

IDŹ DO

PRZYKŁADOWY ROZDZIAŁ



SPIS TREŚCI

KATALOG KSIĄŻEK

KATALOG ONLINE

ZAMÓW DRUKOWANY KATALOG

TWÓJ KOSZYK

DODAJ DO KOSZYKA

CENNIK I INFORMACJE

ZAMÓW INFORMACJE
O NOWOŚCIACH

ZAMÓW CENNIK

CZYTELNIA

FRAGMENTY KSIĄŻEK ONLINE

Bazy danych i PostgreSQL. Od podstaw

Autorzy: Richard Stones, Neil Matthew

Tłumaczenie: Radosław Meryk

ISBN: 83-7197-650-X

Tytuł oryginału: [Beginning Databases with PostgreSQL](#)

Format: B5, stron: 610



PostgreSQL wciąż zyskuje na popularności i jest uważany za najlepszy darmowy system zarządzania relacyjnymi bazami danych. Początkowo był tworzony w środowisku uniwersyteckim, potem – jako otwarty projekt internetowy – przez utalentowanych programistów z całego świata. Coraz częściej duże firmy decydują się na wybór PostgreSQL jako systemu zarządzania bazami danych.

Niniejsza książka jest kompletnym podręcznikiem opisującym cechy systemu PostgreSQL. Zawiera opis najprostszych metod instalacji i zarządzania systemem, tworzenia własnych baz danych, jak również omówienie integracji baz danych z aplikacjami napisanymi w najpopularniejszych językach programowania wykorzystywanych w Internecie. Czytelnik znajdzie w niej wskazówki dotyczące tworzenia coraz bardziej wyrafinowanych zapytań języka SQL, łączenia tabel, wykorzystywania transakcji, monitorowania pracy serwera, tworzenia własnych aplikacji w językach wysokiego poziomu i wiele innych.

Dla kogo jest ta książka?

Książka jest adresowana do Czytelników rozpoczynających swoją przygodę z relacyjnymi bazami danych (nie jest wymagana wiedza z zakresu języków SQL, PHP, Java czy Perl). Opisano w niej zarówno najprostsze zapytania, jak i coraz bardziej skomplikowane metody zarządzania bazami danych, które umożliwią im rozwiązywanie codziennych problemów administratorów baz danych. Dzięki lekturze można nauczyć się zarządzania bazą danych PostgreSQL w środowiskach Windows i Unix.

Co zawiera książka?

- Wprowadzenie do systemu PostgreSQL
- Opis instalacji z pakietów binarnych i kodów źródłowych w środowiskach Windows i Unix
- Opis narzędzi graficznych
- Przykłady zapytań obejmujących zapytania złożone, funkcje agregujące i inne
- Przedstawienie transakcji, poziomów izolacji, procedur składowanych i wyzwalaczy
- Monitorowanie wydajności i kontrolowanie pracy serwera
- Łączenie z bazą danych i wykonywanie instrukcji SQL z poziomu języka C (libpq)
- Tworzenie aplikacji przy użyciu języków PHP, Perl i Java



Spis treści

Podziękowania	15
Wstęp	17
Jak wymawiać „PostgreSQL”	17
Co jest treścią tej książki?.....	17
Stosowane konwencje.....	19
Pobranie kodu źródłowego	20
Rozdział 1. Wstęp do PostgreSQL	21
Programowanie z wykorzystaniem danych.....	21
Kartotekowe bazy danych	23
Co to jest baza danych?	24
Rodzaje baz danych	25
Sieciowy model bazy danych.....	25
Hierarchiczny model baz danych.....	26
Relacyjny model bazy danych.....	27
Języki zapytań.....	28
SQL.....	29
Systemy zarządzania bazą danych	31
Co to jest PostgreSQL?	32
Krótka historia PostgreSQL	33
Architektura PostgreSQL	34
Licencje Open Source	35
Zasoby	36
Rozdział 2. Podstawy relacyjnych baz danych	37
Arkusze kalkulacyjne	37
Trochę terminologii	38
Ograniczenia arkuszy kalkulacyjnych.....	39
Czym wyróżnia się baza danych?.....	40
Wybór kolumn	41
Wybór typu danych dla każdej z kolumn	41
Unikalne identyfikowanie wierszy	42
Porządek wierszy	43
Wprowadzanie danych do bazy danych	43
Dostęp do danych przez sieć	44
Tworzenie podzbiorów informacji	45
Dodatkowe informacje.....	48
Wiele tabel.....	48
Relacje pomiędzy tabelami	49

4 Bazy danych i PostgreSQL. Od podstaw

Projektowanie tabel.....	51
Podstawowe zasady rzemiosła	52
Zasada pierwsza — podział danych na kolumny	52
Zasada druga — określenie unikalnego sposobu identyfikacji każdego wiersza ..	52
Zasada trzecia — usunięcie powtarzających się informacji.....	53
Zasada czwarta — stosowanie właściwych nazw	53
Przykład bazy danych klient-zamówienie	54
Wyjście poza granice dwóch tabel	54
Finalizowanie projektu wstępnego	57
Podstawowe typy danych	59
Wartości specjalna NULL.....	60
Sprawdzanie wartości NULL	61
Przykładowa baza danych	62
Rozdział 3. Instalacja.....	63
Instalować czy uaktualniać?.....	64
Instalacja PostgreSQL z pakietów binarnych systemu Linux	64
Anatomia instalacji PostgreSQL	66
Instalacja PostgreSQL z kodu źródłowego	69
Uruchamianie PostgreSQL.....	72
Tworzenie bazy danych.....	76
Tworzenie tabel	78
Usuwanie tabel	79
Wypełnianie tabel danymi.....	80
Zatrzymywanie PostgreSQL.....	82
Instalacja PostgreSQL w Windows	83
Cygwin — środowisko UNIX w systemie Windows.....	83
Usługi IPC dla Windows	87
PostgreSQL dla Cygwin	88
Kompilacja PostgreSQL w Windows.....	88
Konfiguracja PostgreSQL dla Windows	89
Automatyczne uruchamianie PostgreSQL.....	90
Rozdział 4. Dostęp do danych.....	95
Wykorzystanie psql	96
Proste instrukcje SELECT	98
Podstawianie nazw kolumn.....	100
Porządek wierszy	100
Ukrywanie duplikatów.....	103
Wykonywanie obliczeń	105
Wybór wierszy	107
Bardziej złożone warunki	109
Porównywanie wzorców	111
Ograniczanie liczby wierszy w wyniku	112
Porównania danych o różnych typach	113
Sprawdzanie wartości NULL.....	113
Sprawdzanie danych typu data i czas	114
Ustawianie formatu daty i czasu	115
Funkcje daty i czasu	119

Wiele tabel.....	121
Tworzenie związku pomiędzy dwoma tabelami.....	121
Aliasy nazw tabel.....	126
Tworzenie związku trzech tabel.....	127
Rozdział 5. Graficzne narzędzia PostgreSQL.....	133
psql.....	134
Uruchamianie psql.....	134
Polecenia w psql.....	134
Historia poleceń.....	135
Skrypty w psql.....	136
Badanie bazy danych.....	137
Przegląd opcji wiersza polecenia.....	138
Przegląd poleceń wewnętrznych.....	139
ODBC.....	139
pgAdmin.....	144
Kpsql.....	149
PgAccess.....	150
Formularze i narzędzia do projektowania zapytań.....	152
Microsoft Access.....	153
Tabele łączy.....	154
Wprowadzanie danych.....	158
Raporty.....	158
Microsoft Excel.....	159
Zasoby.....	163
Rozdział 6. Interfejs danych.....	165
Wprowadzanie danych do bazy danych.....	165
Proste operacje INSERT.....	166
Bezpieczniejsza postać instrukcji INSERT.....	169
Wprowadzanie danych do kolumn typu SERIAL.....	170
Dostęp do numerów sekwencji.....	171
Wprowadzanie wartości NULL.....	173
Polecenie \copy.....	175
Pobieranie danych bezpośrednio z innej aplikacji.....	178
Aktualizacja danych w bazie danych.....	182
Ostrzeżenie.....	183
Usuwanie wierszy z bazy danych.....	185
Rozdział 7. Zaawansowane wyszukiwanie danych.....	189
Funkcje agregacji.....	190
COUNT.....	190
GROUP BY a COUNT(*).....	192
HAVING a COUNT(*).....	194
COUNT(nazwa_kolumny).....	196
Funkcja MIN().....	197
Funkcja MAX().....	198
Funkcja SUM().....	199
Funkcja AVG().....	199
Powiązania typu UNION.....	200

Zapytania podrzędne	202
Rodzaje zapytań podrzędnych	205
Zapytania podrzędne skorelowane	206
Powiązania same z sobą	210
Powiązania zewnętrzne	211
Rozdział 8. Definicje danych i operacje manipulowania danymi	217
Typy danych.....	218
Typ Boolean	218
Typy znakowe	220
Typy numeryczne	222
Typy daty i czasu	225
Specjalne typy PostgreSQL	225
Tworzenie własnych typów	226
Typy tablicowe.....	226
Konwersja pomiędzy typami.....	227
Inne operacje manipulowania danymi	229
Magiczne zmienne	230
Kolumna OID.....	230
Manipulowanie tabelami.....	231
Tworzenie tabel	232
Ograniczenia dla kolumny.....	232
Ograniczenia dla tabel	236
Uaktualnianie struktury tabeli	237
Usuwanie tabel	240
Tabele tymczasowe.....	240
Perspektywy	240
Ograniczenia kluczy obcych.....	244
Klucze obce jako ograniczenia dla kolumn	246
Klucze obce jako ograniczenia dla tabel.....	247
Opcje ograniczeń dla kluczy obcych	250
DEFERRABLE	251
ON UPDATE oraz ON DELETE	251
Rozdział 9. Transakcje i blokady	253
Co to są transakcje?	254
Reguły ACID	257
Transakcje dla pojedynczych użytkowników	258
Ograniczenia transakcji	260
Transakcje z wieloma użytkownikami	261
Poziomy izolacji ANSI	261
Niepożądane zjawiska.....	262
Poziomy izolacji ANSI/ISO	266
Tryb chained (autozatwierdzenie) oraz tryb unchained	267
Blokady.....	268
Zakleszczenia.....	269
Jawne blokady.....	271
Blokowanie wierszy.....	271
Blokady tabel	272

Rozdział 10. Procedury przechowywane w bazie danych oraz procedury wyzwalane	275
Operatory	276
Priorytet operatorów oraz kierunek nadawania wartości	277
Operatory arytmetyczne	278
Operatory porównań i operatory znakowe	279
Inne operatory	281
Funkcje	282
Języki proceduralne	284
Czynności wstępne dla języka PL/pgSQL	285
Przeciążanie funkcji	287
Wyświetlanie listingu funkcji	288
Usuwanie funkcji	289
Użycie apostrofów	289
Anatomia procedur zapisywanych w bazie danych	289
Argumenty funkcji	290
Komentarze	290
Deklaracje	291
ALIAS	292
RENAME	293
Prosta deklaracja zmiennej	293
Złożona deklaracja zmiennej	294
ROWTYPE	294
RECORD	294
Instrukcje przypisania	295
Instrukcja SELECT INTO	295
PERFORM	296
Instrukcje sterujące	296
Zwracanie wartości przez funkcje	296
Wyjątki i komunikaty	297
Instrukcje warunkowe	298
Pętle	299
Zapytania dynamiczne	304
Funkcje SQL	305
Procedury wyzwalane	306
Tworzenie wyzwalaczy	307
Procedury wyzwalane	308
Dlaczego procedury przechowywane w bazie danych i procedury wyzwalane?	313
Rozdział 11. Administracja bazą danych PostgreSQL	315
Instalacja domyślna	316
bin	316
include i lib	316
doc	317
man	318
share	318
data	318
Początkowa baza danych	319
Sterowanie serwerem	320
Uruchamianie i zatrzymywanie serwera	320

Użytkownicy.....	322
CREATE USER.....	323
DROP USER.....	324
ALTER USER.....	325
Grupy.....	325
UPRAWNIENIA.....	326
Perspektywy.....	328
Zarządzanie danymi.....	329
Tworzenie i usuwanie baz danych.....	329
Tworzenie kopii zapasowych i odtwarzanie danych.....	330
Uaktualnienia bazy danych.....	335
Bezpieczeństwo bazy danych.....	335
Opcje konfiguracji.....	338
Konfiguracja serwera na etapie kompilacji.....	338
Konfiguracja działania serwera.....	339
Wydajność.....	341
VACUUM.....	341
Indeksy.....	344

Rozdział 12. Projekt bazy danych.....347

Zrozumienie problemu.....	348
Na czym polega dobry projekt bazy danych?.....	349
Zdolność przechowywania potrzebnych danych.....	349
Zdolność obsługi wymaganych związków.....	349
Zdolność rozwiązywania problemu.....	349
Zdolność do narzucania integralności danych.....	350
Zdolność narzucania wydajności w przetwarzaniu danych.....	350
Zdolność uwzględniania przyszłych zmian.....	351
Etapy projektowania bazy danych.....	351
Zbieranie informacji.....	351
Projekt logiczny.....	352
Określenie obiektów.....	352
Przekształcenie obiektów w tabele.....	354
Określenie relacji oraz krotności.....	358
Naszkiecowanie diagramu związków encji.....	358
Przykładowa baza danych.....	359
Przekształcenie w model fizyczny.....	363
Ustalenie kluczy głównych.....	363
Zdefiniowanie kluczy zewnętrznych.....	365
Zdefiniowanie typów danych.....	367
Pełne definicje tabel.....	370
Implementacja reguł biznesu.....	370
Sprawdzenie projektu.....	370
Postacie normalne.....	371
Pierwsza postać normalna.....	371
Druga postać normalna.....	372
Trzecia postać normalna.....	373
Znane wzorce.....	373
Wiele-do-wielu.....	374
Hierarchia.....	374
Relacje rekurencyjne.....	375
Zasoby.....	377

Rozdział 13. Dostęp do PostgreSQL z języka C z wykorzystaniem biblioteki libpq.....	379
Korzystanie z biblioteki libpq	380
Połączenia z bazą danych	381
Plik Makefile	384
Dodatkowe informacje	384
Uruchamianie SQL za pomocą libpq	385
Transakcje	390
Uzyskiwanie danych z zapytań.....	390
Wyświetlanie wyników zapytań	394
Kursory	397
Wartości binarne.....	403
Mechanizm pracy asynchronicznej	403
Rozdział 14. Dostęp do PostgreSQL z języka C z wykorzystaniem wbudowanego SQL	409
Pierwszy program z wbudowanym SQL	410
Argumenty programu ecpg	414
Rejestrowanie wykonywania instrukcji SQL.....	415
Połączenia z bazą danych	416
Obsługa błędów.....	418
Obsługa błędów.....	421
Zmienne hosta	422
Pobieranie danych za pomocą ecpg.....	425
Transakcje	429
Obsługa danych.....	429
Kursory.....	432
Diagnozowanie kodu ecpg	435
Rozdział 15. Dostęp do PostgreSQL z języka PHP	437
Dodanie obsługi PostgreSQL w PHP.....	438
Korzystanie z interfejsu API języka PHP dla PostgreSQL.....	439
Połączenia z bazą danych	439
Połączenia trwałe	440
Zamykanie połączeń	441
Informacje o połączeniu	441
Tworzenie zapytań	442
Złożone zapytania.....	443
Wykonywanie zapytań	444
Przetwarzanie zestawów wyników	445
Pobieranie wartości z zestawów wyników	447
Informacje dotyczące pól.....	450
Zwalnianie pamięci przydzielonej na zestawy wyników.....	451
Konwersja typów wartości wyników	452
Obsługa błędów.....	452
Kodowanie znaków	453
PEAR	454
Interfejs abstrakcji bazy danych PEAR	454
Obsługa błędów PEAR.....	456
Przygotowanie i wykonanie zapytania.....	457

Rozdział 16. Dostęp do PostgreSQL z języka Perl	459
Pgsq_perl5 lub moduł Pg	460
Instalacja pgsq_perl5	460
CPAN	461
Korzystanie z interfejsu pgsq_perl5	462
DBI języka Perl	468
Instalacja DBI i PostgreSQL DBD	468
Wykorzystywanie DBI	469
Co jeszcze możemy zrobić przy użyciu DBI?	475
Wykorzystanie DBIx::Easy	477
DBI i XML	479
Rozdział 17. Dostęp do PostgreSQL z języka Java	483
Opis ogólny JDBC	484
Sterowniki JDBC	484
Typ 1	485
Typ 2	485
Typ 3	485
Typ 4	486
Konfigurowanie sterownika JDBC PostgreSQL	486
DriverManager i Driver	487
Java.sql.DriverManager	487
Zarządzanie sterownikami	487
Zarządzanie połączeniami	488
Zarządzanie rejestracją zdarzeń dotyczących JDBC	489
Zarządzanie limitami czasu logowania się	489
java.sql.Driver	489
Połączenia	492
Tworzenie instrukcji	492
Obsługa transakcji	493
Metadane bazy danych	494
Pobieranie metadanych PostgreSQL	494
Zestawy wyników JDBC	496
Tryb wielodostępu i typ zestawu wyników	496
Typ	496
Tryb wielodostępu	497
Przeglądanie zestawów wyników	497
Przewijanie zestawów wyników	497
Sprawdzanie położenia kursora	498
Kierunek pobierania i rozmiar	499
Korzystanie z danych zestawu wyników	500
Odwzorowanie typów danych PostgreSQL	500
Zestawy wyników, które można aktualizować	500
Usuwanie danych	501
Aktualizacja danych	501
Wstawianie danych	502
Inne metody	503

Instrukcje JDBC	503
Instrukcje.....	504
Sprawdzanie wyników i zestawów wyników.....	505
Obsługa wsadowego przetwarzania instrukcji SQL	506
Metody różne	506
Przykład klienta JDBC	506
Instrukcje przygotowane	508
Wykonywanie instrukcji SQL	509
Aktualizacja danych	510
Przykładowe wykorzystanie przygotowanych instrukcji	510
Wyjątki i ostrzeżenia SQL.....	512
Aplikacja JDBC z Graficznym Interfejsem Użytkownika (GUI).....	512
Diagram klasy	513
Customer	513
CustomerTableModel.....	513
CustomerApp.....	514
CustomerPanel	514
Komunikacja z systemem.....	514
Szczegółowe informacje dotyczące klientów.....	515
Dodawanie nowego klienta.....	516
Usuwanie klienta.....	517
Pliki źródłowe	517
Klasa Customer	517
Klasa CustomerTableModel	519
Klasa CustomerPanel	521
Klasa CustomerApp.....	523
Kompilacja i uruchomienie aplikacji.....	528
Rozdział 18. Dalsze informacje i zasoby	529
Nie-relacyjne modele baz danych.....	529
OLTP, OLAP i pozostała terminologia bazy danych.....	530
Zasoby.....	532
Zasoby Sieciowe.....	533
PostgreSQL.....	533
PHP.....	533
Perl.....	533
Java i JDBC.....	533
Ogólne narzędzia	533
Książki	534
SQL.....	534
PHP.....	534
Perl.....	535
Java	535
Dodatek A Ograniczenia bazy danych PostgreSQL	537
Wielkość bazy danych: bez ograniczenia	538
Wielkość tabeli: 16 TB – 64 TB.....	538
Liczba wierszy w tabeli: bez ograniczenia	538
Indeksy: bez ograniczenia.....	539
Wielkość kolumny: 1 GB.....	539
Kolumny w tabeli: 250+	539
Wielkość wiersza: bez ograniczenia	539

Dodatek B Typy danych PostgreSQL.....	541
Typy logiczne	541
Dokładne typy numeryczne	542
Przybliżone typy numeryczne	542
Typy daty i czasu.....	543
Typy znakowe	544
Typy geometryczne	544
Typy różne.....	545
Dodatek C Składnia SQL w PostgreSQL	547
Polecenia SQL w PostgreSQL.....	547
Składnia dostępnych w PostgreSQL instrukcji SQL.....	547
Dodatek D Opis opcji i poleceń psql.....	561
Opcje wiersza polecenia psql	561
Wewnętrzne polecenia psql	563
Dodatek E Schemat baz danych i tabel	565
Dodatek F Obsługa dużych obiektów w PostgreSQL	569
Dodawanie grafiki do bazy danych	569
Obiekty BLOB	571
Import i eksport	571
Zdalny import i eksport	574
Programowanie obiektów BLOB.....	575
Dodatek G Uwagi do wydania 7.2 PostgreSQL.....	577
Przegląd.....	577
VACUUM	577
Transakcje	577
Numery OID	577
Optymalizator	578
Bezpieczeństwo.....	578
Statystyki.....	578
Ustawienia międzynarodowe	578
Migracja do wersji 7.2.....	578
Zmiany.....	579
Działanie serwera	579
Wydajność	580
Uprawnienia	580
Uwierzytelnianie klientów.....	581
Konfiguracja serwera	581
Zapytania.....	581
Operacje dotyczące schematu	582
Instrukcje pomocnicze	583
Typy danych i funkcje	583
Ustawienia międzynarodowe	585
PL/pgSQL	585
PL/Perl	586
PL/Tcl	586

PL/Python.....	586
Psql.....	586
Libpq.....	586
JDBC.....	587
ODBC.....	588
ECPG.....	588
Różne interfejsy.....	589
Kompilacja i instalacja.....	589
Kod źródłowy.....	590
Contrib.....	590
Skorowidz	593

7

Zaawansowane wyszukiwanie danych

W rozdziale 4. omówiliśmy szczegółowo instrukcję `SELECT` oraz sposób jej użycia do wyszukiwania danych. Omawiane tam zagadnienia obejmowały wybieranie kolumn i wierszy oraz łączenie tabel. W poprzednim rozdziale zaprezentowaliśmy sposoby dodawania, aktualizacji i usuwania danych. W obecnym powrócimy do instrukcji `SELECT` i omówimy jej bardziej zaawansowane cechy. Z niektórych spośród tych możliwości będziemy korzystać bardzo rzadko, ale warto je znać, aby zdawać sobie sprawę z możliwości języka SQL.

Czytelnicy, którzy czytając tę książkę wypróbują przykłady, zauważą, że zarówno w tym rozdziale, jak i w innych, zawsze rozpoczynamy od czystych danych wyjściowych w przykładowej bazie danych. Dzięki temu czytelnicy mogą zgłębiać te rozdziały, na które mają ochotę. Oznacza to, że w przypadku, gdy będziemy korzystać z przykładowych danych z poprzednich rozdziałów, niektóre wyniki mogą być nieco różne od pokazanych. Skrypty, które można pobrać ze strony WWW książki pozwalają na łatwe usunięcie tabel, ponowne ich utworzenie oraz ponowne wypełnienie ich danymi.

W tym rozdziale omówimy najpierw pewne specjalne funkcje, nazywane funkcjami agregacji. Pozwalają one na uzyskiwanie wyników na podstawie grupy wierszy. Następnie omówimy nieco bardziej zaawansowane operacje powiązań, pozwalające na kontrolowanie wyników. W tych przypadkach powiązania między tabelami nie będą tak proste jak te, których używaliśmy poprzednio. Poznamy także całą nową grupę zapytań nazywanych zapytaniami podrzędnymi (ang. *subquery*), w których w pojedynczym zapytaniu używamy kilku instrukcji `SELECT`. Wreszcie poznamy bardzo ważną operację `OUTER JOIN`, która pozwala na łączenie tabel w sposób bardziej elastyczny niż ten, z którym spotkaliśmy się do tej pory.

W rozdziale omówimy następujące funkcje:

- funkcje agregacji;
- powiązania typu `UNION`;

- zapytania podrzędne;
- powiązania same z sobą;
- powiązania zewnętrzne.

Funkcje agregacji

W poprzednich rozdziałach korzystaliśmy z kilku specjalnych funkcji: `MAX (nazwa_kolumny)` — w celu uzyskania największej wartości w kolumnie i `COUNT(*)` — aby uzyskać liczbę wierszy w tabeli. Funkcje te należą do niewielkiej grupy funkcji SQL, nazywanej funkcjami agregacji.

Do grupy tej należą:

- `COUNT(*)`,
- `COUNT(nazwa_kolumny)`,
- `MIN(nazwa_kolumny)`,
- `MAX(nazwa_kolumny)`,
- `SUM(nazwa_kolumny)`,
- `AVG (nazwa_kolumny)`.

Zazwyczaj są to funkcje bardzo przydatne i łatwe do stosowania.

Polecenie `psql \da` wyświetla listę wszystkich funkcji agregacji w PostgreSQL.

Polecenie `psql \da` wyświetla listę wszystkich funkcji agregacji w PostgreSQL.

COUNT

Rozpoczniemy od funkcji `COUNT`, która — jak widać z przedstawionej powyżej listy — ma dwie postacie. Funkcja `COUNT(*)` oblicza liczbę wierszy w tabeli. Pełni ona rolę specjalnej nazwy kolumny w instrukcji `SELECT`. W tych instrukcjach `SELECT`, które wykorzystują dowolne z funkcji agregacji, można stosować dwie opcjonalne klauzule: `GROUP BY` oraz `HAVING`. Składnia jest wówczas następująca:

```
SELECT COUNT(*) lista_kolumn FROM nazwa_tabeli WHERE warunek
[GROUP BY nazwa_kolumny [HAVING warunki agregacji]]
```

Nowa, opcjonalna klauzula `GROUP BY` jest dodatkowym warunkiem, z którego można korzystać w instrukcjach `SELECT`. Zazwyczaj korzysta się z niej w przypadku stosowania funkcji agregacji. Można ją także wykorzystywać jako funkcję podobną do `ORDER BY`, ale działającą z kolumną, na podstawie której została wyliczona wartość funkcji agregacji. Opcjonalna klauzula `HAVING` pozwala na wybór określonych wierszy dla pewnych warunków funkcji `COUNT(*)`, jeżeli wykorzystaliśmy już klauzulę `GROUP BY`.

Brzmi to bardzo tajemniczo, ale w praktyce jest dosyć proste. Spróbujmy skorzystać z bardzo prostej instrukcji `COUNT(*)`, aby mieć obraz jej działania. Wkrótce poznamy także działanie klauzuli `GROUP BY`.

Wypróbuj to — proste zastosowanie funkcji `COUNT(*)`

Przypuśćmy, że chcemy wiedzieć, ilu klientów z tabeli `customer` mieszka w mieście Bingham. Moglibyśmy oczywiście zapisać proste zapytanie SQL w postaci:

```
SELECT * FROM customer WHERE town = 'Bingham';
```

lub, w bardziej wydajny sposób, zapisać instrukcję SQL, która daje w wyniku mniejszą ilość danych:

```
SELECT customer_id FROM customer WHERE town='Bingham';
```

Uzyskamy wprawdzie oczekiwany efekt, ale dość okrężną drogą. Operacje te wymagają wyszukiwania dużej ilości danych, które w zasadzie nie są nam potrzebne. Przypuśćmy, że w tabeli `customer` znajdują się dane wielu tysięcy klientów, z których ponad tysiąc mieszka w Bingham. W takim przypadku wybralibyśmy mnóstwo danych, które nie są nam potrzebne. Funkcja `COUNT(*)` rozwiązuje ten problem, pozwalając na wybranie za ledwie jednego wiersza, który zawiera liczbę wierszy spełniających warunek. Zapiszemy naszą instrukcję `SELECT` w zwykły sposób, ale zamiast wpisywać rzeczywiste kolumny, wykorzystamy funkcję `COUNT(*)`:

```
bpsimple=# SELECT COUNT(*) FROM customer WHERE town = 'Bingham';
count
-----
      3
(1 row)

bpsimple=#
```

Gdybyśmy chcieli policzyć wszystkich klientów, moglibyśmy po prostu pominąć klauzulę `WHERE`:

```
bpsimple=# SELECT COUNT(*) FROM customer;
count
-----
     15
bpsimple=#
```

Zauważmy, że otrzymaliśmy pojedynczy wiersz zawierający liczbę wierszy. Aby sprawdzić wynik, można po prostu zamienić `COUNT(*)` na `customer_id`, co spowoduje wyświetlenie rzeczywistych danych.

Jak to działa?

Funkcja `COUNT(*)` umożliwia uzyskanie liczby obiektów, a nie obiektów samych w sobie. W większości wypadków jest to znacznie bardziej wydajne niż wybieranie danych, z dwóch powodów:

- nie trzeba pobierać z bazy danych informacji, które nie są nam potrzebne;
- funkcja COUNT(*) umożliwia bazie danych korzystanie z jej wewnętrznych informacji bez konieczności przeszukiwania danych.

Nigdy nie należy wybierać danych, jeżeli potrzebujemy tylko liczby wierszy.

GROUP BY a COUNT(*)

Odpowiedź na zapytanie pokazane w poprzednim podrozdziale nie zawsze spełni nasze oczekiwania. Przypuśćmy, że chcielibyśmy wiedzieć, ilu klientów mieszka w każdym mieście. Moglibyśmy dowiedzieć się tego wybierając listę różnych miast, a następnie wyliczając, ilu klientów mieszka w każdym z nich. Jest to jednak proceduralny i raczej żmudny sposób rozwiązania problemu. Czy nie byłoby lepiej zastosować sposób deklarycyjny, formułując zapytanie bezpośrednio w SQL? Moglibyśmy pokusić się o wypróbowanie następującej instrukcji:

```
SELECT COUNT(*), town FROM customer;
```

Jest to rozsądna próba, zważywszy na to, co wiemy do tej pory, ale PostgreSQL wyświetli komunikat o błędzie, ponieważ nie jest to poprawna składnia SQL. Aby rozwiązać ten problem, potrzebujemy dodatkowej klauzuli GROUP BY.

Klauzula GROUP BY informuje PostgreSQL, że funkcja agregacji powinna obliczyć wynik i wyzerować się za każdym razem, kiedy określona kolumna lub kolumny zmieniają wartość. Jest ona bardzo prosta w użyciu. Wystarczy dodać zapis GROUP BY nazwa_kolumny do instrukcji SELECT z funkcją COUNT (*), a PostgreSQL poinformuje nas, ile wierszy o określonej wartości kolumny znajduje się w tabeli.

Wypróbuj to — GROUP BY

Spróbujmy odpowiedzieć na pytanie, ilu klientów mieszka w każdym mieście?

Etap pierwszy polega na napisaniu instrukcji SELECT, która zawiera funkcję COUNT(*) oraz nazwę kolumny, dokładnie tak, jak próbowaliśmy odgadnąć:

```
SELECT COUNT(*), town FROM customer;
```

Następnie należy dodać klauzulę GROUP BY, aby poinformować PostgreSQL, że powinien obliczyć wynik i wyzerować licznik za każdym razem, kiedy zmieni się miasto. Można to zrobić za pomocą następującego zapytania:

```
SELECT COUNT(*), town FROM customer GROUP BY town;
```

A oto nasza instrukcja w działaniu:

```
bpsimple=# SELECT COUNT(*), town FROM customer GROUP BY town;
count | town
-----+-----
      3 | Bingham
```

```

1 | Hightown
1 | Histon
1 | Lowtown
1 | Milltown
2 | Nicetown
1 | Oahenham
1 | Oxbridge
1 | Tibsville
1 | Welltown
1 | Winersby
1 | Yuleville
(12 rows)

```

```
bpsimple=#
```

Jak widzimy, uzyskaliśmy przejrzystą listę miast wraz z liczbą klientów w każdym z nich.

Jak to działa?

PostgreSQL porządkuje wynik według kolumn wymienionych w klauzuli `GROUP BY`, następnie oblicza liczbę wierszy i za każdym razem, kiedy zmienia się miasto, zapisuje wiersz wyniku, po czym zeruje licznik. Zgodzimy się, że jest to o wiele łatwiejsze niż pisanie kodu procedury z pętlą dla każdego miasta.

Jeżeli zachodzi taka potrzeba, sposób ten można zastosować do więcej niż jednej kolumny, pod warunkiem, że wszystkie kolumny, które wybrano, są także wymienione w klauzuli `GROUP BY`. Przypuśćmy, że interesowały nas dwie informacje. Po pierwsze, ilu klientów mieszka w każdym mieście, po drugie, ile różnych nazwisk mają ci klienci. Możemy po prostu dodać kolumnę `lname` zarówno do części `SELECT`, jak `GROUP BY`:

```

bpsimple=# SELECT COUNT(*), lname, town FROM customer GROUP BY town, lname;
count | lname | town
-----+-----+-----
1 | Jones | Bingham
2 | Stones | Bingham
1 | Stones | Hightown
1 | Hickman | Histon
1 | Stones | Lowtown
1 | Hudson | Milltown
2 | Matthew | Nicetown
1 | Cozens | Oahenham
1 | Hendy | Oxbridge
1 | Howard | Tibsville
1 | O'Neill | Welltown
1 | Neill | Winersby
1 | Matthew | Yuleville
(13 rows)

```

```
bpsimple=#
```

Zwróćmy uwagę, że wynik jest posortowany najpierw według miasta, a następnie według nazwiska, ponieważ w tej kolejności (`town, lname`) wymieniono kolumny w klauzuli `GROUP BY` oraz na to, że obecnie Bingham znajduje się na liście dwa razy, ponieważ mieszkają w nim klienci o dwóch różnych nazwiskach, Jones oraz Stones.

HAVING a COUNT(*)

Ostatnią opcjonalną częścią instrukcji jest klauzula `HAVING`. Często jest ona myląca dla początkujących programistów piszących w języku SQL, ale w rzeczywistości nie jest trudna w użyciu. Należy po prostu pamiętać, że `HAVING` jest rodzajem klauzuli `WHERE` dla funkcji agregacji. Klauzulę `HAVING` wykorzystujemy w celu ograniczenia liczby zwracanych wierszy, gdzie

Użycie funkcji agregacji w klauzuli `WHERE` nie jest poprawne. Są one poprawne tylko wewnątrz klauzuli `HAVING`.

określona funkcja agregacji, na przykład `COUNT(*)`, ma wartość `TRUE`. Używamy jej w dokładnie taki sam sposób, jak klauzuli `WHERE`, w celu ograniczenia liczby wierszy na podstawie wartości kolumny.

Spójrzmy na przykład, który powinien sprawić, że zagadnienie to stanie się łatwe i przyjemne. Przypuśćmy, że chcemy znać wszystkie miasta, w których mamy więcej niż jednego klienta. Moglibyśmy wówczas użyć funkcji `COUNT(*)`, a następnie odszukać na liście interesujące nas miasta. Nie jest to jednak rozwiązanie sensowne w sytuacji, gdy mamy tysiące miast. Zamiast tego skorzystamy z klauzuli `HAVING` w celu ograniczenia wyniku do tych wierszy, gdzie wartość funkcji `COUNT(*)` jest większa niż jeden. Zrobimy to w następujący sposób:

```
bpsimple=# SELECT COUNT(*), town FROM customer
bpsimple=# GROUP BY town HAVING COUNT(*)>1;
 count | town
-----+-----
      3 | Bingham
      2 | Nicetown
(2 rows)

bpsimple=#
```

Zauważmy, że w dalszym ciągu musimy zapisać klauzulę `GROUP BY` i musi ona występować przed klauzulą `HAVING`. Teraz, kiedy znamy podstawy funkcji `COUNT(*)`, klauzuli `GROUP BY` oraz `HAVING`, spróbujmy wykorzystać je wszystkie w większym przykładzie.

Wypróbuj to — HAVING

Przypuśćmy, że myślimy o opracowaniu harmonogramu dostaw i chcemy znać nazwiska wszystkich klientów i miasta, skąd pochodzą, oprócz klientów z Lincoln (być może jest to nasze miasto). Interesują nas tylko te miasta, w których mamy więcej niż jednego klienta.

Nie jest to takie trudne, jak mogłoby się wydawać; musimy po prostu stopniowo stworzyć nasze rozwiązanie. Jest to zazwyczaj dobre podejście dla instrukcji SQL. Jeżeli coś wygląda na zbyt trudne, należy rozpocząć od rozwiązania czegoś prostszego, ale podobnego, a następnie rozszerzyć rozwiązanie do momentu, aż uda się rozwiązać problem bardziej skomplikowany. Tak więc należy rozpoznać problem, podzielić go na mniejsze części, a następnie rozwiązać każdą z nich.

Zacznijmy od wybrania danych, a nie ich liczenia. Dane uporządkujemy według miasta, aby można było łatwiej zorientować się, o co chodzi:

```
bpsimple=# SELECT lname, town FROM customer WHERE town <> 'Lincoln';
  lname | town
-----+-----
Stones  | Hightown
Stones  | Lowtown
Matthew | Nicetown
Matthew | Yuleville
Cozens  | Oahenham
Matthew | Nicetown
Stones  | Bingham
Stones  | Bingham
Hickman | Histon
Howard  | Tibsville
Jones   | Bingham
Neill   | Winersby
Hendy   | Oxbridge
O'Neill | Welltown
Hudson  | Milltown
(15 rows)

bpsimple=#
```

Do tej pory wygląda nieźle, nieprawda?

Teraz, aby skorzystać z funkcji COUNT(*) w celu wykonania obliczeń, musimy także umieścić klauzulę GROUP BY i pogrupować kolumny według nazwiska i miasta (lname, town):

```
bpsimple=# SELECT COUNT(*), lname town FROM customer WHERE town <>
bpsimple=# 'Lincoln' GROUP BY lname, town;
 count | lname | town
-----+-----+-----
      1 | Cozens | Oahenham
      1 | Hendy  | Oxbridge
      1 | Hickman | Histon
      1 | Howard | Tibsville
      1 | Hudson | Milltown
      1 | Jones  | Bingham
      2 | Matthew | Nicetown
      1 | Matthew | Yuleville
      1 | Neill  | Winersby
      1 | O'Neill | Welltown
      2 | Stones | Bingham
      1 | Stones | Hightown
      1 | Stones | Lowtown
(13 rows)

bpsimple=#
```

Możemy teraz odnaleźć odpowiedź samodzielnie przeglądając dane, ale jesteśmy zaledwie o krok od właściwego wyniku. Wystarczy dodać klauzulę HAVING, a zostaną wybrane wiersze, gdzie wartość funkcji COUNT(*) jest większa niż 1:

```

bpsimple=# SELECT COUNT(*), lname town FROM customer WHERE town <>
bpsimple=# 'Lincoln' GROUP BY lname, town HAVING COUNT(*)>1;
 count | lname | town
-----+-----+-----
      2 | Matthew | Nicetown
      2 | Stones | Bingham
(2 rows)

bpsimple=#

```

Dosyć proste, jeżeli podzielimy problem na mniejsze części.

Jak to działa?

Rozwiązaliśmy nasz problem w trzech etapach:

- w celu wyszukania wszystkich interesujących nas wierszy zapisaliśmy prostą instrukcję SELECT;
- następnie dodaliśmy słowa kluczowe COUNT(*) oraz GROUP BY w celu obliczenia liczby unikalnych kombinacji nazwiska i miasta (lname oraz town);
- wreszcie dodaliśmy klauzulę HAVING, aby wyszukać tylko te wiersze, w których wartość COUNT(*) była większa niż 1.

Przy takim podejściu istnieje jednak pewien problem. Gdybyśmy mieli do czynienia z bazą danych klientów, która zawierałaby tysiące wierszy, lista klientów przewijałaby się nam bardzo długo w czasie opracowywania naszego zapytania. Dla naszej prostej bazy danych nie stanowiło to problemu, ale dla dużej bazy danych takie interaktywne podejście w opracowywaniu zapytania ma pewne wady. Na szczęście zazwyczaj łatwo opracować zapytania na próbce danych, z wykorzystaniem klucza podstawowego. Gdybyśmy do wszystkich zapytań dodali warunek WHERE customer_id<50, pracowalibyśmy z próbką pierwszych 50 klientów w bazie.

Kiedy już będziemy pewni, że zapytanie jest poprawne, możemy po prostu usunąć klauzulę WHERE i wykonać nasze rozwiązanie dla całej tabeli. Oczywiście musimy być pewni, że zastosowana próbka danych, wykorzystana w celu przetestowania naszej instrukcji SQL, jest reprezentantem całości zbioru danych oraz musimy mieć na uwadze, że mniejsze próbki mogą nie w pełni testować naszą instrukcję SQL.

COUNT(nazwa_kolumny)

Pewną odmianą funkcji COUNT(*) jest użycie nazwy kolumny zamiast znaku '*'. Różnica polega na tym, że funkcja COUNT(nazwa_kolumny) oblicza ilość wierszy w tabeli, w których określona kolumna ma wartość różną od NULL.

Przypuścimy, że do naszej kolumny customer dodaliśmy pewne dane o nowych klientach, zaś numery telefonów zawarte w tych danych mają wartość NULL:

```

INSERT INTO customer(title, fname, lname, addressline, town, zipcode)
VALUES('Mr', 'Gavin', 'Smyth', '23 Harlestone', 'Milltown', 'MT7 7HI');

```

```

INSERT INTO customer(title, fname, lname, addressline, town, zipcode, phone)
VALUES('Mrs', 'Sarah', 'Harvey', '84 Willow Way', 'Lincoln', 'LC3 7RD', '527 3739');
INSERT INTO customer(title, fname, lname, addressline, town, zipcode)
VALUES('Mr', 'Steve', 'Harvey', '84 Willow Way', 'Lincoln', 'LC3 7RD');
INSERT INTO customer(title, fname, lname, addressline, town, zipcode)
VALUES('Mr', 'Paul', 'Garrett', '27 Chase Avenue', 'Lowtown', 'LT5 8TQ');

```

Sprawdźmy, ilu jest klientów, dla których nie znamy numerów telefonów:

```

bpsimple=# SELECT customer_id FROM customer WHERE phone IS NULL;
 customer_id
-----
            16
            18
            19
(3 rows)

bpsimple=#

```

Widzimy, że mamy trzech takich klientów. Sprawdźmy teraz, ilu wszystkich klientów jest w bazie danych:

```

bpsimple=# SELECT COUNT(*) FROM customer;
 count
-----
     19
(1 row)

bpsimple=#

```

Mamy w sumie 19 klientów. Tak więc, jeżeli obliczymy liczbę klientów, których wartość numeru telefonu jest różna od NULL, prawdopodobnie otrzymamy 16:

```

bpsimple=# SELECT COUNT(phone) FROM customer;
 count
-----
     16
(1 row)

bpsimple=#

```

Jest to jedyna różnica pomiędzy COUNT(*) a COUNT(nazwa_kolumny). Odmiana funkcji z nazwą kolumny oblicza wiersze, w których kolumna o określonej nazwie ma wartość różną niż NULL, postać funkcji ze znakiem '*' oblicza zaś liczbę wszystkich wierszy. Pod każdym innym względem, jak choćby w przypadku użycia GROUP BY oraz HAVING, COUNT(nazwa_kolumny) działa dokładnie tak samo jak COUNT(*).

Funkcja MINO

Teraz, kiedy znamy funkcję COUNT(*) i poznaliśmy zasady obowiązujące dla funkcji agregacji, możemy zastosować tę samą logikę do wszystkich pozostałych funkcji agregacji.

Jak można się spodziewać, funkcja `MIN()` ma parametr w postaci nazwy kolumny i zwraca najmniejszą wartość znaną w tej kolumnie. Dla kolumn o typach numerycznych osiągniemy spodziewane wyniki. Dla typów opisujących czas, na przykład daty, uzyskamy największą datę, która może dotyczyć przeszłości bądź przyszłości. Dla ciągów znaków o zmiennej długości wyniki są nieco zaskakujące, ponieważ ciągi są porównywane po uprzednim uzupełnieniu ich spacjami z prawej strony. Funkcje `MIN()` oraz `MAX()` w odniesieniu do kolumn typu `VARCHAR` należy stosować ostrożnie, gdyż w ich przypadku wyniki mogą być różne od oczekiwanych.

Oto kilka przykładów.

Poszukajmy najmniejszej opłaty transportowej, jaką nałożyliśmy na zamówienie:

```
bpsimple=# SELECT MIN(shipping) FROM orderinfo;
 min
-----
 0.00
(1 row)

bpsimple=#
```

W rzeczywistości wartość ta wynosiła zero. Zwróćmy uwagę, co się stanie, jeżeli zastosujemy tę samą funkcję z kolumną `phone`, o której wiemy, że istnieją w niej wartości `NULL`:

```
bpsimple=# SELECT MIN(phone) FROM customer;
 min
-----
010 4567
(1 row)

bpsimple=#
```

Moglibyśmy się spodziewać, że wynik będzie teraz miał wartość `NULL` lub będzie pustym ciągiem znaków. Biorąc jednak pod uwagę, że `NULL` z reguły oznacza „nieznany”, funkcja `MIN()` ignoruje tę wartość. Ignorowanie wartości `NULL` jest cechą wszystkich funkcji agregacji oprócz `COUNT(*)`. To, czy posiadanie informacji o najmniejszym numerze telefonu ma jakiegokolwiek znaczenie, jest oczywiście odrębną kwestią.

Funkcja MAX()

Nie jest zaskoczeniem, że funkcja `MAX()` jest podobna do `MIN()`, ale działa w odwrotnym kierunku.

Jak można się spodziewać, `MAX()` jako parametr przyjmuje nazwę kolumny i zwraca maksymalną wartość znaną w tej kolumnie.

Oto kilka przykładów.

Poszukajmy największej opłaty transportowej, jaką nałożyliśmy na zamówienie:

```
bpsimple=# SELECT MAX(shipping) FROM orderinfo;
 max
-----
```

```

3.99
(1 row)

bpsimple=#

```

Tak jak w przypadku funkcji `MIN()`, wartości `NULL` są ignorowane:

```

bpsimple=# SELECT MAX(phone) FROM customer;
max
-----
961 4526
(1 row)

bpsimple=#

```

To w zasadzie wszystko, co należy wiedzieć o funkcji `MAX()`, z wyjątkiem tego, że można z nią używać klauzul `GROUP BY` oraz `HAVING`, dokładnie tak, jak w przypadku funkcji `COUNT(*)`.

Funkcja SUM()

Funkcja `SUM()` przyjmuje jako parametr nazwę kolumny o typie numerycznym i zwraca sumę wartości dla tej kolumny. Tak jak funkcje `MIN()` oraz `MAX()`, funkcja `SUM()` ignoruje wartości typu `NULL`:

```

bpsimple=# SELECT SUM(shipping) FROM orderinfo;
sum
-----
9.97
(1 row)

bpsimple=#

```

Funkcja `SUM()` posiada interesującą odmianę. Możemy mianowicie zażądać, aby dodano tylko wartości unikalne, tak, aby kilka wierszy o tych samych wartościach zostało uwzględnione w sumie tylko raz:

```

bpsimple=# SELECT SUM(DISTINCT shipping) FROM orderinfo;
sum
-----
6.98
(1 row)

bpsimple=#

```

Zwróćmy uwagę, że rzeczywiste zastosowanie tej odmiany jest dość mgliste.

Funkcja AVG()

Ostatnią opisaną funkcją agregacji jest `AVG()`, jako parametr przyjmująca również nazwę kolumny i zwracająca wartość średnią. Podobnie jak funkcja `SUM()`, także `AVG()` ignoruje

wartości NULL i może być użyta ze słowem kluczowym DISTINCT, aby działała tylko z różnymi wartościami:

```
bpsimple=# SELECT AVG(shipping) FROM orderinfo;
      avg
-----
1.9940000000
(1 row)

bpsimple=#
```

Odmiana ze słowem kluczowym DISTINCT wygląda następująco:

```
bpsimple=# SELECT AVG(DISTINCT shipping) FROM orderinfo;
      avg
-----
2.3266666667
(1 row)

bpsimple=#
```

Zwróćmy uwagę, że w implementacjach standardowego SQL oraz PostgreSQL nie ma funkcji MODE oraz MEDIAN. Niektórzy komercyjni producenci dołączają jednak obsługę tych funkcji jako rozszerzenia.

Powiązania typu UNION

Omówimy teraz sposób połączenia kilku instrukcji SELECT dla zapewnienia większych możliwości wyszukiwania.

Pamiętamy z poprzedniego rozdziału tabelę `tcust`, którą wykorzystaliśmy jako tabelę tymczasową w celu ładowania danych do tabeli `customer`. Przypuśćmy, że w okresie czasu pomiędzy ładowaniem informacji o nowych klientach do tabeli `tcust` a wyczyszczeniem tabeli i załadowaniem danych do rzeczywistej tabeli `customer`, pojawiło się pytanie o listę wszystkich miast, w których mamy klientów, z uwzględnieniem nowych informacji. Możemy słusznie zauważyć, że — ponieważ jeszcze nie załadowaliśmy danych o klientach do głównej tabeli i nie wyczyściliśmy danych — nie możemy być pewni dokładności nowych danych. Tak więc żadna lista miast łącząca obie listy również nie będzie dokładna. Czasami jednak nie jest to ważne. Być może potrzebna była tylko ogólna informacja o geograficznym rozproszeniu klientów, a nie dokładne dane.

Możemy rozwiązać ten problem poprzez wybranie miasta (`town`) z tabeli `customer` i zapisanie wyniku, a następnie wybranie miasta (`town`) z tabeli `tcust`, ponowne zapisanie oraz połączenie obu list. Wygląda to raczej nieelegancko, ponieważ mamy dwie tabele, obie zawierające listę miast.

Czy nie ma sposobu, aby inaczej połączyć listy? Jak można wywnioskować z tytułu tego podrozdziału, istnieje taki sposób i nazywa się powiązaniem typu UNION. Powiązania te nie są zbyt popularne, ale w pewnych okolicznościach są właściwym środkiem do rozwiązania problemu i są ponadto bardzo łatwe w użyciu.

Spróbujmy ponownie umieścić pewne dane w tabeli `tcust`, aby miała następującą zawartość:

```
bpsimple=# SELECT * FROM tcust;
 title | fname | lname | addressline | town | zipcode | phone
-----+-----+-----+-----+-----+-----+-----
 Mr   | Peter | Bradley | 72 Milton Rise | Keynes | MK41 2HQ | 
 Mr   | Kevin | Carney  | 43 Glen Way   | Lincoln | LI2 7RD  | 786 3454
 Mr   | Brian | Waters  | 21 Troon Rise | Lincoln | LI7 6GT  | 786 7245
 Mr   | Malcolm | Whalley | 3 Craddock Way | Welltown | WT3 4GQ  | 435 6543
(4 rows)

bpsimple=#
```

Porównajmy listę miast z tej tabeli z listą z tabeli `customer`.

Wiemy już, w jaki sposób wybrać miasto (`town`) z każdej z tabel. Musimy użyć bardzo prostej pary instrukcji `SELECT` następującej postaci:

```
SELECT town FROM tcust;
SELECT town FROM customer;
```

Każda z tych instrukcji daje w wyniku listę miast. Aby je połączyć, zastosujemy operator `UNION`:

```
SELECT town FROM tcust UNION SELECT town FROM customer;
```

Wprowadziliśmy naszą instrukcję `SQL` dla ułatwienia czytania w kilku wierszach. Zwróćmy uwagę, że znak zachęty `psql` zmienia się z `=#` na `-#`, dla zaznaczenia, że jest to kontynuacja instrukcji. Ponieważ jest to pojedyncza instrukcja `SQL`, występuje tylko jeden średnik na końcu:

```
bpsimple=# SELECT town FROM tcust
bpsimple-# UNION
bpsimple-# SELECT town FROM customer;
 town
-----
 Bingham
 Hightown
 Histon
 Keynes
 Lincoln
 Lowtown
 Milltown
 Nicetown
 Oahenham
 Oxbridge
 Tibsville
 Welltown
 Winersby
 Yuleville
(14 rows)

bpsimple=#
```

Jak to działa?

PostgreSQL stworzył listę miast z obu tabel i połączył je w pojedynczą listę. Zauważmy, że wszystkie duplikaty zostały usunięte. Gdybyśmy chcieli uzyskać listę wszystkich miast włącznie z duplikatami, zapisalibyśmy `UNION ALL` zamiast `UNION`.

Właściwość łączenia instrukcji `SELECT` nie ogranicza się do pojedynczej kolumny, moglibyśmy połączyć także listę miast i kodów pocztowych:

```
SELECT town, zipcode FROM tcust UNION SELECT town, zipcode FROM customer;
```

Spowodowałyby to utworzenie listy złożonej z obu kolumn. Byłaby to dłuższa lista, ponieważ ze względu na kod pocztowy, istnieje więcej unikalnych wierszy.

Powiązanie typu `UNION` nie potrafi jednak czynić cudów; obie listy kolumn muszą zawierać jednakową ich liczbę, a ponadto wybrane odpowiadające sobie kolumny muszą mieć zgodne typy. Popatrzmy:

```
bpsimple=# SELECT title FROM customer
bpsimple=# UNION
bpsimple=# SELECT town FROM tcust;
 title
-----
 Keynes
 Lincoln
 Miss
 Mr
 Mrs
 Welltown
(6 rows)

bpsimple=#
```

Zapytanie, jakkolwiek raczej pozbawione sensu, jest poprawne, ponieważ PostgreSQL może połączyć kolumny, mimo że kolumna `title` ma stałą długość, natomiast kolumna `town` — zmienną, ponieważ obie kolumny są ciągami znaków. Gdybyśmy dla przykładu spróbowali powiązać pole `customer_id` oraz `town`, PostgreSQL poinformowałby nas, że jest to niemożliwe, ponieważ typy kolumn są różne.

W zasadzie to wszystko, co należy wiedzieć o powiązaniach typu `UNION`, które czasem okazują się bardzo przydatne do łączenia danych z dwóch (lub więcej) tabel.

Zapytania podrzędne

Teraz, kiedy poznaliśmy instrukcje SQL zawierające więcej niż jedną instrukcję `SELECT`, możemy zapoznać się z całą klasą instrukcji wyszukiwania danych, które łączą instrukcje `SELECT` w o wiele bardziej wyszukany sposób. Są one trudniejsze do zrozumienia niż zapytania złożone z pojedynczej instrukcji `SELECT` lub powiązania typu `UNION`, ale są bardzo przydatne i otwierają nowe możliwości tworzenia kryteriów wyboru.

Zapytanie podrzędne ma miejsce wtedy, gdy tworzymy jeden (lub więcej) warunków WHERE instrukcji SELECT jako odrębną instrukcję SELECT.

Przypuśćmy, że chcemy odnaleźć wszystkie towary z tabeli item, z ceną zakupu (cost_price) większą niż 10. Instrukcja SELECT jest w tym przypadku raczej złożona ze względu na konieczność konwersji typu liczby na typ NUMERIC(7,2) po to, aby typ liczby był zgodny z typem kolumny cost_price w tabeli item, ale w zasadzie jest dość oczywista:

```
bpsimple=# SELECT * FROM item WHERE cost_price > CAST(10.0 AS NUMERIC(7,2));
 item_id | description | cost_price | sell_price
-----+-----+-----+-----
       1 | Wood Puzzle |      15.23 |      21.95
       7 | Fan Large   |      13.36 |      19.95
      11 | Speakers    |      19.73 |      25.32
(3 rows)

bpsimple=#
```

Przypuśćmy, że chcemy znaleźć towary, których cena zakupu jest większa od średniej ceny zakupu. Z łatwością można to zrobić w dwóch zapytaniach:

```
bpsimple=# SELECT AVG(cost_price) FROM item;
      avg
-----
7.2490909091
(1 row)

bpsimple=# SELECT * FROM item WHERE cost_price > CAST(7.249 AS
bpsimple=# NUMERIC(7,2));
 item_id | description | cost_price | sell_price
-----+-----+-----+-----
       1 | Wood Puzzle |      15.23 |      21.95
       2 | Rubic Cube  |       7.45 |      11.49
       5 | Picture Frame |       7.54 |       9.95
       6 | Fan Small   |       9.23 |      15.75
       7 | Fan Large   |      13.36 |      19.95
      11 | Speakers    |      19.73 |      25.32
(6 rows)

bpsimple=#
```

Jest to jednak rozwiązanie mało eleganckie. Tak naprawdę chcemy przekazać wynik pierwszego zapytania bezpośrednio do drugiego, bez konieczności pamiętania go i wpiisywania do drugiego zapytania.

Jest to właśnie jedna z możliwości, które daje zastosowanie zapytań podrzędnych. Możemy umieścić pierwsze zapytanie w nawiasach i wykorzystać jako część klauzuli WHERE w drugim zapytaniu:

```
bpsimple=# SELECT * FROM ITEM WHERE cost_price > (SELECT AVG(cost_price)
bpsimple=# FROM item);
 item_id | description | cost_price | sell_price
-----+-----+-----+-----
       1 | Wood Puzzle |      15.23 |      21.95
       2 | Rubic Cube  |       7.45 |      11.49
```

```

5 | Picture Frame | 7.54 | 9.95
6 | Fan Small | 9.23 | 15.75
7 | Fan Large | 13.36 | 19.95
11 | Speakers | 19.73 | 25.32
(6 rows)

```

```
bpsimple=#
```

Jak widzimy, uzyskaliśmy ten sam wynik, ale bez konieczności wykonywania kroku pośredniego oraz konwersji typów, ponieważ wynik jest już właściwego typu.

PostgreSQL najpierw wykonuje zapytanie w nawiasach. Po uzyskaniu odpowiedzi uruchamia zapytanie zewnętrzne, zastępując wynik zapytania wewnętrznego. Jeżeli zachodzi taka potrzeba, możemy korzystać z wielu zapytań podrzędnych dla różnych klauzul WHERE. Nie ma ograniczeń co do liczby, ale konieczność korzystania z wielu zagnieżdżonych instrukcji SELECT występuje niezbyt często.

Wypróbuj to — zapytania podrzędne

Wypróbujmy bardziej złożony przykład. Przypuśćmy, że chcemy znać wszystkie towary, których cena zakupu jest większa od średniej ceny zakupu, ale cena sprzedaży jest mniejsza od średniej ceny sprzedaży. Sugeruje nam to, że nasza marża nie jest zbyt wysoka, zatem prawdopodobnie niezbyt wiele towarów spełni takie kryteria.

Wiemy już, jak znaleźć średnią cenę zakupu: `SELECT AVG(cost_price) FROM item`. Odnalezienie średniej ceny sprzedaży realizuje się analogicznie: `SELECT AVG(sell_price) FROM item`.

Nasze zapytanie główne przyjmie następującą postać:

```
SELECT * FROM item WHERE cost_price > średnia cena zakupu AND sell_price
< średnia cena sprzedaży
```

Jeżeli połączymy te trzy zapytania otrzymamy:

```
bpsimple=# SELECT * FROM item WHERE cost_price > (SELECT AVG(cost_price)
bpsimple=# FROM item) AND sell_price < (SELECT AVG(sell_price) FROM item);
 item_id | description | cost_price | sell_price
-----+-----+-----+-----
5 | Picture Frame | 7.54 | 9.95
(1 row)

bpsimple=#
```

Być może ktoś powinien przyjrzeć się cenie ramek do obrazków i sprawdzić, czy jest właściwa!

Jak to działa

PostgreSQL skanuje zapytanie i stwierdza, że istnieją dwa zapytania w nawiasach — zapytania podrzędne. Następnie rozwiązuje te zapytania niezależnie, po czym przesyła odpowiedzi do właściwej części klauzuli WHERE zapytania głównego i wykonuje to zapytanie.

Moglibyśmy zastosować inne klauzule `WHERE` lub `ORDER BY`. Połączenie warunków `WHERE` pochodzących z zapytań podrzędnych z warunkami konwencjonalnymi jest całkowicie poprawne.

Rodzaje zapytań podrzędnych

Do tej pory wykorzystywaliśmy tylko takie zapytania podrzędne, które zwracały pojedyncze wyniki, ponieważ korzystaliśmy w nich z funkcji agregacji. W zasadzie zapytania podrzędne mogą mieć wyniki trzech typów:

- pojedyncza wartość (jak te, które już widzieliśmy);
- brak wierszy lub kilka wierszy;
- test istnienia czegoś.

Spójrzmy na drugi rodzaj zapytań podrzędnych, gdzie w wyniku może wystąpić kilka wierszy. Przypuśćmy, że chcemy wiedzieć, jakie towary, których cena zakupu jest większa niż 10, znajdują się w magazynie. Możemy dowiedzieć się tego za pomocą pojedynczej instrukcji `SELECT` następującej postaci:

```
bpsimple=# SELECT s.item_id, s.quantity FROM stock s, item i WHERE
bpsimple=# i.cost_price > CAST(10.0 AS NUMERIC(7,2)) AND s.item_id =
bpsimple=# i.item_id;
 item_id | quantity
-----+-----
       1 |        12
       7 |         8
(2 rows)

bpsimple=#
```

Zauważmy, że dla skrócenia zapytania zastosowaliśmy aliasy nazw tabel (`stock` będzie obecnie tabelą `s`, `item` — tabelą `i`). Połączymy teraz dwie tabele (`s.item_id = i.item_id`) oraz dodamy w tabeli `item` warunek dotyczący ceny zakupu (`i.cost_price > CAST(10.0 AS NUMERIC(7,2))`).

Możemy także zapisać to zapytanie podrzędne stosując słowo kluczowe `IN`, w celu zbadania listy wartości. Należy zapisać zapytanie, które daje w wyniku listę identyfikatorów towarów, dla których cena zakupu towaru jest mniejsza niż 10.0:

```
SELECT * FROM item WHERE cost_price > CAST(10.0 AS NUMERIC(7,2));
```

Potrzebujemy także zapytania wybierającego towary z tabeli `stock`:

```
SELECT * FROM stock WHERE item_id IN lista wartości
```

Możemy następnie połączyć oba zapytania w następujący sposób:

```
bpsimple=# SELECT * FROM stock WHERE item_id IN (SELECT item_id FROM item
bpsimple=# WHERE cost_price > CAST(10.0 AS NUMERIC(7,2)));
 item_id | quantity
-----+-----
       1 |        12
```

```

      7 |      8
(2 rows)

bpsimple=#

```

Procedury te dają nam te same wyniki. Zapytania podrzędne — chociaż nie wszystkie — można zazwyczaj zapisać jako powiązania. Z tego względu ważne jest, aby je zrozumieć. Tak jak w przypadku bardziej konwencjonalnych zapytań, można zanegować warunek, zapisując `NOT IN`. Można też wpisać dodatkowe klauzule `WHERE` oraz warunki `ORDER BY`.

Czego powinniśmy użyć w przypadku, gdy mamy zapytanie podrzędne, które można zapisać jako powiązanie? Należy rozważyć dwie sprawy — czytelność i wydajność. Dla okazyjnie wykorzystywanych zapytań działających z niewielkimi tabelami i wykonującymi się szybko wykorzystujemy dowolną postać, która jest najbardziej czytelna. Jeżeli jest to zapytanie wykorzystywane często, dla dużych tabel, opłaca się zapisać je na różne sposoby i doświadczalnie sprawdzić wydajność. Być może optymalizator zapytań będzie w stanie zoptymalizować oba rodzaje i wydajność obu zapytań będzie identyczna. Zwycięży wówczas zapytanie, które będzie bardziej czytelne.

Należy ostrożnie badać wydajność instrukcji SQL. Istnieje wiele czynników znajdujących się poza naszą kontrolą, jak np. buforowanie danych przez system operacyjny.

Można się także przekonać, że wydajność zależy w bardzo dużym stopniu od konkretnych danych w naszej bazie lub zmienia się diametralnie wraz ze zmianą liczby wierszy w poszczególnych tabelach.

Nie poznaliśmy jeszcze ostatniego typu zapytania podrzędnego — takiego, które bada istnienie czegoś — ponieważ jest ono dosyć złożone. Przed końcem rozdziału wrócimy do tego typu zapytań.

Zapytania podrzędne skorelowane

Do tej pory poznaliśmy takie typy zapytań podrzędnych, gdzie dla uzyskania wyniku wykonywaliśmy zapytanie, a następnie „włączaliśmy je” do drugiego zapytania. Te dwa zapytania nie są jednak związane w innym przypadku i dlatego nazywa się je zapytaniami podrzędnymi nieskorelowanymi. Wynika to z faktu, że pomiędzy wewnętrznym, a zewnętrznym zapytaniem nie ma powiązanych tabel. W obu częściach instrukcji `SELECT` można używać tej samej kolumny z tej samej tabeli, ale są one związane tylko poprzez wynik zapytania podrzędnego, które zasilą klauzulę `WHERE` głównego zapytania.

Istnieje inna grupa zapytań podrzędnych, które nazywa się zapytaniami podrzędnymi skorelowanymi, gdzie związek pomiędzy dwiema częściami zapytania jest bardziej złożony. W zapytaniu podrzędnym skorelowanym tabela w wewnętrznej instrukcji `SELECT` jest powiązana z tabelą w zewnętrznej części instrukcji. Z tego właśnie względu te dwa zapytania są skorelowane. Ta grupa zapytań podrzędnych daje duże możliwości. Bardzo często można je zapisać jako zwykłe instrukcje `SELECT` z powiązaniami.

Zapytanie skorelowane ma następującą postać ogólną:

```
SELECT kolumnaA FROM tabela1 T1 WHERE T1.kolumnaB = (SELECT T2.kolumnaB FROM
tabela2 T2
WHERE T2.kolumnaC = T1.kolumnaC)
```

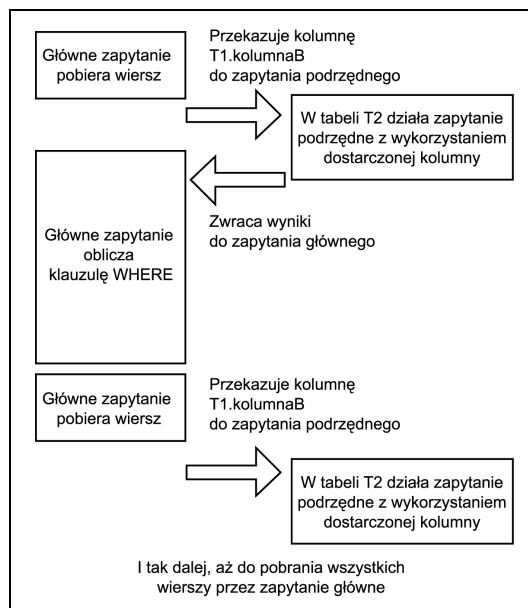
Zapisałiśmy tę instrukcję w kodzie pseudo-SQL, aby można ją było łatwiej wyjaśnić. Ważną rzeczą, którą należy zauważyć, jest fakt, że tabela T1 z zewnętrznej instrukcji SELECT występuje także w wewnętrznej instrukcji SELECT. Zatem tabele zewnętrzną i wewnętrzną uważa się za powiązane. Zauważmy, że zastosowaliśmy aliasy nazw tabel. Jest to bardzo ważne, ponieważ reguły nazw tabel w skorelowanych zapytaniach są dość złożone i niewielka pomyłka może skutkować niezrozumiałymi wynikami.

Zalecamy, aby w zapytaniach podrzędnych skorelowanych zawsze stosować aliasy tabel, ponieważ jest to opcja najbezpieczniejsza.

Po wykonaniu tej instrukcji dzieją się dosyć skomplikowane rzeczy. Po pierwsze, dla wewnętrznej instrukcji SELECT z tabeli T1 pobierany jest wiersz, a następnie kolumna T1.kolumnaB jest przekazywana do wewnętrznego zapytania, które wykonuje się wybierając wiersze z tabeli T2, korzystając jednak z przekazanych informacji. Wynik jest ponownie przekazywany do zapytania wewnętrznego, które przed przejściem do następnego wiersza kończy obliczanie klauzuli WHERE.

Pokazano to na poniższym diagramie:

Rysunek 7.1.



Jeżeli wydaje się to nam trochę skomplikowane, to trzeba przyznać, że tak właśnie jest. Skorelowane zapytania podrzędne wykonywane są dość nieefektywnie. Czasami jednak udaje się dzięki nim rozwiązać bardzo złożone problemy. Tak więc dobrze wiedzieć, że istnieją, nawet jeżeli nieczęsto będziemy z nich korzystać.

Wypróbuj to — zapytanie podrzędne skorelowane

W prostej bazie danych, jak ta, którą wykorzystujemy, potrzeba użycia zapytań podrzędnych skorelowanych występuje niezbyt często. Zazwyczaj można je zapisać w inny sposób. Możemy jednak wykorzystać nawet naszą prostą bazę danych w celu zademonstrowania ich zastosowania.

Przypuśćmy, że chcemy znać datę złożenia zamówień dla klientów w Bingham. Chociaż moglibyśmy zapisać to w sposób bardziej konwencjonalny, skorzystamy z zapytania podrzędnego skorelowanego w następującej postaci:

```
bpsimple=# SELECT oi.date_placed FROM orderinfo oi WHERE oi.customer_id =
bpsimple=# (SELECT c.customer_id from customer c WHERE c.customer_id =
bpsimple=# oi.customer_id and town = 'Bingham');
 date_placed
-----
2000-06-23
2000-07-21
(2 rows)

bpsimple=#
```

Jak to działa?

Zapytanie rozpoczyna działanie od pobrania wiersza z tabeli `orderinfo`. Następnie wykonuje ono zapytanie podrzędne dla tabeli `customer`, korzystając z odnalezionej wartości `customer_id`. Wykonuje się zapytanie podrzędne poszukując wierszy, gdzie pole `customer_id` z zewnętrznego zapytania daje wiersz w tabeli `customer`, który zawiera także miasto Bingham. W przypadku znalezienia takiego wiersza, pole `customer_id` jest przekazywane z powrotem do zapytania głównego, które kończy klauzulę `WHERE` i jeżeli jest ona prawdziwa, wyświetla kolumnę `date_placed`. Zapytanie zewnętrzne przechodzi następnie do kolejnego wiersza i sekwencja powtarza się.

Spójrzmy na inny przykład. Tym razem wykorzystamy trzeci typ zapytania, którego do tej pory jeszcze nie poznaliśmy, gdzie zapytanie podrzędne bada istnienie czegoś.

Przypuśćmy, że chcemy wyszczególnić wszystkich klientów, którzy składali zamówienia. W naszej przykładowej bazie danych nie ma ich wielu. Pierwsza część zapytania jest prosta; zapiszmy:

```
SELECT fname, lname FROM customer c;
```

Zwróćmy uwagę, że zastosowaliśmy alias tabeli `customer` — `c`, który został przygotowany dla zapytania podrzędnego. Kolejna część zapytania powinna sprawdzić, czy wartość pola `customer_id` występuje także w tabeli `orderinfo`:

```
SELECT 1 FROM orderinfo oi WHERE oi.customer_id = c.customer_id;
```

Należy tu zwrócić uwagę na dwa bardzo ważne aspekty. Po pierwsze, zastosowaliśmy znaną sztuczkę. Jeżeli zależy nam na wykonaniu zapytania, ale nie interesują nas wyniki, po prostu umieszczamy '1' tam, gdzie zwykle umieszcza się nazwy kolumn. Ozna-

cza to, że jeżeli zostaną odnalezione jakiegokolwiek dane, wynikiem zapytania będzie 1, co jest łatwym i wydajnym sposobem powiedzenia 'true'. Może to wydawać się dosyć dziwne, zatem zobaczmy:

```
bpsimple=# SELECT 1 FROM customer WHERE town = 'Bingham';
?column?
-----
      1
      1
      1
(3 rows)

bpsimple=#
```

To działa, nawet jeśli wygląda nieco dziwnie. Ważne jest, aby nie korzystać tu z funkcji COUNT(*), ponieważ potrzebujemy wyniku z każdego wiersza, gdzie kolumna town ma wartość Bingham, a nie informacji, ilu mamy klientów pochodzących z Bingham.

Drugą ważną rzeczą, na którą należy zwrócić uwagę jest fakt, że skorzystaliśmy z tabeli customer w tym zapytaniu podrzędnym, które w zasadzie było użyte w zapytaniu głównym. Właśnie to decyduje o tym, że są to zapytania skorelowane. Tak jak poprzednio, dla wszystkich tabel zastosowaliśmy aliasy. Musimy teraz połączyć obie połowy.

Czas na zapoznanie się z ostatnim rodzajem zapytań podrzędnych, które wcześniej pominęliśmy. Bada ono za pomocą słowa kluczowego EXISTS w klauzuli WHERE istnienie wartości, bez konieczności znajomości danych.

Dla naszego zapytania skorzystanie z EXISTS jest dobrym sposobem połączenia dwóch instrukcji SELECT, ponieważ chcemy wiedzieć tylko, czy zapytanie podrzędne zwraca wiersz. Klauzula EXISTS zazwyczaj działa wydajniej niż inne typy powiązań w warunkach IN. Z tego względu, w przypadku, gdy istnieje wybór sposobu zapisu zapytania, często warto korzystać właśnie z niej zamiast innych typów powiązań.

```
bpsimple=# SELECT fname, lname FROM customer c WHERE EXISTS (SELECT 1 FROM
bpsimple=# orderinfo oi WHERE oi.customer_id=c.customer_id);
fname | lname
-----+-----
Alex  | Matthew
Ann   | Stones
Laura | Hendy
David | Hudson
(4 rows)

bpsimple=#
```

Można tu zobaczyć, jak są zapisywane skorelowane zapytania podrzędne. Czasami, kiedy napotkamy problem, który wydaje się niemożliwy do rozwiązania za pomocą zwykłych zapytań SQL, może się okazać, że rozwiązaniem tych trudności jest skorelowane zapytanie podrzędne.

Powiązania same z sobą

Specjalnym typem powiązań są powiązania same z sobą. Wykorzystuje się je w celu powiązania kolumn znajdujących się w tej samej tabeli. Potrzeba korzystania z tych powiązań jest niezwykle rzadka, ale czasami bardzo się one przydają, dlatego pokrótce omówimy je w tym podrozdziale.

Przypuśćmy, że sprzedajemy towary, które można sprzedawać w kompletach lub pojedynczo. Dla potrzeb przykładu założymy, że sprzedajemy komplet krzeseł i stół, a także stół i krzesła oddzielnie. Chcielibyśmy zapisać nie tylko poszczególne, pojedyncze towary, ale także relacje między nimi, podczas gdy są sprzedawane jako całość. Często nazywa się to *eksplozją części*. Z pojęciem tym spotkamy się ponownie w rozdziale 12.

Rozpocznijmy od utworzenia tabeli, która zawiera nie tylko identyfikatory towarów i ich opis, ale także dodatkowy identyfikator towaru:

```
CREATE TABLE part (part_id INT, description VARCHAR(32), parent_part_id INT);
```

Wykorzystamy pole `parent_part_id` do przechowywania informacji o identyfikatorze komponentu, którego częścią jest nasz towar. Na przykład, przypuśćmy, że mamy zestaw krzeseł i stołu, któremu nadamy wartość `item_id = 1`, składający się z krzesła, dla którego przypisujemy `item_id = 2` oraz stołu, określonego jako `item_id = 3`. Instrukcje INSERT wyglądałyby wówczas następująco:

```
bpsimple=# INSERT INTO part (part_id, description, parent_part_id) VALUES(1,
bpsimple=# 'table and chairs', NULL);
INSERT 21579 1
bpsimple=# INSERT INTO part (part_id, description, parent_part_id) VALUES(2,
bpsimple=# 'chair', 1);
INSERT 21580 1
bpsimple=# INSERT INTO part (part_id, description, parent_part_id) VALUES(3,
bpsimple=# 'table', 1);
INSERT 21581 1
bpsimple=#
```

Zapisałiśmy dane, ale w jaki sposób uzyskamy informacje o tym, które pojedyncze części składają się na poszczególne komponenty? Musimy powiązać tabelę z nią samą.

Okazuje się to dosyć proste. Musimy zastosować aliasy nazw tabel, a następnie zapisać klauzulę WHERE odnoszącą się do tej samej tabeli, stosując jednak różne nazwy:

```
bpsimple=# SELECT p1.description, p2.description FROM part p1, part p2 WHERE
bpsimple=# p1.part_id = p2.parent_part_id;
description | description
-----+-----
table and chairs | chair
table and chairs | table
(2 rows)

bpsimple=#
```

To działa, ale jest trochę mylące, ponieważ mamy dwie kolumny wyniku z tą samą nazwą. Możemy w łatwy sposób poprawić tę niedogodność za pomocą słowa kluczowego AS:

```
bpsimple=# SELECT p1.description AS "Combined", p2.description AS "Parts"
bpsimple=# FROM part p1, part p2 WHERE p1.part_id = p2.parent_part_id;
 Combined      | Parts
-----+-----
 table and chairs | chair
 table and chairs | table
(2 rows)

bpsimple=#
```


Z powiązaniem typu „same z sobą” spotkamy się ponownie w rozdziale 12., w którym omówimy sposób zapisu związku przełożony — podwładny w pojedynczej tabeli.

Powiązania zewnętrzne

Ostatnim głównym zagadnieniem, jakie poruszymy w tym rozdziale, jest klasa powiązań znana jako powiązania zewnętrzne. Są one podobne do powiązań konwencjonalnych, ale wykorzystują nieco inną składnię. Z tego względu odłożyliśmy spotkanie z nimi na koniec tego rozdziału.

Spójrzmy na nasze tabele `item` i `stock`:

Rysunek 7.2.



Jak pamiętamy, wszystkie towary przeznaczone do sprzedaży znajdują się w tabeli `item`, natomiast w tabeli `stock` znajdują się tylko te, które aktualnie znajdują się w magazynie.

Przypuśćmy, że chcemy uzyskać listę wszystkich towarów, które sprzedajemy, ze wskazaniem ilości, jaką mamy w magazynie. To z pozoru proste żądanie okazuje się zaskakująco trudne do zapisania w języku SQL, który znamy do tej pory — chociaż jest możliwe. Bardzo dobrze jest włożyć nieco pracy w rozwiązanie; spróbujmy zatem skoryzować tylko z tych instrukcji SQL, które znamy do tej pory.

Zastosujmy prostą instrukcję `SELECT` łączącą dwie tabele:

```
bpsimple=# SELECT i.item_id, s.quantity FROM item i, stock s WHERE i.item_id
bpsimple=# = s.item_id
 item_id | quantity
-----+-----
      1 |      12
```

```

      2 |      2
      4 |      8
      5 |      3
      7 |      8
      8 |     18
     10 |      1
(7 rows)

```

```
bpsimple=#
```

Łatwo zauważyć (ponieważ wiemy, że nasze identyfikatory `item_id` występują w tabeli kolejno, bez luk), że brakuje niektórych identyfikatorów `item_id`. Brakujące wiersze dotyczą towarów, których nie mamy w magazynie, ponieważ nie istnieje dla nich powiązanie pomiędzy tabelami `item` oraz `stock` — w tabeli `stock` brakuje zapisu dla tego `item_id`.

Brakujące wiersze możemy znaleźć za pomocą zapytania podrzędnego oraz klauzuli `IN`:

```

bpsimple=# SELECT i.item_id FROM item i WHERE i.item_id NOT IN (SELECT
bpsimple=# i.item_id FROM item i, stock s WHERE i.item_id = s.item_id);
 item_id
-----
      3
      6
      9
     11
(4 rows)

```

```
bpsimple=#
```

Mówiąc prościej, możemy zażądać: „znajdź wszystkie identyfikatory `item_id` w tabeli `item`, poza tymi, które znajdują się w tabeli `stock`”.

Wewnętrzna instrukcja `SELECT` jest tą samą, którą zastosowaliśmy wcześniej, ale tym razem skorzystaliśmy z listy identyfikatorów `item_id`, które instrukcja ta zwraca jako część innej instrukcji `SELECT`. Główna instrukcja `SELECT` wyszczególnia wszystkie znane identyfikatory `item_id` poza znalezionymi w zapytaniu podrzędnym, usuniętymi przez klauzulę `WHERE NOT IN`.

Tak więc mamy teraz listy identyfikatorów `item_id` zarówno dla towarów, których nie ma w magazynie, jak i dla tych, które się w nim znajdują. Listy te uzyskaliśmy jednak w oddzielnych zapytaniach. Musimy teraz powiązać obie listy; możemy to zrobić za pomocą instrukcji `UNION`. Istnieje jednak pewien problem. Nasza pierwsza instrukcja zwraca dwie kolumny: `item_id` oraz `quantity`, natomiast druga tylko identyfikatory `item_id`, ponieważ w magazynie nie ma odpowiednich towarów. Należy zatem dodać sztuczną kolumnę do drugiej instrukcji `SELECT`, aby miała tę samą co pierwsza liczbę kolumn oraz kolumny tego samego typu. Mamy zamiar wykorzystać wartość `NULL`, chociaż równie dobrze moglibyśmy użyć `0` (zero). Później zobaczymy, dlaczego wybraliśmy `NULL`.

Oto nasze kompletne zapytanie:

```
SELECT i.item_id, s.quantity FROM item i, stock s WHERE i.item_id = s.item_id
UNION
SELECT i.item_id, NULL FROM item i WHERE i.item_id NOT IN
(SELECT i.item_id FROM item i, stock s WHERE i.item_id = s.item_id);
```

Wygląda to na nieco skomplikowane, ale spróbujmy zobaczyć, jak działa:

```
bpsimple=# SELECT i.item_id, s.quantity FROM item i, stock s WHERE i.item_id
bpsimple=# = s.item_id
bpsimple=# UNION
bpsimple=# SELECT i.item_id, NULL FROM item i WHERE i.item_id NOT IN (select
bpsimple=# i.item_id FROM item i, stock s WHERE i.item_id = s.item_id);
item_id | quantity
-----+-----
      1 |         12
      2 |          2
      3 |
      4 |          8
      5 |          3
      6 |
      7 |          8
      8 |         18
      9 |
     10 |          1
     11 |
(11 rows)

bpsimple=#
```

W początkowym okresie istnienia języka SQL był to jedyny sposób rozwiązania tego typu problemów, poza tym, że SQL89 nie umożliwiał stosowania wartości NULL, z której skorzystaliśmy w drugiej instrukcji SELECT, jako kolumny. Na szczęście większość producentów SQL dawała taką możliwość. W przeciwnym przypadku byłoby jeszcze trudniej. Gdybyśmy nie mogli wykorzystać wartości NULL, musielibyśmy zastosować 0 jako nieco gorszą alternatywę. Wartość NULL jest lepszym rozwiązaniem, ponieważ 0 może być mylące, natomiast NULL zawsze będzie wyświetlane jako puste miejsce.

Aby obejść to raczej skomplikowane rozwiązanie dla dość popularnych problemów, producenci wymyślili mechanizm znany jako powiązania zewnętrzne. Niestety, ponieważ nie było tego w standardzie, każdy z producentów opracował swoje własne rozwiązanie, o podobnym do innych działaniu, ale różnej składni.

W systemach Oracle oraz DB2 zastosowano składnię, w której w klauzuli WHERE wykorzystywano znak + dla zaznaczenia, że w wyniku mają się znaleźć wszystkie wartości z tabeli (tabeli chronionej), nawet jeżeli powiązanie nie powiedzie się. W systemie Sybase zastosowano w klauzuli WHERE symbol *=, aby oznaczyć tabelę chronioną. Obie te składnie są dosyć oczywiste, ale niestety różne, co nie jest dobre dla przenośności kodu SQL.

Kiedy pojawił się standard SQL92, zdefiniowano w nim ogólny sposób implementowania powiązań zewnętrznych, który stosował jeszcze inną składnię. Producenci dosyć wolno implementowali nowy standard. W systemie Sybase 11 nie obsługiwano jeszcze tego mechanizmu, podobnie jak w Oracle8. Obydwa produkty wydano już po ukazaniu

się standardu. W systemie PostgreSQL zaimplementowano standardową metodę porównującą od wersji 7.1. Tak więc, jeżeli korzystamy ze starszej wersji, aby móc wypróbować przykłady z ostatniej części tego rozdziału, musimy uaktualnić posiadaną wersję PostgreSQL. Jeżeli korzystamy z wersji PostgreSQL starszej niż 7.1, uaktualnienie opłaca się także z innych powodów, ponieważ wersja 7.1 jest znacząco lepsza od wersji starszych.

Składnia standardu SQL92 zamienia klauzulę WHERE, którą znamy. Wprowadza dla łączenia tabel klauzulę ON oraz słowo kluczowe LEFT OUTER JOIN.

Składnia jest w tym przypadku następująca:

```
SELECT kolumny FROM tabela1 LEFT OUTER JOIN tabela2 ON tabela1.kolumna
= tabela2.kolumna
```

Tabela z lewej strony LEFT OUTER JOIN jest zawsze tabelą chronioną — tą, dla której są wyświetlane wszystkie wiersze.

Możemy zatem zapisać nasze zapytanie ponownie, za pomocą następującej składni:

```
SELECT i.item_id, s.quantity FROM item i LEFT OUTER JOIN stock s ON i.item_id =
s.item_id;
```

Wygląda to niemal na zbyt proste, aby mogło być prawdziwe. Spróbujmy zatem zobaczyć działanie podanej wyżej składni:

```
bpsimple=# SELECT i.item_id, s.quantity FROM item i LEFT OUTER JOIN stock s
bpsimple=# ON i.item_id = s.item_id;
 item_id | quantity
-----+-----
       1 |         12
       2 |          2
       3 |
       4 |          8
       5 |          3
       6 |
       7 |          8
       8 |         18
       9 |
      10 |          1
      11 |
(11 rows)

bpsimple=#
```

Świetnie, odpowiedź jest identyczna z tą, jaką otrzymaliśmy w wyniku zastosowania poprzedniego sposobu. Widzimy teraz, dlaczego producenci czuli potrzebę implementacji powiązań zewnętrznych, nawet jeżeli nie było ich w oryginalnym standardzie SQL89.

Istnieje także odpowiednik poznanego wyżej słowa kluczowego, RIGHT OUTER JOIN, ale prawie zawsze korzysta się z powiązania lewostronnego, ze względu na to, że przynajmniej dla mieszkańców Zachodu bardziej sensowne jest wyświetlanie listy wszystkich obiektów po lewej stronie wyniku, a nie po prawej.

Wypróbuj to — bardziej złożony warunek

Proste lewostronne powiązanie zewnętrzne, które wykorzystaliśmy, jest doskonałe tak długo, jak działa, ale w jaki sposób dodać bardziej złożone warunki?

Przypuśćmy, że interesują nas tylko te wiersze z tabeli `stock`, dla których w magazynie znajdują się więcej niż dwie sztuki towaru, a ponadto te, w których cena zakupu jest większa niż 5,0. Jest to dosyć złożony problem, ponieważ chcemy zastosować jedną regułę do tabeli `item` (`cost_price > 5.0`), a inną regułę do tabeli `stock` (`quantity > 2`). W dalszym ciągu chcemy jednak wyświetlić wszystkie wiersze z tabeli `item`, dla których prawdziwy jest warunek dla tabeli `item`, nawet jeżeli tych towarów wcale nie ma w magazynie.

W tym celu połączymy warunki `ON`, które działały tylko z tabelami związanymi lewostronnym powiązaniem zewnętrznym, z warunkami `WHERE`, ograniczającymi zwracane wiersze po powiązaniu tabel.

Warunek dla tabeli `stock` jest częścią powiązania zewnętrznego, w którym nie chcemy ograniczać wierszy dla towarów, których nie ma w magazynie, zatem zapiszemy go jako część warunku `ON`:

```
ON item_id = s.item_id AND s.quantity > 2
```

Dla warunku `item`, który dotyczy wszystkich wierszy, zastosujemy klauzulę `WHERE`:

```
WHERE i.cost_price > CAST(5.0 AS NUMERIC(7,2));
```

Łącząc obie części otrzymamy:

```
bpsimple=# SELECT i.item_id, i.cost_price, s.quantity FROM item i LEFT OUTER
bpsimple=# JOIN stock s ON i.item_id = s.item_id AND s.quantity > 2 WHERE
bpsimple=# i.cost_price > CAST(5.0 AS NUMERIC(7,2));
 item_id | cost_price | quantity
-----+-----+-----
       1 |    15.23 |         12
       2 |     7.45 |
       5 |     7.54 |          3
       6 |     9.23 |
       7 |    13.36 |          8
      11 |    19.73 |
(6 rows)

bpsimple=#
```

Jak to działa?

Aby uzyskać wszystkie wartości z tabeli `item`, opcjonalnie w połączeniu z tabelą `stock`, gdzie istnieją oba wiersze, a wartość pola `quantity` jest większa niż 2, stosujemy mechanizm `LEFT OUTER JOIN`. Daje to nam zbiór, w którym znajdują się wszystkie wiersze z tabeli `item`, ale kolumna `quantity` z tabeli `stock` będzie zawierała wartość `NULL`, chyba że obydwie tabele zawierają zapis dla danego towaru oraz wartość pola `quantity` jest większa niż 2. Następnie stosujemy klauzulę `WHERE`, która pozwala na wyświetlanie tylko tych wierszy, w których cena zakupu (`cost_price` z tabeli `item`) jest większa niż 5,0.