποίησης** μιας Σχέσης - γενικά, η χρήση ως **ευρεστικό εργαλείο επιλογής** ενός Σχεδιασμού έναντι κάποιου άλλου
- Υπάρχουν πρακτικά αποτελέσματα της Θεωρίας που επιτρέπουν σε έναν Σχεδιαστή να κάνει ανάλυση της μορφής:
 - Αν μια σχέση είναι σε 3NF και κάθε υποψήφιο κλειδί αποτελείται ακριβώς από ένα γνώρισμα, τότε είναι και σε 5NF (Fagin, 1991)

ΣΧΟΛΙΑ

- Η διαδικασία Κανονικοποίησης έχει και **μειονεκτήματα**:
 - **Δεν είναι δημιουργική** -- με στόχο τα κριτήρια που αναφέρθηκαν προηγουμένως, δεν υπάρχει τρόπος να δημιουργηθεί μια «καλή» βάση δεδομένων
 - Συνήθως η Κανονικοποίηση γίνεται **αφού έχουμε κάποιο Σχήμα** (μας λέει αν είναι «καλό» ή «κακό»)
 - **Δεν προσφέρει ένα εννοιολογικό σχήμα** (ασχολείται μόνο με Σχέσεις και Γνωρίσματα)
- Όμως, είναι μια αξιέπαινη και πρακτικά χρήσιμη προσπάθεια να γίνουν με τυπικό και συστηματικό τρόπο πράγματα που τα κάνουμε συνήθως διαισθητικά.