

Содержание

Предисловие	13
Зачем изучать SQL	13
Почему стоит использовать данную книгу	14
Структура книги	14
Соглашения, принятые в этой книге	16
Использование примеров из этой книги	17
Благодарности	18
Ждем ваших отзывов!	18
Глава 1. Небольшая предыстория	19
Введение в базы данных	19
Нереляционные СУБД	20
Реляционная модель	22
Немного терминологии	26
Что такое SQL	26
Классы инструкций SQL	27
SQL: непроцедурный язык	29
Примеры SQL	30
Что такое MySQL	33
Отказ от SQL	34
Что дальше	35
Глава 2. Создание и наполнение базы данных	37
Создание базы данных MySQL	37
Использование инструмента командной строки <code>mysql</code>	39
Типы данных MySQL	40
Символьные данные	41
Числовые данные	45
Временные данные	46

Создание таблицы	49
Шаг 1. Проектирование	49
Шаг 2. Уточнение	50
Шаг 3. Построение инструкции схемы SQL	52
Заполнение и изменение таблиц	56
Добавление данных	56
Изменение данных	61
Удаление данных	61
Когда хорошие инструкции становятся плохими	62
Не уникальный первичный ключ	62
Несуществующий внешний ключ	62
Нарушения значений столбцов	63
Некорректное преобразование данных	63
База данных Sakila	64
Глава 3. Запросы	67
Механика запросов	67
Части запроса	69
Предложение <code>select</code>	70
Псевдонимы столбцов	72
Удаление дубликатов	74
Предложение <code>from</code>	75
Таблицы	76
Связи таблиц	79
Определение псевдонимов таблиц	80
Предложение <code>where</code>	81
Предложения <code>group by</code> и <code>having</code>	84
Предложение <code>order by</code>	85
Сортировка по возрастанию и убыванию	87
Сортировка с помощью номера столбца	88
Проверьте свои знания	89
Глава 4. Фильтрация	91
Вычисление условий	91
Использование скобок	92
Использование оператора <code>not</code>	93
Построение условия	94
Типы условий	95
Условия равенства	95

Условия диапазона	97
Условия членства	102
Условия соответствия	104
Этот таинственный null	107
Проверьте свои знания	110
Глава 5. Запросы к нескольким таблицам	113
Что такое соединение	113
Декартово произведение	114
Внутренние соединения	115
Синтаксис соединения ANSI	117
Соединение трех и более таблиц	119
Использование подзапросов в качестве таблиц	122
Использование одной таблицы дважды	124
Самосоединение	125
Проверьте свои знания	126
Глава 6. Работа с множествами	129
Основы теории множеств	129
Теория множеств на практике	132
Операторы для работы с множествами	134
Оператор union	134
Оператор intersect	137
Оператор except	138
Правила применения операторов для работы с множествами	139
Сортировка результатов составного запроса	140
Приоритеты операций над множествами	141
Проверьте свои знания	143
Глава 7. Генерация, обработка и преобразование данных	145
Работа со строковыми данными	145
Генерация строк	146
Манипуляции строками	152
Работа с числовыми данными	160
Выполнение математических функций	161
Управление точностью чисел	163
Работа со знаковыми данными	165
Работа с временными данными	166
Часовые пояса	166

Генерация временных данных	168
Манипуляции временными данными	172
Функции преобразования	177
Проверьте свои знания	178
Глава 8. Группировка и агрегация	179
Концепции группировки	179
Агрегатные функции	183
Неявная и явная группировка	184
Использование выражений	186
Обработка значений null	186
Генерация групп	188
Группировка по одному столбцу	188
Многостолбцовая группировка	189
Группировка с помощью выражений	190
Генерация итоговых данных	190
Условия группового фильтра	192
Проверьте свои знания	194
Глава 9. Подзапросы	195
Что такое подзапрос	195
Типы подзапросов	197
Некоррелированные подзапросы	197
Подзапросы с несколькими строками и одним столбцом	199
Многостолбцовые подзапросы	204
Коррелированные подзапросы	205
Оператор exists	207
Работа с данными с помощью коррелированных подзапросов	209
Применение подзапросов	211
Подзапросы как источники данных	211
Подзапросы как генераторы выражений	218
В заключение	221
Проверьте свои знания	221
Глава 10. Соединения	223
Внешние соединения	223
Левое и правое внешние соединения	226
Трехсторонние внешние соединения	227
Перекрестные соединения	228

Естественные соединения	235
Проверьте свои знания	237
Глава 11. Условная логика	239
Что такое условная логика	239
Выражение case	240
Поисковые выражения case	240
Простые выражения case	242
Примеры выражений case	243
Преобразования результирующего набора	243
Проверка существования	244
Ошибки деления на ноль	247
Условные обновления	248
Обработка значений null	249
Проверьте свои знания	250
Глава 12. Транзакции	251
Многопользовательские базы данных	251
Блокировка	252
Гранулярность блокировок	253
Что такое транзакция	254
Запуск транзакции	256
Завершение транзакции	257
Точки сохранения транзакции	259
Проверьте свои знания	262
Глава 13. Индексы и ограничения	263
Индексы	263
Создание индекса	264
Типы индексов	269
Как используются индексы	272
Обратная сторона индексов	274
Ограничения	275
Создание ограничения	276
Проверьте свои знания	279
Глава 14. Представления	281
Что такое представление	281
Зачем использовать представления	284

Безопасность данных	284
Агрегация данных	285
Соккрытие сложности	286
Соединение разделенных данных	287
Обновляемые представления	288
Обновление простых представлений	288
Обновление сложных представлений	290
Проверьте свои знания	293
Глава 15. Метаданные	295
Данные о данных	295
information_schema	296
Работа с метаданными	302
Сценарии генерации схемы	302
Проверка базы данных	305
Динамическая генерация SQL	306
Проверьте свои знания	310
Глава 16. Аналитические функции	311
Концепции аналитических функций	311
Окна данных	312
Локализованная сортировка	313
Ранжирование	315
Функции ранжирования	315
Генерация нескольких рейтингов	318
Функции отчетности	321
Рамки окон	324
Запаздывание и опережение	327
Конкатенация значений в столбце	328
Проверьте свои знания	329
Глава 17. Работа с большими базами данных	331
Секционирование	331
Концепции секционирования	332
Секционирование таблицы	333
Секционирование индекса	333
Методы секционирования	334
Преимущества секционирования	343
Кластеризация	343

Шардинг	344
Большие данные	345
Hadoop	346
NoSQL и базы данных документов	347
Облачные вычисления	347
Заключение	348
Глава 18. SQL и большие данные	349
Введение в Apache Drill	349
Запрос файлов с помощью Apache Drill	350
Запрос MySQL с использованием Apache Drill	353
Запрос MongoDB с использованием Apache Drill	356
Apache Drill и несколько источников данных	363
Будущее SQL	365
Приложение А. Схема базы данных Sakila	367
Приложение Б. Ответы к упражнениям	369
Глава 3	369
Глава 4	371
Глава 5	373
Глава 6	375
Глава 7	378
Глава 8	378
Глава 9	380
Глава 10	384
Глава 11	386
Глава 12	387
Глава 13	388
Глава 14	389
Глава 15	391
Глава 16	393
Предметный указатель	397


```

|          599 |
|          599 |
|          599 |
|          599 |
+-----+
16044 rows in set (0.01 sec)

```

При наличии 599 клиентов, имеющих более 16000 записей об аренде, просмотрев необработанные данные, невозможно определить, какие клиенты взяли напрокат больше всего фильмов. Вместо этого вы можете попросить сервер базы данных сгруппировать данные с помощью предложения `group by`. Вот тот же запрос, но с использованием предложения `group by` для группировки данных о прокате по идентификатору клиента:

```

mysql> SELECT customer_id
      -> FROM rental
      -> GROUP BY customer_id;
+-----+
| customer_id |
+-----+
|           1 |
|           2 |
|           3 |
|           4 |
|           5 |
|           6 |
|         ... |
|          594 |
|          595 |
|          596 |
|          597 |
|          598 |
|          599 |
+-----+
599 rows in set (0.00 sec)

```

Результирующий набор содержит по одной строке для каждого отдельного значения в столбце `customer_id`, в результате получается 599 строк вместо общего количества в 16044 строк. Причина меньшего результирующего набора в том, что некоторые заказчики брали напрокат более одного фильма. Чтобы увидеть, сколько фильмов было взято напрокат каждым клиентом, можно использовать *агрегатную функцию* в предложении `select` для подсчета количества строк в каждой группе:

```

mysql> SELECT customer_id, count(*)
      -> FROM rental
      -> GROUP BY customer_id;
+-----+-----+

```

```

| customer_id | count(*) |
+-----+-----+
|          1 |       32 |
|          2 |       27 |
|          3 |       26 |
|          4 |       22 |
|          5 |       38 |
|          6 |       28 |
|    ...    |         |
|         594 |       27 |
|         595 |       30 |
|         596 |       28 |
|         597 |       25 |
|         598 |       22 |
|         599 |       19 |
+-----+-----+
599 rows in set (0.01 sec)

```

Агрегатная функция `count()` подсчитывает количество строк в каждой группе, а звездочка сообщает серверу, что нужно считать все, что есть в группе. Используя комбинацию `group by` и агрегатную функцию `count()`, вы можете сгенерировать точные данные, необходимые для ответа на имеющийся бизнес-вопрос.

Глядя на результаты, можно увидеть, что 32 фильма были взяты напрокат клиентом с идентификатором 1, а 25 фильмов — клиентом с идентификатором 597. Чтобы определить, какие клиенты взяли напрокат больше всего фильмов, просто добавим предложение `order by`:

```

mysql> SELECT customer_id, count(*)
-> FROM rental
-> GROUP BY customer_id
-> ORDER BY 2 DESC;
+-----+-----+
| customer_id | count(*) |
+-----+-----+
|         148 |       46 |
|         526 |       45 |
|         236 |       42 |
|         144 |       42 |
|          75 |       41 |
|    ...    |         |
|         248 |       15 |
|         110 |       14 |
|         281 |       14 |
|          61 |       14 |
|         318 |       12 |
+-----+-----+
599 rows in set (0.01 sec)

```

Теперь, когда результаты отсортированы, легко увидеть, что клиент с идентификатором 148 брал напрокат наибольшее количество фильмов (46), в то время как клиент с идентификатором 318 брал наименьшее количество фильмов (12).

При группировке данных вам может потребоваться отфильтровать нежелательные данные из набора результатов на основе групп данных, а не необработанных данных. Поскольку предложение `group by` выполняется после того, как вычислено предложение `where`, добавить условия фильтрации к предложению `where` для этой цели нельзя. Например, вот к чему приводит попытка отфильтровать клиентов, бравших напрокат менее 40 фильмов:

```
mysql> SELECT customer_id, count(*)
-> FROM rental
-> WHERE count(*) >= 40
-> GROUP BY customer_id;
ERROR 1111 (HY000): Invalid use of group function1
```

Вы не можете обратиться к агрегатной функции `count (*)` в предложении `where`, потому что во время вычисления предложения `where` группы еще не были сгенерированы. Вместо этого вы должны поместить условия группового фильтра в предложение `having`. Вот как выглядит правильный запрос:

```
mysql> SELECT customer_id, count(*)
-> FROM rental
-> GROUP BY customer_id
-> HAVING count(*) >= 40;
```

```
+-----+-----+
| customer_id | count(*) |
+-----+-----+
|          75 |         41 |
|          144 |         42 |
|          148 |         46 |
|          197 |         40 |
|          236 |         42 |
|          469 |         40 |
|          526 |         45 |
+-----+-----+
```

7 rows in set (0.01 sec)

Поскольку группы, содержащие менее 40 членов, отфильтрованы с помощью предложения `having`, результирующий набор теперь содержит только тех клиентов, которые брали напрокат 40 и более фильмов.

¹ Неверное применение групповой функции.

Агрегатные функции

Агрегатные функции выполняют определенные операции над всеми строками в группе. Несмотря на то что каждый сервер базы данных имеет собственный набор специализированных агрегатных функций, имеются распространенные агрегатные функции, реализованные всеми основными серверами, в частности следующие.

`max()`

Возвращает максимальное значение в наборе.

`min()`

Возвращает минимальное значение в наборе.

`avg()`

Возвращает усредненное значение набора.

`sum()`

Возвращает сумму значений набора.

`count()`

Возвращает количество значений в наборе.

Вот как выглядит запрос, в котором используются все распространенные агрегатные функции для анализа данных по прокату фильмов:

```
mysql> SELECT MAX(amount) max_amt,  
-> MIN(amount) min_amt,  
-> AVG(amount) avg_amt,  
-> SUM(amount) tot_amt,  
-> COUNT(*) num_payments  
-> FROM payment;
```

```
+-----+-----+-----+-----+-----+  
| max_amt | min_amt | avg_amt | tot_amt | num_payments |  
+-----+-----+-----+-----+-----+  
| 11.99 | 0.00 | 4.200667 | 67416.51 | 16049 |  
+-----+-----+-----+-----+-----+  
1 row in set (0.09 sec)
```

Результаты этого запроса говорят о том, что из 16 049 строк в таблице платежей максимальная выплаченная за прокат фильма сумма составила 11,99 доллара, минимальная — 0 долларов, средний платеж равен 4,20 доллара, а общая сумма всех платежей — 67 416,51 доллара. Надеюсь, этот пример даст вам представление о роли агрегатных функций. В следующих подразделах более подробно разъясняется, как эти функции можно использовать.

Неявная и явная группировка

В предыдущем примере каждое значение, возвращаемое запросом, генерируется агрегатной функцией. Поскольку предложения `group by` в запросе нет, существует единственная неявная группа (все строки в таблице `payment`).

Однако в большинстве случаев требуется получить дополнительные столбцы вместе со столбцами, генерируемыми агрегатными функциями. Например, можно расширить предыдущий запрос и выполнить те же пять агрегатных функций, но не для всех клиентов одновременно, а для каждого клиента. Для такого запроса нужно вместе с пятью агрегатными функциями выполнить выборку `customer_id`:

```
SELECT customer_id,
       MAX(amount) max_amt,
       MIN(amount) min_amt,
       AVG(amount) avg_amt,
       SUM(amount) tot_amt,
       COUNT(*) num_payments
FROM payment;
```

Однако, если вы попытаетесь выполнить такой запрос, то получите сообщение об ошибке:

```
ERROR 1140 (42000): In aggregated query without GROUP BY,
expression #1 of SELECT list contains nonaggregated column2
```

Хотя для вас может быть очевидно, что вы хотите применения агрегатных функций к каждому найденному в таблице `payment` клиенту, этот запрос не выполняется, потому что в нем не указано *явно*, как должны быть сгруппированы данные. Следовательно, в запрос нужно добавить предложение `group by`, чтобы указать, к какой группе строк следует применять агрегатные функции:

```
mysql> SELECT customer_id,
->    MAX(amount) max_amt,
->    MIN(amount) min_amt,
->    AVG(amount) avg_amt,
->    SUM(amount) tot_amt,
->    COUNT(*) num_payments
-> FROM payment
-> GROUP BY customer_id;
```

```
+-----+-----+-----+-----+-----+-----+
|customer_id|max_amt|min_amt|avg_amt|tot_amt|num_payments|
+-----+-----+-----+-----+-----+-----+
```

² В агрегированном запросе без `GROUP BY` выражение №1 списка `SELECT` содержит неагрегированный столбец.

1	9.99	0.99	3.708750	118.68	32
2	10.99	0.99	4.767778	128.73	27
3	10.99	0.99	5.220769	135.74	26
4	8.99	0.99	3.717273	81.78	22
5	9.99	0.99	3.805789	144.62	38
6	7.99	0.99	3.347143	93.72	28
...					
594	8.99	0.99	4.841852	130.73	27
595	10.99	0.99	3.923333	117.70	30
596	6.99	0.99	3.454286	96.72	28
597	8.99	0.99	3.990000	99.75	25
598	7.99	0.99	3.808182	83.78	22
599	9.99	0.99	4.411053	83.81	19

599 rows in set (0.04 sec)

При включении предложения `group by` сервер понимает, что надо сначала сгруппировать строки, имеющие одинаковое значение в столбце `customer_id`, а затем применить к каждой из 599 групп пять агрегатных функций.

Подсчет различных значений

При использовании функции `count ()` для определения количества членов в каждой группе у вас есть выбор: подсчитать *все* элементы группы или подсчитать только *различные* значения столбца среди всех элементов группы.

Рассмотрим, например, следующий запрос, в котором функция `count ()` и столбец `customer_id` используются двумя разными способами:

```
mysql> SELECT COUNT(customer_id) num_rows,
-> COUNT(DISTINCT customer_id) num_customers
-> FROM payment;
```

num_rows	num_customers
16049	599

1 row in set (0.01 sec)

В первом столбце запроса просто подсчитывается количество строк в таблице `payment`, в то время как во втором столбце исследуются значения в столбце `customer_id` и подсчитывается только количество уникальных значений. Таким образом, при указании ключевого слова `distinct` функция `count ()` проверяет значения столбца для каждого члена группы, находя и удаляя дубликаты, а не просто подсчитывает количество значений в группе.

Использование выражений

Наряду с использованием столбцов в качестве аргументов агрегатных функций можно использовать и выражения. Например, можно найти максимальное количество дней между моментом, когда фильм был взят напрокат, и последующим его возвратом. Эту информацию можно получить с помощью следующего запроса:

```
mysql> SELECT MAX(datediff(return_date,rental_date))
-> FROM rental;
+-----+
| MAX(datediff(return_date,rental_date)) |
+-----+
|                                     33 |
+-----+
1 row in set (0.01 sec)
```

Функция `datediff` используется для вычисления количества дней между датой возврата фильма и датой взятия его напрокат для каждой аренды фильма, а функция `max` возвращает максимальное найденное значение, которое в данном случае составляет 33 дня.

Хотя в этом примере используется довольно простое выражение, на практике выражения, используемые в качестве аргументов агрегатных функций, могут быть любой необходимой степени сложности, лишь бы они возвращали числа, строки или даты. В главе 11, “Условная логика”, показано, как для того, чтобы определить, должна ли конкретная строка быть включена в агрегацию, можно использовать выражения `case` с агрегатными функциями.

Обработка значений `null`

При выполнении агрегации (на самом деле — любого вида числовых вычислений) всегда следует учитывать, как на результат вычислений могут повлиять значения `null`. Для иллюстрации я построю простую таблицу для хранения числовых данных и заполню ее множеством {1, 3, 5}:

```
mysql> CREATE TABLE number_tbl
-> (val SMALLINT);
Query OK, 0 rows affected (0.01 sec)

mysql> INSERT INTO number_tbl VALUES (1);
Query OK, 1 row affected (0.00 sec)

mysql> INSERT INTO number_tbl VALUES (3);
Query OK, 1 row affected (0.00 sec)
```

```
mysql> INSERT INTO number_tbl VALUES (5);
Query OK, 1 row affected (0.00 sec)
```

Рассмотрим следующий запрос, который выполняет пять агрегатных функций для указанного множества чисел:

```
mysql> SELECT COUNT(*) num_rows,
-> COUNT(val) num_vals,
-> SUM(val) total,
-> MAX(val) max_val,
-> AVG(val) avg_val
-> FROM number_tbl;
```

num_rows	num_vals	total	max_val	avg_val
3	3	9	5	3.0000

```
1 row in set (0.08 sec)
```

Результаты оказываются такими, как и следовало ожидать: и `count (*)`, и `count (val)` возвращают значение 3, `sum (val)` возвращает значение 9, `max (val)` возвращает 5, а `avg (val)` возвращает 3. Теперь я добавляю в таблицу `number_tbl` значение `null` и снова выполняю тот же запрос:

```
mysql> INSERT INTO number_tbl VALUES (NULL);
Query OK, 1 row affected (0.01 sec)
```

```
mysql> SELECT COUNT(*) num_rows,
-> COUNT(val) num_vals,
-> SUM(val) total,
-> MAX(val) max_val,
-> AVG(val) avg_val
-> FROM number_tbl;
```

num_rows	num_vals	total	max_val	avg_val
4	3	9	5	3.0000

```
1 row in set (0.00 sec)
```

Даже при добавлении в таблицу значения `null` функции `sum ()`, `max ()` и `avg ()` возвращают те же значения; такие результаты указывают на то, что эти функции игнорируют любые встречающиеся значения `null`. Функция `count (*)` теперь возвращает значение 4, которое является корректным, поскольку таблица `number_tbl` сейчас содержит четыре строки, а функция `count (val)` по-прежнему возвращает значение 3. Дело в том, что `count (*)` подсчитывает количество строк, тогда как `count (val)` подсчитывает

количество значений, содержащихся в столбце `val`, и игнорирует любые обнаруженные в нем значения `null`.

Генерация групп

Людей редко интересуют необработанные данные. Обычно те, кто заинтересован в анализе данных, манипулируют необработанными данными так, чтобы они удовлетворяли их потребностям. Распространенными примерами манипуляции являются:

- генерация итогов для географического региона, например общий объем продаж в Европе;
- выявление отклоняющихся значений, таких как лучший продавец 2020 года;
- определение частотных показателей, например количества фильмов, взятых напрокат за месяц.

Чтобы ответить на эти типы запросов, нужно запросить сервер базы данных сгруппировать строки вместе по одному или нескольким столбцам или выражениям. Как вы уже видели в приводимых примерах, механизм для группировки данных в запросе — это предложение `group by`. Из этого раздела вы узнаете, как группировать данные по одному или нескольким столбцам, как группировать данные с помощью выражений и как создавать сводки внутри групп.

Группировка по одному столбцу

Группы из одного столбца — это самый простой и наиболее часто используемый тип группировки. Если, например, вы хотите найти количество фильмов, связанных с каждым актером, нужна группировка по единственному столбцу `film_actor.actor_id`:

```
mysql> SELECT actor_id, count(*)
        -> FROM film_actor
        -> GROUP BY actor_id;
```

```
+-----+-----+
| actor_id | count(*) |
+-----+-----+
|         1 |         19 |
|         2 |         25 |
|         3 |         22 |
|         4 |         22 |
| ...      |          |
```

```

|      197 |      33 |
|      198 |      40 |
|      199 |      15 |
|      200 |      20 |
+-----+-----+
200 rows in set (0.11 sec)

```

Этот запрос генерирует 200 групп, по одной для каждого актера, а затем суммирует количество фильмов для каждого участника группы.

Многостолбцовая группировка

В некоторых случаях вам может потребоваться создавать группы, охватывающие более одного столбца. Расширяя предыдущий пример, представьте, что для каждого актера вы хотите найти общее число фильмов с разными рейтингами (G, PG, ...). В следующем примере показано, как этого добиться:

```

mysql> SELECT fa.actor_id, f.rating, count(*)
-> FROM film_actor fa
->   INNER JOIN film f
->   ON fa.film_id = f.film_id
-> GROUP BY fa.actor_id, f.rating
-> ORDER BY 1,2;

```

```

+-----+-----+-----+
| actor_id | rating | count(*) |
+-----+-----+-----+
|         1 | G      |         4 |
|         1 | PG     |         6 |
|         1 | PG-13  |         1 |
|         1 | R      |         3 |
|         1 | NC-17  |         5 |
|         2 | G      |         7 |
|         2 | PG     |         6 |
|         2 | PG-13  |         2 |
|         2 | R      |         2 |
|         2 | NC-17  |         8 |
| ...      |        |          |
|        199 | G      |         3 |
|        199 | PG     |         4 |
|        199 | PG-13  |         4 |
|        199 | R      |         2 |
|        199 | NC-17  |         2 |
|        200 | G      |         5 |
|        200 | PG     |         3 |
|        200 | PG-13  |         2 |
|        200 | R      |         6 |
|        200 | NC-17  |         4 |
+-----+-----+-----+

```

```

996 rows in set (0.01 sec)

```

Эта версия запроса генерирует 996 групп, по одной для каждой комбинации “актер/рейтинг фильма”, полученной путем соединения таблицы `film_actor` с таблицей `film`. Столбец `rating` я добавил и в предложение `select`, и в предложение `group by`, поскольку значение `rating` извлекается из таблицы, а не генерируется с помощью агрегатной функции, такой как `max` или `count`.

Группировка с помощью выражений

Для группировки можно использовать не только данные столбцов, но и значения, генерируемые выражениями. Рассмотрим следующий запрос, который группирует прокат по годам:

```
mysql> SELECT extract(YEAR FROM rental_date) year,  
-> COUNT(*) how_many  
-> FROM rental  
-> GROUP BY extract(YEAR FROM rental_date);
```

```
+-----+-----+  
| year | how_many |  
+-----+-----+  
| 2005 |    15862 |  
| 2006 |     182  |  
+-----+-----+
```

```
2 rows in set (0.01 sec)
```

В этом запросе применено довольно простое выражение, которое использует функцию `extract()` для того, чтобы вернуть из даты только год для соответствующей группировки строк в таблице `rental`.

Генерация итоговых данных

В разделе “Многостолбцовая группировка” приведен пример, в котором подсчитывается количество фильмов для каждого актера и рейтинга фильмов. Пусть, однако, вместе с общим количеством для каждой комбинации “актер/рейтинг”, нужно получить и общее количество для каждого отдельного актера. Можно выполнить дополнительный запрос и объединить результаты, можно загрузить результаты запроса в электронную таблицу или создать сценарий Python, программу Java или какой-либо иной механизм для получения этих данных и выполнения дополнительных вычислений. Но еще лучше использовать конструкцию `with rollup`, чтобы сервер базы данных сделал эту работу вместо вас. Вот измененный запрос, использующий `with rollup` в предложении `group by`:

```
mysql> SELECT fa.actor_id, f.rating, count(*)
-> FROM film_actor fa
-> INNER JOIN film f
-> ON fa.film_id = f.film_id
-> GROUP BY fa.actor_id, f.rating WITH ROLLUP
-> ORDER BY 1,2;
```

```
+-----+-----+-----+
| actor_id | rating | count(*) |
+-----+-----+-----+
| NULL    | NULL   | 5462    |
|         | 1     | 19      |
|         | 1     | 4       |
|         | 1     | 6       |
|         | 1     | 1       |
|         | 1     | 3       |
|         | 1     | 5       |
|         | 2     | 25      |
|         | 2     | 7       |
|         | 2     | 6       |
|         | 2     | 2       |
|         | 2     | 2       |
|         | 2     | 8       |
| ...     |       |         |
| 199    | NULL   | 15      |
| 199    | G     | 3       |
| 199    | PG    | 4       |
| 199    | PG-13 | 4       |
| 199    | R     | 2       |
| 199    | NC-17 | 2       |
| 200    | NULL   | 20      |
| 200    | G     | 5       |
| 200    | PG    | 3       |
| 200    | PG-13 | 2       |
| 200    | R     | 6       |
| 200    | NC-17 | 4       |
+-----+-----+-----+
1197 rows in set (0.07 sec)
```

Теперь в результирующем наборе имеется 201 дополнительная строка, по одной для каждого из 200 различных актеров и одна общая (для всех актеров вместе). В столбце `rating` для итоговых значений для 200 актеров предоставляется значение `null`, поскольку выполняется накопление по всем рейтингам. Взглянув, например, на первую строку для `actor_id`, равного 200, вы увидите, что всего с этим актером связано 20 фильмов; это значение равно сумме итогов по каждому рейтингу (4 NC-17 + 6 R + 2 PG-13 + 3 PG + 5 G). Для строки общего итога (первая строка вывода) значение `null` предоставлено как для столбца `actor_id`, так и для столбца `rating`; сумма в первой строке вывода равна 5462, что соответствует числу строк в таблице `film_actor`.



В Oracle Database нужно использовать немного другой синтаксис, указывающий, что вы хотите выполнить сведение итоговых данных. Предложение `group by` из предыдущего запроса при использовании Oracle выглядело бы следующим образом:

```
GROUP BY ROLLUP (fa.actor_id, f.rating)
```

Преимущество этого синтаксиса в том, что он позволяет выполнять сведение для подмножества столбцов в предложении `group by`. Если группировка выполняется по столбцам `a`, `b` и `c`, например, можно указать, что сервер должен выполнять сведение только для столбцов `b` и `c` с помощью следующей конструкции:

```
GROUP BY a, ROLLUP (b, c)
```

Если, помимо итогов по актерам, вы хотите подсчитать итоги по рейтингу, можете использовать конструкцию `with cube`, которая будет генерировать итоговые строки для *всех* возможных комбинаций столбцов группировки. К сожалению, конструкция `with cube` недоступна в MySQL версии 8.0, но доступна в SQL Server и Oracle Database.

Условия группового фильтра

В главе 4, “Фильтрация”, вы познакомились с типами условий фильтрации и узнали, как их использовать в предложении `where`. При группировке данных также можно применить фильтрующее условие к данным *после* того, как были сгенерированы группы. Эти типы условий фильтрации должны быть размещены в предложении `having`. Рассмотрим следующий пример:

```
mysql> SELECT fa.actor_id, f.rating, count(*)
-> FROM film_actor fa
-> INNER JOIN film f
-> ON fa.film_id = f.film_id
-> WHERE f.rating IN ('G','PG')
-> GROUP BY fa.actor_id, f.rating
-> HAVING count(*) > 9;
```

actor_id	rating	count(*)
137	PG	10
37	PG	12
180	PG	12
7	G	10
83	G	14
129	G	12

111	PG	15
44	PG	12
26	PG	11
92	PG	12
17	G	12
158	PG	10
147	PG	10
14	G	10
102	PG	11
133	PG	10

-----+-----+-----+
16 rows in set (0.01 sec)

Этот запрос имеет два условия фильтрации: одно — в предложении `where`, которое отфильтровывает любые фильмы с рейтингом, отличным от G или PG, и еще одно — в предложении `having`, которое отфильтровывает всех актеров, снявшихся менее чем в 10 фильмах. Таким образом, один из фильтров действует на данные до их группировки, а другой — после того, как группы были созданы. Если вы по ошибке поместите оба фильтра в предложение `where`, то получите сообщение об ошибке:

```
mysql> SELECT fa.actor_id, f.rating, count(*)
-> FROM film_actor fa
-> INNER JOIN film f
-> ON fa.film_id = f.film_id
-> WHERE f.rating IN ('G','PG')
-> AND count(*) > 9
-> GROUP BY fa.actor_id, f.rating;
ERROR 1111 (HY000): Invalid use of group function3
```

Этот запрос не работает, потому что нельзя включать агрегатную функцию в предложение `where` запроса. Это связано с тем, что фильтры в предложении `where` вычисляются до группировки, поэтому сервер еще не в состоянии выполнять какие-либо функции для групп.



При добавлении фильтров в запрос, который включает предложение `group by`, хорошо подумайте, действует ли фильтр на необработанные данные, — в этом случае он должен принадлежать предложению `where`. Если же фильтр относится к сгруппированным данным, он должен принадлежать предложению `having`.

³ Неверное применение групповой функции.

Проверьте свои знания

Предлагаемые здесь упражнения призваны закрепить понимание вами возможностей группировки и агрегации SQL. Ответы к упражнениям вы найдете в приложении Б.

УПРАЖНЕНИЕ 8.1

Создайте запрос, который подсчитывает количество строк в таблице payment.

УПРАЖНЕНИЕ 8.2

Измените запрос из упражнения 8.1 так, чтобы подсчитать количество платежей, произведенных каждым клиентом. Выведите идентификатор клиента и общую уплаченную сумму для каждого клиента.

УПРАЖНЕНИЕ 8.3

Измените запрос из упражнения 8.2, включив в него только тех клиентов, у которых имеется не менее 40 выплат.