

‘R’ te dá asas...

Neale Ahmed El-Dash neale.eldash@gmail.com

R Day Curitiba (Dez/2019)

Introdução

Minha trajetória...

- Graduação em Estatística - UNICAMP (1995-1999) - ???
 - Trabalho no Núcleo de Estudos de Políticas Públicas NEPP (1998-1999) - SAS
 - Mestrado em Estatística - UNICAMP (2000-2002) - Matlab
 - Trabalho na IPSOS Brasil (2002-2006) - SPSS
 - Doutorado em Estatística - USP (2006-2010) - R
 - Trabalho na IPSOS EUA (2011-2013) - SPSS
 - Consultor (2006 até hoje) - Principalmente R
-
- Não deveria haver uma distinção tão grande entre “*Academia x Mercado*”...
 - São complementares, não opostos!

“*A teoria sem a prática é vazia. A prática sem a teoria é cega.*”

A importância do R

- Após o Mestrado me tornei “*autodidata*”
- Na teoria ok, mas na prática não conseguia entregar
 - Artigos incríveis, queria aplicar
 - Não havia tempo pra implementar
 - Era refém do software estatístico
 - No “*mercado*”, tem que entregar o melhor possível dentro do prazo (curto)
- Quando conheci o R, fiquei mais confiante que podia fazer qualquer análise...
 - Porém o meu workflow com o R era péssimo...
- Quando conheci o R + RStudio + Bibliotecas, minha vida mudou...
 - **O “R” me deu asas...**
 - **Teoria <=> R <=> Prática**

Essa apresentação

- Aprendendo o R
 - Como migrei para o R
- Depois do R
 - As bibliotecas que me possibilitaram fazer coisas que eu não conseguia fazer antes
- Algumas aplicações

Aprendendo R (entre 2006 e 2013)

Motivação

- Empresas de pesquisa gostam de fazer uma aplicação customizada de uma técnica
 - Batizam com um nome
 - Vendem como um produto
- Precisava replicar algum produto que usava **Régressão Bayesiana**
 - Na Ipsos Brasil usava-se SPSS e Excel
 - Só consegui fazer com R
- Dificuldades:
 - Linha de comando
 - Importar os dados para o R
 - Diferentes formatos de dados:
 - dataframe, list, array e matrix

Doutorado

- Me forcei a fazer em R
 - código em espaguete
 - Biblioteca **base** somente
- Via potencial, mas continuava sofrendo...
 - Análises específicas / novas
 - Gráficos (é possível fazer qualquer coisa)

Trabalhando com SPSS + R

- Uma das maiores demandas com pesquisas de opinião pública é a ponderação dos dados
 - No começo fazia manualmente.
- Ponderação:
 - Dar pesos diferentes para cada observação da base de dados
 - Para que a soma ponderada de variáveis na amostra reproduzam o perfil conhecido da população
 - Ex. Mulheres representando 40% das observações na base e 50% na população
 - Com muitas variáveis é bem mais complexo - **Raking / Post-stratification**
- Workflow inicial (SPSS »> R):
 - Manipulava bancos de dados no SPSS
 - Exportava dados para o R
 - **PONDERAR OS DADOS** (biblioteca survey)
 - Importava resultados do R

Automatizando workflow SPSS + R

- R Essentials for SPSS (link)
 - Foi possível automozatizar todo o processo
 - Na eleição de 2012 nos EUA, usava todo dia na pesquisa da Reuters/Ipsos
 - usado até hoje
- Ninguém na Ipsos US usava R
 - Indispensável parece bom, porém causa problemas...
 - usar o SPSS como interface me permitiu tirar férias...

Trabalhando com Excel + R

- Workflow inicial (EXCEL »> R):
 - Usava a interface do Excel + VBA + Formulários
 - Exportava dados para o R
 - **Ponderar dados**
 - Importava resultados do R
- Biblioteca RExcel
 - integração muito legal entre Excel e R
 - instala o R Commander também
- Uso na Ipsos
 - Na eleição de 2012 nos EUA, usei no “*Exit Poll*” Reuters/Ipsos

Livros “cross-over”

- R for SAS and SPSS Users
 - Robert A. Muenchen
- R Through Excel: A Spreadsheet Interface for Statistics, Data Analysis, and Graphics
 - Richard M.Heiberger, Erich Neuwirth
- Também dá pra usar o SAS para chamar o R
 - explicação aqui

“R” te dá asas...

- Já usava:
 - análises estatísticas específicas
 - gráficos
- (1)) RStudio foi lançado em 2011...
- (2) Conseguir importar e exportar dados sem erros
 - **openxlsx** (importar e exportar pro excel, fácil instalação)
 - **haven** (importar e exportar do SPSS, inclusive nomes de variáveis e níveis de fatores)
- (3) Conseguir manipular dados eficientemente
 - **dplyr** (transform data)
 - **tidyverse** (reshape data)

“Entendi que o que importava mesmo era escolher a biblioteca certa!!!”

Depois do R (2013 em diante...)

Depois do R (2013 em diante...)

Fazendo o trabalho no R fluir...

- Me ajudaram muito:
 - **str**: mostra a estrutura do objeto (hoje em dia a janela do RStudio já faz isso)
 - **dput**: transforma um objeto em um texto que constrói o objeto no R
 - **CTRL+C e CTRL+V**: `write.table('clipboard')` e `read.table('clipboard')`
 - Biblioteca datapasta: permite colar objetos direto no R de forma bastante flexível
- Permite customizar o R:
 - Criar um arquivo **.Rprofile**
 - Criar um pacote pessoal. Referências: R Packages e GitHub

Aprendendo mais sobre o R...

- Acessei o libgen e baixei todos os livros com "R" no título.
 - Uso o R para aprender e para aplicar
 - Seymour Papert: "**Knowledge is only part of understanding. Genuine understanding comes from hands-on experience**"
- Cheatsheets do R
- Newsletters como R-Bloggers e sites como o StackOverflow
- Livro "*Advanced R*" do **Hadley Wickham**

Workflow com o R+Rstudio

- Depois que fiquei confortável com o R
 - Uso o R como **interface** para vários outros softwares/linguagens
 - Algumas bibliotecas são justamente desenhadas para ser a interface
- Exemplos:
 - **Linha de comando**
 - rJava
 - C++
 - zip
 - gmail
 - PDFTables API
 - highcharts
 - html widgets
 - Google Big Query
 - Amazon S3
 - Microsoft Office

Integração com Python

- Biblioteca reticulate
 - Permite rodar o Python de dentro do R
 - Sessão interativa ou importar funções ou rodar scripts
- Polêmica Python versus R. Minha opinião/experiência:
 - **R utiliza menos tempo do programador:** Permite pensar mais rápido!
 - Python usa menos tempo do processador
 - Python: Tem mais API's já implementadas

Bibliotecas fundamentais - Análise de dados e amostragem

- dplyr e tidyr
 - Transformar qualquer base de dados
- ggplot2
 - Visualizar qualquer informação (pode adicionar quantos níveis quiser)
- lme4
 - Modelos Hierárquicos entre outros
- survey
 - Ponderação - Pós-estratificação e Raking
- sampling
 - Amostras complexas

Bibliotecas fundamentais - Análise de dados 2

- **fuzzyjoin**
 - Juntar bases de dados quando as chaves são strings (não idênticas)
- **stringr**
 - Utilizar expressões regulares (regra de formação da string)
- **purrr**
 - Loops incrivelmente flexíveis e dataframes com list-columns, entre outros
- **multidplyr**
 - Analisar bases de dados em paralelo

Bibliotecas fundamentais - Web Scrapping

- rvest
 - Raspar dados de quase qualquer site
 - usar comandos do **CSS** ou **XPath**
- rSelenium
 - Raspar dados dos sites onde não é possível utilizar o rvest

Bibliotecas fundamentais - Análise Bayesiana

- R2WinBUGS
 - Análise bayesiana usando gibbs sampling
- INLA
 - Análise bayesiana muito rápida
- rstan
 - Esse é o pacote mais ativo hoje...

Bibliotecas fundamentais - Montar um site

- shiny
 - Montar seu próprio site interativo
- rmarkdown
 - Escrever relatórios e códigos no mesmo documento
- blogdown
 - Montar seu próprio site estático
- rplumber
 - transformar sua função em uma API acessível por qualquer um

Aplicações

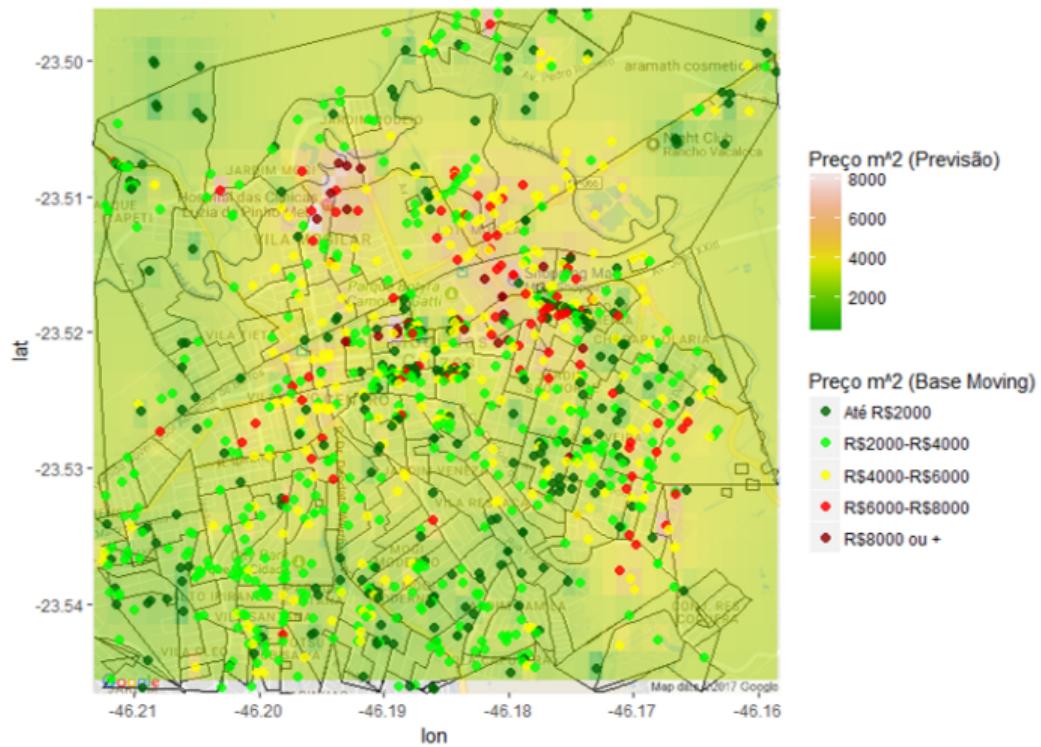
App da Moving

- Prevendo preços de imóveis utilizando um modelo estatístico (link):
 - Toda a parte estatística feita em R (BACK-END)
 - Porém a parte acessível aos analistas (FRONT-END) foi feita em Python / PHP / Angular
 - Estimativas do modelo acessíveis pela API criada usando rplumber
- Os dados de imóveis:
 - WebScraping de sites de anúncio de imóveis (Zap, ImovelWeb, VivaReal e Moving)
 - Geocodificar endereços de forma **assíncrona** usando api do Google de Geocode e a biblioteca curl

O modelo da Moving

- O sistema permite que um verificador valide a estimativa antes de aprová-la
 - Planilha com os imóveis próximos mais similares (Dist. de Mahalanobis)
 - A estimativa pode ser alterada manualmente (ajustes serão utilizados para melhorar o modelo)
- O modelo têm três níveis de dados:
 - Base de setores censitários
 - Menor unidade geográfica com informações oficiais ()
 - Informações de água, esgoto, iluminação, renda, etc..
 - Informações dos imóveis
 - m^2 , banheiros, dormitórios, suítes, vagas na garagem, tipo do imóvel, condomínio
 - Benfeitorias: copa, varanda, academia,etc..
 - Calculamos uma estimativa de preço do m^2 de construção por setor censitário, utilizando **interpolação espacial** (algoritmo “*Inverse Distance Weights*”). Usamos o pacote gstat.

Visualização do método



Site Polling Data

- Site Polling Data

- <http://www.pollingdata.com.br/>

- Pesquisas Eleitorais

- http://www.pollingdata.com.br/menu_pesquisas/
 - Agregador de pesquisas eleitorais
 - Mais preciso do que as pesquisas eleitorais vista separadamente
 - Entra todo dia no wikipedia e baixa todos os dados de eleições com pesquisas eleitorais
 - Roda um modelo bayesiano para cada eleição.
 - Estima o **house effect** de cada empresa de pesquisa
 - Prevê as chances de vitória de cada partido/candidato
 - Já ganhei dinheiro prevendo qual seria o resultado do datafolha/ibope, e não da eleição em si

Blog

- Novo site (estático)
- **Blog** +<http://www.pollingdata.com.br/blog/>
 - Utilizando Hugo
 - pacote Rmarkdown
 - pacote Blogdown
 - Adicionar apps do Shiny dentro do site como no post do tutorial inferência bayesiana
<http://www.pollingdata.com.br/bayes/>

Previsão Futebol

- **Previsão Futebol**

- http://www.pollingdata.com.br/menu_futebol/
- Utiliza um modelo esperto que extrai os poderes de ataque e defesa de cada time
- Só leva em conta informações como placar dos jogos e mando de campo.
- webscrapping diário de jogos de futebol de mais de 30 países e de todas as seleções
- Apostava no Bet Fair
- Sulamerica ganhava, mas quando expandi Mundo + Seleções, perdi 500 libras. Parei de apostar...

Outras aplicações do site

- **API de amostragem**

- http://www.pollingdata.com.br/api_amostra/
- Com o R, automatizei totalmente a seleção da amostra. Tempo necessário é o de execução apenas.
- Antigamente para selecionar a mesma amostra, 2 estatísticos levam 3 dias de trabalho cada um.

- **App Tabela Fipe corrigida pela Km**

- <http://www.pollingdata.com.br/2019/10/app-para-ajustar-as-estimativas-da-tabela-fipe/>
- Permite corrigir os dados da tabela FIPE levando em consideração a kilometragem do seu carro
- Utiliza todos os dados da FIPE mais informações do site Mercado Livre
- Usa biblioteca fuzzyjoin pra compatibilizar as marcas/veículos dos dois sites

O “R” te dá asas...

- Estatística não é só sobre ganhar \$
- Podemos tentar responder qualquer pergunta
- H. G. Wells no seu livro *Mankind in the Making* em 1914:

“Um dia o pensamento estatístico será tão importante para o pleno exercício da cidadania quanto ler e escrever.”

- Hoje, graças ao R, acredito que estamos muito mais perto desse futuro...
 - Acesso gratuito ao software
 - **pensamento estatístico:** conhecimento + R

Quem sabe o “R” não dará asas, em algum momento, a todos?