05. Manipulace s daty

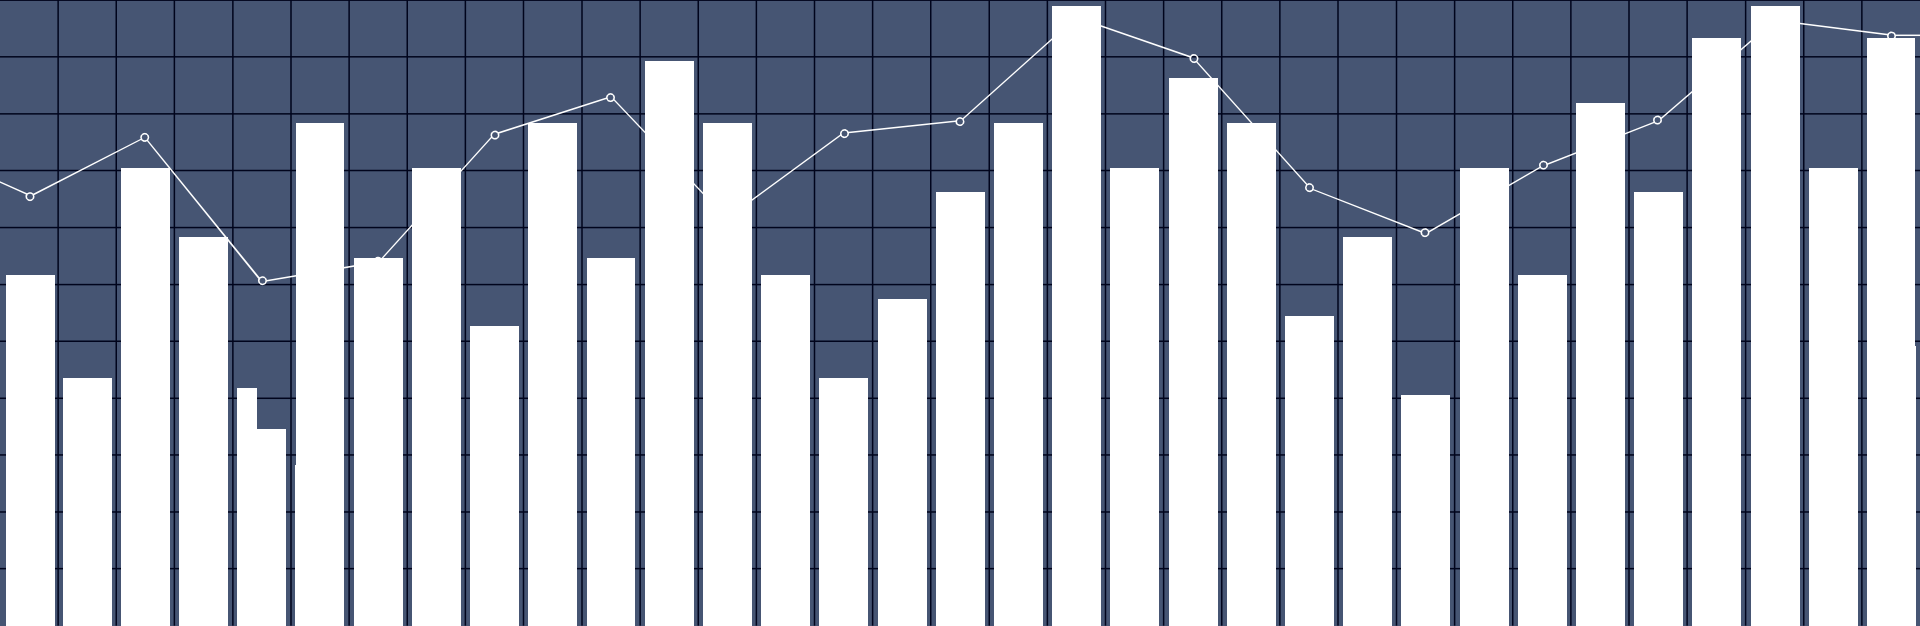

Harmonogram

- 01. tbl
- 02. select, mutate
- 03. filter, arrange
- 04. summarise, %>%
- 05. group_by

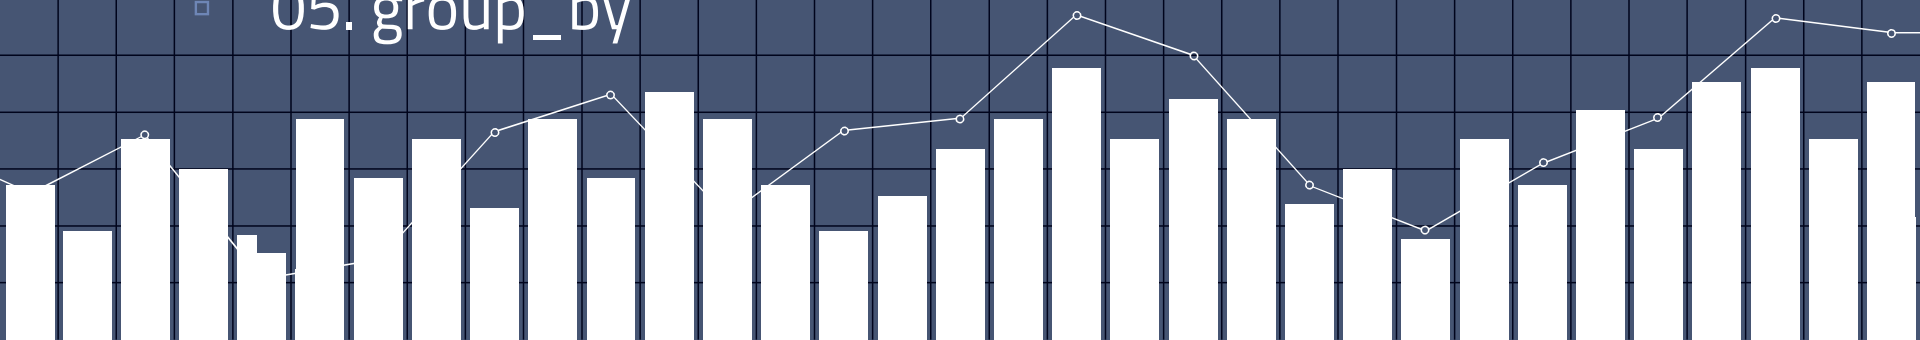

dplyr a tibble

```
# Načtení knihovny
library(dplyr)  # install.packages("dplyr")

# Data
Titanic = read.csv("Train.csv")

# Typ objektu
class(Titanic)

# konverze na tibble
Titanic = as_tibble(Titanic)

# Struktura dat
glimpse(Titanic)
```

```
# Pojmenování proměnných
Port = c("C" = "Cherbourg", "Q" = "Queenstown",
"S" = "Southampton")

Titanic$Embarked =
as.character(Titanic$Embarked)

Titanic$Embarked = Port[Titanic$Embarked]

# Struktura dat
glimpse(Titanic$Embarked)
```

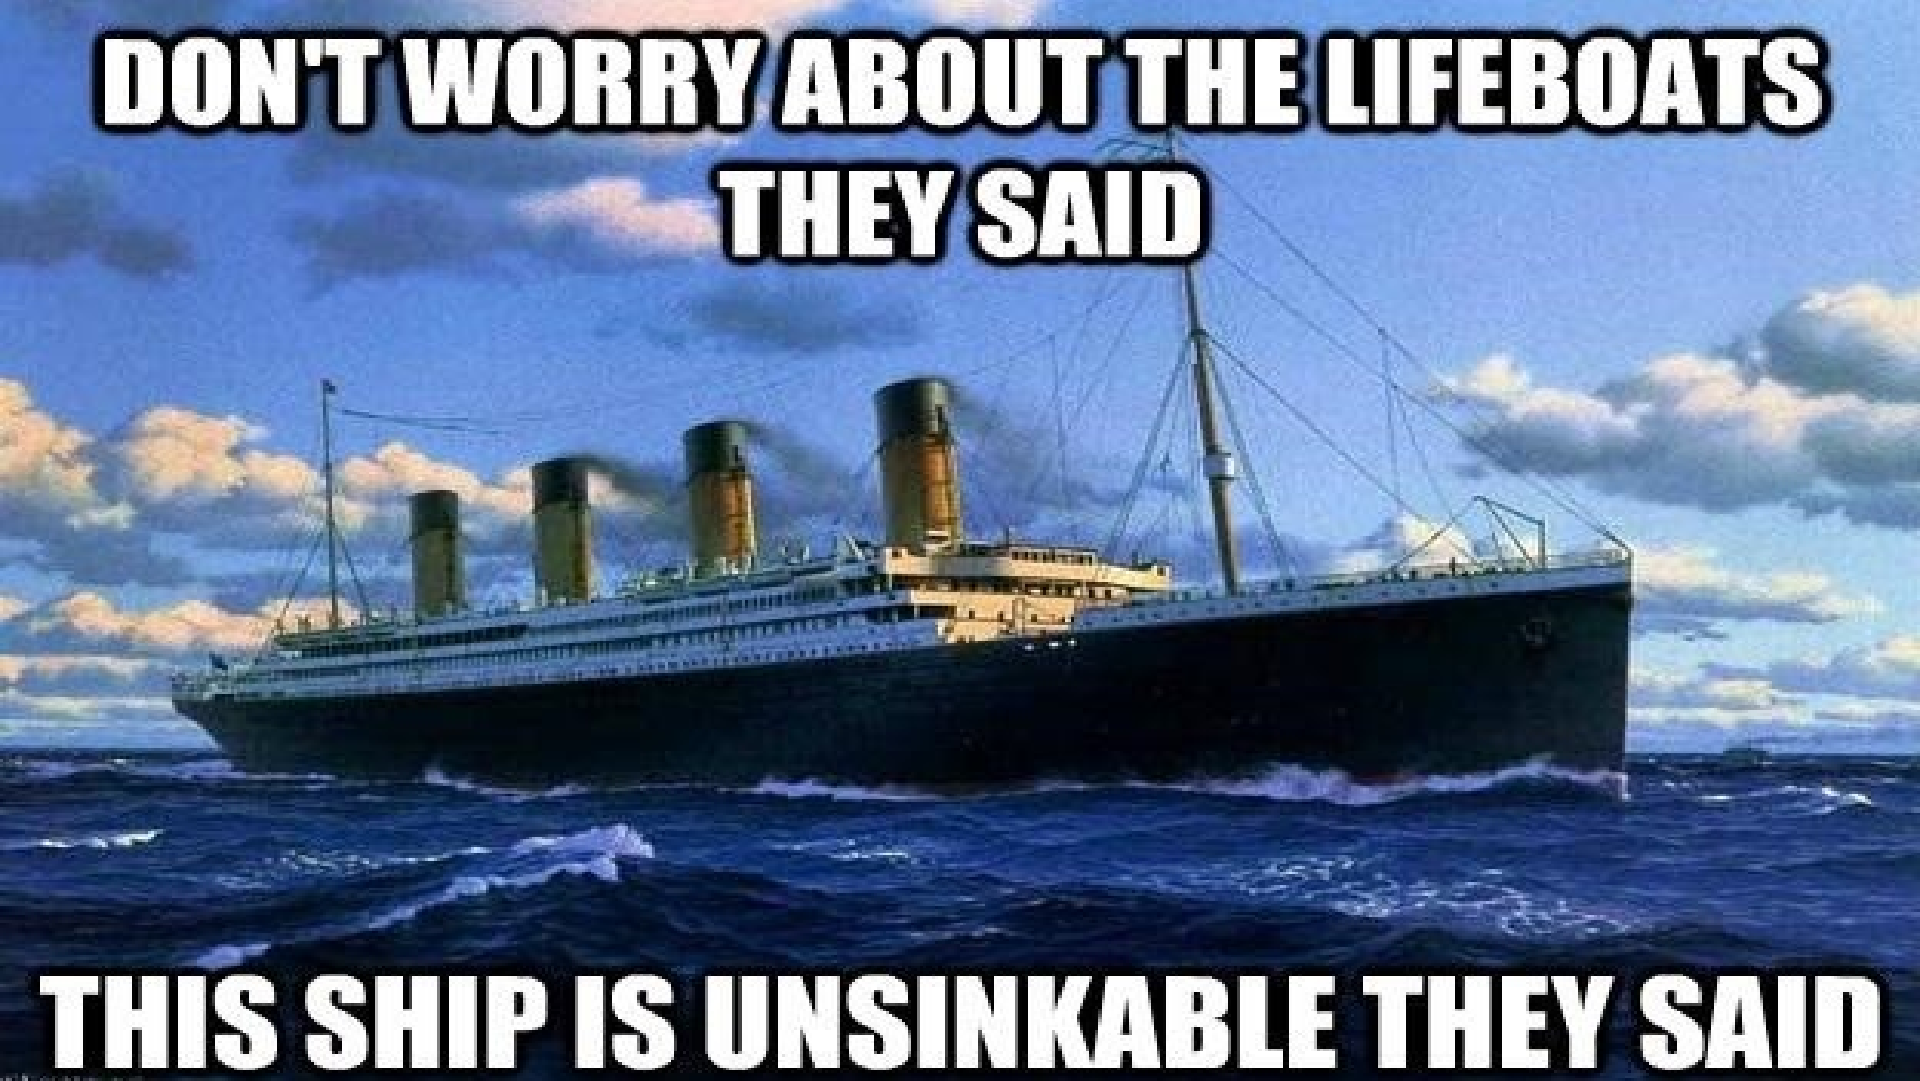
DON'T WORRY ABOUT THE LIFEBOATS
THEY SAID
THIS SHIP IS UNSINKABLE THEY SAID

select

Manipulace s proměnnými

```
# Výběr proměnné výčtem
select(Titanic, Name)

# Výběr více proměnných - pořadím
select(Titanic, PassengerId:Survived, Name:Age)

# Výběr více proměnných – na základě znění
select(Titanic, contains("e"))

# Výběr více proměnných – kombinace postupů
select(Titanic, 1:2, contains("t"))
```

mutate

Manipulace s proměnnými

```
# Tvorba nových proměnných
Titanic_2018 = mutate(Titanic, Age_2018 = (Age + (2018-1912))

# Tvorba nových proměnných – více případů současně
Titanic_02 = mutate(Titanic, Price_Year_Ratio = (Fare / Age), Family = Sibsp + Parch)
```

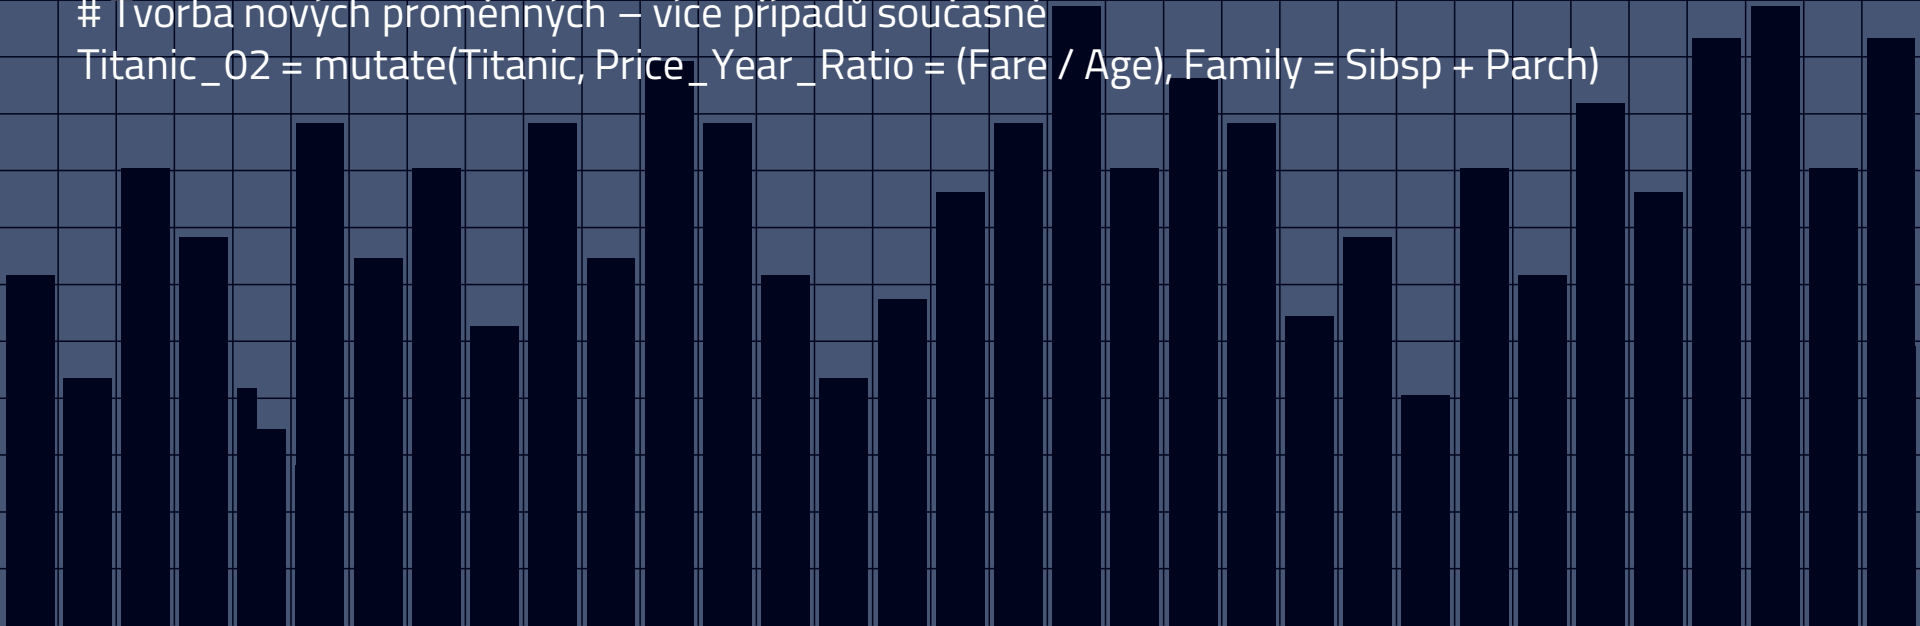


Sorry Sir. Women and children first.
Did you just assume my gender?

filter

Manipulace s pozorováními

```
# Výběr na základě logických operátorů
filter(Titanic, Age < 18)
filter(Titanic, Embarked %in% c("Southampton", "Queenstown")

# Kombinace operátorů
filter(Titanic, Age < 18, Survived == 1)
filter(Titanic, Age < 18, Pclass == 1  |  Pclass ==  2)

# Filtrace na základě textu
library(stringr)
filter(Titanic, str_detect(Name, str_detect(Name, "Rose")
```

arrange

Manipulace s pozorováními

```
# Seřazení přeživších podle věku, bez chybějících hodnot
Survived = filter(Titanic, Survived == 1, !is.na(Age))
arrange(Survived, Age)

# Seřazení přeživších podle věku od nejstarších po nejmladší, bez chybějících hodnot
arrange(Survived, desc(Age))

# Seřazení přeživších podle věku od nejstarších po nejmladší a místa nalodění
arrange(Survived, desc(Age), Embarked)
```

summarize

Agregační funkce

```
# Nejnižší cena za lístek a nejstarší osoba
summarize(Titanic, Fare_Min = min(Fare), Age_Max = max(Age))

# Průměrný věk těch, kdo přežili
summarize(filter(Titanic, Survived == 1), Age_Avg = mean(Age, na.rm = TRUE))

# Průměrná cena palubního lístku a její směrodatná odchylka, median, minimum, maximum
Titanic_03 = filter(Titanic, !is.na(Fare))
summarize(Titanic_03, Mean_Fare = mean(Fare), SD_Fare = sd(Fare), Median_Fare =
median(Fare), Min_Fare = min(Fare), Max_Fare = max(Fare))
```

%>%

Pipe operator

```
# Průměrný věk osob z 3. třídy, které nepřežily
Titanic %>%
        filter(Pclass == 3) %>%
        filter(Survived == 0) %>%
        summarize(Age_Died_Avg = mean(Age, na.rm = TRUE))

# Nejvyšší cena do 1. třídy pro osobu, která se jmenuje William a která přežila
Titanic %>%
        filter(Pclass == 1 ) %>%
        filter(str_detect(Name, "William") %>%
        filter(Survived == 1) %>%
        summarize(Fare_Avg_Will = min(Fare)
```


CECI N'EST PAS UNE %>%.

group_by

Pipe operator

```
# Průměrný věk osob z 3. třídy, které nepřežily
Titanic %>%
        group_by(Sex) %>%
        summarize(Mean_Fare = mean(Fare, na.rm = TRUE), Count = n(), Mean_Age =
        mean(Age, na.rm = TRUE))
```

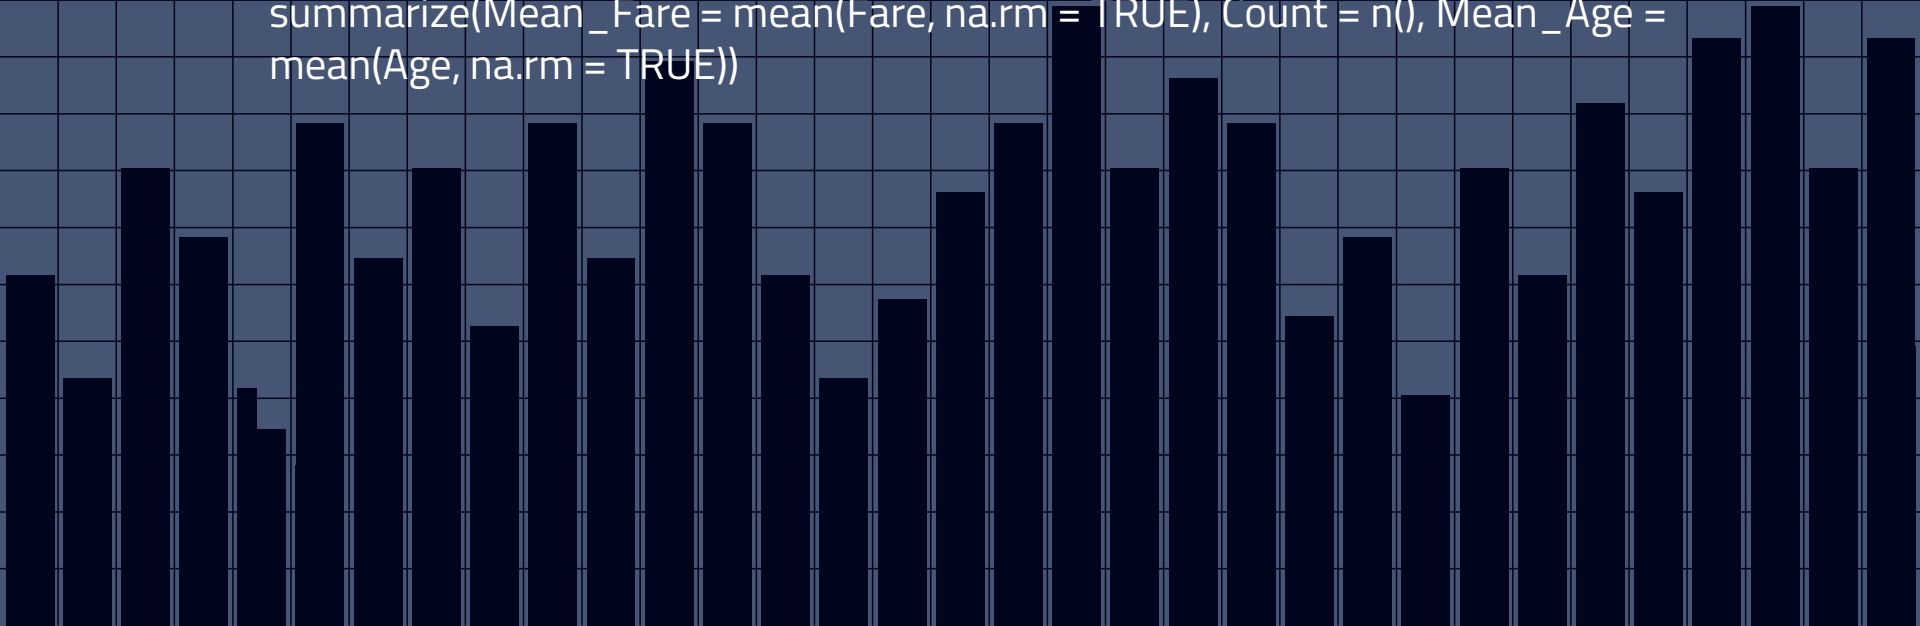

Zdroje

Data Wrangling with dplyr and tidyr Cheat Sheet – https://www.rstudio.com/wp-content/uploads/2015/02/data-wrangling-cheatsheet.pdf