WYDANIE II

SQL W PRAKTYCE

JAK DZIĘKI DANYM UZYSKIWAĆ CENNE INFORMACJE

ANTHONY DeBARROS

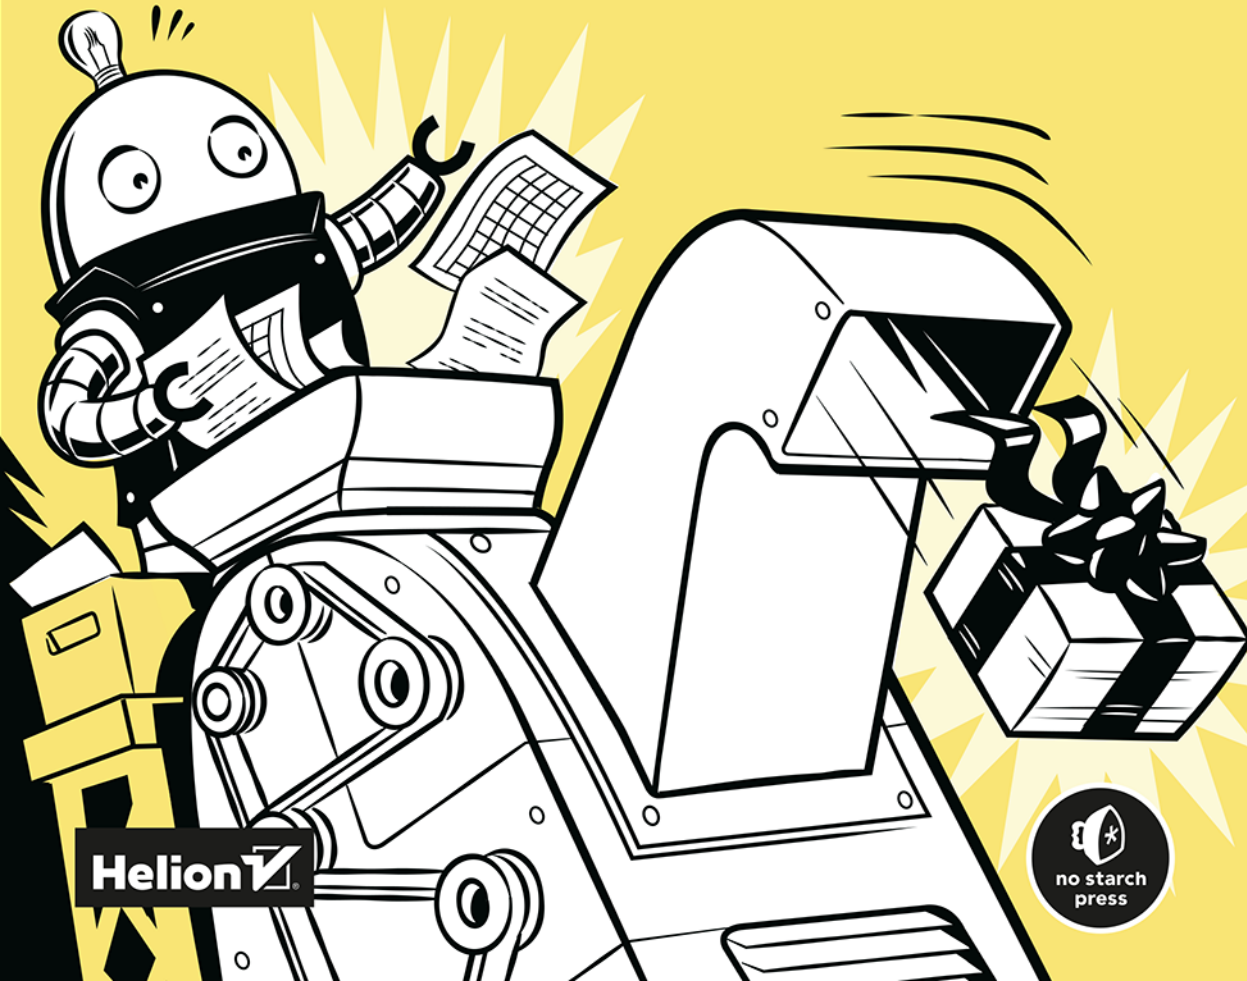

Helion

no starch press

Tytuł oryginału: Practical SQL: A Beginner's Guid e to Storytelling with Data, 2nd Edition

Tłumaczenie: Piotr Pilch

ISBN: 978-83-289-1018-8

Drogi Czytelniku!
Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres
https://helion.pl/user/opinie/sqlpr2
Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Pliki z przykładami omawianymi w książce można znaleźć pod adresem:
https://ftp.helion.pl/przyklady/sqlpr2.zip

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

Printed in Poland.

Spis treści

9

Wyodrębnianie informacji przez grupowanie i podsumowywanie

Każdy zbiór danych niesie w sobie informacje tworzące pewną całość, a zadaniem analityka danych jest ich znalezienie. W rozdziale 3. dowiedziałeś się więcej na temat sprawdzania danych za pomocą instrukcji `SELECT`, które umożliwiają sortowanie kolumn, znajdowanie różnych wartości oraz filtrowanie wyników. Zaznajomiłeś się również z fundamentami operacji matematycznych języka SQL, typami danych, projektem tabel oraz złączaniem ich. Dysponując tymi narzędziami w swoim arsenale, możesz zacząć uzyskiwać dodatkowe wnioski przy użyciu *funkcji grupowania* i *agregujących*, które służą do podsumowywania Twoich danych.

Dzięki podsumowywaniu danych możesz zidentyfikować przydatne informacje, których nie mógłbyś dojrzeć w wyniku samego skanowania wierszy tabeli. W niniejszym rozdziale w ramach przykładu posłużymy się dobrze znanym obiektem, czyli lokalną biblioteką.

Biblioteki pozostają istotną częścią społeczności na całym świecie, ale internet i postępy w dziedzinie technologii związanych z bibliotekami zmieniły sposób, w jaki z nich korzystamy. Na przykład e-booki i dostęp sieciowy do materiałów cyfrowych na dobre zagościły obecnie w bibliotekach razem z książkami i periodykami.

W Stanach Zjednoczonych instytut IMLS (Institute of Museum and Library Services) w ramach corocznych badań Public Libraries Survey prowadzi pomiar aktywności związanej z bibliotekami. Podczas tych badań gromadzi się dane z około 9000 jednostek administrujących bibliotekami, które w badaniach określono jako agencje zapewniające usługi bibliotekarskie w konkretnej miejscowości. Niektóre agencje to systemy bibliotek hrabstw, inne są częścią okręgów szkół. Dane powiązane z każdą agencją obejmują liczbę oddziałów, pracowników, zbiór książek, godziny funkcjonowania bibliotek w skali roku itp. Instytut IMLS gromadzi dane każdego roku od 1988 r., a ponadto uwzględnia wszystkie publiczne agencje bibliotek zlokalizowane w 50 stanach, a także w Dystrykcie Kolumbia oraz na obszarze takich terytoriów Stanów Zjednoczonych jak Samoa Amerykańskie (więcej na temat programu możesz przeczytać pod adresem *https://www.imls.gov/research-↪evaluation/data-collection/public-libraries-survey/*).

Na potrzeby realizowanego tutaj ćwiczenia przyjmiemy, że zadaniem analityka, który właśnie otrzymał nową kopię zbioru danych bibliotek, jest utworzenie raportu opisującego trendy wynikające z danych. Zostaną utworzone trzy tabele przechowujące dane z badań przeprowadzonych w latach 2016, 2017 i 2018 (w dostrzeganiu trendów często pomocne jest ocenianie danych z wielu lat). Później w każdej tabeli zostaną podsumowane bardziej interesujące dane, po czym tabele zostaną złączone w celu pokazania, jak wyniki pomiarów zmieniły się z czasem.

Tworzenie tabel badań dotyczących bibliotek

Utwórzmy trzy tabele badań odnoszących się do bibliotek i zaimportujmy dane. Dla każdej kolumny zostaną zastosowane odpowiednie typy danych i ograniczenia, a ponadto tam, gdzie będzie to wskazane, zostaną dodane indeksy. Kod oraz trzy pliki CSV są dostępne w przykładach dołączonych do książki.

Tworzenie tabeli danych bibliotecznych z roku 2018

Zaczniemy od utworzenia tabeli dla danych bibliotecznych z roku 2018. W kodzie z listingu 9.1 za pomocą instrukcji `CREATE TABLE` utworzono tabelę `pls_fy2018_libraries` przeznaczoną na zawartość pliku danych systemu bibliotek publicznych z roku budżetowego 2018 pochodzącego z badań Public Libraries Survey. W pliku tym podsumowano dane na poziomie agencji, ustalając liczbę działań podjętych we wszystkich ich punktach, które obejmują biblioteki centralne i oddziałowe oraz biblioteki mobilne. W ramach corocznych badań generowane są dwa dodatkowe pliki, z których nie będziemy korzystać: w pierwszym pliku dokonuje się podsumowania danych na poziomie stanów, a w drugim znajdują się dane dotyczące poszczególnych punktów. W przypadku omawianego ćwiczenia

pliki te są nadmiarowe, ale z informacjami opisującymi dane, jakie one zawierają, możesz zaznajomić się pod adresem *https://www.imls.gov/sites/default/files/2018_pls_data_file_documentation.pdf*.

Listing 9.1. Tworzenie i wypełnianie tabeli danymi z badań Public Libraries Survey z roku 2018

```
CREATE TABLE pls_fy2018_libraries (
    stabr text NOT NULL,
    fscskey text CONSTRAINT fscskey_2018_pkey PRIMARY KEY, ❶
    libid text NOT NULL,
    libname text NOT NULL,
    address text NOT NULL,
    city text NOT NULL,
    zip text NOT NULL,
    --cięcie--
    longitude numeric(10,7) NOT NULL,
    latitude numeric(10,7) NOT NULL
);

COPY pls_fy2018_libraries ❷
FROM 'C:\TwojKatalog\pls_fy2018_libraries.csv'
WITH (FORMAT CSV, HEADER);

CREATE INDEX libname_2018_idx ON pls_fy2018_libraries (libname); ❸
```

Dla wygody utworzyłem dla tabel schemat nazewniczy: łańcuch `pls` odnosi się do tabeli badań, łańcuch `fy2018` identyfikuje rok budżetowy, z którego są dane, a łańcuch `libraries` to nazwa konkretnego pliku z badań. Dla uproszczenia wybrałem 47 spośród 166 bardziej odpowiednich kolumn zawartych w oryginalnym pliku z badań, aby wypełnić tabelę `pls_fy2018_libraries`, z wykluczeniem takich danych jak kody objaśniające źródło poszczególnych odpowiedzi. Gdy biblioteka nie przekazała danych, agencja uzyskiwała je za pomocą innych metod. Na potrzeby niniejszego ćwiczenia nie będą jednak potrzebne te informacje.

Dla ułatwienia kod z listingu 9.1 skrócono, na co wskazuje wiersz komentarza `--cięcie--` widoczny w kodzie. Pełna wersja tego kodu znajduje się jednak w przykładach dołączonych do książki.

Po znalezieniu kodu i pliku danych powiązanych z listingiem 9.1 połącz się za pomocą narzędzia pgAdmin ze swoją bazą danych `analysis` i uruchom kod. Pamiętaj o wstawieniu w miejsce łańcucha `C:\TwojKatalog` ścieżki identyfikującej miejsce, w którym zapisałeś plik *pls_fy2018_libraries.csv*.

Najpierw kod tworzy tabelę przy użyciu instrukcji `CREATE TABLE`. Dla kolumny o nazwie `fscskey` ❶ określono ograniczenie klucza głównego. Zgodnie ze słownikiem danych kolumna ta zawiera unikalny kod przypisywany każdej bibliotece. Ze względu na to, że wartość tej kolumny jest unikalna i obecna w każdym wierszu, a ponadto z małym prawdopodobieństwem zostanie zmieniona, może pełnić rolę naturalnego klucza głównego.

Definicja każdej kolumny uwzględnia odpowiedni typ danych oraz ograniczenia `NOT NULL`, w przypadku których w kolumnach nie ma brakujących wartości. Kolumny `startdate` i `enddate` zawierają daty, ale w kodzie jako ich typ danych określono typ `text`. W pliku CSV kolumny te uwzględniają wartości niebędące datami. Wykonywana przez nas operacja

importowania nie powiedzie się, jeśli podejmie się próbę użycia typu danych `date`. W rozdziale 10. dowiesz się, jak poradzić sobie z tego rodzaju sytuacjami. Na razie kolumny w tej postaci są zupełnie wystarczające.

Po utworzeniu tabeli instrukcja `COPY` ❷ importuje przy użyciu podanej przez Ciebie ścieżki dane z pliku CSV o nazwie *pls_fy2018_libraries.csv*. Do kolumny `libname` dodano indeks ❸, aby szybciej zapewnić wyniki dla operacji wyszukiwania konkretnej biblioteki.

Tworzenie tabel z danymi dotyczącymi bibliotek z roku 2016 i 2017

Tworzenie tabel dla danych badań z roku 2016 i 2017 dotyczących bibliotek wymaga wykonania podobnych kroków. Połączyłem kod, aby utworzyć i wypełnić obie tabele (listing 9.2). Zauważ, że ponownie kod w zaprezentowanym listingu został obcięty, ale pełny kod znajduje się w przykładach dołączonych do książki dostępnych do pobrania z serwera FTP o adresie *https://ftp.helion.pl/przyklady/sqlpr2.zip*

Listing 9.2. Tworzenie i wypełnianie tabel danymi z badań Public Libraries Survey z roku 2016 i 2017

```
CREATE TABLE pls_fy2017_libraries (
    stabr text NOT NULL,
    fscskey text CONSTRAINT fscskey_17_pkey PRIMARY KEY, ❶
    libid text NOT NULL,
    libname text NOT NULL,
    address text NOT NULL,
    city text NOT NULL,
    zip text NOT NULL,
    --cięcie--
    longitude numeric(10,7) NOT NULL,
    latitude numeric(10,7) NOT NULL
);

CREATE TABLE pls_fy2016_libraries (
    stabr text NOT NULL,
    fscskey text CONSTRAINT fscskey_16_pkey PRIMARY KEY,
    libid text NOT NULL,
    libname text NOT NULL,
    address text NOT NULL,
    city text NOT NULL,
    zip text NOT NULL,
    --cięcie--
    longitude numeric(10,7) NOT NULL,
    latitude numeric(10,7) NOT NULL
);

COPY pls_fy2017_libraries ❷
FROM 'C:\TwojKatalog\pls_fy2017_libraries.csv'
WITH (FORMAT CSV, HEADER);

COPY pls_fy2016_libraries
FROM 'C:\TwojKatalog\pls_fy2016_libraries.csv'
WITH (FORMAT CSV, HEADER);
```

```
CREATE INDEX libname_2017_idx ON pls_fy2017_libraries (libname); ❸
CREATE INDEX libname_2016_idx ON pls_fy2016_libraries (libname);
```

Dla obu operacji importowania zaktualizuj ścieżki do plików w instrukcjach `COPY` i uruchom kod.

Najpierw tworzone są dwie tabele, w ramach których ponownie użyto kolumny `fscskey` ❶ jako klucza głównego. Dalej wykonano polecenia `COPY` ❷, aby do tabel zaimportować zawartość plików CSV. I wreszcie w obu tabelach utworzono indeks dla kolumny `libname` ❸.

Sprawdzając kod, zauważysz, że trzy tabele mają identyczną strukturę. Większość realizowanych badań będzie zawierać pewną ilość zmian pojawiających się w kolejnych latach, ponieważ twórcy badań przygotowują nowe pytania lub modyfikują już istniejące. Kolumny, które wybrałem na potrzeby tych trzech tabel, są jednak spójne. Dokumentacja z informacjami o kolejnych latach badań jest dostępna pod adresem *https://www.imls.gov/research-↪evaluation/data-collection/public-libraries-survey/*. Pora zagłębić się w te dane, aby stwierdzić, jakie informacje w sobie zawierają.

Eksplorowanie danych dotyczących bibliotek za pomocą funkcji agregujących

Funkcje agregujące łączą wartości z wielu wierszy, wykonują operację względem tych wartości i zwracają pojedynczy wynik. Jak się dowiedziałeś w rozdziale 6., możesz na przykład za pomocą funkcji agregującej `avg()` zwrócić średnią wartości. Niektóre funkcje agregujące są częścią standardu języka SQL, natomiast pozostałe są powiązane z systemem PostgreSQL oraz innymi systemami zarządzania bazami danych. Większość tych funkcji użytych w tym rozdziale wchodzi w skład standardu języka SQL (pełna lista funkcji agregujących systemu PostgreSQL znajduje się pod adresem *https://www.postgresql.org/docs/current/functions-aggregate.html*).

W niniejszym podrozdziale przeanalizujemy dane biblioteczne przy użyciu agregatów zastosowanych dla pojedynczych i wielu kolumn, a następnie dowiesz się, jak możesz rozszerzyć zakres wykorzystania agregatów przez grupowanie zwracanych przez nie wyników z wartościami z dodatkowych kolumn.

Ustalanie liczby wierszy i wartości za pomocą funkcji count()

Po zaimportowaniu zbioru danych pierwszym sensownym krokiem jest upewnienie się, że tabela zawiera oczekiwaną liczbę wierszy. W dokumentacji instytutu IMLS podano, że zaimportowany przez nas plik z danymi z roku 2018 liczy 9261 wierszy. Z kolei pliki z danymi z lat 2017 i 2016 zawierają odpowiednio 9245 i 9252 wiersze. Widoczna różnica prawdopodobnie odzwierciedla otwarcia, zamknięcia lub połączenia bibliotek. Po sprawdzeniu liczby wierszy w tych tabelach wyniki powinny być zgodne z tymi wartościami.

Funkcja agregująca `count()`, która jest częścią standardu ANSI SQL, ułatwia sprawdzenie liczby wierszy oraz umożliwia wykonanie innych operacji zliczających. Jeśli jako

dane wejściowe wprowadzisz znak gwiazdki, tak jak w przypadku wywołania funkcji `count(*)`, znak ten będzie pełnić rolę symbolu wieloznacznego, dlatego funkcja zwróci liczbę wierszy tabeli niezależnie od tego, czy zawierają one wartości `NULL`. Postąpiono tak w każdej z trzech instrukcji kodu z listingu 9.3.

Listing 9.3. Użycie funkcji count() do ustalenia liczby wierszy tabeli

```
SELECT count(*)
FROM pls_fy2018_libraries;

SELECT count(*)
FROM pls_fy2017_libraries;

SELECT count(*)
FROM pls_fy2016_libraries;
```

Wykonaj po jednym na raz każdą z instrukcji zawartych w listingu 9.3, aby ujrzeć liczbę wierszy tabeli. W przypadku tabeli `pls_fy2018_libraries` wynik powinien wyglądać następująco:

```
count
-----
 9261
```

Dla tabeli `pls_fy2017_libraries` wynik prezentuje się następująco:

```
count
-----
 9245
```

I wreszcie w przypadku tabeli `pls_fy2016_libraries` wynik powinien być taki:

```
count
-----
 9252
```

Wszystkie trzy wyniki zawierają oczekiwaną liczbę wierszy. Jest to właściwy pierwszy krok, gdyż w ramach niego zostaniesz ostrzeżony o takich problemach jak brakujące wiersze lub sytuacja, w której mogłeś zaimportować zły plik.

Uwaga

Korzystając z interfejsu narzędzia pgAdmin, też możesz sprawdzić liczbę wierszy, ale jest to niewygodne. Kliknięcie prawym przyciskiem myszy nazwy tabeli w przeglądarce obiektów tego narzędzia i wybranie pozycji All Rows *menu* View/Edit *spowoduje wykonanie zapytania SQL zwracającego wszystkie wiersze. W obrębie panelu wyników zostanie następnie wyświetlony komunikat z liczbą wierszy, który jednak znika po kilku sekundach.*

Określanie liczby wartości obecnych w kolumnie

Jeżeli w funkcji `count()` podasz nazwę kolumny zamiast znaku gwiazdki, zwróci ona liczbę wierszy pozbawionych wartości `NULL`. Za pomocą tej funkcji możesz na przykład ustalić liczbę wartości innych niż `NULL` w kolumnie `phone` tabeli `pls_fy2018_libraries` (listing 9.4).

Listing 9.4. Użycie funkcji count() do uzyskania liczby wartości w kolumnie

```
SELECT count(phone)
FROM pls_fy2018_libraries;
```

Wynik potwierdza, że kolumna `phone` zawiera wartość w przypadku 9261 wierszy, co odpowiada łącznej liczbie wierszy, którą wcześniej podano.

```
count
-----
 9261
```

Oznacza to, że w każdym wierszu kolumna `phone` przechowuje wartość. Być może już to podejrzewałeś, biorąc pod uwagę to, że w instrukcji `CREATE TABLE` dla kolumny tej określono ograniczenie `NOT NULL`. Warto jednak przeprowadzić to sprawdzenie, ponieważ brak wartości może mieć wpływ na Twoją decyzję dotyczącą tego, czy w ogóle kontynuować analizę. Aby w pełni zweryfikować dane, zwykle dobrym pomysłem będzie współpraca z ekspertami z danej dziedziny, a także dokładniejsze zagłębienie się w dane. Zalecam skorzystanie z rady ekspertów jako części obszerniejszej metodologii analizy (więcej na ten temat znajdziesz w rozdziale 20.).

Ustalanie liczby różnych wartości w kolumnie

W rozdziale 3. omówiono słowo kluczowe `DISTINCT` będące częścią standardu języka SQL, które w ramach instrukcji `SELECT` powoduje zwrócenie listy unikalnych wartości. Za pomocą tego słowa możesz uzyskać unikalne wartości w pojedynczej kolumnie lub wyświetlić niepowtarzalne kombinacje wartości z wielu kolumn. Słowo kluczowe `DISTINCT` może też zostać dodane do funkcji `count()` w celu zwrócenia przez nią liczby różnych wartości zawartych w kolumnie.

Kod z listingu 9.5 zawiera dwa zapytania. Pierwsze z nich zapewnia liczbę wszystkich wartości w kolumnie `libname` tabeli z danymi z roku 2018. Drugie zapytanie wykonuje to samo działanie, ale przed nazwą kolumny wstawiono w nim słowo kluczowe `DISTINCT`. Wykonaj oba zapytania po jednym na raz.

Listing 9.5. Zastosowanie funkcji count() do uzyskania liczby różnych wartości w kolumnie

```
SELECT count(libname)
FROM pls_fy2018_libraries;

SELECT count(DISTINCT libname)
FROM pls_fy2018_libraries;
```

Pierwsze zapytanie zwraca liczbę wierszy zgodną z liczbą wierszy w tabeli, którą uzyskano za pomocą kodu z listingu 9.3:

```
count
-----
 9261
```

Znakomicie. Oczekuje się, że nazwa agencji bibliotek będzie podana w każdym wierszu. Drugie zapytanie zwraca jednak mniejszą liczbę:

```
count
-----
 8478
```

Użycie słowa kluczowego `DISTINCT` do usunięcia duplikatów ogranicza liczbę unikalnych nazw bibliotek do 8478. Po bliższym przyjrzeniu się danym okazuje się, że w udostępnionych danych badań z 2018 r. 526 agencji bibliotek ma taką samą nazwę jak jedna lub większa liczba agencji. 10 agencji bibliotek nosi nazwę `OXFORD PUBLIC LIBRARY`, a każda z nich znajduje się w miejscowości o nazwie Oxford zlokalizowanej w różnych stanach, takich między innymi jak Alabama, Connecticut, Kansas i Pensylwania. W punkcie „Agregowanie danych za pomocą klauzuli GROUP BY" utworzymy zapytanie, które pozwoli ujrzeć kombinacje różnych wartości.

Znajdowanie maksymalnych i minimalnych wartości za pomocą funkcji max() i min()

Funkcje `max()` i `min()` zapewniają największe i najmniejsze wartości w kolumnie, a ponadto są przydatne z kilku powodów. Po pierwsze ułatwiają zorientowanie się w zakresie raportowanych wartości. Po drugie, jak się okaże, funkcje mogą ujawnić nieoczekiwane problemy z danymi.

Funkcje `max()` i `min()` działają w taki sam sposób z nazwą kolumny będącą ich danymi wejściowymi. W kodzie z listingu 9.6 użyto obu tych funkcji względem kolumny `visits` tabeli z danymi z roku 2018, w której jest rejestrowana liczba rocznych wizyt w agencji bibliotek oraz wszystkich jej oddziałów. Uruchom kod.

Listing 9.6. Znajdowanie największej i najmniejszej liczby wizyt przy użyciu funkcji max() i min()

```
SELECT max(visits), min(visits)
FROM pls_fy2018_libraries;
```

Zapytanie zwraca następujące wyniki:

```
max        min
--------   ---
16686945    -3
```

Cóż, wyniki są interesujące. Wartość maksymalna wynosząca ponad 16,6 miliona jest sensowna w przypadku dużego systemu miejskich bibliotek, ale liczba `-3` jako wartość minimalna? Początkowo można odnieść wrażenie, że taki wynik to pomyłka. Okazuje się jednak, że twórcy badań dotyczących bibliotek używają przy gromadzeniu danych powszechnej, lecz potencjalnie problematycznej konwencji polegającej na umieszczaniu w kolumnie liczby ujemnej lub jakiejś sztucznie zawyżonej wartości w celu wskazania pewnego warunku.

W tym przypadku wartości ujemne w kolumnach liczbowych wskazują następujące rzeczy:

Wartość `-1` oznacza brak udzielonej odpowiedzi na pytanie.

Wartość `-3` wskazuje status „nienadające się do zastosowania" i jest stosowana, gdy agencja bibliotek została tymczasowo lub trwale zamknięta.

W trakcie eksplorowania danych konieczne będzie uwzględnienie wartości ujemnych i wykluczenie ich, ponieważ sumowanie wartości kolumny wraz z wartościami ujemnymi spowoduje uzyskanie niepoprawnej sumy. Odfiltrowanie tych wartości umożliwia klauzula `WHERE`. Warto o tym pamiętać, aby zawsze zaznajomić się z dokumentacją danych w celu wyeliminowania problemu zawczasu, a nie być zmuszonym do cofania się po poświęceniu mnóstwa czasu na głębszą analizę!

Uwaga

Lepszą alternatywą dla takiego wariantu z wartością ujemną jest zastosowanie wartości `NULL` w kolumnie `visits` wierszy, w przypadku których nie ma danych odpowiedzi, a następnie utworzenie osobnej kolumny `visits_flag` do przechowywania kodów objaśniających powód braku danych.

Agregowanie danych za pomocą klauzuli GROUP BY

Gdy używasz klauzuli `GROUP BY` w połączeniu z funkcjami agregującymi, możesz grupować wyniki zgodnie z wartościami znajdującymi się w jednej lub większej liczbie kolumn. Pozwala to wykonywać operacje realizowane za pomocą funkcji `sum()` lub `count()` względem każdego stanu w tabeli lub poszczególnych typów agencji bibliotek.

Wyjaśnijmy, na czym polega stosowanie klauzuli `GROUP BY` z funkcjami agregującymi. Sama w sobie klauzula ta, która stanowi również część standardu ANSI SQL, eliminuje z wyników zduplikowane wartości (podobnie do klauzuli `DISTINCT`). W kodzie z listingu 9.7 zaprezentowano działanie klauzuli `GROUP BY`.

Listing 9.7. Użycie klauzuli GROUP BY względem kolumny stabr

```
SELECT stabr
FROM pls_fy2018_libraries
GROUP BY stabr ❶
ORDER BY stabr;
```

Klauzulę `GROUP BY` dodano po klauzuli `FROM` ❶ i dołączono nazwę kolumny, dla której ma zostać wykonane grupowanie. W tym przypadku wybrano kolumnę `stabr`, która zawiera skrót nazwy stanu, a ponadto dokonano grupowania według tej kolumny. Dalej zastosowano

też klauzulę `ORDER BY stabr`, aby wyniki zostały pogrupowane w kolejności alfabetycznej. Dzięki temu uzyska się wynik z unikalnymi skrótami nazw stanów z tabeli z danymi z roku 2018. Oto część wyników:

```
stabr
-----
AK
AL
AR
AS
AZ
CA
--cięcie--
WV
WY
```

Zauważ, że w 55 zwróconych wierszach nie ma żadnych duplikatów. Te standardowe, 2-literowe skrócone kody pocztowe dotyczą 50 stanów oraz miasta Waszyngton w Dystrykcie Kolumbii i kilku terytoriów Stanów Zjednoczonych, takich jak wyspa Guam i Wyspy Dziewicze.

Nie jesteś ograniczony do grupowania tylko jednej kolumny. W kodzie z listingu 9.8 użyto klauzuli `GROUP BY` względem danych z roku 2018, aby na potrzeby grupowania określić kolumny `city` i `stabr`.

Listing 9.8. Użycie klauzuli GROUP BY względem kolumn city i stabr

```
SELECT city, stabr
FROM pls_fy2018_libraries
GROUP BY city, stabr
ORDER BY city, stabr;
```

Wyniki są sortowane według miasta, a następnie z uwzględnieniem stanu. Następujące dane wyjściowe prezentują unikalne kombinacje w takiej kolejności:

```
city        stabr
----------  -----
ABBEVILLE   AL
ABBEVILLE   LA
ABBEVILLE   SC
ABBOTSFORD  WI
ABERDEEN    ID
ABERDEEN    SD
ABERNATHY   TX
--cięcie--
```

W ramach tego grupowania zwrócono 9013 wierszy, czyli o 248 wierszy mniej, niż wynosi łączna liczba wierszy tabeli. Wynik wskazuje na to, że plik zawiera wiele wierszy, w przypadku których dla konkretnej kombinacji miasta i stanu występuje więcej niż jedna agencja bibliotek.

Łączenie klauzuli GROUP BY z funkcją count()

Jeśli połączy się klauzulę `GROUP BY` z funkcją agregującą, taką jak `count()`, z naszych danych można wyodrębnić więcej opisowych informacji. Na przykład wiadomo, że w tabeli danych z roku 2018 figuruje 9261 agencji bibliotek. Możliwe jest uzyskanie liczby agencji według stanu i posortowanie ich w celu stwierdzenia, w których stanach jest ich najwięcej. Kod z listingu 9.9 demonstruje, jak to zrobić.

Listing 9.9. Zastosowanie klauzuli GROUP BY z funkcją count() względem kolumny stabr

```
SELECT stabr, count(*) ❶
FROM pls_fy2018_libraries
GROUP BY stabr ❷
ORDER BY count(*) DESC; ❸
```

Tym razem zapytanie dotyczy wartości w kolumnie `stabr` oraz liczby wierszy zawierających daną wartość. W obrębie listy kolumn objętych zakresem zapytania ❶ określono kolumnę `stabr` wraz z funkcją `count()`, dla której jako dane wejściowe podano znak gwiazdki (spowoduje ona uwzględnienie przez tę funkcję wartości `NULL`). Ponadto, gdy w ramach funkcji agregującej wybiera się poszczególne kolumny, w klauzuli `GROUP BY` trzeba określić te same kolumny ❷. W przeciwnym razie baza danych zwróci komunikat o błędzie informujący o konieczności wykonania tego działania, gdyż nie możesz grupować wartości przez agregowanie oraz w tym samym zapytaniu używać niegrupowanych wartości kolumn.

W celu posortowania wyników tak, aby na samej górze został wyświetlony stan z największą liczbą agencji, można skorzystać z klauzuli `ORDER BY` ❸, która uwzględnia funkcję `count()` i słowo kluczowe `DESC`.

Uruchom kod z listingu 9.9. W wynikach widać, że w stanach Nowy Jork, Illinois i Teksas w 2018 r. była największa liczba agencji bibliotek:

```
stabr   count
-----   -----
NY        756
IL        623
TX        560
IA        544
PA        451
MI        398
WI        381
MA        369
--cięcie--
```

Pamiętaj o tym, że przykładowa tabela reprezentuje agencje bibliotek obsługujące okolicę. Samo to, że w stanach Nowy Jork, Illinois i Teksas znajduje się najwięcej agencji bibliotek, nie oznacza, że dysponują one największą liczbą punktów, do których można się udać, aby przejrzeć zawartość półek. Agencja może mieć tylko jedną centralną bibliotekę albo może nie oferować żadnej takiej biblioteki, a jedynie 23 oddziały rozproszone po całym hrabstwie. Aby umożliwić policzenie punktów, każdy wiersz tabeli zawiera również wartości

w kolumnach `centlib` i `branlib`, które rejestrują odpowiednio liczbę bibliotek centralnych i oddziałowych. W celu określenia łącznych liczb należy względem obu kolumn zastosować funkcję agregującą `sum()`.

Zastosowanie klauzuli GROUP BY z funkcją count() względem wielu kolumn

Jeszcze więcej informacji można uzyskać z danych przez połączenie klauzuli `GROUP BY` z funkcją `count()` w przypadku wielu kolumn. Na przykład kolumna `stataddr` obecna we wszystkich trzech tabelach zawiera kod wskazujący, czy w ciągu ostatniego roku zmienił się adres agencji. Wartości w kolumnie `stataddr` są następujące:

00. Brak zmiany w ciągu ostatniego roku.

07. Przeniesiono do nowej lokalizacji.

15. Niewielka zmiana w adresie.

Kod z listingu 9.10 zawierający klauzulę `GROUP BY` z kolumnami `stabr` i `stataddr` oraz uwzględniający funkcję `count()` służy do ustalenia liczby agencji w każdym stanie, w przypadku których dokonano przeniesienia w nowe miejsce, wprowadzono drobną zmianę w adresie lub nie dokonano żadnej zmiany.

Listing 9.10. Użycie klauzuli GROUP BY z funkcją count() względem kolumn stabr i stataddr

```
SELECT stabr, stataddr, count(*) ❶
FROM pls_fy2018_libraries
GROUP BY stabr, stataddr ❷
ORDER BY stabr, stataddr; ❸
```

Kluczowe sekcje zapytania to nazwy kolumn i funkcja `count()` umieszczone po instrukcji `SELECT` ❶. Ważne jest też określenie obu kolumn w klauzuli `GROUP BY` ❷, tak aby funkcja `count()` zapewniła liczbę unikalnych kombinacji wartości kolumn `stabr` i `stataddr`.

Aby ułatwić analizowanie danych wyjściowych, posortujmy je najpierw w kolejności rosnącej według kodów stanów i kodów statusu adresu ❸. Oto wyniki:

```
stabr   stataddr   count
-----   --------   -----
AK      00          82
AL      00         220
AL      07           3
AL      15           1
AR      00          58
AR      07           1
AR      15           1
AS      00           1
--cięcie--
```

W kilku pierwszych wierszach widać, że kod 00 (brak zmiany w adresie) to najczęstsza wartość dla każdego stanu. Można było tego oczekiwać, ponieważ bardziej prawdopodobne jest to, że w przypadku większej liczby agencji bibliotek adres nie ulegnie zmianie, niż to, że się zmieni. Otrzymany wynik pomaga w upewnieniu się, że dane są analizowane w staranny sposób. Jeśli kod 07 (przeniesienie do nowej lokalizacji) występowałby najczęściej dla każdego stanu, przywodziłoby to na myśl pytanie o to, czy poprawnie utworzono zapytanie albo czy występuje problem z danymi.

Ponowne użycie funkcji sum() do sprawdzania aktywności związanej z bibliotekami

Rozszerzmy stosowane techniki, aby uwzględnić grupowanie i agregowanie dla złączonych tabel zawierających dane dotyczące bibliotek z lat 2016, 2017 i 2018. Naszym celem jest zidentyfikowanie trendów w zakresie odwiedzania bibliotek w okresie obejmującym trzy lata. Aby to zrealizować, niezbędne jest obliczenie całkowitych liczb za pomocą funkcji agregującej `sum()`.

Zanim zagłębimy się w te zapytania, zajmijmy się wartościami `-3` i `-1`, które wskazują odpowiednio status „nienadające się do zastosowania" i brak udzielonej odpowiedzi. Aby uniknąć wpływu na analizę tych wartości ujemnych, zostaną one odfiltrowane za pomocą klauzuli `WHERE` ograniczającej wyniki zapytań do wierszy, w których wartości w kolumnie `visits` są większe lub równe 0.

Zacznijmy od obliczenia sumy uzyskanych z poszczególnych tabel liczb wizyt w bibliotekach z całego roku. Uruchom osobno każdą instrukcję `SELECT` zawartą w kodzie z listingu 9.11.

Listing 9.11. Zastosowanie funkcji agregującej sum() do zsumowania liczby wizyt w bibliotekach w latach 2016, 2017 i 2018

```
SELECT sum(visits) AS visits_2018
FROM pls_fy2018_libraries
WHERE visits >= 0;

SELECT sum(visits) AS visits_2017
FROM pls_fy2017_libraries
WHERE visits >= 0;

SELECT sum(visits) AS visits_2016
FROM pls_fy2016_libraries
WHERE visits >= 0;
```

W roku 2018 łączna liczba wizyt wyniosła w przybliżeniu 1,29 miliarda:

```
visits_2018
-----------
 1292348697
```

W roku 2017 całkowita liczba wizyt to w przybliżeniu 1,32 miliarda:

```
visits_2017
-----------
 1319803999
```

Z kolei w przypadku roku 2016 ustalono łączną liczbę wizyt wynoszącą w przybliżeniu 1,36 miliarda:

```
visits_2016
-----------
 1355648987
```

Coś tutaj stwierdziliśmy, ale może to nie być dobra wiadomość dla bibliotek. Wydaje się, że trend jest spadkowy z liczbą wizyt zmniejszającą się o około 5% w okresie od roku 2016 do roku 2018.

Udoskonalmy to rozwiązanie. Zapytania sumują wizyty zarejestrowane w każdej tabeli. Na podstawie liczb wierszy ustalonych wcześniej w rozdziale wiadomo, że każda tabela zawiera inną liczbę agencji bibliotek: 9261 agencji w 2018 r., 9245 agencji w 2017 r. oraz 9252 agencje w 2016 r. Różnice wynikają prawdopodobnie z faktu otwierania, zamykania lub łączenia agencji. Określmy zatem, jak suma wizyt będzie się różnić, jeśli analiza zostanie ograniczona do wierszy agencji bibliotek istniejących we wszystkich trzech tabelach i niezawierających w kolumnie `visits` wartości ujemnych. W tym celu należy złączyć tabele za pomocą kodu z listingu 9.12.

Listing 9.12. Użycie funkcji sum() do zsumowania liczby wizyt ze złączonych tabel z danymi z lat 2016, 2017 i 2018

```
SELECT sum(pls18.visits) AS visits_2018, ❶
       sum(pls17.visits) AS visits_2017,
       sum(pls16.visits) AS visits_2016
FROM pls_fy2018_libraries pls18 ❷
       JOIN pls_fy2017_libraries pls17 ON pls18.fscskey = pls17.fscskey
       JOIN pls_fy2016_libraries pls16 ON pls18.fscskey = pls16.fscskey
WHERE pls18.visits >= 0 ❸
       AND pls17.visits >= 0
       AND pls16.visits >= 0;
```

Zapytanie to łączy w sobie kilka zagadnień omówionych we wcześniejszych rozdziałach, w tym złączenia tabel. W kodzie na początku użyto funkcji agregującej `sum()` ❶ w celu zsumowania wartości w kolumnie `visits` każdej z trzech tabel. Podczas złączania tabel za pomocą ich kluczy głównych zadeklarowano aliasy tabel ❷ w sposób objaśniony w rozdziale 7. Pominięto tutaj przed każdym aliasem opcjonalne słowo kluczowe `AS`. Na przykład zadeklarowano nazwę `pls18` jako alias tabeli z danymi z roku 2018, aby uniknąć podawania w obrębie zapytania jej dłuższej, pełnej nazwy.

Zauważ, że użyto standardowego złączenia `JOIN` znanego również jako złączenie `INNER JOIN`. Oznacza to, że wyniki zapytania będą zawierać wyłącznie wiersze, w których wartości kolumny klucza głównego `fscskey` są takie same we wszystkich trzech tabelach.

Tak jak w kodzie z listingu 9.11, za pomocą klauzuli `WHERE` ❸ określono tutaj, że wynik powinien uwzględniać tylko te wiersze, w których wartość kolumny `visits` tabel jest większa lub równa 0. W ten sposób zapobiegnie się wpływaniu na sumy sztucznych wartości ujemnych.

Uruchom zapytanie. Wyniki powinny wyglądać następująco:

```
visits_2018  visits_2017  visits_2016
-----------  -----------  -----------
 1278148838   1319325387   1355078384
```

Wyniki są podobne do tego, co uzyskano po użyciu zapytań kierowanych osobno do każdej tabeli, choć podane sumy dla roku 2018 nie przekraczają 14 milionów. W dalszym ciągu trend spadkowy utrzymuje się.

Aby dysponować pełnym obrazem tego, jak zmienia się kwestia korzystania z bibliotek, wskazane będzie uruchomienie podobnego zapytania względem wszystkich kolumn zawierających wskaźniki wydajności mające na celu rejestrowanie trendu w każdej tabeli. Na przykład kolumna `wifisess` umożliwia stwierdzenie, ile razy użytkownicy połączyli się z bezprzewodową siecią internetową biblioteki. Jeśli w kodzie z listingu 9.11 użyje się tej kolumny zamiast kolumny `visits`, zostanie otrzymany następujący wynik:

```
wifi_2018  wifi_2017  wifi_2016
---------  ---------  ---------
349767271  311336231  234926102
```

Wprawdzie liczba wizyt spadła, ale pracownicy bibliotek zauważyli szybki wzrost stopnia korzystania z sieci bezprzewodowej. Fakt ten zapewnia znaczącą informację w odniesieniu do tego, jak zmienia się rola bibliotek.

Uwaga

Choć złączono tabele za pomocą kolumny `fscskey`, całkowicie możliwe jest to, że niektóre agencje bibliotek pojawiające się we wszystkich trzech tabelach w ciągu trzech lat zostały objęte procesem łączenia lub podziału. Dobrym pomysłem jest skontaktowanie się z instytutem IMLS w celu zapytania o zastrzeżenia towarzyszące analizowaniu tych danych.

Grupowanie sum wizyt według stanów

Gdy już wiadomo, że między rokiem 2016 i 2018 całościowo spadła liczba wizyt w bibliotekach na obszarze Stanów Zjednoczonych, możesz sobie zadać następujące pytanie: „Czy w każdej części hrabstwa zanotowano spadek, czy też stopień trendu spadkowego zmienia się zależnie od regionu?”. Odpowiedź na to pytanie można uzyskać przez zmodyfikowanie

poprzedniego zapytania pod kątem grupowania według kodu stanów. Zastosujmy również obliczenie zmiany procentowej w celu porównania trendu według stanów. Listing 9.13 zawiera pełny kod.

Listing 9.13. Użycie klauzuli GROUP BY do monitorowania zmiany procentowej liczby wizyt w bibliotekach poszczególnych stanów

```
SELECT pls18.stabr, ❶
       sum(pls18.visits) AS visits_2018,
       sum(pls17.visits) AS visits_2017,
       sum(pls16.visits) AS visits_2016,
       round( (sum(pls18.visits::numeric) - sum(pls17.visits)) /
            sum(pls17.visits) * 100, 1 ) AS chg_2018_17, ❷
       round( (sum(pls17.visits::numeric) - sum(pls16.visits)) /
            sum(pls16.visits) * 100, 1 ) AS chg_2017_16
FROM pls_fy2018_libraries pls18
       JOIN pls_fy2017_libraries pls17 ON pls18.fscskey = pls17.fscskey
       JOIN pls_fy2016_libraries pls16 ON pls18.fscskey = pls16.fscskey
WHERE pls18.visits >= 0
       AND pls17.visits >= 0
       AND pls16.visits >= 0
GROUP BY pls18.stabr ❸
ORDER BY chg_2018_17 DESC; ❹
```

Po słowie kluczowym `SELECT` podano nazwę kolumny `stabr` ❶ tabeli z danymi z roku 2018. Ta sama kolumna pojawia się w klauzuli `GROUP BY` ❸. Nie ma znaczenia to, z której tabeli zostanie użyta kolumna `stabr`, ponieważ zapytanie dotyczy wyłącznie agencji obecnych we wszystkich trzech tabelach. Po kolumnach `visits` dodano znajome już obliczenie zmiany procentowej, o którym była mowa w rozdziale 6. Obliczenia tego użyto dwa razy, stosując w celu zwiększenia przejrzystości aliasy `chg_2018_17` ❷ i `chg_2017_16`. Zapytanie zakończono klauzulą `ORDER BY` ❹ z sortowaniem według aliasu kolumny `chg_2018_17`.

Po uruchomieniu zapytania na początku wyników widocznych jest 10 stanów, dla których w okresie od roku 2017 do roku 2018 zwiększa się liczba wizyt. Reszta wyników prezentuje spadek wizyt. W przypadku Samoa Amerykańskiego znajdującego się na dole rankingu zanotowano spadek wynoszący 28%!

```
stabr visits_2018 visits_2017 visits_2016 chg_2018_17 chg_2017_16
----- ----------- ----------- ----------- ----------- -----------
SD        3824804     3699212     3722376         3.4        -0.6
MT        4332900     4215484     4298268         2.8        -1.9
FL       68423689    66697122    70991029         2.6        -6.0
ND        2216377     2162189     2201730         2.5        -1.8
ID        8179077     8029503     8597955         1.9        -6.6
DC        3632539     3593201     3930763         1.1        -8.6
ME        6746380     6731768     6811441         0.2        -1.2
NH        7045010     7028800     7236567         0.2        -2.9
UT       15326963    15295494    16096911         0.2        -5.0
DE        4122181     4117904     4125899         0.1        -0.2
OK       13399265    13491194    13112511        -0.7         2.9
WY        3338772     3367413     3536788        -0.9        -4.8
MA       39926583    40453003    40427356        -1.3         0.1
```

```
WA      37338635    37916034    38634499      -1.5      -1.9
MN      22952388    23326303    24033731      -1.6      -2.9
--cięcie--
GA      26835701    28816233    27987249      -6.9       3.0
AR       9551686    10358181    10596035      -7.8      -2.2
GU         75119       81572       71813      -7.9      13.6
MS       7602710     8581994     8915406     -11.4      -3.7
HI       3456131     4135229     4490320     -16.4      -7.9
AS         48828       67848       63166     -28.0       7.4
```

W kwestii zapewnienia kontekstu pomocne jest również sprawdzenie zmiany procentowej wartości kolumny `visits` tabel z danymi z okresu od roku 2016 do roku 2017. Dla wielu stanów, takich jak Minnesota, zanotowano ciągłe spadki. W innych stanach, w tym w kilku z samej góry listy, stwierdzono wzrosty po znaczących spadkach w poprzednim roku.

Właśnie w takiej sytuacji dobrym pomysłem jest przeanalizowanie tego, co powoduje zmiany. Analiza danych może czasami skutkować pojawieniem się takiej samej liczby pytań i odpowiedzi, ale jest to częścią procesu. Zawsze warto zadzwonić do osoby zajmującej się bezpośrednio danymi, aby zaznajomiła się z Twoimi obserwacjami. Czasem taka osoba może zapewnić odpowiednie wyjaśnienie. Innym razem ekspert stwierdzi: „Nie wygląda to dobrze". Taka odpowiedź może sprawić, że ponownie zgłosisz się do posiadacza danych lub dokumentacji w celu ustalenia, czy przeoczyłeś kod lub jakiś niuans powiązany z danymi.

Filtrowanie zapytania agregującego za pomocą klauzuli HAVING

Aby udoskonalić prowadzoną analizę, można sprawdzić podzbiór stanów i terytoriów mających podobne, wspólne cechy. W przypadku zmiany procentowej liczby wizyt sensowne jest oddzielenie dużych stanów od małych. W małym stanie, takim jak Rhode Island, jedna biblioteka zamknięta przez 6 miesięcy z powodu remontu mogłaby mieć znaczący wpływ na wynik. Zamknięcie jednej biblioteki w stanie Kalifornia może być ledwo zauważalne w łącznej liczbie dla całego stanu. W celu przyjrzenia się stanom z podobną liczbą wizyt wyniki można posortować przy użyciu jednej z kolumn `visits`. Dane wyjściowe byłyby jednak bardziej przejrzyste, gdyby uzyskano mniejszy zestaw wynikowy dzięki odfiltrowaniu danych zwracanych przez użyte zapytanie.

Aby wykonać operację filtrowania wyników funkcji agregujących, musisz skorzystać z klauzuli `HAVING` będącej częścią standardu ANSI SQL. Jesteś już zaznajomiony z użyciem klauzuli `WHERE` do filtrowania, ale funkcje agregujące, takie jak `sum()`, nie mogą być stosowane w obrębie klauzuli `WHERE`, ponieważ działają one na poziomie wierszy i między nimi. Klauzula `HAVING` określa warunki względem grup tworzonych w wyniku agregowania. W kodzie z listingu 9.14 zmodyfikowano zapytanie z listingu 9.13 przez wstawienie klauzuli `HAVING` po klauzuli `GROUP BY`.

Listing 9.14. Użycie klauzuli HAVING do filtrowania wyników zapytania agregującego

```
SELECT pls18.stabr,
       sum(pls18.visits) AS visits_2018,
       sum(pls17.visits) AS visits_2017,
       sum(pls16.visits) AS visits_2016,
```

```
        round( (sum(pls18.visits::numeric) - sum(pls17.visits)) /
             sum(pls17.visits) * 100, 1 ) AS chg_2018_17,
        round( (sum(pls17.visits::numeric) - sum(pls16.visits)) /
             sum(pls16.visits) * 100, 1 ) AS chg_2017_16
FROM pls_fy2018_libraries pls18
        JOIN pls_fy2017_libraries pls17 ON pls18.fscskey = pls17.fscskey
        JOIN pls_fy2016_libraries pls16 ON pls18.fscskey = pls16.fscskey
WHERE pls18.visits >= 0
        AND pls17.visits >= 0
        AND pls16.visits >= 0
GROUP BY pls18.stabr
HAVING sum(pls18.visits) > 50000000 ❶
ORDER BY chg_2018_17 DESC;
```

W tym przypadku tak określono wyniki zapytania, żeby zawierały wyłącznie wiersze z sumą wizyt w roku 2018 przekraczającą 50 milionów. Jest to wartość wybrana przeze mnie arbitralnie w celu pokazania tylko największych stanów. Dodanie klauzuli `HAVING` ❶ ogranicza liczbę wierszy w danych wyjściowych do zaledwie sześciu. W praktyce możesz poeksperymentować z różnymi wartościami. Oto wyniki:

```
stabr visits_2018 visits_2017 visits_2016 chg_2018_17 chg_2017_16
----- ----------- ----------- ----------- ----------- -----------
FL       68423689    66697122    70991029         2.6        -6.0
NY       97921323   100012193   103081304        -2.1        -3.0
CA      146656984   151056672   155613529        -2.9        -2.9
IL       63466887    66166082    67336230        -4.1        -1.7
OH       68176967    71895854    74119719        -5.2        -3.0
TX       66168387    70514138    70975901        -6.2        -0.7
```

W pięciu z sześciu stanów zanotowano spadek liczby wizyt, ale zwróć uwagę na to, że skala zmiany procentowej nie jest tak szeroka jak w przypadku pełnego zestawu stanów i terytoriów. Zależnie od tego, czego się dowiemy od ekspertów zajmujących się bibliotekami, przyjrzenie się innym wariantom grupowania, jak i analizowanie jako grupy stanów z największą aktywnością może ułatwić opisanie trendów. Zastanów się nad następującym stwierdzeniem, jakie możesz sformułować: „Wśród stanów z największą liczbą wizyt Floryda była jedynym stanem, w którym zanotowano wzrost aktywności między rokiem 2017 i rokiem 2018. W reszcie stanów zauważono spadek liczby wizyt wynoszący od 2% do 6%". Mógłbyś przygotować podobne wnioski odnoszące się do małych stanów i stanów średniej wielkości.

Podsumowanie

Jeżeli zainspirowałeś się już do odwiedzenia swojej lokalnej biblioteki i sprawdzenia kilku książek, zapytaj jej pracownika, czy w okresie trwającym dłużej niż kilka ostatnich lat ten oddział biblioteczny odnotował wzrost lub spadek liczby wizyt. Prawdopodobnie jesteś w stanie domyśleć się odpowiedzi. W tym rozdziale dowiedziałeś się, jak za pomocą

standardowych technik języka SQL podsumowywać dane w tabeli przez zastosowanie grupowania wartości i kilku funkcji agregujących. Dzięki złączeniu zbiorów danych byłeś w stanie zidentyfikować interesujące trendy.

Uświadomiono Ci też, że otrzymywane dane nie zawsze są idealnie przygotowane. Obecność w kolumnie wartości ujemnych, które pełnią bardziej rolę wskaźnika niż faktycznej wartości liczbowej, zmusiła nas do odfiltrowania takich wierszy. Niestety, tego rodzaju wyzwania są częścią codziennego świata analityka danych, dlatego w następnym rozdziale zostanie wyjaśnione, jak oczyścić zbiór danych z kilkoma problemami. W dalszej części książki zaznajomisz się też z kolejnymi funkcjami agregującymi, które ułatwią Ci zidentyfikowanie przydatnych informacji w posiadanych danych.

WYPRÓBUJ TO SAM

Wykorzystaj swoje umiejętności z zakresu grupowania i agregowania, aby sprawdzić się w pojedynku z następującymi wyzwaniami:

1. Stwierdzono, że w większości miejsc w ostatnim czasie zmniejszyła się liczba wizyt w bibliotekach. Jaki jest jednak schemat zatrudnienia w bibliotekach? Wszystkie trzy tabele badań dotyczących bibliotek zawierają kolumnę `totstaff`, w której przechowuje się liczbę pracowników zatrudnionych na pełnym etacie. Zmodyfikuj kod z listingów 9.13 i 9.14, aby obliczyć zmianę procentową w czasie w przypadku sumy wartości kolumny. Sprawdź wszystkie stany, a także stany z największą liczbą osób odwiedzających. Uważaj na wartości ujemne!
2. W tabelach badań dotyczących bibliotek jest kolumna o nazwie `obereg` zawierająca 2-cyfrowy kod urzędu BEA (Bureau of Economic Analysis), który klasyfikuje każdą agencję bibliotek zgodnie z regionem Stanów Zjednoczonych, takim jak Nowa Anglia, Góry Skaliste itp. Tak jak obliczono zmianę procentową dla liczby wizyt grupowanych według stanu, tak to samo działanie wykonaj w celu pogrupowania za pomocą kolumny `obereg` zmian procentowych liczby wizyt według regionów Stanów Zjednoczonych. Zajrzyj do dokumentacji badań, aby zaznajomić się ze znaczeniem kodu każdego regionu. W ramach dodatkowego wyzwania utwórz tabelę z kodem kolumny `obereg` pełniącym rolę klucza głównego oraz z nazwą regionu jako kolumną tekstową. Dołącz następnie tę tabelę do zapytania podsumowującego w celu pogrupowania wyników według nazwy regionu, a nie według kodu.
3. Wracając myślami do typów złączeń omówionych w rozdziale 7., zastanów się, jaki typ złączenia umożliwi pokazanie wszystkich wierszy każdej z trzech tabel z uwzględnieniem wierszy bez pasującej wartości? Utwórz takie zapytanie i dodaj w klauzuli `WHERE` filtr `IS NULL`, aby wyświetlić agencje, których nie ma w jednej lub większej liczbie tabel.


PROGRAM
PARTNERSKI
GRUPY HELION
1. ZAREJESTRUJ SIĘ
2. PREZENTUJ KSIĄŻKI
3. ZBIERAJ PROWIZJĘ
Zmień swoją stronę WWW w działający bankomat!
Dowiedz się więcej i dołącz już dzisiaj!
http://program-partnerski.helion.pl
GRUPA
Helion

PRZEJRZYSTE WPROWADZENIE DO PROCESU EKSPLOROWANIA I ANALIZOWANIA DANYCH ORAZ ZARZĄDZANIA NIMI

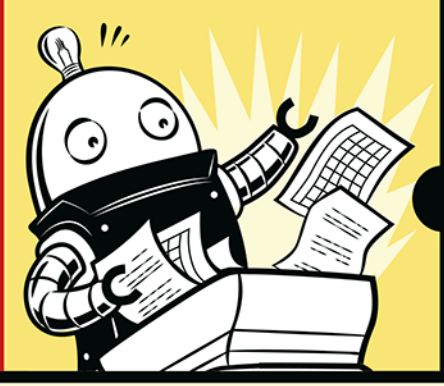

Język SQL służy do definiowania, porządkowania i eksplorowania danych w relacyjnych bazach danych. Nieco bardziej złożone zapytania SQL pozwalają na efektywne wydobywanie wiedzy z danych. SQL jest dojrzałym językiem, używanym w wielu systemach bazodanowych. Jednym z nich jest PostgreSQL, darmowy i powszechnie znany, dostępny również dla środowisk chmurowych.

Książka jest przystępnym przewodnikiem po zastosowaniu języka SQL w procesie uzyskiwania informacji zawartych w danych. Zaczniesz od przyswojenia podstawowej wiedzy o bazach danych i SQL, a następnie przystąpisz do analizy prawdziwych zbiorów danych, takich jak demografia spisu ludności w Stanach Zjednoczonych, przejazdy taksówek w Nowym Jorku i szczegóły z krajowego katalogu targów rolniczych. Dzięki ćwiczeniom i przykładom zamieszczonym w każdym rozdziale szybko zaznajomisz się ze wszystkimi, również najnowszymi, narzędziami niezbędnymi do budowania zaawansowanych baz danych PostgreSQL. Zrozumiesz również, jak w szybki i efektywny sposób dane pozwalają zdobyć potrzebne informacje.

Dowiedz się, jak:

- tworzyć bazy PostgreSQL z użyciem własnych danych
- agregować, sortować i filtrować dane w celu zidentyfikowania wzorców
- tworzyć zapytania dla systemów GIS
- używać funkcji do wykonywania działań matematycznych i operacji statystycznych
- tworzyć złożone zapytania i automatyzować zadania

Anthony DeBarros jest redaktorem „Wall Street Journal", gdzie zajmuje się gospodarką, demografią i finansami w polityce. Jest zwolennikiem tzw. dziennikarstwa danych i wyszukiwania w nich informacji. Wcześniej brał udział w przygotowywaniu wydań gazet „USA Today" i „Poughkeepsie Journal", a także zajmował się opracowywaniem strategii dotyczącej treści.

Helion
helion.pl
HELION S.A.
ul. Kościuszki 1c
44-100 Gliwice
tel.: 32 230 98 63
helion@helion.pl

KOD KORZYŚCI
Sięgnij po więcej! ▶

ISBN 978-83-289-1018-8
9 788328 910188

Cena: 99,00 zł

no starch press