[MAC0313]
Introdução aos Sistemas de Bancos de Dados
Aula 23
Acessando um Banco de Dados a partir do R

Kelly Rosa Braghetto

DCC–IME–USP

14 de novembro de 2019

Usando a SQL para cálculos numéricos e estatísticos

Somente as funções básicas estão disponíveis na versão padrão da linguagem

- Operadores matemáticos: $+, -, *, /$
- Funções de agregação: MAX, MIN, COUNT, SUM, AVG

Exemplos de consultas difíceis de se fazer em SQL

- Medianas, quartis
- Mínimos quadrados (regressão linear)

Usando a SQL para cálculos numéricos e estatísticos

Outros problemas

- Nem sempre as funções de agregação são implementadas no SGBD com garantias de acurácia numérica
- Cálculos envolvendo diferentes tipos de valores numéricos podem ter resultados diferentes dos esperados
  - A SQL possui uma grande variedade de tipos numéricos (smallint, int, float, double, numeric)
  - Frequentemente, o cálculo de expressões matemáticas envolvendo diferentes tipos de valores requer a realização de conversões de tipos
  - As conversões entre tipos numéricos podem produzir truncamentos ou arredondamentos inesperados

Solução: usar um pacote estatístico para analisar os dados armazenados em um BD

Analisando os dados de um BD por meio de um pacote estatístico

Diferentes estratégias possíveis:

1. Extrair os dados do BD, armazená-los em arquivos (geralmente no formato CSV) e depois importá-los no software estatístico
2. A partir do software estatístico, abrir uma conexão com o BD e obter os dados desejados por meio da submissão de consultas ao SGBD
3. Implementar dentro do SGBD novas funções de agregação, que podem ser usadas em consultas SQL mas que são executadas por um software estatístico

Um "parênteses" sobre arquivos CSV

- CSV = *Comma-separated values*
- Arquivos CSV armazena dados tabulares (números ou texto) em formato puramente textual
- Cada linha do arquivo corresponde a um registro
- Cada registro tem um ou mais campos, separados por vírgulas
- Esse formato não é padronizado, mas softwares de análise de dados costumam reconhecê-lo facilmente
  - algum outro caractere pode ser usar usado para separar campos no lugar da vírgula (ex.: ';', 'tab', '|', etc.)
  - strings podem ter caracteres delimitadores (como aspas ou apóstrofes)
  - Valores nulos geralmente são denotados por vazios

Analisando os dados de um BD por meio de um pacote estatístico

Diferentes estratégias possíveis:

1. **Extrair os dados do BD, armazená-los em arquivos (texto: CSV) e depois importá-los no software estatístico**

   Vantagens

   - Simples de se implementar (não requer novos conhecimentos específicos)

   Desvantagens

   - Viável quando deseja-se fazer a análise dos dados do BD uma única (ou poucas) vez(es)
   - Dificulta a análise de grandes volumes de dados

Analisando os dados de um BD por meio de um pacote estatístico

Diferentes estratégias possíveis:

2. **A partir do software estatístico, abrir uma conexão com o BD e obter os dados desejados por meio da submissão de consultas ao SGBD**

   Vantagens

   - Garante que os dados analisados são sempre os mais novos presentes no BD
   - Fornece facilidades para lidar com grandes volumes de dados (recuperação em "lotes")

   Desvantagens

   - Requer o conhecimento de funções específicas para a comunicação com o BD a partir do software estatístico
   - O transferência de muitos dados entre o BD e o software estatístico pode ser lenta

Analisando os dados de um BD por meio de um pacote estatístico

Diferentes estratégias possíveis:

3. **Implementar dentro do SGBD novas funções de agregação, que podem ser usadas em consultas SQL mas que são executadas por um software estatístico**

   Vantagens

   - Garante que os dados analisados são sempre os mais novos presentes no BD
   - Isenta o usuário de se preocupar com o tratamento dos dados quando esses não cabem na memória principal

   Desvantagens

   - Requer conhecimentos específicos para a criação de novas funções de agregação no SGBD
   - O transferência de muitos dados entre o BD e o software estatístico pode ser lenta

Sobre o R

- Para exemplificar as estratégias discutidas nos slides anteriores, usaremos o SGBD PostgreSQL e o software estatístico **R**
- O **R** é um ambiente de software para computação estatística e gráficos
- Ele é um software livre e roda em uma grande variedade de plataformas Linux, Windows e MacOS
- Site: `http://www.r-project.org/`

Instalação do R

- No Linux: pacotes `r-base` (versão completa) ou `littler` (versão "leve")

  ```
  $ sudo apt-get install r-base
  ```
  ou
  ```
  $ sudo apt-get install littler
  ```

- No Windows:

  Baixar o instalador em:
  `http://nbcgib.uesc.br/mirrors/cran/`

Estratégia 1: Exportando dados do BD

Exemplo 1 de comando de exportação de dados no PostgreSQL

- No `psql` (linha de comando no Linux), usar o comando `\copy`:

```
\copy Produto to 'produto.csv'
                (FORMAT csv, DELIMITER ';', HEADER true,
                 FORCE_QUOTE (fabricante));
```

O comando copia o conteúdo da tabela `Produto` em um arquivo texto (CSV), chamado "produto.csv", onde cada linha do arquivo corresponde a uma tupla da tabela e os valores dos atributos em cada linha aparecem separados pelo caracter delimitador ponto-e-vírgula (';') e o valor do atributo fabricante (que é uma string) fica entre aspas

Estratégia 1: Exportando dados do BD

Exemplo 2 de comando de exportação de dados no PostgreSQL

- No `psql` (linha de comando no Linux), usar o comando `\copy`:

```
\copy (SElECT * FROM PC WHERE ram = 128)
          TO 'pc.csv'
          (FORMAT csv, DELIMITER ';', HEADER true);
```

  No exemplo acima, o comando é usado para gravar o resultado de uma consulta SQL em um arquivo CSV chamado "pc.csv"

Para ver outros parâmetros de configuração do comando `\copy`, acesse:
`http://www.postgresql.org/docs/current/sql-copy.html`

Estratégia 1: Exportando dados do BD

Exemplo 2 de comando de exportação de dados no PostgreSQL

- No `psql` (linha de comando no Linux), usar o comando `\copy`:

```
\copy (SElECT * FROM PC WHERE ram = 128)
          TO 'pc.csv'
          (FORMAT csv, DELIMITER ';', HEADER true);
```

O conteúdo do arquivo `'pc.csv'` gerado é:

```
modelo;velocidade;ram;hd;cd;preco
1002;1500;128;60;2x;2499.00
1003;866;128;20;8x;1999.00
1005;1000;128;20;2x;1499.00
1007;1400;128;80;2x;2299.00
1009;1200;128;80;6x;1699.00
1011;1100;128;60;6x;1299.00
```

Estratégia 1: Exportando dados do BD

Exemplos de comando de exportação de dados no PostgreSQL

No `PhpPgAdmin`, é possível gravar o resultado de uma consulta SQL num arquivo CSV clicando em "Download" no final da listagem

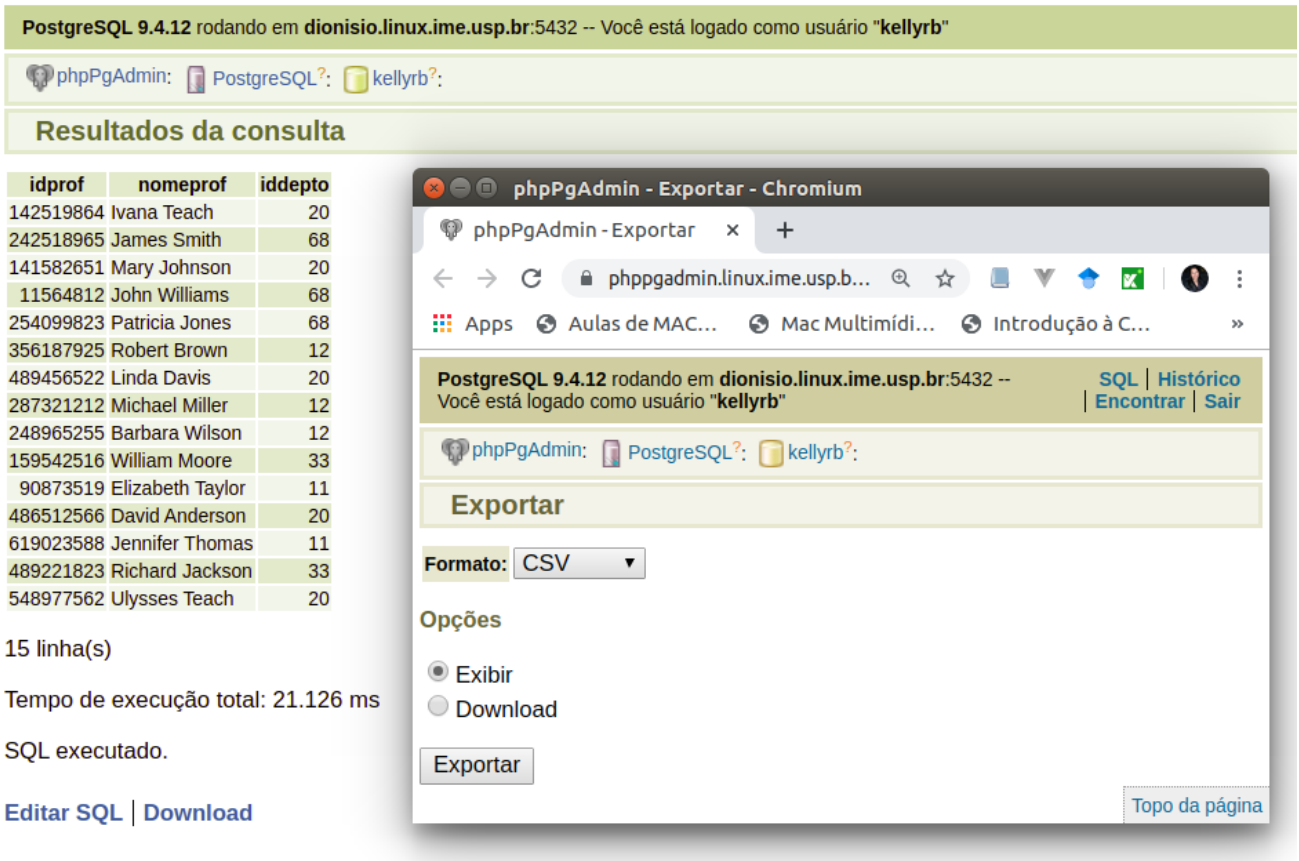

Estratégia 1: Exportando dados do BD

Exemplos de comando de exportação de dados no PostgreSQL

No `PgAdmin`, na janela `Query Tool` é possível gravar o resultado de uma consulta SQL num arquivo CSV, no menu "File » Export..."

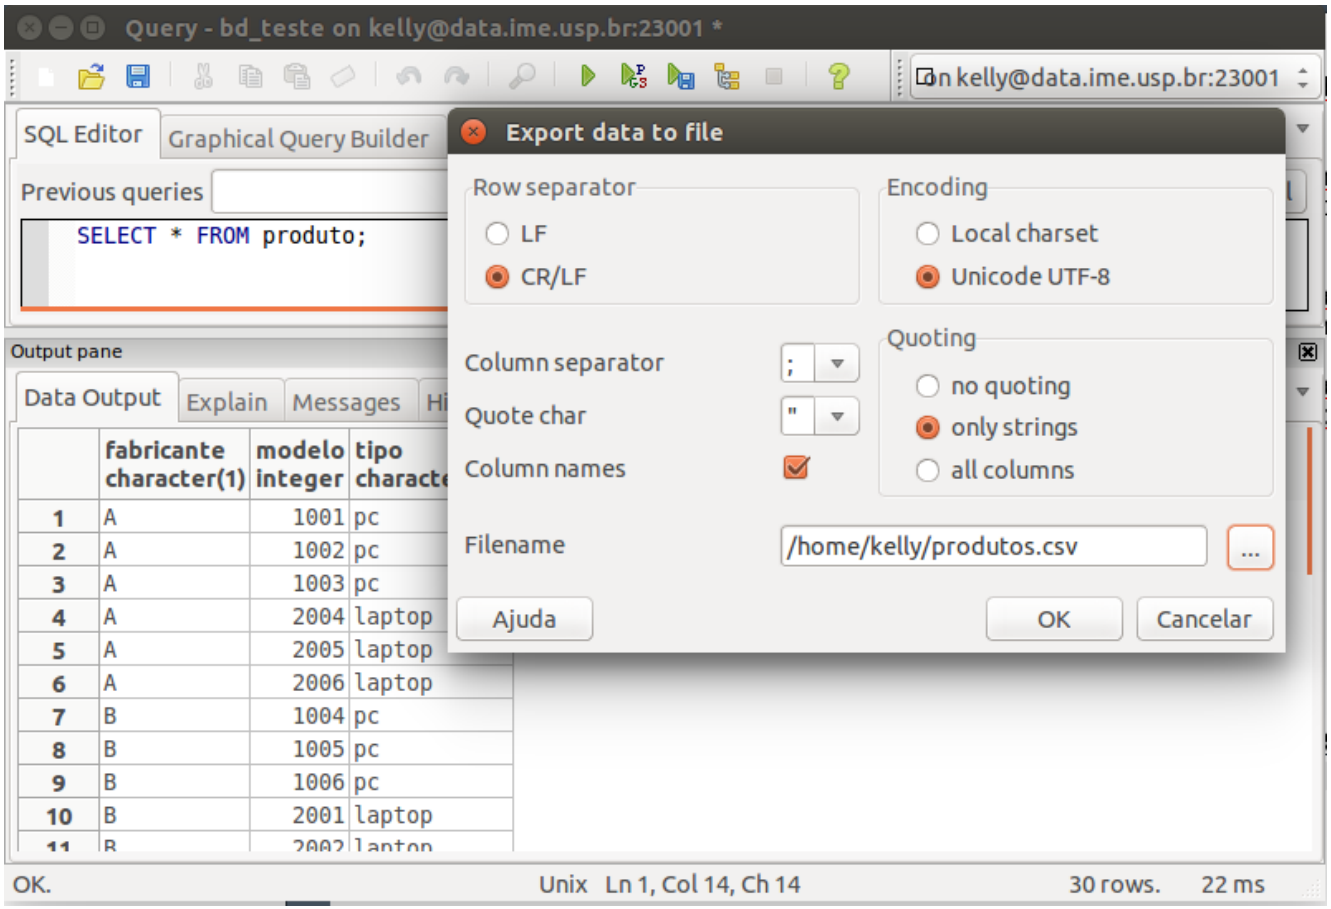

Estratégia 1: Importando arquivos no R

Exemplo de comando de importação de arquivos CSV no R

- No prompt do `R` (linha de comando no Linux), usar a função `read.csv()`:

```
dados <- read.csv("pc.csv", sep=";")
```

O comando acima lerá o conteúdo do arquivo `'pc.csv'` e o armazenará em um objeto do tipo *data frame()* do R.

Estratégia 2: Acessando o BD a partir do software estatístico

- O software estatístico pode estar instalado em uma máquina diferente da do SGBD
- A conexão com um BD hospedado em um SGBD é feita por meio de funcionalidades especiais providas pelo software estatístico
- No R, o pacote **DBI – Database Interface** é quem provê a interface de acesso a BDs
  - A interface DBI permite que diferentes tipos de SGBDs sejam acessados a partir do R de **modo uniforme**

Estratégia 2: Acessando o BD a partir do software estatístico

A interface DBI do R é composta por três elementos principais:

- o *driver* – que provê a comunicação entre uma sessão do R e um tipo particular de SGBD (como o PostgreSQL, por exemplo)
- a *conexão* – que pode ser vista como o "canal" de comunicação com o SGBD; é quem transmite as consultas e outros comandos ao SGBD
- o *resultado* – que "rastreia" o status de uma consulta, como o número de linhas que foram recuperadas e se a consulta foi ou não completada

Estratégia 2: Acessando um BD a partir do R

Para criar um *data frame* no R com dados recuperados de um BD, há 4 passos básicos:

1. Instanciar um *driver*
2. A partir do *driver* instanciado, criar uma conexão com o BD
3. Submeter uma consulta ao BD por meio da conexão criada
4. Manipular os resultados obtidos da execução da consulta

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Instalação da DBI para PostgreSQL no R

- Para que possamos instanciar um *driver* para o PostgreSQL, precisamos primeiro instalar no R a implementação da DBI para PostgreSQL – a *RPostgres*
- No prompt do R, digite:

```
> install.packages("RPostgres");
```

- Após a instalação da RPostgres, você estará apto a acessar um BD hospedado num SGBD PostgreSQL a partir do R
- Para informações sobre a RPostgres, acesse: `https://cran.r-project.org/web/packages/RPostgres/index.html`

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Instanciando ("carregando") um driver PostgreSQL

- No prompt do R, primeiro indique que o pacote RPostgres será usado por meio da função `library()`:

```
> library(RPostgres)
```

- Depois, crie uma instância do *driver* do PostgreSQL por meio da função `dbDriver()` (no exemplo, a instância foi chamada de `drv`):

```
> drv <- dbDriver("Postgres")
```

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Criando uma conexão com um BD PostgreSQL

- No prompt do R, use a função `dbConnect()` para criar um objeto de conexão (no exemplo, a seguir, o nome atribuído a esse objeto é `con`):

```
> con <- dbConnect(drv, host="postgresql.linux.ime.usp.br",
                   port="5432", dbname="login_rede",
                   user="login_rede", password="senha")
```

- São parâmetros para a função `dbConnect` o *driver* para o SGBD que hospeda o BD ao qual se deseja conectar, mais as informações para a conexão com o banco

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Criando uma conexão com um BD PostgreSQL

- Podemos criar dentro de uma mesma sessão do R várias conexões (para um mesmo BD ou para BDs diferentes no mesmo servidor – quando o SGBD oferecer suporte para isso – ou BDs em servidores diferentes)
- Uma conexão fica aberta até que o usuário a encerre explicitamente ou até que a sessão R na qual ela foi criada seja encerrada

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Criando uma conexão com um BD PostgreSQL

- Para pedir para o usuário digitar a senha para a conexão com o BD (em lugar de deixá-la "desprotegida" no comando dbConnect, é possível usar a função `getPass()` do pacote `getPass`:

```
> install.packages("getPass")
> con <- dbConnect(drv, host="postgresql.linux.ime.usp.br",
                   port="5432", dbname="login_rede",
                   user="login_rede",
                   password=getPass::getPass("Senha: "))
```

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Submetendo consultas a um BD PostgreSQL

- Depois que uma conexão é aberta, podemos submeter consultas ao BD
- Algumas consultas são submetidas de forma explícita pelo usuário da sessão R
- Outras consultas são submetidas implicitamente por funções do R. Exemplos:
  - `dbListTables(con)` – devolve a lista dos nomes de tabelas encontrados na conexão `con`
  - `dbExistsTable(con,"NomeTabela")` – verifica se a tabela de nome "NomeTabela" existe na conexão `con` (o resultado é um valor booleano)
  - `dbListFields(con,"NomeTabela")` – devolve a lista dos nomes dos atributos da tabela "NomeTabela" na conexão `con`

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Submetendo consultas a um BD PostgreSQL

- Para recuperar todas as tuplas de uma tabela do BD e armazená-las em um objeto do tipo *data frame*, podemos usar a função `dbReadTable`, como mostrado a seguir:

```
> todosProdutos <- dbReadTable(con, "produto",
                               row.names = "modelo")
```

- O comando acima importa a tabela `Produto` do BD no R como um data frame chamado `todosProdutos`, usando o atributo `modelo` como `row.names` para o *data frame* (ou seja, `modelo` fará o papel de chave primária)

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Submetendo consultas a um BD PostgreSQL

- Podemos usar a função data `dbGetQuery` para submeter consultas SQL diretamente ao BD, como mostrado a seguir:

```
> todosPCs <- dbGetQuery(con,
                "SELECT modelo, preco, velocidade FROM pc;")
```

- O resultado da consulta do exemplo acima é importado no R como um *data frame* chamado `todosPCs`

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Submetendo consultas a um BD PostgreSQL

- Em algumas consultas, o conjunto de tuplas devolvido como resposta pode ser bem grande
- Para evitar que todas as tuplas sejam transferidas do BD para o R de uma só vez, é possível solicitar que as tuplas sejam trazidas em "lotes" (que podem ser analisados separadamente)
- A função `dbSendQuery` nos permite submeter uma consulta SQL ao BD, mas sem trazer a resposta da consulta em seguida. A resposta é recuperada por meio da função `dbFetch`. Exemplo:

```
> rs <- dbSendQuery(con, "SELECT * FROM produto;")
> lote1Produtos <- dbFetch(rs, n = 5)
> lote2Produtos <- dbFetch(rs, n = 10)
```

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Submetendo consultas a um BD PostgreSQL

- A função `dbSendQuery` devolve um objeto do tipo *result set*, que no exemplo do slide anterior foi atribuído à variável `rs`
- A partir de um objeto *result set*, podemos obter todas as informações sobre o resultado da consulta da qual ele resultou:
  - consulta SQL de origem
  - nomes dos atributos na resposta
  - número de tuplas na resposta
  - quantas tuplas já foram recuperadas do resultado ("dbFetched")
- A função `dbGetInfo(rs)` mostra as informações do *result set* `rs`

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Submetendo consultas a um BD PostgreSQL

- A função `dbFetch` recupera a partir de um objeto *result set* um novo lote de tuplas ainda não recuperadas do resultado e o devolve como um objeto do tipo *data frame*
- No exemplo abaixo, o primeiro `dbFetch` devolve as primeiras 5 tuplas da resposta ao comando SQL submetido ao BD, enquanto o segundo `dbFetch` devolve as 10 tuplas seguintes:

```
> rs <- dbSendQuery(con, "SELECT * FROM Produto;")
> lote1Produtos <- dbFetch(rs, n = 5)
> lote2Produtos <- dbFetch(rs, n = 10)
```

- A execução de um `dbFetch` com $n = -1$ faz com que todas as tuplas ainda não recuperadas no *result set* sejam recuperadas e carregadas no *data frame*

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Outras funções relacionadas a um objeto result set

- A função `dbGetStatement(rs)` devolve a consulta SQL associada ao *result set* `rs`
- A função `dbColumnInfo(rs)` devolve informações sobre os atributos que aparecem no conjunto resposta da consulta associada ao *result set* `rs`
- A função `dbGetRowCount(rs)` devolve o número total de tuplas no conjunto resposta da consulta associada ao *result set* `rs`

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Outras funções relacionadas a um objeto result set

- A função `dbGetRowsAffected(rs)` devolve o número de tuplas afetadas pela consulta associada ao *result set* `rs` (-1 indica que nenhuma tupla foi afetada)
  (Só pode ser diferente de -1 quando a consulta é na verdade um comando de modificação do BD)
- A função `dbHasCompleted(rs)` devolve um valor booleano que indica se todas as tuplas do conjunto resposta da consulta associada ao *result set* `rs` já foram recuperadas ("fetched")
- A função `dbClearResult(rs)` "encerra" o *result set* `rs` sem carregar nenhuma de suas tuplas ainda não recuperadas
  (Obs: depois da execução dessa função, nenhuma operação pode ser realizada sobre o *result set*)

Outras funções do RPostgres

- A função `dbRemoveTable(con,"NomeTabela")` remove a tabela de nome "NomeTabela" se ela existir na conexão `con`. A função devolve um valor booleano indicando se a remoção foi feita com sucesso
- A função `dbWriteTable(con,"NovaTabela",dados)` grava as tuplas contidas no *data frame* `dados` em uma nova tabela chamada "NovaTabela" na conexão `con`. A função devolve um valor booleano indicando se a gravação foi feita com sucesso
- As funções `dbGetInfo(objeto)` e `summary(objeto)` mostram informações sobre um objeto de banco de dados (um *driver*, uma conexão ou um *result set*). Exemplos:

```
> dbGetInfo(con)
> summary(con)
```

Outras funções do RPostgres

Ao final de um acesso a um BD, é sempre bom liberar os objetos usados no acesso:

- Para encerrar uma conexão `con`:

  ```
  > dbDisconnect(con)
  ```

- Para liberar os recursos usados por um *driver* `dvr`:

  ```
  > dbUnloadDriver(drv)
  ```

Estratégia 2: Acessando um BD PostgreSQL a partir do R

Exemplo

No Paca, junto com estes slides, há um *script* R com um exemplo completo de acesso a um BD PostgreSQL.

dbplyr – uma outra forma de acessar BDs no R

- O **dplyr** é uma gramática para manipulação de dados, composta por um conjunto de "verbos" que representam funções de manipulação de dados mais comuns, implementada como um pacote do R no **tidyverse**
- O **tidyverse** é um pacote de pacotes para ciência de dados projetados segundo uma mesma "filosofia"
- Os códigos em dplyr são bastante legíveis, por usar verbos e encadeamento de funções
- As funções do dplyr podem ser utilizadas para manipular tabelas de BDs, sem a necessidade de importação para o R
  - dplyr abstrai a forma como os dados estão armazenados; um mesmo código em R pode ser usado para manipular tanto dados *data frames* locais quando tabelas de BD remotas

dplyr – funções/verbos mais usados

- `mutate()` – cria novas variáveis que são funções de variáveis existentes
- `select()` – seleciona variáveis com base em seus nomes
- `filter()` – seleciona linhas com base em seus valores
- `summarise()` – agrega múltiplos valores em um só, sumariando-os
- `arrange()` – muda a ordenação das linhas

Todas as funções acima podem ser usadas combinadas à operação `group_by()`, que agrupa linhas com base em seus valores.

dbplyr

Correspondência de comandos

Verbo no dplyr	**Equivalente no SQL**
select	select
mutate	select + expressões
filter	select-from-**where**
summarise	função de agregração
group_by	group by
arrange	order by

dplyr – Instalação

- Para instalar o **tidyverse** completo, digite no prompt do R:
  `> install.packages("tidyverse")`
- Para instalar somente o **dplyr**:
  `> install.packages("dplyr")`
- Para usar o **dplyr com BDs**, é preciso instalar também o pacote **dbplyr**:
  `> install.packages("dbplyr")`
- Para informações sobre esses pacotes, acesse:
  `https://www.tidyverse.org/`
  `https://dplyr.tidyverse.org/`
  `https://dbplyr.tidyverse.org/`

dbplyr (dplyr para manipulação de BDs)

- A principal diferença entre consultas feitas sobre *data frames* comuns e consultas feitas sobre BDs remotos é que, nestas últimas, o código R é traduzido em SQL e executado no BD.
- O dbplyr adota uma estratégia "preguiçosa" (= *lazy load*) ao lidar com os dados de BDs:
  - Ele só traz os dados de um BD para o R quando isso é solicitado pelo usuário explicitamente.
  - Ele adia tanto quanto for possível a execução do trabalho: ele "coleciona" todas as operações que precisam ser feitas e então as envia para o BD em um só passo.
- dplyr+dbplyr não cobrem todos os recursos da linguagem SQL, seu foco é nos comandos SELECT
- Para informações sobre o dbplyr, acesse: `https://dbplyr.tidyverse.org/`

dplyr – Exemplos

```
## Cria uma tabela no BD com dados para teste, copiados do
## pacote nycflights13, que contém:
## s"Airline on-time data for all flights departing NYC in 2013.
## Also includes useful 'metadata' on airlines, airports,
## weather, and planes."

copy_to(con, nycflights13::flights, "flights",
  temporary = FALSE,
  indexes = list(
    c("year", "month", "day"),
    "carrier",
    "tailnum",
    "dest"
  )
)
```

dplyr – Exemplo 1

```
## Cria uma referência para a tabela "flights"
flights_db <- tbl(con, "flights")

## Seleciona as colunas de data, destino, atraso na partida e
## atraso na chegada dos voos
delays <- select(flights_db, year:day, dest, dep_delay, arr_delay)

## Seleciona as linhas dos voos que tiveram um atraso > 240 minutos
## na partida (dep_delay) maior que 240
big_delays <- filter(delays, dep_delay > 240)

## Agrupa os grandes atrasos por destino
delays_by_dest <- group_by(big_delays, dest)

## Obtém o atraso médio na partida por destino
mean_delays_by_dest <- summarise(delays_by_dest, delay = mean(dep_delay))
print(mean_delays_by_dest)
```

dplyr – Exemplo 1 (versão *pipeline*)

```
## EXEMPLO 1 -- Versão Pipeline
flights_db <- tbl(con, "flights")

mean_delays_by_dest <- flights_db %>%
   select(year:day, dest, dep_delay, arr_delay) %>%
   filter(dep_delay > 240) %>%
   group_by(dest) %>%
   summarise(delay = mean(dep_delay))

print(mean_delays_by_dest)
```

dplyr – Exemplo 2

Atraso médio na chegada por aeronave (identificada por `tailnum`), para as aeronaves que fizeram pelo menos 100 voos

```
## O comando abaixo não "toca" nos dados,
## ele apenas prepara a consulta
tailnum_delay_db <- flights_db %>%
  group_by(tailnum) %>%
  summarise(
    delay = mean(arr_delay),
    n = n()
  ) %>%
  arrange(desc(delay)) %>%
  filter(n > 100)

## Os dados só são trazidos do BD para o R no comando
## abaixo, quando pede-se que os resultados sejam exibidos
print(tailnum_delay_db)
```

dplyr – Exemplo 2

É possível ver o SQL gerado pela dbplyr, com a função `show_query()`

```
tailnum_delay_db %>% show_query()
```

Resultado:

```
<SQL>
SELECT *
FROM (SELECT *
FROM (SELECT "tailnum", AVG("arr_delay") AS "delay",
                        COUNT(*) AS "n"
FROM "flights"
GROUP BY "tailnum")
ORDER BY "delay" DESC)
WHERE ("n" > 100.0)
```

dplyr – Exemplo 3

Chegadas atrasadas × chegadas no tempo certo (por companhia aérea)

```
## Cria uma nova variável (dep_type) para classificar se um
## voo está no horário certo ou atrasado e plota um gráfico
## de barras das frequências dela por companhia aerea
library(ggplot2)
flights_db %>%
mutate(dep_type = ifelse(dep_delay < 5, "on time", "delayed")) %>%
ggplot(aes(x = carrier, fill = dep_type,
  main = "Frequency of Delayed vs On Time Arrivals by Carrier")) + geom_bar()
```

dplyr – Exemplo 3

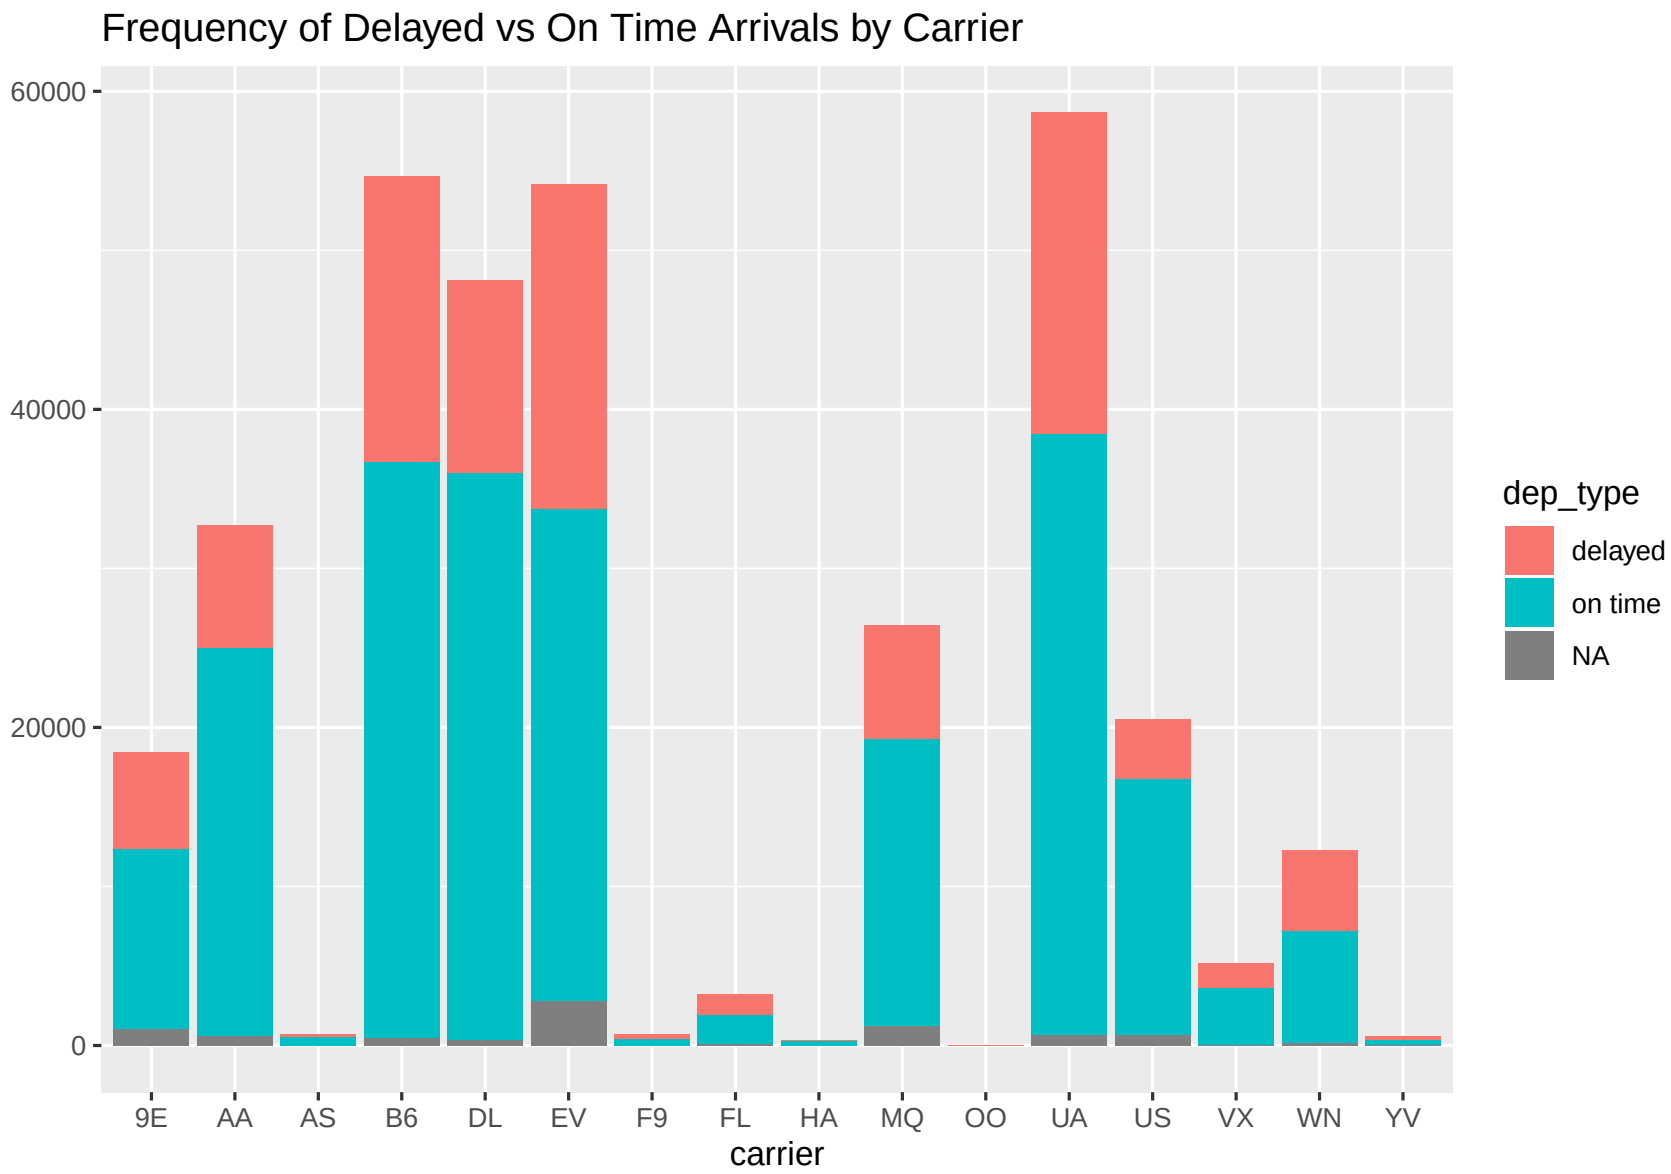

dbplyr

Exemplo

No Paca, junto com estes slides, há um *script* R com todos os exemplos relacionados ao acesso a BDs no PostgreSQL por meio do dbplyr.

Referências Bibliográficas

- Site do RPostgres:
  `https://cran.r-project.org/web/packages/RPostgres/`
- Documentação completa do pacote DBI:
  `https://cran.r-project.org/web/packages/DBI/`
- Página *Databases using R (from R Stdudio)*
  `https://db.rstudio.com/getting-started/database-queries`
  `https://db.rstudio.com/dplyr/`
- Wiki-R: Manipulando dados com dplyr e tidyr
  `https://www.ufrgs.br/wiki-r/index.php?title=Manipulando_Dados_com_dplyr_e_tidyr`
- Cheat Sheet Data Transformation with dplyr
  `https://github.com/rstudio/cheatsheets/raw/master/data-transformation.pdf`