

# Προγραμματισμός Σημασιολογικού Ιστού

Ενότητα 3: Εισαγωγή στην Οργάνωση των  
Σημασιολογικών Δεδομένων

Μ.Στεφανιδάκης

27-2-2018

# Ποιο το κατάλληλο μοντέλο δεδομένων;

- ▶ Τα σημασιολογικά δεδομένα πρέπει να εκτεθούν “ώς έχουν” (raw)
  - ▶ Ποιο είναι το κατάλληλο μοντέλο οργάνωσης;
  - ▶ Και πώς θα εμπεριέχονται και τα μεταδεδομένα;
- ▶ Ας ξεκινήσουμε με ένα απλό μοντέλο: δεδομένα σε μορφή πίνακα (**tabular data**)
  - ▶ Η σημασιολογία των δεδομένων προκύπτει **έμμεσα από τη θέση τους** (γραμμή-στήλη)

Τύπος	Αριθμός
Λεωφορεία	58.519
ΙΧ	2.062.880
Οδοποιητικά	7.642
<b>Εκχιονιστικά</b>	<b>6</b>
Ποδήλατα	8.540.192

# Η έμμεση σημασιολογία του πίνακα

- ▶ Κάθε γραμμή αντιστοιχεί σε μία βασική **οντότητα** (entity) δεδομένων
  - ▶ Έμμεση πληροφορία
- ▶ Κάθε στήλη αντιστοιχεί σε μια **ιδιότητα** (attribute)
  - ▶ Ρητή πληροφορία, αν υπάρχει περιγραφή στηλών

Οντότητα<sub>i</sub>

Τύπος	Αριθμός
Λεωφορεία	58.519
ΙΧ	2.062.880
Οδοποιητικά	7.642
Εκχιονιστικά	6
Ποδήλατα	8.540.192

Ιδιότητα<sub>j</sub>

# Μοντέλο και Μορφή Αποθήκευσης

- ▶ Η μορφή πίνακα είναι ένα μοντέλο οργάνωσης δεδομένων (**data model**)
  - ▶ Προσδιορίζει τον τρόπο δόμησης της πληροφορίας
- ▶ Η δομημένη πληροφορία όμως
  - ▶ Πρέπει να **αποθηκευτεί** ως ακολουθία bytes
  - ▶ Και να **μεταδοθεί** μεταξύ παραγωγού και καταναλωτή
- ▶ Συνεπώς, πέρα από το μοντέλο των δεδομένων, είναι απαραίτητο ένα μορφότυπο σειριοποίησης (**serialization format**) των δεδομένων

# Η μορφή αποθήκευσης CSV

- ▶ Comma Separated Values
  - ▶ Ένα ..μη πρότυπο πρότυπο (τουλάχιστον μέχρι πρόσφατα)
  - ▶ Με πολλές “διαλέκτους” (σχεδόν κάθε εφαρμογή έχει τη δική της!)
  - ▶ Για εξαγωγή-εισαγωγή μεγάλων σετ δεδομένων σε μορφή πίνακα από-σε βάσεις δεδομένων
- ▶ Έλεγχος Ιδιοτήτων:
  - ▶ Ανοικτό πρότυπο: **NAI**
  - ▶ Χρήση στο Web: **NAI** (αν και όχι τόσο συχνά)
  - ▶ Ευκολία προγραμματισμού: **NAI** (βιβλιοθήκες για πολλές γλώσσες)
  - ▶ Ρητά μεταδεδομένα: **OXI** (προαιρετικά, ονόματα στηλών στην πρώτη γραμμή)

# Προσθήκη ρητού αναγνωριστικού (id)

- ▶ Οικείο σχήμα από τις σχεσιακές βάσεις...
- ▶ Κάθε βασική οντότητα διαθέτει μοναδικό αναγνωριστικό
  - ▶ Θεωρήστε προς το παρόν ότι αυτός είναι ο μοναδικός πίνακας στον κόσμο!

id	Τύπος	Αριθμός
1	Λεωφορεία	58.519
2	ΙΧ	2.062.880
3	Οδοποιητικά	7.642
4	Εκχιονιστικά	6
5	Ποδήλατα	8.540.192

# Το μετα-μοντέλο EAV

- ▶ Μια νέα μεταμόρφωση: το μοντέλο **Entity-Attribute-Value**
  - ▶ Μορφή **τριάδας** (triple): (**Οντότητα, Ιδιότητα, Τιμή**)
    - ▶ Η Οντότητα συμβολίζεται με το ρητό αναγνωριστικό της
    - ▶ Ως Ιδιότητες μπαίνουν οι (ρητές ή εννοούμενες) επικεφαλίδες των στηλών
    - ▶ Ως Τιμές χρησιμοποιούνται τα περιεχόμενα των κελιών στις διασταυρώσεις γραμμών-στηλών
  - ▶ Όλα τα μεταδεδομένα (ιδιότητες) δηλώνονται ρητά
  - ▶ Ο “εφιάλτης” του σχεσιακού μοντέλου!!!
    - ▶ Πλήρης απο-κανονικοποίηση (denormalization)

# Παράδειγμα μετασχηματισμού

- ▶ Έστω ο πίνακας (δείχνεται μια γραμμή μόνο)

id	Engine	Weight(kg)	Tracks(mm)	Boom(m)
...	...	...	...	...
38rb	V8	60000	850	18
...	...	...	...	...



## Δεδομένα κατά το μοντέλο ΕΑV

- ▶ Η μία αυτή γραμμή παράγει από μόνη της τις εξής τριάδες

Entity	Attribute	Value
38rb	Engine	V8
38rb	Weight(kg)	60000
38rb	Tracks(mm)	850
38rb	Boom(m)	18

- ▶ Κάθε άλλη γραμμή του αρχικού πίνακα θα μετασχηματιστεί επίσης στις αντίστοιχες τριάδες!