

Modernizing the Curricula of Statistics courses through Statistical Learning

New Approaches to Statistical Learning in
Developing Countries
3rd LISA 2020 Symposium

Marcus Nunes

29 October 2020

Federal University of Rio Grande do Norte

Motivation

Motivation

- It is easier than ever to fit complex models to data
- Many data repositories are available for free
- Free software and data can be used
- How statistical educators can take advantage of new technologies

Motivation

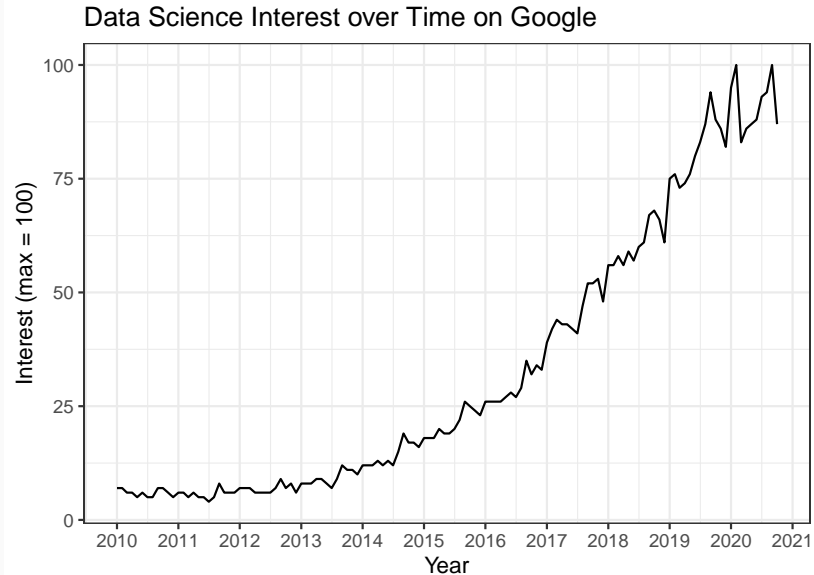
2014 ASA Guidelines:

- Increased importance of data science
- Real applications
- More diverse models and approaches
- Ability to communicate

Motivation

- These guidelines have been applied in a course called *Introduction to Big Data Modeling*
- Offered since 2015 at the Federal University of Rio Grande do Norte, Brazil
- It is offered regularly as an elective course to second-year students
- Pre-requisites: basic statistical inference (t-test, ANOVA, simple linear regression) and R programming

Increased Importance of Data Science



Real Applications

- One of the pillars of *Introduction to Big Data Modeling* is the use of real datasets
- According to Hicks and Irizarry (2016), students are more motivated when they see data collected from the real world
- Simple and complex datasets: Fisher's Iris dataset and FIFA Soccer

Real Applications

- As the course advances, the datasets become more complex
- There are many free great sources with interesting datasets
- US Government open data and Brazilian Institute of Geography and Statistics are two of them
- Kaggle and UC Irvine Machine Learning Repository are great sources too

More Diverse Models and Approaches

- Many courses in undergraduate level choose to show fewer modeling techniques to the students
- Proving results and going deep on the math behind them
- We prefer to present models focusing on their strengths and limitations
- The students are only required to intuitively know how the algorithms work

More Diverse Models and Approaches

- k-means
- Hierarchical clustering
- Principal components analysis
- Data acquisition
- Cross validation
- K nearest neighbor
- Support vector machine
- Classification and regression trees
- Random forests
- Model ensemble

Ability to Communicate

- The students are evaluated through midterms and a final project
- The final project has two parts: written report and live presentation
- While the default is to present slides, some students have built dashboards to present their results

Case Study: Web Scraping

Case Study: Web Scraping

- This is the project the students have to complete on the web scraping module
- This is the fifth module of the course
- Dogucu and Çetinkaya-Rundel (2020) is a very good resource on this topic

Case Study: Web Scraping

- Extract data from websites
- Collect and organize data automatically
- Only open data can be reached this way

Case Study: Web Scraping

W Lista de municípios do Brasil p: x +

← → ↻ pt.wikipedia.org/wiki/Lista_de_municípios_do_Brasil_por_população_(2020)

Wikipédia A enciclopédia livre

Discussão Contribuições Criar uma conta Entrar

Artigo Discussão

Editar Ver histórico Pesquisar na Wikipédia

Lista de municípios do Brasil por população (2020)

Origem: Wikipédia, a enciclopédia livre.
(Redirecionado de [Lista de municípios do Brasil por população](#))

Esta é uma lista de **municípios do Brasil por população**, segundo a estimativa da população residente à data de 1º de julho de 2020 feita pelo [Instituto Brasileiro de Geografia e Estatística](#) (IBGE).^[1]

Índice [esconder]

- Municípios
- Ver também
- Referências
- Ligações externas

Municípios

Ver também: *Lista de concentrações urbanas do Brasil por população*

Posição	Código IBGE	Município	Unidade federativa	População
1º	3550308	São Paulo	 São Paulo	12 325 232
2º	3304557	Rio de Janeiro	 Rio de Janeiro	6 747 815
3º	5300108	Brasília	 Distrito Federal	3 055 149
4º	2927408	Salvador	 Bahia	2 886 698
5º	2304400	Fortaleza	 Ceará	2 686 612
6º	3106200	Belo Horizonte	 Minas Gerais	2 521 564
7º	1302603	Manaus	 Amazonas	2 219 580

Case Study: Web Scraping

W Lista de municípios brasileiros x +

← → C pt.wikipedia.org/wiki/Lista_de_municípios_brasileiros_por_área_decrescente

Não autenticado Discussão Contribuições Criar uma conta Entrar

Artigo Discussão Ler Editar Ver histórico Pesquisar na Wikipédia

 **WIKIPÉDIA**
A enciclopédia livre

[Página principal](#)
[Conteúdo destacado](#)
[Eventos atuais](#)
[Esplanada](#)
[Página aleatória](#)
[Portais](#)
[Informar um erro](#)
[Loja da Wikipédia](#)

[Colaboração](#)
[Boas-vindas](#)
[Ajuda](#)
[Página de testes](#)
[Portal comunitário](#)
[Mudanças recentes](#)
[Manutenção](#)
[Criar página](#)
[Páginas novas](#)
[Contato](#)
[Doações](#)


[Ferramentas](#)
[Páginas afiluentes](#)
[Alterações relacionadas](#)
[Carregar ficheiro](#)
[Páginas especiais](#)
[Hiperligação](#)

Lista de municípios brasileiros por área decrescente

Origem: Wikipédia, a enciclopédia livre.

Relação das áreas territoriais totais de todos os 5570 municípios do Brasil, segundo dados do Instituto Brasileiro de Geografia e Estatística^{[1][2]} e apresentados em ordem decrescente. As capitais aparecem em **negrito**.

Posição	Município	Código do IBGE	Unidade federativa	Área (km²)
1	Altamira	1500602	Pará	159 533,328
2	Barcelos	1300409	Amazonas	122 461,086
3	São Gabriel da Cachoeira	1303809	Amazonas	109 181,245
4	Oriximiná	1505304	Pará	107 613,838
5	Tapauá	1304104	Amazonas	84 946,035
6	São Félix do Xingu	1507300	Pará	84 212,958
7	Atalaia do Norte	1300201	Amazonas	76 435,093
8	Almeirim	1500503	Pará	72 954,798
9	Jutai	1302306	Amazonas	69 457,415
10	Lábrea	1302405	Amazonas	68 262,680
11	Corumbá	5003207	Mato Grosso do Sul	64 438,363
12	Santa Isabel do Rio Negro	1303601	Amazonas	62 800,078
13	Itaituba	1503606	Pará	62 042,472
14	Coari	1301209	Amazonas	57 970,768
15	Japurá	1302108	Amazonas	55 827,203
16	Apuí	1300144	Amazonas	54 240,556


Altamira, no Pará, é o maior município do Brasil em área


Barcelos, no Amazonas, é o segundo mais extenso

Case Study: Web Scraping

```
> library(rvest)
> library(dplyr)
> library(ggplot2)
> theme_set(theme_bw())
> library(stringr)
> library(scales)
```

Case Study: Web Scraping

```
> url <- "https://pt.wikipedia.org/wiki/Lista_de_munic%C3%A9s_de_Pernambuco"
>
> population <- url %>%
+   read_html()
>
> population <- population %>%
+   html_table(fill=TRUE)
>
> population <- population[[1]]
>
> names(population) <- c("Position", "IBGE.Code",
+   "City", "State", "Population")
```

Case Study: Web Scraping

```
> head(population)
```

##	Position	IBGE.Code	City	State
## 1	1º	3550308	São Paulo	São Paulo
## 2	2º	3304557	Rio de Janeiro	Rio de Janeiro
## 3	3º	5300108	Brasília	Distrito Federal
## 4	4º	2927408	Salvador	Bahia
## 5	5º	2304400	Fortaleza	Ceará
## 6	6º	3106200	Belo Horizonte	Minas Gerais

##	Population
## 1	12 325 232
## 2	6 747 815
## 3	3 055 149
## 4	2 886 698
## 5	2 686 612
## 6	2 521 564

Case Study: Web Scraping

```
> head(area)
```

##	Position	City	IBGE.Code	Stat
## 1	1	Altamira	1500602	Par
## 2	2	Barcelos	1300409	Amazona
## 3	3	São Gabriel da Cachoeira	1303809	Amazona
## 4	4	Oriximiná	1505304	Par
## 5	5	Tapauá	1304104	Amazona
## 6	6	São Félix do Xingu	1507300	Par

##	Area
## 1	159 533,328
## 2	122 461,086
## 3	109 181,245
## 4	107 613,838
## 5	84 946,035
## 6	84 212,958

Case Study: Web Scraping

```
> brazil <- left_join(population, area,  
+   by = "IBGE.Code")  
>  
> brazil <- brazil %>%  
+   select(City.x, State.x, Area, Population)  
>  
> names(brazil) <- c("City", "State", "Area",  
+   "Population")
```

Case Study: Web Scraping

```
> head(brazil)
```

##	City	State	Area	Population
## 1	São Paulo	São Paulo	1 521,110	12 325 232
## 2	Rio de Janeiro	Rio de Janeiro	1 200,329	6 747 815
## 3	Brasília	Distrito Federal	5 760,783	3 055 149
## 4	Salvador	Bahia	693,453	2 886 698
## 5	Fortaleza	Ceará	312,353	2 686 612
## 6	Belo Horizonte	Minas Gerais	331,354	2 521 564

Case Study: Web Scraping


```
> brazil <- brazil %>%  
+   mutate(Area = str_replace(Area,  
+     "[[:space:]]", "")) %>%  
+   mutate(Area = str_replace(Area, ",", ".")) %>%  
+   mutate(Area = as.numeric(Area)) %>%  
+   mutate(Population = str_replace_all(Population,  
+     "[[:space:]]", "")) %>%  
+   mutate(Population = as.numeric(Population))
```

Case Study: Web Scraping

```
> head(brazil)
```

##	City	State	Area	Population
## 1	São Paulo	São Paulo	1521.110	12325232
## 2	Rio de Janeiro	Rio de Janeiro	1200.329	6747815
## 3	Brasília	Distrito Federal	5760.783	3055149
## 4	Salvador	Bahia	693.453	2886698
## 5	Fortaleza	Ceará	312.353	2686612
## 6	Belo Horizonte	Minas Gerais	331.354	2521564

Case Study: Web Scraping



Final Remarks

- Student evaluations indicate students are satisfied with this course contents
- 2019 was the first year the course was offered for the students enrolled in the Actuarial Science Department
- Our future plans for this course include expanding it from a one-semester course to a two-semester course
- And everything is free!

References

- Dogucu, Mine and Çetinkaya-Rundel, Mine (2020) “Web Scraping in the Statistics and Data Science Curriculum: Challenges and Opportunities.” *Journal of Statistics Education* **0** (0): 1-11.
- Hicks, Stephanie C. and Rafael A. Irizarry (2016) “A Guide to Teaching Data Science.” *The American Statistician* **72** (4): 382-391.

Modernizing the Curricula of Statistics courses through Statistical Learning

New Approaches to Statistical Learning in
Developing Countries
3rd LISA 2020 Symposium

Marcus Nunes

29 October 2020

Federal University of Rio Grande do Norte