SQLite: inserindo dados + dbplyr

Benilton Carvalho & Guilherme Ludwig

Inserindo dados

- Na última aula, discutimos sobre consultas e operações de organização dos dados.
- Um segundo aspecto importante de manipulação de bancos de dados é a inserção de novos dados. No caso de SQLite, consideraremos:
  - Inserção de novas tabelas.
  - Inserção de linhas em uma tabela.
  - Criação de um banco de dados.

```
library(RSQLite)
library(tidyverse)
if(!"discoCopy.db" %in% list.files("../dados/")){
  file.copy("../dados/disco.db", "../dados/discoCopy.db")
} # Modificaremos esse arquivo
```

```
## [1] TRUE
```

```
db <- dbConnect(SQLite(), "../dados/discoCopy.db")
```

Banco de Dados de Exemplo: `discoCopy.df`

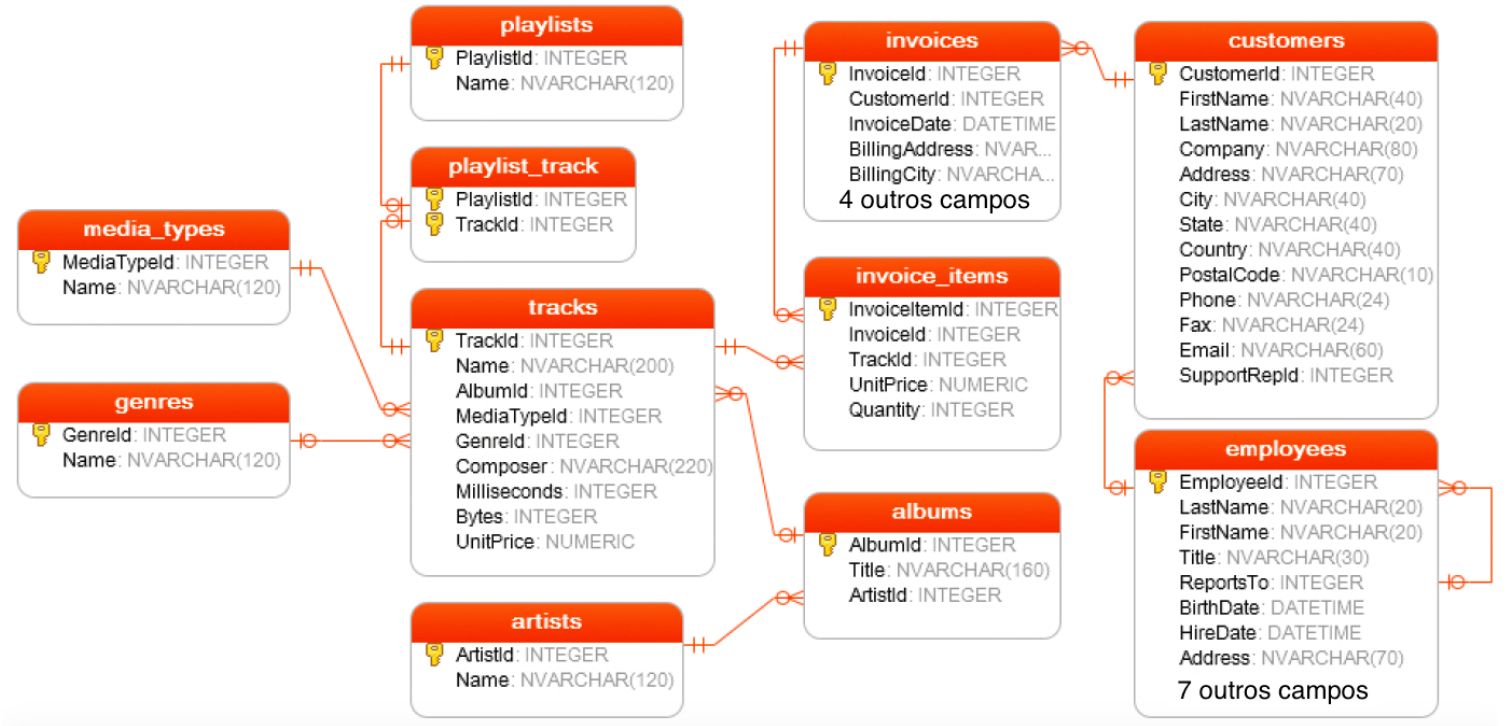

Inserindo uma tabela

Neste momento, existem as seguintes tabelas em `disco.db`:

```
dbListTables(db)
```

```
##  [1] "albums"          "artists"         "customers"
##  [4] "employees"       "genres"          "invoice_items"
##  [7] "invoices"        "media_types"     "playlist_track"
## [10] "playlists"       "sqlite_sequence" "sqlite_stat1"
## [13] "tracks"
```

A sintaxe para criar uma tabela vazia, no SQLite, é através do comando `CREATE TABLE nome (col1 tipo, col2 tipo2, ...)`

```
dbExecute(db, "CREATE TABLE instruments
               (AlbumId INTEGER,
                TrackId INTEGER,
                ElectricGuitar INTEGER,
                Singer INTEGER,
                Trumpet INTEGER)")
```

```
## [1] 0
```

Removendo uma tabela

```
dbListFields(db, 'instruments')
```

```
## [1] "AlbumId"        "TrackId"        "ElectricGuitar" "Singer"
## [5] "Trumpet"
```

Você pode remover uma tabela usando o comando `DROP TABLE nome`:

```
dbExecute(db, "DROP TABLE instruments")
```

```
## [1] 0
```

```
dbListTables(db)
```

```
##  [1] "albums"          "artists"         "customers"
##  [4] "employees"       "genres"          "invoice_items"
##  [7] "invoices"        "media_types"     "playlist_track"
## [10] "playlists"       "sqlite_sequence" "sqlite_stat1"
## [13] "tracks"
```

Em geral, `DROP TABLE` é perigoso. Se você abrir seu servidor, pode ficar sujeito aos chamados "injection attacks"!

Um ligeiro parêntese: Best practices

Esse exemplo está na documentação em https://db.rstudio.com: se você tem um aplicativo (por exemplo, em Shiny) que colhe inputs do usuário em `aname` e diz quais álbums deste artista estão listados:

```
aname = "Gilberto Gil"
sql = paste0("SELECT ArtistId FROM artists ",
             "WHERE Name = '", aname, "'")
aId = dbGetQuery(db, sql)
sql = paste('SELECT Title FROM albums',
            'WHERE ArtistId =', aId)
dbGetQuery(db, sql)
```

```
##                                    Title
## 1                 As Canções de Eu Tu Eles
## 2             Quanta Gente Veio Ver (Live)
## 3 Quanta Gente Veio ver--Bônus De Carnaval
```

Um usuário malicioso pode inserir algo como

```
aname <- "Gilberto Gil'; DROP TABLE 'albums"
```

E destruir seu banco de dados!

Best practices

O `RSQLite` oferece funções que executam queries com segurança.

```
sql = paste("SELECT ArtistId FROM artists",
            "WHERE Name = ?")
query <- dbSendQuery(db, sql)
dbBind(query, list("Gilberto Gil"))
aId <- dbFetch(query)
dbClearResult(query)
# Segundo passo interno, não deve causar problema
sql = paste('SELECT Title FROM albums',
            'WHERE ArtistId =', aId)
dbGetQuery(db, sql)
```

```
##                                       Title
## 1                  As Canções de Eu Tu Eles
## 2              Quanta Gente Veio Ver (Live)
## 3 Quanta Gente Veio ver--Bônus De Carnaval
```

Incluindo linhas numa tabela

Voltando ao caso de instrumentos, suponha que eu tenha criado a tabela "instruments", e quero completá-la com alguma informação. Uma maneira de fazê-lo é usando o comando `INSERT INTO tabela VALUES (...)`

```
dbListFields(db, 'instruments')
```

```
## [1] "AlbumId"        "TrackId"        "ElectricGuitar" "Singer"
## [5] "Trumpet"
```

```
# Eu Tu Eles: AlbumId 85,
sql = paste('SELECT TrackId, Name FROM tracks',
            'WHERE AlbumId = 85')
dbGetQuery(db, sql) %>% head
```

```
##   TrackId                Name
## 1    1073 Óia Eu Aqui De Novo
## 2    1074      Baião Da Penha
## 3    1075 Esperando Na Janela
## 4    1076            Juazeiro
## 5    1077 Último Pau-De-Arara
## 6    1078          Asa Branca
```

Incluindo linhas numa tabela

```
dbExecute(db, "INSERT INTO instruments
               VALUES ('85', '1075', 0, 1, 0),
                      ('85', '1078', 0, 1, 0); ")
```

```
## [1] 2
```

```
dbGetQuery(db, "SELECT * FROM instruments")
```

```
##   AlbumId TrackId ElectricGuitar Singer Trumpet
## 1      85    1075              0      1       0
## 2      85    1078              0      1       0
```

Inserindo uma tabela diretamente

O `data.frame` `mtcars` é um exemplo famoso de data frame no R. Eu vou incluí-lo no nosso banco de dados:

```
dbWriteTable(db, "mtcars", mtcars)
dbListTables(db)
```

```
##  [1] "albums"          "artists"         "customers"
##  [4] "employees"       "genres"          "instruments"
##  [7] "invoice_items"   "invoices"        "media_types"
## [10] "mtcars"          "playlist_track"  "playlists"
## [13] "sqlite_sequence" "sqlite_stat1"    "tracks"
```

Note que o atributo `rownames` (marcas dos carros) foi perdido! Mas há um parâmetro `row.names` em `dbWriteTable`.

```
dbGetQuery(db, "SELECT * FROM mtcars") %>% head(3)
```

```
##    mpg cyl disp  hp drat    wt  qsec vs am gear carb
## 1 21.0   6  160 110 3.90 2.620 16.46  0  1    4    4
## 2 21.0   6  160 110 3.90 2.875 17.02  0  1    4    4
## 3 22.8   4  108  93 3.85 2.320 18.61  1  1    4    1
```

Inserindo uma tabela diretamente: append

O parâmetro append concatena uma tabela nova a dados existentes. Por exemplo,

```
theAvgCar <- mtcars %>%
  summarise_all(function(x) round(mean(x), 2))
theAvgCar
```

```
##     mpg  cyl   disp     hp drat   wt  qsec   vs   am gear carb
## 1 20.09 6.19 230.72 146.69  3.6 3.22 17.85 0.44 0.41 3.69 2.81
```

```
dbWriteTable(db, "mtcars", theAvgCar, append = TRUE)
dbGetQuery(db, "SELECT * FROM mtcars") %>% tail(3)
```

```
##      mpg  cyl   disp     hp drat   wt  qsec   vs   am gear carb
## 31 15.00 8.00 301.00 335.00 3.54 3.57 14.60 0.00 1.00 5.00 8.00
## 32 21.40 4.00 121.00 109.00 4.11 2.78 18.60 1.00 1.00 4.00 2.00
## 33 20.09 6.19 230.72 146.69 3.60 3.22 17.85 0.44 0.41 3.69 2.81
```

Inserindo uma tabela diretamente: overwrite

O parâmetro `overwrite` sobrescreve a tabela (use com cuidado!).

```
dbWriteTable(db, "mtcars", mtcars, overwrite = TRUE)
dbGetQuery(db, "SELECT * FROM mtcars") %>% tail(3)
```

```
##     mpg cyl disp  hp drat   wt qsec vs am gear carb
## 30 19.7   6  145 175 3.62 2.77 15.5  0  1    5    6
## 31 15.0   8  301 335 3.54 3.57 14.6  0  1    5    8
## 32 21.4   4  121 109 4.11 2.78 18.6  1  1    4    2
```

Lendo chunks

Em certo sentido, `dbGetQuery()` é um atalho para `dbSendQuery()` seguido de `dbFetch()` (e `dbClearResult()`). Uma vantagem de usar a sintaxe mais longa é que podemos ler dados em chunks:

```
res <- dbSendQuery(db, "SELECT * FROM mtcars WHERE cyl = 4")
while(!dbHasCompleted(res)){
  chunk <- dbFetch(res, n = 5)
  print(nrow(chunk))
}
```

```
## [1] 5
## [1] 5
## [1] 1
```

```
dbClearResult(res)
```

O exemplo acima só guarda o último chunk, e não é muito eficiente... mas pode ser suficiente se você estiver guardando os resultados com `dbWriteTable` e `append = TRUE`.

Fechando conexões

É importante encerrar suas conexões com `dbDisconnect()`. Além disso, vou remover a cópia que fiz da database `disco.db`.

```
dbDisconnect(db)
if("discoCopy.db" %in% list.files("../dados/")){
  file.remove("../dados/discoCopy.db")
}
```

```
## [1] TRUE
```

Criando sua base de dados

```
airports <- read_csv("../dados/airports.csv", col_types = "ccccdd")
airlines <- read_csv("../dados/airlines.csv", col_types = "cc")
air <- dbConnect(SQLite(), dbname="../dados/air.db")
dbWriteTable(air, name = "airports", airports)
dbWriteTable(air, name = "airlines", airlines)
dbListTables(air)
```

```
## [1] "airlines" "airports"
```

Criando sua base de dados

Você também pode usar a função `copy_to(conn, df)` do `dplyr`! A sintaxe é parecida.

Vou agora destruir a conexão e a tabela.

```
dbDisconnect(air)
if("air.db" %in% list.files("../dados/")){
  file.remove("../dados/air.db")
}
```

```
## [1] TRUE
```

Breve introdução ao dbplyr

O pacote `dbplyr` estende algumas funcionalidades do `dplyr` a dados que estão armazenados em um bancos de dados externo.

```
library(RSQLite)
library(tidyverse)
library(dbplyr)
db <- dbConnect(SQLite(), "../dados/disco.db") # original
tracks <- tbl(db, "tracks") # dplyr
tracks %>% head(3)
```

```
## # Source:   lazy query [?? x 9]
## # Database: sqlite 3.29.0
## #   [/Volumes/Disk2/github/me315-unicamp.github.io/dados/disco.db]
##   TrackId Name  AlbumId MediaTypeId GenreId Composer Milliseconds  Bytes
##     <int> <chr>   <int>       <int>   <int> <chr>           <int>  <int>
## 1       1 For …       1           1       1 Angus Y…       343719 1.12e7
## 2       2 Ball…       2           2       1 <NA>           342562 5.51e6
## 3       3 Fast…       3           2       1 F. Balt…       230619 3.99e6
## # … with 1 more variable: UnitPrice <dbl>
```

Verbos do `dplyr` disponíveis...

```
meanTracks <- tracks %>%
  group_by(AlbumId) %>%
  summarise(AvLen = mean(Milliseconds, na.rm = TRUE),
            AvCost = mean(UnitPrice, na.rm = TRUE))
meanTracks
```

```
## # Source:   lazy query [?? x 3]
## # Database: sqlite 3.29.0
## #   [/Volumes/Disk2/github/me315-unicamp.github.io/dados/disco.db]
##    AlbumId   AvLen AvCost
##      <int>   <dbl>  <dbl>
##  1       1 240042.  0.99
##  2       2 342562   0.99
##  3       3 286029.  0.990
##  4       4 306657.  0.99
##  5       5 294114.  0.99
##  6       6 265456.  0.99
##  7       7 270780.  0.99
##  8       8 207638.  0.99
##  9       9 333926.  0.99
## 10      10 280551.  0.99
## # … with more rows
```

...mas secretamente, são comandos de SQLite!

```
meanTracks %>% show_query()
```

```
## <SQL>
## SELECT `AlbumId`, AVG(`Milliseconds`) AS `AvLen`, AVG(`UnitPrice`) AS `AvC
## FROM `tracks`
## GROUP BY `AlbumId`
```

Consulta, de fato

Repare que o sumário só diz "... with more rows". Quando você decidir o que precisa, pode usar o comando `collect()`.

```
mT <- meanTracks %>% collect()
mT
```

```
## # A tibble: 347 x 3
##    AlbumId   AvLen AvCost
##      <int>   <dbl>  <dbl>
##  1       1 240042.  0.99
##  2       2 342562   0.99
##  3       3 286029.  0.990
##  4       4 306657.  0.99
##  5       5 294114.  0.99
##  6       6 265456.  0.99
##  7       7 270780.  0.99
##  8       8 207638.  0.99
##  9       9 333926.  0.99
## 10      10 280551.  0.99
## # … with 337 more rows
```

```
dbDisconnect(db)
```