

Folha 2: Manipulação de Dados - Soluções

Importação de Dados

1. O site [UCI ML Repository - Post-Operative Patient](#) contém um conjunto de dados com a informação sobre para onde devem ser enviados pacientes na área de recobro pós-operatório: cuidados intensivos, área geral do hospital, ou para casa.

- (a) Faça download do ficheiro [post-operative.data](#).
- (b) Importe o conjunto de dados para um data frame do R, garantindo que os valores desconhecidos são corretamente traduzidos para a nomenclatura do R.

```
path <- "/Users/rpribeiro/MyStuff/Teaching/PROG/1617/exercicios/folha2/"  
pop <- read.csv(paste(path, "post-operative.data", sep=""), header=F, na.strings="?")
```


2. No ficheiro [monthly-reported-number-of-chick.xlsx](#) estão registados o número de casos de varicela reportados mensalmente em Nova York entre 1931 e 1972.

- (a) Faça download do ficheiro e, usando a função `read_excel` da package `readxl` importe o conjunto de dados para um data frame do R.

```
library(readxl)  
chick <- read_excel(paste(path, "monthly-reported-number-of-chick.xlsx", sep=""))
```

- (b) Chame a função `plot` sobre o data frame criado.

```
plot(chick)
```




- (c) Este conjunto de dados representa uma série temporal. Use a função `xts` da package `xts` para criar uma série temporal com valores indicados pela segunda coluna e datas indicadas pela primeira coluna.

```
library(xts)
chick.ts <- xts(chick$Nr_chickenpox, chick$Month)
```


- (d) Chame, novamente, a função `plot` mas agora sobre o objeto criado.

```
plot(chick.ts)
```




- (e) Produza o gráfico correspondente ao período a partir de 1970.

```
plot(chick.ts["1970/"])
```



- (f) Produza o gráfico correspondente ao período entre 1970 e 1971.

```
plot(chick.ts["1970/1971"])
```



Manipulação de Dados com dplyr

3. Crie um *data frame table* a partir do conjunto de dados Aids2 da package MASS. Sobre este conjunto de dados, execute as operações necessárias de forma a responder às seguintes questões.

```
library(dplyr)
data(Aids2, package="MASS")
d <- tbl_df(Aids2)
```

(a) Inspeção as primeiras e as últimas linhas do dataset.

```
head(d); tail(d)

## Source: local data frame [6 x 7]
##
##   state sex  diag death status T.categ age
## 1 NSW   M 10905 11081      D      hs   35
## 2 NSW   M 11029 11096      D      hs   53
## 3 NSW   M  9551  9983      D      hs   42
## 4 NSW   M  9577  9654      D     haem  44
## 5 NSW   M 10015 10290      D      hs   39
## 6 NSW   M  9971 10344      D      hs   36
## Source: local data frame [6 x 7]
##
##   state sex  diag death status T.categ age
## 1 Other  M 11359 11504      A      hs   27
## 2 Other  M 11475 11504      A     het   46
## 3 Other  F 11420 11504      A     het   34
## 4 Other  M 11496 11504      A     haem  49
## 5 Other  M 11460 11504      A      hs   55
## 6 Other  M 11448 11504      A      hs   37
```

(b) Mostre apenas as colunas cujo nome começa por s.

```
select(d,starts_with("s"))

## Source: local data frame [2,843 x 3]
##
##   state sex status
## 1  NSW  M      D
## 2  NSW  M      D
## 3  NSW  M      D
## 4  NSW  M      D
## 5  NSW  M      D
## 6  NSW  M      D
## 7  NSW  M      D
## 8  NSW  M      D
## 9  NSW  M      D
## 10 NSW  M      D
## .. ... ..
```

- (c) Mostre apenas as linhas referentes a pacientes do sexo feminino que estejam vivos.

```
filter(d, sex=="M", status == "A")

## Source: local data frame [1,046 x 7]
##
##   state sex  diag death status T.categ age
## 1  NSW  M 10452 11504      A    hs    30
## 2  NSW  M 10923 11504      A   haem   21
## 3  NSW  M 10993 11504      A    hs    56
## 4  NSW  M 10996 11504      A    hs    38
## 5  NSW  M 10738 11504      A   het    26
## 6  NSW  M 11063 11504      A    id    39
## 7  NSW  M 11056 11504      A   haem   13
## 8  NSW  M 11283 11504      A    hs    34
## 9  NSW  M 11195 11504      A   het    39
## 10 NSW  M 10848 11504      A    hs    31
## .. ... ..
```

- (d) Ordene as linhas pela idade e pela categoria de transmissão do vírus.

```
arrange(d,age,T.categ)

## Source: local data frame [2,843 x 7]
##
##   state sex  diag death status T.categ age
## 1  QLD  M  9023  9039      D  blood    0
## 2  QLD  M  8963  8979      D  blood    0
## 3  QLD  M  8815  8815      D  blood    0
## 4 Other F  9447  9447      D mother    0
## 5  QLD  M  9199  9215      D  blood    1
## 6  NSW  M 11289 11504      A mother    1
## 7  VIC  F 11312 11327      D mother    1
## 8  NSW  M  9436 10938      D  blood    3
## 9  QLD  M  9868  9881      D  blood    3
## 10 NSW  M 10767 11504      A mother    3
## .. ... ..
```

- (e) Crie, para os pacientes que morreram, uma nova coluna com a diferença em dias entre o momento do diagnóstico e o momento da morte.

```
filter(d,status=="D") %>% mutate(days=death-diag)

## Source: local data frame [1,761 x 8]
```

```
##
##   state sex   diag death status T.categ age days
## 1  NSW   M 10905 11081      D      hs   35  176
## 2  NSW   M 11029 11096      D      hs   53   67
## 3  NSW   M  9551  9983      D      hs   42  432
## 4  NSW   M  9577  9654      D    haem   44   77
## 5  NSW   M 10015 10290      D      hs   39  275
## 6  NSW   M  9971 10344      D      hs   36  373
## 7  NSW   M 10746 11135      D   other   36  389
## 8  NSW   M 10042 11069      D      hs   31 1027
## 9  NSW   M 10464 10956      D      hs   26  492
## 10 NSW   M 10439 10873      D    hsid   27  434
## ..   ...   ...   ...   ...   ...   ...   ...
```

- (f) Obtenha, para os pacientes que morreram, o número médio de dias de vida para cada categoria de transmissão.

```
filter(d,status=="D") %>% mutate(days=death-diag) %>%
  group_by(T.categ) %>% summarize(avg.days=mean(days))

## Source: local data frame [8 x 2]
##
##   T.categ avg.days
## 1      hs 367.1188
## 2    hsid 399.5556
## 3     id 394.4737
## 4     het 559.3529
## 5    haem 309.8276
## 6   blood 225.4211
## 7  mother 223.0000
## 8    other 218.2750
```

- (g) Sobre o data set anterior obtenha, também para cada categoria, o número de pacientes total.

```
filter(d,status=="D") %>% mutate(days=death-diag) %>%
  group_by(T.categ) %>% summarize(avg.days=mean(days),total=n())

## Source: local data frame [8 x 3]
##
##   T.categ avg.days total
## 1      hs 367.1188  1532
## 2    hsid 399.5556    45
## 3     id 394.4737    19
## 4     het 559.3529    17
## 5    haem 309.8276    29
## 6   blood 225.4211    76
## 7  mother 223.0000     3
## 8    other 218.2750    40
```

- (h) Adicione o sexo como outro nível de agrupamento e volte a executar a operação anterior.

```
filter(d,status=="D") %>% mutate(days=death-diag) %>%
  group_by(T.categ,sex) %>% summarize(avg.days=mean(days),total=n())

## Source: local data frame [12 x 4]
## Groups: T.categ
##
##   T.categ sex avg.days total
## 1      hs   M 367.1188  1532
## 2    hsid   M 399.5556    45
## 3     id   F 467.1667     6
## 4     id   M 360.9231    13
```

## 5	het	F	658.0000	10
## 6	het	M	418.4286	7
## 7	haem	M	309.8276	29
## 8	blood	F	200.4242	33
## 9	blood	M	244.6047	43
## 10	mother	F	223.0000	3
## 11	other	F	83.0000	1
## 12	other	M	221.7436	39