

Βάσεις Δεδομένων

Ενότητα 7: Ερωτήματα ομαδοποίησης και συνάθροισης στην SQL

Τσούρος Δήμος

Συναρτήσεις συνάθροισης

Υπάρχουν πέντε βασικές συναρτήσεις συνάθροισης, που υποστηρίζονται από όλα τα συστήματα SQL

- **COUNT** για την καταμέτρηση πλήθους
- **SUM** για το άθροισμα
- **AVG** για το μέσο όρο
- **MIN** για την ελάχιστη τιμή
- **MAX** για την μέγιστη τιμή

Υπάρχουν αρκετές άλλες συναρτήσεις (πχ **STDEV**, **VAR**), αλλά η υποστήριξή τους ποικίλει από σύστημα σε σύστημα.

Ο πίνακας *employees* από τη βάση *company*

Έστω η σχέση *employees* με σχήμα:

employees(*empid*, *firstname*, *lastname*, *depid*, *salary*, *hiredate*)

empid	firstname	lastname	depid	salary	hiredate
102	Νικηφόρος	Διαμαντίδης	6	1212.50	2003-06-02
109	Μαρία	Αθανασίου	1	2787.69	2000-01-26
153	Μαρία	Αλεβιζάτου	2	1321.92	2001-05-15
172	Χρήστος	Βλάσσης	3	1101.70	2000-07-04
189	Θεόδωρος	Αγγελίνας	6	1908.28	2000-06-19
...	...	...	...	...	...

Παράδειγμα αθροίσματος στήλης

Να βρεθεί το άθροισμα των μισθών όλων των υπαλλήλων

$$\mathcal{G}_{sum(salary)}(employees)$$

Παράδειγμα αθροίσματος στήλης

Να βρεθεί το άθροισμα των μισθών όλων των υπαλλήλων

$\mathcal{G}_{sum(salary)}(employees)$

```
1  SELECT SUM(salary)
2  FROM employees;
```

```
3
4  | SUM(salary) |
5  |-----|
6  |    38232.03 |
```

Παράδειγμα αθροίσματος υπό συνθήκη

Να βρεθεί το άθροισμα των μισθών όλων των υπαλλήλων του τμήματος 4

$$\mathcal{G}_{sum(salary)}(\sigma_{depid=4}(employees))$$

Παράδειγμα αθροίσματος υπό συνθήκη

Να βρεθεί το άθροισμα των μισθών όλων των υπαλλήλων του τμήματος 4

$$\mathcal{G}_{sum(salary)}(\sigma_{depid=4}(employees))$$

```
1  SELECT SUM(salary)
2      FROM employees
3      WHERE depid = 4;
```

```
5  | SUM(salary) |
6  |-----|
7  |      3542.80 |
```

Παράδειγμα αθροίσματος γενικευμένης προβολής

Να βρεθεί το επιπλέον ποσό που θα δοθεί σε μισθούς αν οι υπάλληλοι του τμήματος 3 πάρουν αύξηση 3%

$$\mathcal{G}_{sum(salary \times 0.03) \rightarrow sumsal3}(\sigma_{dept=3}(employees))$$

Παράδειγμα αθροίσματος γενικευμένης προβολής

Να βρεθεί το επιπλέον ποσό που θα δοθεί σε μισθούς αν οι υπάλληλοι του τμήματος 3 πάρουν αύξηση 3%

$$\mathcal{G}_{sum(salary \times 0.03) \rightarrow sumsal3}(\sigma_{depid=3}(employees))$$

```
1 SELECT SUM(salary*0.03) AS sumsal3
2   FROM employees
3  WHERE depid = 3;
```

Η μετονομασία του πεδίου είναι χρήσιμη αλλά προαιρετική.

Προσέξτε πως το μόνο που δηλώνει ο χρήστης στην **SQL** είναι ονόματα πεδίων και πινάκων.

Παράδειγμα υπολογισμού μέσου όρου

Να βρεθεί ο μέσος μισθός όλων των υπαλλήλων

$$\mathcal{G}_{avg(salary)}(employees)$$

Παράδειγμα υπολογισμού μέσου όρου

Να βρεθεί ο μέσος μισθός όλων των υπαλλήλων

$$\mathcal{G}_{avg(salary)}(employees)$$

```
1  SELECT AVG(salary)
2     FROM employees;
```

```
3
4  | AVG(salary) |
5  -----
6  | 1416.001111 |
```

Μέσος όρος με περιορισμό εγγραφών

Να βρεθεί ο μέσος μισθός των υπαλλήλων του τμήματος 3

$$\mathcal{G}_{avg(salary)}(\sigma_{depid=3}(employees))$$

Μέσος όρος με περιορισμό εγγραφών

Να βρεθεί ο μέσος μισθός των υπαλλήλων του τμήματος 3

$$\mathcal{G}_{avg(salary)}(\sigma_{depid=3}(employees))$$

```
1  SELECT AVG(salary)
2      FROM employees
3      WHERE depid = 3;
```

```
5  | AVG(salary) |
6  -----
7  | 1311.651250 |
```

Ελάχιστη τιμή

Να βρεθεί ο μικρότερος μισθός των υπαλλήλων του τμήματος 3

$$\mathcal{G}_{\min(\text{salary})\sigma_{\text{depid}=3}(\text{employees})}$$

Ελάχιστη τιμή

Να βρεθεί ο μικρότερος μισθός των υπαλλήλων του τμήματος 3

$$\mathcal{G}_{\min(\text{salary})\sigma_{\text{depid}=3}(\text{employees})}$$

```
1  SELECT MIN(salary)
2      FROM employees
3      WHERE depid = 3;
```

```
5  | MIN(salary) |
6  -----
7  |      1050.96      |
```

Μέγιστη τιμή

Να βρεθεί η ημερομηνία της πιο πρόσφατης πρόσληψης

$\mathcal{G}_{\max(\text{hiredate})}(\text{employees})$

```
1  SELECT MAX(hiredate)
2  FROM employees;
```

```
3
4  | MAX(hiredate) |
5  -----
6  | 2004-10-05   |
```

Καταμέτρηση πλήθους

Να βρεθεί πόσοι υπάλληλοι εργάζονται στο τμήμα 4

$$\mathcal{G}_{count(empid)}(\sigma_{depid=4}(employees))$$

Καταμέτρηση πλήθους

Να βρεθεί πόσοι υπάλληλοι εργάζονται στο τμήμα 4

$$\mathcal{G}_{count(empid)}(\sigma_{depid=4}(employees))$$

```
1  SELECT COUNT(empid)
2      FROM employees
3      WHERE depid = 4;
```

```
5  | COUNT(empid) |
6  -----
7  |              5 |
```

COUNT(*)

Να βρεθεί πόσοι υπάλληλοι εργάζονται στο τμήμα 4

```
1  SELECT COUNT(*)  
2      FROM employees  
3      WHERE depid = 4;
```

```
4  
5  | COUNT(*)          |  
6  -----  
7  |                   5 |
```

- ❶ **COUNT(empid)** : Καταμέτρηση εγγραφών με μη NULL τιμές στο πεδίο *empid*.
- ❷ **COUNT(*)** : Καταμέτρηση εγγραφών

Δύο συναρτήσεις στο ίδιο ερώτημα

Να βρεθεί το εύρος το μισθών του τμήματος 4

$$\mathcal{G}_{\max(\text{salary})-\min(\text{salary})}(\text{employees})$$

Δύο συναρτήσεις στο ίδιο ερώτημα

Να βρεθεί το εύρος το μισθών του τμήματος 4

$$\mathcal{G}_{\max(\text{salary})-\min(\text{salary})}(\text{employees})$$

```
1  SELECT MAX(salary)-MIN(salary)
2      FROM employees
3      WHERE depid = 4;
```

```
4
5  | MAX(salary)-MIN(salary) |
6  -----
7  |                      331.34 |
```

Πλήθος μισθοδοτούμενων υπαλλήλων

Να βρεθεί το πλήθος
καταχωρημένων μισθών

```
1 SELECT COUNT(salary)
2   FROM employees;
3
4 | count(salary) |
5 -----
6 |                27 |
```

Να βρεθεί το πλήθος των
κωδικών των υπαλλήλων

```
1 SELECT COUNT(empid)
2   FROM employees;
3
4 | count(empid) |
5 -----
6 |                30 |
```

- Υπάρχουν 30 υπάλληλοι αλλά 27 μισθοί
- **COUNT(salary)** δεν μετράει τις τιμές **NULL**
- Το πεδίο **empid** δεν παίρνει ποτέ τιμές **NULL** γιατί είναι πρωτεύον κλειδί

Τιμές NULL

Να βρεθεί το πλήθος των υπαλλήλων χωρίς μισθό

```
1 SELECT COUNT(salary)
2   FROM employees
3  WHERE salary IS NULL;
4
5 | COUNT(salary) |
6 -----
7 |                0 |
```

Να βρεθεί το πλήθος των υπαλλήλων χωρίς μισθό

```
1 SELECT COUNT(empid)
2   FROM employees
3  WHERE salary IS NULL;
4
5 | count(empid) |
6 -----
7 |                3 |
```

- Οι τιμές **NULL** δεν απαριθμούνται.
- Το πλήθος των εγγραφών με τιμή **NULL** στο πεδίο *salary* είναι 3.

Καταμέτρηση μοναδικών τιμών (Λάθος)

Να βρεθεί το πλήθος των τμημάτων των υπαλλήλων

```
1 SELECT COUNT(depid)
2   FROM employees;
```

```
3
4 | COUNT(depid) |
5 -----
6 |                30 |
```

Καταμέτρηση μοναδικών τιμών (Σωστό)

Να βρεθεί το πλήθος των τμημάτων των υπαλλήλων

```
1 SELECT COUNT(DISTINCT depid)
2   FROM employees;
```

```
3
4 | COUNT(DISTINCT depid) |
5 -----
6 |                        6 |
```

Ομαδοποίηση

- Μέχρι τώρα είδαμε απλά ερωτήματα, η απάντηση των οποίων ήταν μία τιμή.
- Πολλές φορές το ζητούμενο είναι μια λίστα τιμών, μία τιμή **ανά** κατηγορία.
- Πχ ο μέσος μισθός **ανά** τμήμα, ή ο αρχαιότερος υπάλληλος **ανά** τμήμα
- Για αυτές τις περιπτώσεις θα χρειαστούμε μια νέα φράση:
GROUP BY

Πλήθος υπαλλήλων ανά τμήμα

Πλήθος υπαλλήλων ανά τμήμα

$depid \mathcal{G}_{count(*)}(employees)$

Πλήθος υπαλλήλων ανά τμήμα

Πλήθος υπαλλήλων ανά τμήμα

$depid \mathcal{G}_{count(*)}(employees)$

```
1 SELECT depid, COUNT(*)  
2   FROM employees  
3 GROUP BY depid;
```

depid	COUNT(*)
-------	----------

 Η **SQL** έχει πλεονεκτήματα:

1	3
2	4
3	9
4	5
5	2
6	7

- Δεν χρειάζεται να γνωρίζουμε το μέγεθος του πίνακα.
- Το ίδιο ακριβώς ερώτημα **SQL** θα χρησιμοποιηθεί έστω και αν αλλάξουν τα δεδομένα του πίνακα μετά από προσθήκη ή αφαίρεση εγγραφών.

Μικρότερο ανά ...

Ο μικρότερος μισθός ανά τμήμα υπαλλήλων

$depid \mathcal{G}_{min(salary)}(employees)$

Μικρότερο ανά ...

Ο μικρότερος μισθός ανά τμήμα υπαλλήλων

$depid \mathcal{G}_{min(salary)}(employees)$

```
1  SELECT depid, MIN(salary)
2      FROM employees
3  GROUP BY depid;
```

```
4
5  depid  MIN(salary)
6  -----
7      1      1754.67
8      2      1105.04
9      3      1050.96
10     4      1054.71
11     5      1051.92
12     6      1100.13
```

Περιορισμός και ομαδοποίηση

Να βρεθεί το άθροισμα των μισθών των υπαλλήλων ανά τμήμα για τους υπαλλήλους που προσλήφθηκαν μέσα στο 2004

$$depid \mathcal{G}_{sum}(salary)(\sigma_{hiredate \geq '2004-01-01' \wedge hiredate \leq '2004-12-31'}(employees))$$

Ομαδοποίηση και ταξινόμηση

Να βρεθεί το άθροισμα των μισθών των υπαλλήλων ανά τμήμα με φθίνουσα ταξινόμηση ως προς το άθροισμα των μισθών

Ομαδοποίηση και ταξινόμηση

Να βρεθεί το άθροισμα των μισθών των υπαλλήλων ανά τμήμα με φθίνουσα ταξινόμηση ως προς το άθροισμα των μισθών

```
1  SELECT depid, SUM(salary)
2      FROM employees
3  GROUP BY depid
4  ORDER BY SUM(salary) DESC;
```

```
5
6  | depid | SUM(salary) |
7  |-----|-----|
8  |      3 |    10493.21 |
9  |      6 |     9853.82 |
10 |      1 |     6395.35 |
11 |      2 |     5360.28 |
12 |      4 |     3542.80 |
13 |      5 |     2586.57 |
```

Περιορισμός μετά την ομαδοποίηση

Τμήματα με περισσότερους από 4 υπαλλήλους

$$\sigma_{count(depId) > 4} \left(depId \mathcal{G}_{count(empId)}(employees) \right)$$

Περιορισμός μετά την ομαδοποίηση

Τμήματα με περισσότερους από 4 υπαλλήλους

$$\sigma_{count(depId) > 4} \left(depId \mathcal{G}_{count(empId)}(employees) \right)$$

```
1 SELECT depId, COUNT(depId)
2   FROM employees
3  GROUP BY depId
4   HAVING COUNT(depId) > 4;
```

depId	COUNT(*)
1	3
2	4
3	9
4	5
5	2
6	7

- Ο όρος **HAVING** τοποθετείται μετά τον όρο **GROUP BY**.
- Η σύνταξη είναι παρόμοια με αυτή του όρου **WHERE**.
- Ο όρος **HAVING** περιορίζει το αποτέλεσμα του ερωτήματος με βάση πεδία που παράγονται από τον όρο **GROUP BY**.

Περιορισμός πριν και μετά την ομαδοποίηση

Να βρεθούν τα τμήματα με περισσότερους από 3 υπαλλήλους με μισθό μεγαλύτερο από 1200 €

$$\sigma_{count(depid)>3} \left(depid \mathcal{G}_{count(empid)} (\sigma_{salary>1200}(employees)) \right)$$

Περιορισμός πριν και μετά την ομαδοποίηση

Να βρεθούν τα τμήματα με περισσότερους από 3 υπαλλήλους με μισθό μεγαλύτερο από 1200 €

$\sigma_{count(depId) > 3} \left(depId \mathcal{G}_{count(empId)} \left(\sigma_{salary > 1200}(employees) \right) \right)$

```
1  SELECT depid
2      FROM employees
3      WHERE salary > 1200
4  GROUP BY depid
5      HAVING COUNT(depid) > 3;
```

```
7  | depid |
8  |-----|
9  |      3 |
10 |      6 |
```