MINERAÇÃO DE DADOS

Thiago Marzagão[1]

[1]marzagao.1@osu.edu

PRÉ-PROCESSAMENTO

mineração de dados

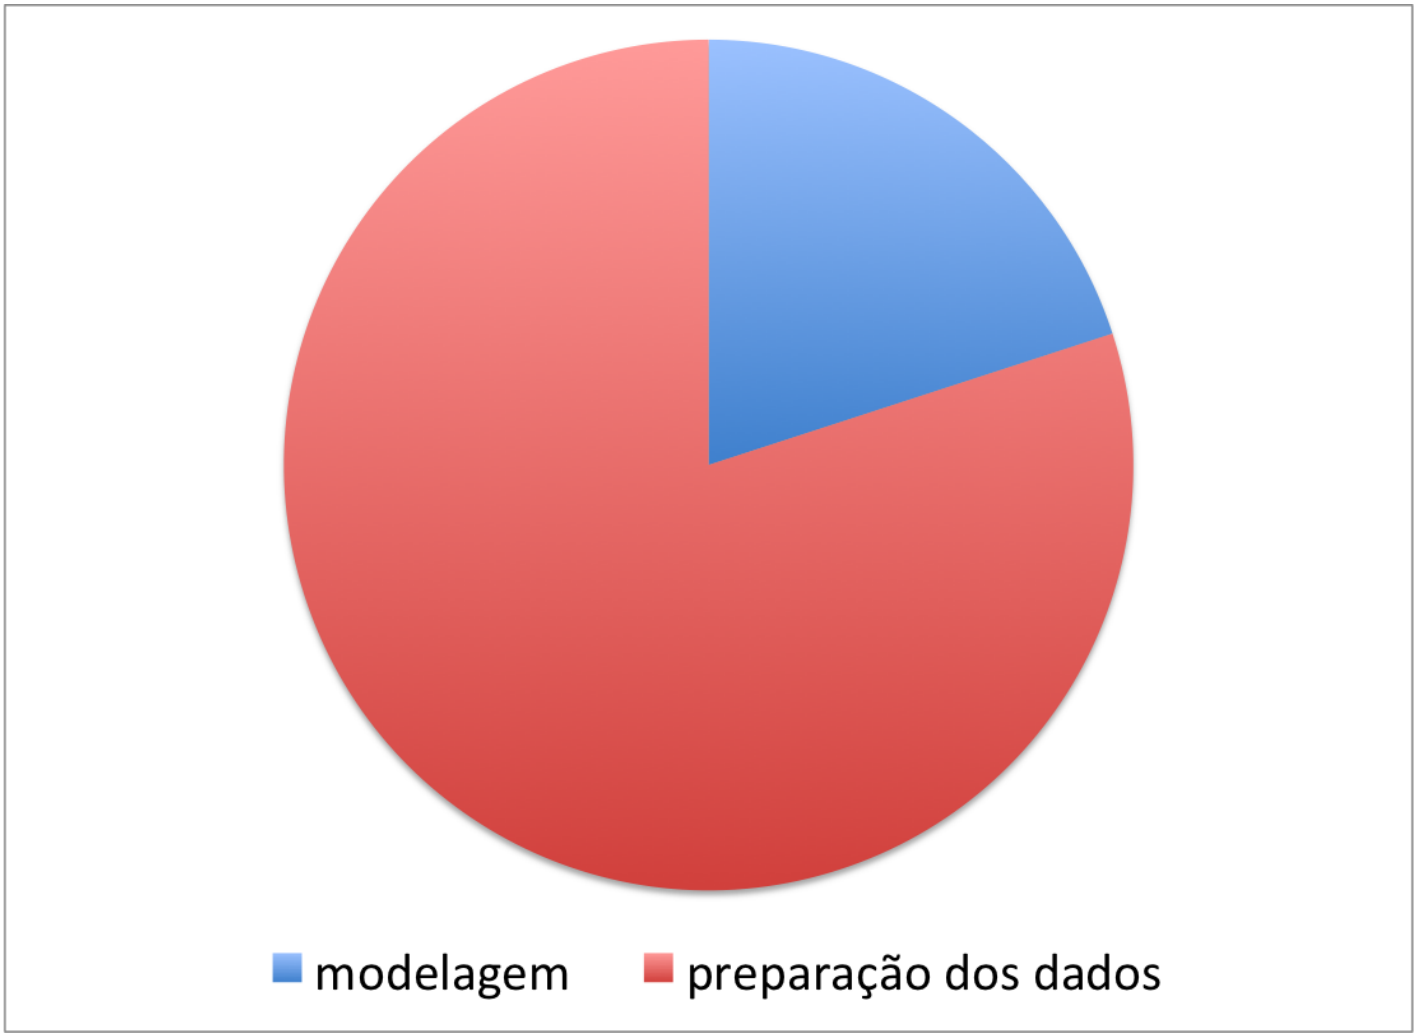

Excel não permite reprodutibilidade e facilita acidentes

pandas - Python Data Analysis Library

pandas

$$y_{it} = \beta' x_{it} + \mu_i + \epsilon_{it}$$

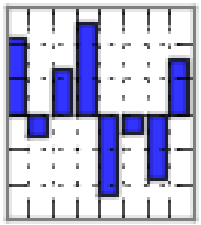

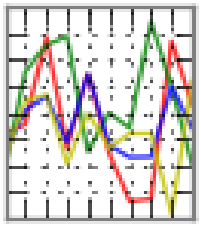

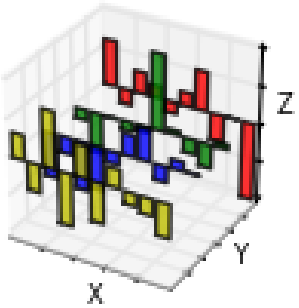

str como int/float

```
import pandas as pd
data = pd.read_csv('municipios.csv')
data
data.columns
data['codigo']
```

- id ('codigo') deveria ser str (ou object), não int
- do contrário várias coisas podem dar errado:
- ...zeros à esquerda podem desaparecer
- ...id pode ser arredondado
- ...id pode ser truncado (ex.: mais de 15 dígitos no Excel)

int/float como str

```
data[‘rural’]
data[‘rural’] + 5
data[‘rural’] * 5
"macarena" * 5
```

- ‘rural’ deveria ser float, não str ou object
- do contrário várias coisas podem dar errado:
- ...operações matemáticas vão dar erro
- ...o erro pode ser silencioso!

solução

```
data = pd.read_csv('municipios.csv',
                   dtype = {'codigo': str,
                            'rural': float})
data
```

- O parâmetro 'dtype' permite especificar o tipo de cada coluna

separador de campos = separador de decimal

```
data = pd.read_csv('municipios2.csv')
data
```

- Em municipios2.csv o separador de campos e o separador de decimal são o mesmo: ,
- Ou seja, 7,50 vira duas "colunas" separadas: 7 e 50

separador de campos = separador de decimal

```
data = pd.read_csv('municipios.csv',
                   dtype = {'rural': float"},
                   decimal = ',')
data['rural']
```

separador de campos != vírgula

- Nem sempre a vírgula é o separador de campo.
- O Excel em português, por exemplo, exporta p/ CSV separando c/ ponto-e-vírgula.
- Nesses casos é preciso informar explicitamente o separador:

```
data = pd.read_csv('nomedoarquivo.csv', sep = ';')
```

CSV sem nomes de colunas

- Quando o CSV não tem nomes de colunas:

```
data = pd.read_csv('municipios.csv', header = None)
```

pulando linhas

```
data = pd.read_csv('municipios.csv', skiprows = 5)
data
```

- Mas cuidado: o header também é pulado.

pulando colunas

```
data = pd.read_csv('municipios.csv',
                   usecols = ['latitude',
                              'longitude'])
data
```

missing data

- vários “tipos” de missing data:
- None (em Python)
- NULL (SQL, outras linguagens)
- (errado! não façam)
- - (errado! não façam)
- 0 (errado! não façam)
- 01/01/1900 (errado! não façam)
- -9, -999, -1, etc (errado, errado, errado! não façam)

missing data

- missing data propriamente identificado:

```
(50.5 + 42.1 + 30.4 + 60.7 + None + 45.8) / 6
```

- dá erro; e isso é bom!
- você *não* quer que essa média seja calculada
- missing data impropriamente identificado:

```
(50.5 + 42.1 + 30.4 + 60.7 + -999 + 45.8) / 6
(50.5 + 42.1 + 30.4 + 60.7 + 0 + 45.8) / 6
(50.5 + 42.1 + 30.4 + 60.7 + -1 + 45.8) / 6
```

- *não* dá erro; e isso é ruim!
- você *não* quer que essa média seja calculada

missing data

- p/ encontrar possíveis problemas:

```
data['rural'].describe()
```

duplicidades

- origem: por exemplo, diferentes grafias de um mesmo nome
- ...Mônica e Monica

unidade inconsistente

- caso mais comum: confusão entre preço unitário e preço total

datas em formatos inconsistentes

- caso mais comum: confusão entre DD/MM/AAAA e MM/DD/AAAA
- 3/4/2005? 3 de abril de 2005 ou 4 março de 2005?
- formato correto: AAAA-MM-DD (ISO 8601)

dicionário de dados

- dicionário de dados = arquivo contendo descrição detalhada de cada variável e origem dos dados