O'REILLY®

Wydanie II

SQL

Zapytania i techniki dla bazodanowców

Receptury

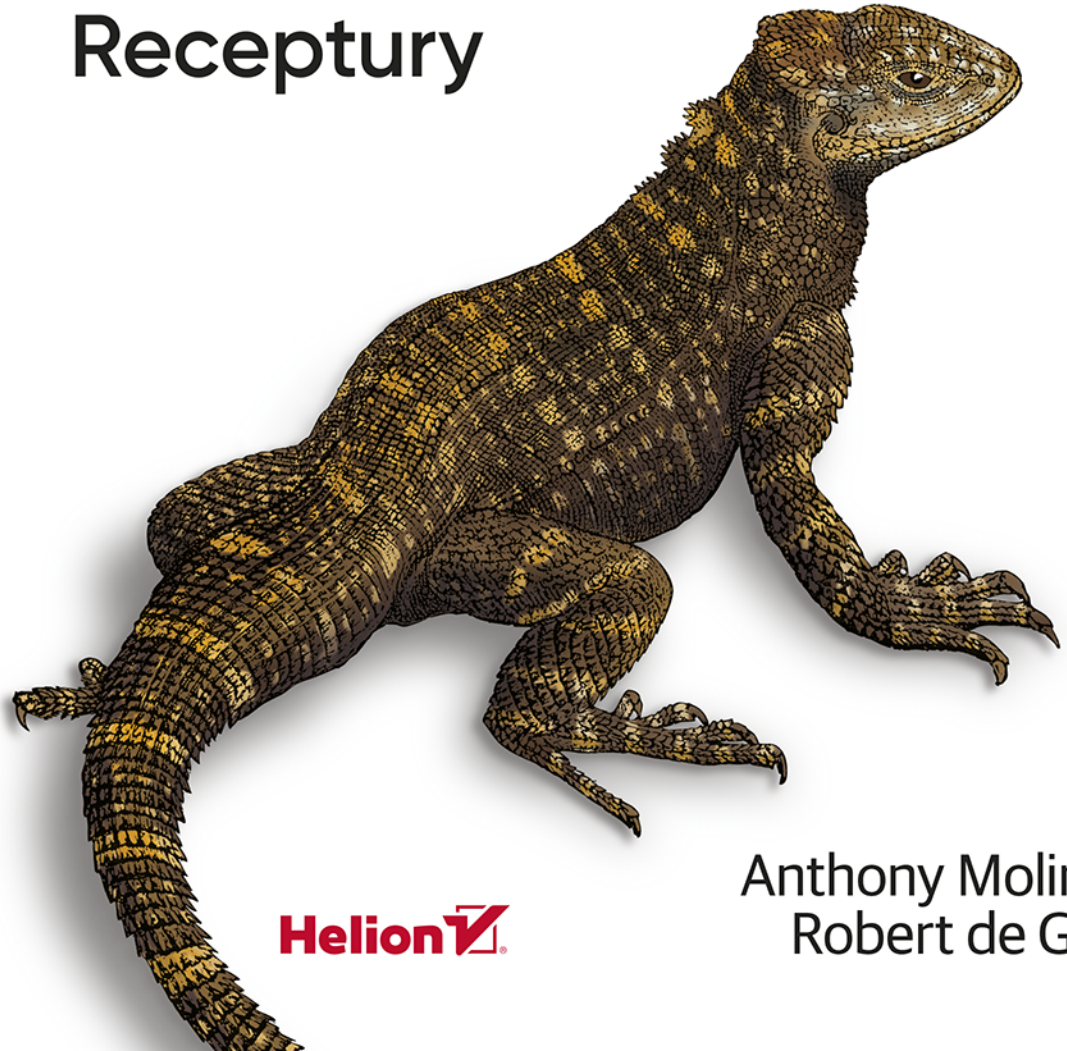

Anthony Molinaro
Robert de Graaf

Helion

Tytuł oryginału: SQL Cookbook: Query Solutions and Techniques for All SQL Users, 2nd Edition

Tłumaczenie: Mikołaj Szczepaniak, Piotr Cieślak

ISBN: 978-83-283-7847-6

Helion S.A.
ul. Kościuszki 1c, 44-100 Gliwice
tel. 32 231 22 19, 32 230 98 63
e-mail: *helion@helion.pl*
WWW: *http://helion.pl* (księgarnia internetowa, katalog książek)

Drogi Czytelniku!
Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres
http://helion.pl/user/opinie/sqlzr2
Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Pliki z przykładami omawianymi w książce można znaleźć pod adresem:
https://ftp.helion.pl/przyklady/sqlzr2.zip

Printed in Poland.

Spis treści

ROZDZIAŁ 1.

Odczytywanie rekordów

W niniejszym rozdziale skupimy się na podstawowych wyrażeniach SELECT. Opanowanie podstaw jest ważne, gdyż wiele omówionych w tym rozdziale zagadnień przewija się nie tylko w trudniejszych recepturach, ale też w codziennej pracy z językiem SQL.

1.1. Odczytywanie wszystkich wierszy i kolumn tabeli

Problem

Dysponujemy tabelą bazy danych i chcemy się zapoznać ze wszystkimi zawartymi w niej danymi.

Rozwiązanie

Należy użyć dla interesującej nas tabeli wyrażenia SELECT ze znakiem specjalnym gwiazdki (*):

```
1 select *
2   from emp
```

Omówienie

Znak gwiazdki (*) ma w języku SQL znaczenie specjalne. Użycie tego znaku w wyrażeniu SELECT spowoduje zwrócenie wszystkich kolumn wskazanej tabeli. Ponieważ w prezentowanym rozwiązaniu nie ma klauzuli WHERE, zwrócony wynik będzie zawierał także wszystkie wiersze tabeli EMP. Alternatywnym rozwiązaniem byłoby wymienienie wprost listy wszystkich kolumn tej tabeli:

```
select empno, ename, job, sal, mgr, hiredate, comm, deptno
   from emp
```

W przypadku zapytań budowanych ad hoc i wykonywanych w sposób interaktywny dużo prostszym rozwiązaniem jest stosowanie wyrażeń SELECT *. Podczas pisania właściwego kodu programu warto jednak wprost wymieniać odczytywane kolumny. Wydajność obu zapytań będzie identyczna, ale obecność konkretnych nazw kolumn ułatwi identyfikację pobieranych danych i będzie stanowiła pewne zabezpieczenie programu na wypadek zmian w bazie danych. Co więcej, tak zapisywane zapytania łatwiej zrozumieć osobom analizującym nasz kod (które nie muszą przecież znać wszystkich kolumn tworzących przetwarzaną tabelę). Problemy z umieszczonym w kodzie

zapytaniem SELECT * mogą się też pojawić w przypadku odwołania się programu do innego zbioru kolumn, niż oczekiwaliśmy. Jeśli wymienimy wszystkie kolumny i okaże się, że którejś (lub którychś) brakuje, otrzymany komunikat błędu ułatwi namierzenie owych braków.

1.2. Odczytywanie podzbioru wierszy tabeli

Problem

Dysponujemy tabelą bazy danych i chcemy się zapoznać wyłącznie z zawartością tych wierszy, które spełniają określony warunek.

Rozwiązanie

Należy użyć klauzuli WHERE definiującej warunek kwalifikowania wierszy do generowanego zbioru wynikowego. Przykładowo, aby uzyskać listę wszystkich pracowników zatrudnionych w dziesiątym dziale firmy, powinniśmy wykonać następujące wyrażenie:

```
1 select *
2   from emp
3  where deptno = 10
```

Omówienie

Klauzula WHERE umożliwia uzyskiwanie tylko tych wierszy, które nas interesują. Jeśli wyrażenie zdefiniowane w klauzuli WHERE okaże się prawdziwe dla danego wiersza, wiersz ten zostanie uwzględniony w zbiorze wynikowym.

Większość producentów oferuje w swoich systemach takie operatory porównawcze jak =, <, >, <=, >=, ! oraz <>. Dodatkowo mamy możliwość definiowania klauzul, które będą wymagały od wierszy kwalifikowanych do zbioru wynikowego spełniania wielu warunków — można to osiągnąć, stosując operatory AND, OR oraz nawiasy (patrz następny przepis).

1.3. Odnajdywanie wierszy spełniających wiele warunków

Problem

Chcemy uzyskać wiersze, które spełniają wiele warunków.

Rozwiązanie

Należy użyć klauzuli WHERE zawierającej operatory OR i/lub AND. Przykładowo, jeśli będziemy zainteresowani listą wszystkich pracowników dziesiątego działu firmy, pracowników, którzy są wynagradzani w trybie prowizyjnym, oraz wszystkich pracowników dwudziestego działu firmy zarabiających nie więcej niż 2000 dolarów miesięcznie, powinniśmy zastosować następujące wyrażenie SELECT:

```
1 select *
2   from emp
3  where deptno = 10
4    or comm is not null
5    or sal <= 2000 and deptno = 20
```

Omówienie

Możemy użyć kombinacji operatorów AND i OR oraz nawiasów, aby zakwalifikować do zbioru wynikowego wiersze spełniające wiele warunków. W prezentowanym przykładzie klauzula WHERE powinna wskazywać na wiersze, które:

- w kolumnie DEPTNO zawierają wartość 10,
- w kolumnie COMM nie zawierają NULL,
- w kolumnie SAL zawierają wartość mniejszą lub równą 2000 i w kolumnie DEPTNO wartość 20.

Warunki ujęte w nawiasy są analizowane łącznie.

Przykładowo, zastanówmy się, jak zmieni się zbiór wynikowy, jeśli w naszym zapytaniu umieścimy nawiasy tak jak w poniższym przykładzie:

```
select *
 from emp
where (    deptno = 10
        or comm is not null
        or sal <= 2000
      )
and deptno = 20

EMPNO ENAME  JOB      MGR HIREDATE      SAL       COMM DEPTNO
----- ------ ------ ----- ----------- ----- ---------- ------
 7369 SMITH  CLERK   7902 17-DEC-2005   800                20
 7876 ADAMS  CLERK   7788 12-JAN-2008  1100                20
```

1.4. Odczytywanie podzbioru kolumn tabeli

Problem

Dysponujemy tabelą bazy danych i chcemy się zapoznać z wartościami określonych kolumn zamiast z zawartością wszystkich kolumn danej tabeli.

Rozwiązanie

Należy wymienić w klauzuli SELECT wszystkie interesujące nas kolumny. Przykładowo, aby uzyskać nazwisko, numer działu i wynagrodzenie pracowników, powinniśmy wykonać zapytanie SELECT w postaci:

```
1 select ename, deptno, sal
2   from emp
```

Omówienie

Wymieniając poszczególne kolumny w klauzuli SELECT, możemy zagwarantować, że zbiór wynikowy nie będzie zawierał żadnych dodatkowych, zbędnych danych. Tego rodzaju pewność jest szczególnie istotna w sytuacji, gdy zapytania są kierowane do bazy danych za pośrednictwem sieci, ponieważ eliminuje to opóźnienia wynikające z wyszukiwania i przesyłania niepotrzebnych danych.

1.5. Definiowanie sensownych nazw kolumn

Problem

Chcielibyśmy tak zmienić nazwy kolumn uwzględnianych w zbiorze wynikowym wygenerowanym przez nasze zapytanie, aby były bardziej czytelne i zrozumiałe. Przeanalizujmy zapytanie zwracające wysokość wynagrodzeń i prowizji otrzymywanych przez wszystkich pracowników:

```
1 select sal, comm
2   from emp
```

Czym jest SAL? Skróconą wersją słowa sale? Czyimś nazwiskiem? Czym jest COMM? Skróconą wersją słowa communication? Chcemy, aby etykiety kolumn tabeli wynikowej były bardziej zrozumiałe.

Rozwiązanie

Aby zmienić nazwy prezentowane w wynikach zapytań, należy użyć słowa kluczowego AS w następującej formie: *nazwa_oryginalna* AS *nowa_nazwa*. Niektóre bazy danych nie wymagają stosowania słowa kluczowego AS, ale wszystkie akceptują i prawidłowo interpretują to słowo:

```
1 select sal as salary, comm as commission
2   from emp

SALARY COMMISSION
------ ----------
   800
  1600        300
  1250        500
  2975
  1250       1300
  2850
  2450
  3000
  5000
  1500          0
  1100
   950
  3000
  1300
```

Omówienie

Stosowanie słowa kluczowego AS do nadawania nowych nazw kolumnom zwracanym przez nasze zapytanie często jest nazywane *nadawaniem aliasów* (ang. *aliasing*) tym kolumnom. Nowe nazwy są określane mianem *aliasów*. Zdefiniowanie dobrych aliasów może bardzo ułatwić ewentualnym odbiorcom wyników zapytania ich prawidłową interpretację.

1.6. Odwołania do aliasów kolumn w klauzuli WHERE

Problem

Używaliśmy już aliasów do definiowania bardziej zrozumiałych nazw kolumn dla generowanych zbiorów wynikowych; tym razem chcielibyśmy dodatkowo wyłączyć część wierszy za pomocą klauzuli `WHERE`. Okazuje się jednak, że próba bezpośredniego odwołania do nazw aliasów w tej klauzuli kończy się niepowodzeniem:

```
select sal as salary, comm as commission
   from emp
  where salary < 5000
```

Rozwiązanie

Aby zyskać możliwość odwoływania się do kolumn reprezentowanych przez aliasy, trzeba zastosować tzw. widok wewnętrzny (ang. *inline view*), określany niekiedy mianem perspektywy wewnętrznej lub wbudowanej:

```
1 select *
2   from (
3 select sal as salary, comm as commission
4   from emp
5        ) x
6  where salary < 5000
```

Omówienie

W tym prostym przykładzie moglibyśmy oczywiście uniknąć konieczności stosowania widoku wewnętrznego i użyć w klauzuli `WHERE` bezpośrednich odwołań do kolumn `COMM` i `SAL` (efekt byłby identyczny). Przedstawione rozwiązanie wprowadza mechanizm, którego będziemy potrzebowali podczas stosowania odwołań do następujących konstrukcji w klauzuli `WHERE`:

- funkcji agregujących,
- podzapytań skalarnych,
- funkcji okna,
- aliasów.

Wróćmy do naszego przykładowego zapytania, w którym użyliśmy aliasu. Okazuje się, że aliasy przypisane kolumnom w podzapytaniu mogą być przedmiotem odwołań w zapytaniu zewnętrznym. Dlaczego należy postąpić w taki sposób? Otóż klauzula `WHERE` jest interpretowana przed klauzulą `SELECT`, zatem w chwili interpretowania klauzuli `WHERE` w oryginalnym zapytaniu („Problem”) aliasy `SALARY` i `COMMISSION` jeszcze nie istnieją. Powstają one dopiero po zakończeniu przetwarzania klauzuli `WHERE`. Z kolei klauzula `FROM` jest przetwarzana przed klauzulą `WHERE`. Umieszczając oryginalne zapytanie w klauzuli `FROM`, spowodujemy, że niezbędne aliasy zostaną zdefiniowane przed osiągnięciem skrajnie zewnętrznej klauzuli `WHERE`, zatem będą widoczne dla tej klauzuli. Opisana technika jest szczególnie przydatna w sytuacji, gdy nazwy kolumny tabeli nie zostały zbyt szczęśliwie dobrane.

Widok wewnętrzny w prezentowanym rozwiązaniu jest reprezentowany przez alias X. Nie wszystkie bazy danych wymagają reprezentowania zapytań wewnętrznych za pomocą definiowanych wprost aliasów, ale wszystkie bazy danych akceptują tego rodzaju zabiegi składniowe.

1.7. Konkatenacja wartości kolumn

Problem

Chcemy zwrócić wartości składowane w wielu kolumnach w formie pojedynczej kolumny. Wyobraźmy sobie np., że chcemy skonstruować zapytanie, które na podstawie tabeli EMP wygeneruje następujący zbiór wynikowy:

```
CLARK WORKS AS A MANAGER
KING WORKS AS A PRESIDENT
MILLER WORKS AS A CLERK
```

Warto jednak pamiętać, że dane potrzebne do wygenerowania tego rodzaju wyników pochodzą z dwóch różnych kolumn tabeli EMP — ENAME oraz JOB:

```
select ename, job
   from emp
   where deptno = 10

ENAME      JOB
---------- ---------
CLARK      MANAGER
KING       PRESIDENT
MILLER     CLERK
```

Rozwiązanie

Należy odnaleźć wbudowaną funkcję naszego systemu zarządzania bazą danych, która umożliwia konkatenację wartości, i użyć jej.

DB2, Oracle, PostgreSQL

W tych systemach baz danych operatorem konkatenacji jest para pionowych kresek (||):

```
1 select ename||' WORKS AS A '||job as msg
2   from emp
3  where deptno = 10
```

MySQL

Baza danych MySQL oferuje funkcję nazwaną CONCAT:

```
1 select concat(ename, ' WORKS AS A ', job) as msg
2   from emp
3  where deptno = 10
```

SQL Server

Użytkownicy systemu SQL Server mogą konkatenować wartości wielu tabel za pomocą standardowego operatora dodawania (+):

```
1 select ename + ' WORKS AS A ' + job as msg
2   from emp
3  where deptno = 10
```

Omówienie

Konkatenacja wartości pochodzących z wielu kolumn wymaga użycia funkcji `CONCAT`. Operator `||` jest skrótem funkcji `CONCAT` stosowanym w systemach baz danych DB2, Oracle i PostgreSQL, natomiast operator + jest skrótem funkcji `CONCAT` w systemie SQL Server.

1.8. Stosowanie logiki warunkowej w wyrażeniu SELECT

Problem

Chcemy wykonać operacje `IF-ELSE` na wartościach zwróconych przez wyrażenie `SELECT`. Przykładowo, planujemy uzyskać zbiór wynikowy, w którym kolumna `STATUS` będzie zawierała wartość `UNDERPAID` dla pracowników zarabiających nie więcej niż 2000 dolarów, wartość `OVERPAID` dla pracowników zarabiających co najmniej 4000 dolarów lub wartość `OK` dla pracowników, których zarobki mieszczą się w przedziale od 2000 do 4000 dolarów. Zbiór wynikowy powinien mieć następującą postać:

```
ENAME             SAL STATUS
---------- ---------- ---------
SMITH              800 UNDERPAID
ALLEN             1600 UNDERPAID
WARD              1250 UNDERPAID
JONES             2975 OK
MARTIN            1250 UNDERPAID
BLAKE             2850 OK
CLARK             2450 OK
SCOTT             3000 OK
KING              5000 OVERPAID
TURNER            1500 UNDERPAID
ADAMS             1100 UNDERPAID
JAMES              950 UNDERPAID
FORD              1000 OK
MILLER            1300 UNDERPAID
```

Rozwiązanie

Musimy użyć wyrażenia `CASE`, za pośrednictwem którego możemy zdefiniować instrukcje warunkowe bezpośrednio w zapytaniu `SELECT`:

```
1 select ename, sal,
2        case when sal <= 2000 then 'UNDERPAID'
3             when sal >= 4000 then 'OVERPAID'
4             else 'OK'
5        end as status
6   from emp
```

Omówienie

Wyrażenie CASE umożliwia definiowanie rozmaitych instrukcji warunkowych, wykorzystujących wartości zwracane przez zapytanie. Istnieje możliwość przypisania do wyrażenia CASE aliasu, który zapewni większą czytelność generowanego zbioru wynikowego. W prezentowanym przykładzie nadano wynikowi wyrażenia CASE alias STATUS. Klauzula ELSE ma charakter opcjonalny. Jeśli zrezygnujemy z tej klauzuli i dany wiersz nie zostanie dopasowany do żadnego z badanych kryteriów, wyrażenie CASE zwróci wartość NULL.

1.9. Ograniczanie liczby zwracanych wierszy

Problem

Chcemy ograniczyć liczbę wierszy zwracanych przez nasze zapytanie. Nie interesuje nas porządek wierszy w zbiorze wynikowym — chcemy tylko, by ich liczba wynosiła dokładnie *n*.

Rozwiązanie

Należy użyć odpowiedniej funkcji oferowanej przez nasz system zarządzania bazą danych umożliwiającej kontrolę liczby zwracanych wierszy.

DB2

W systemie bazy danych DB2 powinniśmy użyć klauzuli FETCH FIRST:

```
1 select *
2   from emp fetch first 5 rows only
```

MySQL i PostgreSQL

Ten sam efekt osiągniemy w systemach MySQL i PostgreSQL, stosując klauzulę LIMIT:

```
1 select *
2   from emp limit 5
```

Oracle

W systemie zarządzania bazą danych Oracle ograniczenia liczby wierszy zwracanych przez zapytania powinny mieć postać klauzul WHERE definiujących wartość progową funkcji ROWNUM:

```
1 select *
2   from emp
3  where rownum <= 5
```

SQL Server

W systemie SQL Server można ograniczyć liczbę zwracanych wierszy, stosując słowo kluczowe TOP:

```
1 select top 5 *
2   from emp
```

Omówienie

Wielu producentów oferuje obsługę klauzul podobnych do `FETCH FIRST` oraz `LIMIT`, dzięki którym możemy określać liczbę wierszy zwracanych przez zapytanie. Inaczej jest w systemie Oracle, gdzie jesteśmy zmuszeni użyć funkcji nazwanej `ROWNUM`, która zwraca liczbę wierszy wchodzących w skład zbioru wynikowego (licznik jest automatycznie zwiększany o jeden wraz z każdym wierszem kwalifikowanym do zbioru wynikowego).

Poniżej opisano procedurę wykonywania zapytania zawierającego w klauzuli `WHERE` warunek `ROWNUM <= 5`, który ogranicza liczbę zwracanych wierszy do pięciu:

1. System Oracle zaczyna wykonywać zapytanie.
2. System Oracle odczytuje pierwszy wiersz i przypisuje licznikowi wartość 1.
3. Czy osiągnęliśmy już limit pięciu wierszy? Jeśli nie, system Oracle zwróci dany wiersz, ponieważ zdefiniowane w klauzuli `WHERE` kryterium liczby wierszy mniejszej lub równej 5 jest spełnione. Jeśli tak, system Oracle nie zwróci kolejnego wiersza.
4. System Oracle odczytuje kolejny wiersz ze wskazanej tabeli i zwiększa wartość licznika wierszy (do 2, do 3, do 4 itd.).
5. Powrót do kroku trzeciego.

Z powyższego opisu wynika, że funkcja `ROWNUM` systemu Oracle przypisuje wartość odpowiedniemu licznikowi *po* odczytaniu kolejnego wiersza. Sekwencja działań jest w tym przypadku niezwykle istotna. Wielu programistów baz danych Oracle próbuje zwracać np. tylko piąty wiersz za pomocą wyrażenia `ROWNUM = 5`.

Stosowanie znaku równości w połączeniu z `ROWNUM` nie jest jednak dobrym pomysłem. Oto co się stanie, gdy spróbujemy zwrócić piąty wiersz za pomocą wyrażenia `ROWNUM = 5`:

1. System Oracle zaczyna wykonywać zapytanie.
2. System Oracle odczytuje pierwszy wiersz i przypisuje licznikowi wartość 1.
3. Czy dotarliśmy już do piątego wiersza? Jeśli nie, system Oracle pomija dany wiersz, ponieważ zdefiniowane w klauzuli `WHERE` kryterium liczby wierszy równej 5 nie jest spełnione. Jeśli tak, system Oracle zwróci dany wiersz. Ale odpowiedź nigdy nie brzmi „tak”!
4. System Oracle odczytuje kolejny wiersz ze wskazanej tabeli i przypisuje mu numer 1. Wynika to z faktu, że pierwszy wiersz zwracany przez zapytanie zawsze musi być oznaczany numerem 1.
5. Powrót do kroku trzeciego.

Wystarczy uważnie przeanalizować opisaną powyżej procedurę, aby się przekonać, dlaczego stosowanie warunku `ROWNUM = 5` nie przyniesie spodziewanych rezultatów. Nie otrzymamy przecież piątego wiersza, jeśli najpierw nie zostaną zwrócone wiersze od pierwszego do czwartego!

Ponadto warto zauważyć, że warunek `ROWNUM = 1` spowoduje zwrócenie pierwszego wiersza, co pozornie jest sprzeczne z powyższymi wyjaśnieniami. Otóż w przypadku pierwszego wiersza warunek `ROWNUM = 1` zadziała, bo w celu sprawdzenia, czy wskazana tabela zawiera jakieś wiersze, Oracle musi podjąć przynajmniej jedną próbę pobrania ich. Zachęcamy do ponownego przejrzenia powyższych punktów i zastąpienia wartości 5 jednością; to dobry sposób na przekonanie się, dlaczego warunek `ROWNUM = 1` jest poprawny (w przypadku chęci zwrócenia jednego wiersza).

1.10. Zwracanie n losowych rekordów tabeli

Problem

Chcemy zwrócić określoną liczbę losowo wybranych rekordów tabeli. Naszym celem jest taka modyfikacja poniższego wyrażenia, która spowoduje, że następujące po sobie wywołania będą zwracały różne zbiory, przy czym każdy z nich będzie się składał z pięciu losowo wybranych wierszy:

```
select ename, job
  from emp
```

Rozwiązanie

Należy użyć funkcji wbudowanej w wykorzystywany system zarządzania bazą danych, która zwraca wartości losowe. Powinniśmy zastosować tę funkcję w klauzuli `ORDER BY`, aby posortować wiersze w sposób przypadkowy. Następnie należy wykorzystać opisaną w poprzednim podrozdziale technikę ograniczania liczby losowo posortowanych wierszy, które znajdą się w zbiorze wynikowym.

DB2

Należy użyć wbudowanej funkcji `RAND` łącznie z klauzulą `ORDER BY` i funkcją `FETCH`:

```
1 select ename, job
2   from emp
3  order by rand() fetch first 5 rows only
```

MySQL

Należy użyć wbudowanej funkcji `RAND` łącznie z klauzulami `LIMIT` i `ORDER BY`:

```
1 select ename, job
2   from emp
3  order by rand() limit 5
```

PostgreSQL

Powinniśmy użyć wbudowanej funkcji `RANDOM` łącznie z klauzulami `LIMIT` i `ORDER BY`:

```
1 select ename, job
2   from emp
3  order by random() limit 5
```

Oracle

Należy użyć wbudowanej funkcji `VALUE` będącej częścią wbudowanego pakietu `DBMS_RANDOM` łącznie z klauzulą `ORDER BY` oraz wywołaniem funkcji `ROWNUM`:

```
1 select *
2   from (
3  select ename, job
4    from emp
5   order by dbms_random.value()
8        )
9   where rownum <= 5
```

SQL Server

Aby uzyskać losowy pięcioelementowy zbiór wynikowy, należy użyć wbudowanej funkcji NEWID w połączeniu z klauzulami TOP oraz ORDER BY:

```
1 select top 5 ename, job
2   from emp
3  order by newid()
```

Omówienie

Klauzula ORDER BY może otrzymywać wartość zwróconą przez funkcję i na jej podstawie modyfikować porządek elementów w zbiorze wynikowym. Wszystkie podane rozwiązania sprawdzają liczbę wierszy w zbiorze wynikowym *po* wykonaniu funkcji wywoływanej w klauzuli ORDER BY. Użytkownicy systemów zarządzania bazą danych innych niż Oracle powinni skorzystać z okazji i przeanalizować rozwiązanie zaproponowane właśnie dla tego systemu, ponieważ właśnie to zapytanie najlepiej ilustruje ideę stojącą także za pozostałymi zapytaniami.

W żadnym razie nie należy mylić stosowania funkcji w klauzuli ORDER BY ze stosowaniem stałych numerycznych. Podanie takiej stałej (numeru) w klauzuli ORDER BY oznacza, że chcemy posortować dane zgodnie z kolumną o tym numerze na liście klauzuli SELECT. Umieszczenie w klauzuli ORDER BY wywołania jakiejś funkcji sprawi, że operacja sortowania zostanie wykonana zgodnie z rezultatami zwróconymi przez tę funkcję dla każdego kolejnego wiersza.

1.11. Odnajdywanie wartości pustych (NULL)

Problem

Chcemy odnaleźć wszystkie wiersze, które zawierają wartości puste w określonej kolumnie.

Rozwiązanie

Aby określić, czy w danym wierszu określona kolumna zawiera wartość pustą, musimy użyć wyrażenia IS NULL.

```
1 select *
2   from emp
3  where comm is null
```

Omówienie

Ponieważ wartość NULL nigdy nie jest ani równa czemukolwiek, ani różna od czegokolwiek (nawet od samej siebie), nie możemy za pomocą standardowych operatorów = lub != sprawdzić, czy dana kolumna zawiera NULL. Aby się o tym przekonać, należy użyć wyrażenia IS NULL. Odnajdywanie wierszy, które nie zawierają wartości pustych w określonej kolumnie, wymaga zastosowania w klauzuli WHERE wyrażenia IS NOT NULL.

1.12. Przekształcanie wartości pustych w rzeczywiste

Problem

Mamy do czynienia z wierszami zawierającymi wartości puste i chcielibyśmy, aby w ich miejsce były zwracane inne, konkretne wartości.

Rozwiązanie

Należy użyć funkcji COALESCE, aby zastąpić wartości puste rzeczywistymi wartościami (w tym przypadku zerami):

```
1 select coalesce(comm, 0)
2   from emp
```

Omówienie

Funkcja COALESCE przyjmuje co najmniej jeden argument i zwraca z listy tych argumentów pierwszą wartość różną od NULL. Oznacza to, że w prezentowanym przykładzie wartość kolumny COMM jest zwracana pod warunkiem, że nie jest wartością pustą. W przeciwnym razie funkcja zwraca zero.

Podczas pracy z wartościami pustymi zawsze warto korzystać z wbudowanej funkcjonalności stosowanego systemu zarządzania bazą danych (DBMS). Znaczna część tych systemów oferuje wiele funkcji, których można z powodzeniem używać do realizacji tego zadania. W prezentowanym rozwiązaniu wykorzystaliśmy funkcję COALESCE, ponieważ działa ona we wszystkich systemach zarządzania bazami danych. Drugą uniwersalną konstrukcją języka SQL obsługiwaną przez wszystkie systemy jest klauzula CASE:

```
select case
       when comm is null then 0
       else comm
       end
  from emp
```

Chociaż wyrażenie CASE może być wykorzystywane do tłumaczenia wartości NULL na inne wartości, powyższy przykład dowodzi, że funkcja COALESCE jest zdecydowanie prostsza w użyciu i bardziej zwięzła.

1.13. Poszukiwanie wzorców

Problem

Chcemy zwrócić wiersze spełniające określone kryteria — wiersze, których zawartość można dopasować do określonego podłańcucha lub wzorca. Przeanalizujmy poniższe zapytanie i zbiór wynikowy:

```
select ename, job
  from emp
 where deptno in (10, 20)
```

```
ENAME      JOB
---------- ----------
SMITH      CLERK
JONES      MANAGER
CLARK      MANAGER
SCOTT      ANALYST
KING       PRESIDENT
ADAMS      CLERK
FORD       ANALYST
MILLER     CLERK
```

Chcemy, aby zbiór wynikowy zawierał nazwiska i stanowiska pracy tylko tych pracowników dziesiątego i dwudziestego działu, których nazwiska zawierają literę `I` lub których nazwa stanowiska pracy kończy się literami `ER`.

```
ENAME      JOB
---------- ----------
SMITH      CLERK
JONES      MANAGER
CLARK      MANAGER
KING       PRESIDENT
MILLER     CLERK
```

Rozwiązanie

Należy użyć operatora `LIKE` łącznie ze stosowanym w języku SQL symbolem wieloznacznym `%`:

```
1 select ename, job
2   from emp
3  where deptno in (10, 20)
4    and (ename like '%I%' or job like '%ER')
```

Omówienie

Operator `%` stosowany łącznie z uniwersalnym operatorem dopasowywania wzorców `LIKE` jest dopasowywany do dowolnej sekwencji znaków. Większość implementacji standardu SQL dodatkowo oferuje operator podkreślenia (_), który jest dopasowywany do pojedynczych znaków. Umieszczając prosty, jednoliterowy wzorzec przeszukiwania `I` pomiędzy dwoma operatorami `%`, określamy, że do zbioru wynikowego będą kwalifikowane łańcuchy zawierające literę `I` (na dowolnej pozycji). Gdybyśmy użyli tylko jednego operatora `%`, zawartość zbioru wynikowego naszego zapytania byłaby uzależniona od umiejscowienia tego operatora. Przykładowo, aby otrzymać stanowiska pracy o nazwach kończących się literami `ER`, powinniśmy szukany łańcuch `ER` poprzedzić operatorem `%`; gdybyśmy chcieli odnaleźć nazwy stanowisk pracy rozpoczynające się od tych samych liter, powinniśmy użyć wyrażenia `ER%`.

1.14. Podsumowanie

Przedstawione receptury są proste, lecz mają fundamentalne znaczenie. Pobieranie informacji jest podstawą tworzenia zapytań do baz danych, a to oznacza, że podane rozwiązania stanowią serce wszystkich innych zagadnień omówionych w dalszej części tej książki.

SQL: dokładnie to, czego potrzebujesz!

SQL jest *linqua franca* dla profesjonalistów zajmujących się przetwarzaniem danych. To wyjątkowo dojrzałe narzędzie, z którego korzysta już kilka pokoleń inżynierów i programistów. Wydaje się jednak, że zbyt często ten język nie jest należycie wykorzystywany: wielu użytkowników posługuje się nim na co dzień, ale mało kto wychodzi poza stosunkowo proste zapytania. Tymczasem z możliwości nowoczesnego SQL mogą skorzystać nie tylko osoby zajmujące się bazami danych, ale także analitycy danych, analitycy biznesowi, statystycy czy osoby zajmujące się wizualizacją danych.

To drugie, gruntownie zaktualizowane wydanie nieocenionego zbioru receptur, podanych tak, aby maksymalnie ułatwić rozwiązywanie codziennych problemów związanych z budową zapytań SQL. Uwzględniono tu kilka wariantów języka SQL, zaimplementowanych w systemach: Oracle, DB2, SQL Server, MySQL i PostgreSQL. W książce znalazły się propozycje zastosowania takich nowoczesnych rozwiązań jak funkcje okna, wspólne wyrażenia tablicowe i rekurencyjne zapytania hierarchiczne. Nie zabrakło receptur opracowanych specjalnie dla analityków danych, umożliwiających zastosowanie mediany odchylenia bezwzględnego i prawa Benforda, a także wyszukiwanie danych tekstowych na podstawie brzmienia słów.

W książce znajdziesz receptury, dzięki którym:

- łatwiej opanujesz podstawy SQL
- dobrze wykorzystasz funkcje okna
- zastosujesz wspólne wyrażenia tablicowe (CTE) do tworzenia czytelniejszych rozwiązań
- zwiększysz użyteczność SQL w analizie danych
- skuteczniej obsłużysz dane liczbowe i ciągi znaków

Anthony Molinaro jest analitykiem danych w Johnson & Johnson. Zajmuje się metodami nieparametrycznymi, analizą szeregów czasowych i wielkoskalowymi bazami danych. Jest członkiem otwartej społeczności naukowej OHDSI.

Robert de Graaf jest starszym analitykiem danych w firmie RightShip Wcześniej pracował w przemyśle wytwórczym. Jest zafascynowany potęgą statystyki w rozwiązywaniu praktycznych problemów.

ISBN 978-83-283-7847-6