

Ciência de Dados e Multidisciplinaridade

II Seminário de Aplicações em Ciência de Dados

Marcus Nunes

7 de Dezembro de 2018

Universidade Federal do Rio Grande do Norte

Quem sou Eu?

Quem sou Eu?

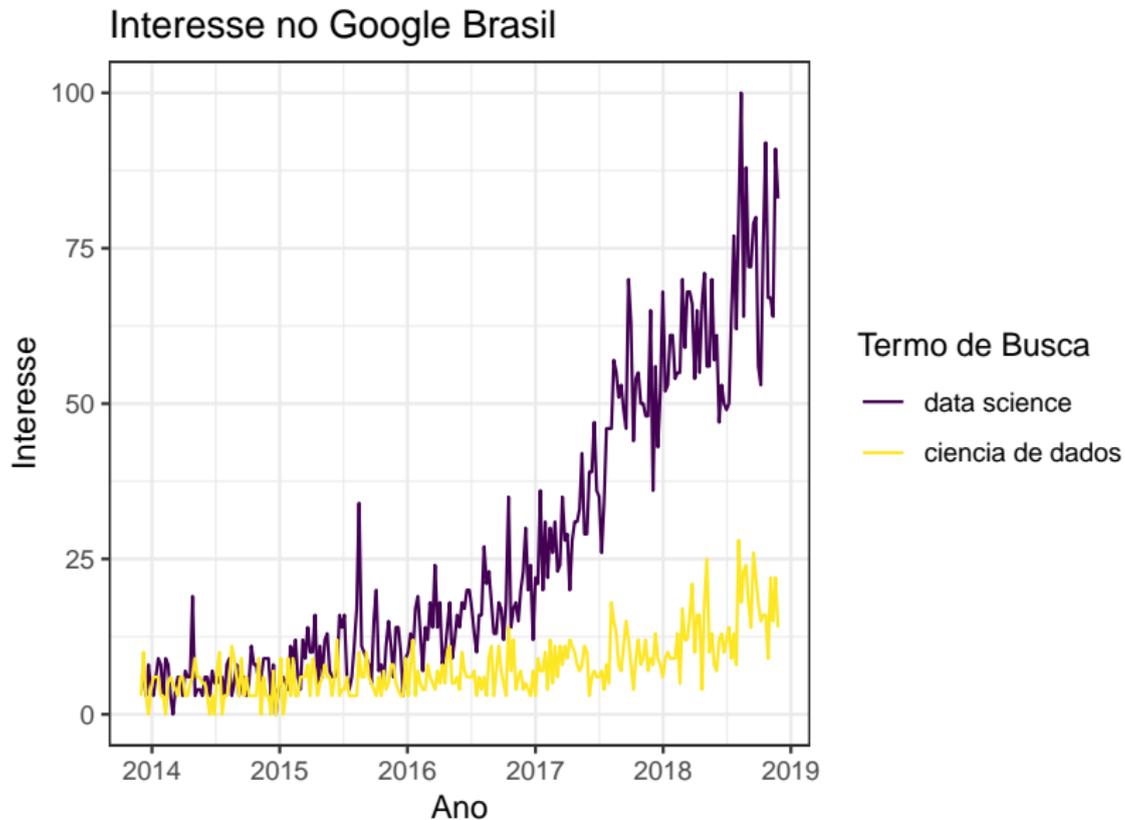
- Marcus Nunes, professor do Departamento de Estatística da UFRN
- Coordenador do Laboratório de Estatística Aplicada - http://www.estatistica.ccet.ufrn.br/?page_id=156
- 1ª Competição de Ciência de Dados do Departamento de Estatística - http://www.estatistica.ccet.ufrn.br/?page_id=608
- <https://marcusnunes.me/>

O que é Ciência de Dados?

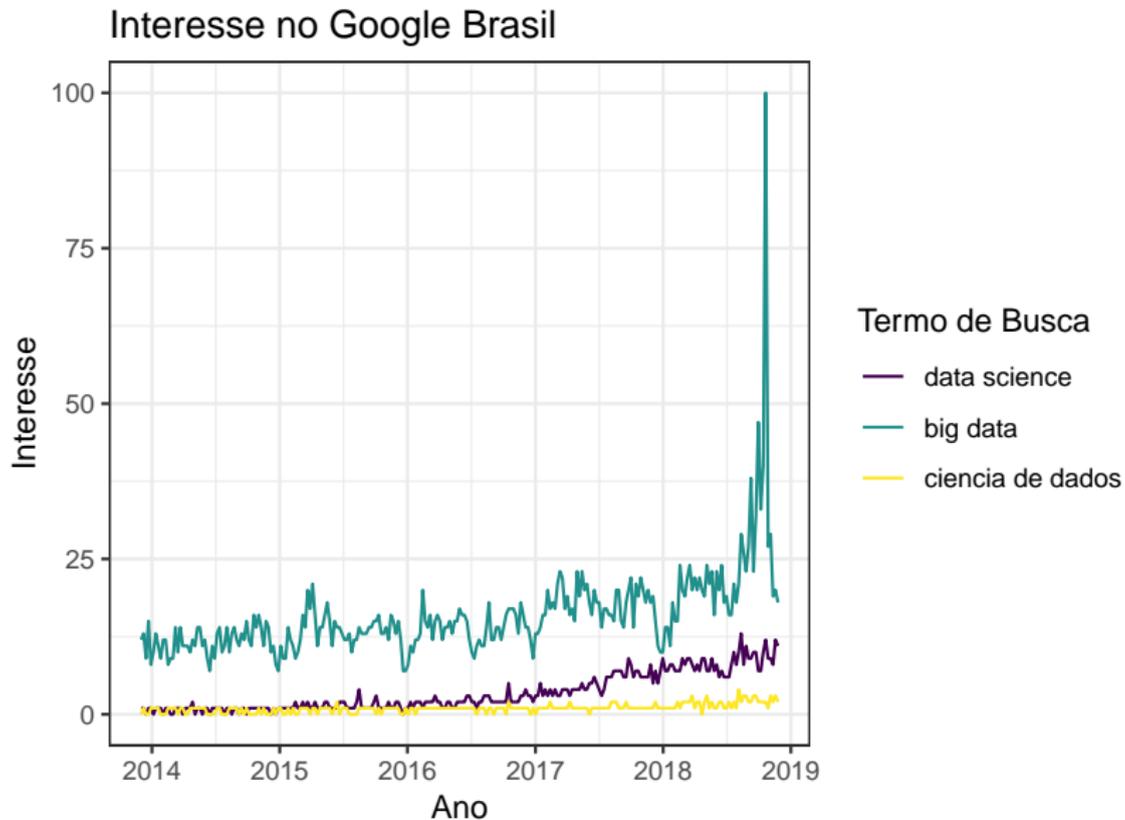
O que é Ciência de Dados?

- *Buzzword* muito utilizada atualmente
- Juntamente com *big data* e *data science*, o termo ganhou muita força nos últimos cinco anos

O que é Ciência de Dados?



O que é Ciência de Dados?



O que é Ciência de Dados?

- Alguém tem alguma definição?

Multidisciplinaridade

- Uma equipe multidisciplinar é formada por especialistas em várias áreas do conhecimento
- É através da combinação de ideias e do conflito entre elas que surgirão soluções para os problemas

- Competências de um profissional 100% capacitado para trabalhar com Ciência de Dados:
 - Estatística
 - Programação
 - Negócios
 - Conhecer bem a área de atuação (internet, varejo, finanças etc)

Multidisciplinaridade

- Que tipo de profissionais temos no momento?
 - Bons estatísticos e matemáticos que escrevem códigos sem otimização
 - Bons cientistas da computação que entendem um pouco de estatística e matemática
 - Bons cientistas da computação que entendem um pouco de negócios, depois de muita experiência na área
 - Especialistas em alguma área de atuação
 - Gerentes que sabem fazer estas pessoas trabalharem juntas

Quem Trabalha com Ciência de Dados?

- Estatísticos
- Programadores
- Físicos
- Cientistas de Dados

Um Problema Real

Como solucionar o limite 53 categorias do randomForest do R?

Faça uma pergunta



No R, utilizando a library `randomForest`, quando executo `randomForest()` recebo a seguinte mensagem de erro:

6



```
Error in randomForest.default(m, y, ...) :  
  Can not handle categorical predictors with more than 53 categories.
```



O fator em questão tem 57 categorias. Como posso mudar este limite ou contornar este problema?

r randomforest

compartilhar editar
fechar sinalizar

editada 5/11 às 16:36

4.259 ● 2 ● 4 ● 28

perguntada 5/11 às 16:22

541 ● 2 ● 23

Um Problema Real

- A construção da árvore envolve os seguintes passos:
 1. A seleção das divisões
 2. As decisões de quando declarar um nó como folha ou continuar dividindo-o
 3. A alocação de cada nó folha a uma classe

Um Problema Real

- Em particular, precisamos decidir o seguinte:
 1. Um conjunto \mathcal{Q} de decisões binárias do tipo $\{X \in A\}, A \subset \mathcal{X}$
 2. Um critério de divisão $\phi(s, t)$ que pode ser calculado para qualquer divisão s de qualquer nó t
 3. Uma regra para finalizar as divisões
 4. Uma regra para alocar cada nó folha a uma classe

Um Problema Real

- Se X é categórica com valores, digamos, $\{1, 2, \dots, M\}$, então \mathcal{Q} contém todas as questões da forma

$$\{X_j \in A?\},$$

onde A varia sob todos os subconjuntos de $\{1, 2, \dots, M\}$

- As divisões para todas as p variáveis constituem o conjunto padrão de questões

Um Problema Real

- Como são 57 categorias na variável, são $2^{57} - 2 \approx 1,441 \times 10^{17}$ separações diferentes que devem ser feitas
- Por melhor que seja o seu hardware, algo da ordem de 10^{17} ainda é muito grande
- Desta forma, não basta apenas trabalhar mais: é preciso trabalhar de forma inteligente

Um Problema Real

- Ela seria uma variável numérica que foi lida incorretamente?
- Caso a variável seja categórica, é possível tratá-la como variável ordinal?
- Caso a variável seja categórica nominal, é possível simplificá-la em menos categorias? Por exemplo, caso sejam países do mundo, é possível criar uma nova variável chamada continente que vai ter apenas 6 níveis?
- Caso a variável seja categórica nominal, é possível simplificá-la em menos categorias? Todos os níveis são representativos? Seria possível combinar os níveis de menor frequência em um novo nível?

O que é um Cientista de Dados?

- Cientista de Dados (*Data Scientist*) é o novo nome para Estatístico
- Alguns dizem que o Cientista de Dados é um Estatístico que mora em São Francisco e usa um Mac
- No fundo, ambos são a mesma coisa, embora uma destas profissões trabalhe melhor seu marketing pessoal

O que é um Cientista de Dados?

- É alguém que entende mais de programação do que um Estatístico tradicional
- É alguém que entende mais de estatística do que um Cientista da Computação tradicional
- E, principalmente, é alguém que consegue encontrar soluções para problemas juntando estas duas áreas do conhecimento

Quem já jogou RPG?

Quem já jogou RPG?



PLANILHA DE PERSONAGEM

NOME DO PERSONAGEM _____ JOGADOR _____
 CLASSE E NÍVEL _____ RAÇA _____ TENDÊNCIA _____ DIVINDADE _____
 TAMANHO _____ IDADE _____ SEXO _____ ALTURA _____ PESO _____ OLHOS _____ CABELOS _____ PELE _____

HABILIDADE	VALOR	MOD. DE HABILIDADE	VALOR TEMPORÁRIO	MOD. TEMPORÁRIO
FOR FORÇA	<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
DES DESTREZA	<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
CON CONSTITUIÇÃO	<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
INT INTELIgÊNCIA	<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
SAB SABEDORIA	<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>
CAR CARISMA	<input type="text"/>	<input type="text"/>	<input type="text"/>	<input type="text"/>

PV PONTOS DE VIDA **TOTAL** _____

CA CLASSE DE ARMADURA **TOTAL** = 10 + (BÔNUS DE ARMADURA) + (BÔNUS DE ESCUDO) + (MOD. DE DESTREZA) + (MOD. DE TAMANHO) + (ARMADURA NATURAL) + (MOD. DE DEFLEXÃO) + (OUTROS)

TOQUE CLASSE DE ARMADURA **SURPRESA** CLASSE DE ARMADURA

INICIATIVA MODIFICADOR = (MOD. DE DESTREZA) + (OUTROS) **TOTAL** _____

FERIMENTOS / PVs ATUAIS _____

DANO POR CONTUSÃO _____

DESLOCAMENTO _____

REDUÇÃO DE DANO _____

TESTE DE RESISTÊNCIA	TOTAL	BÔNUS BASE	MOD. DE HABILIDADE	MOD. MÁGICO	OUTROS	MOD. TEMPORÁRIO	MOD. CONDICIONAIS
FORTITUDE (CONSTITUIÇÃO)	<input type="text"/>	= <input type="text"/>	+ <input type="text"/>	+ <input type="text"/>	+ <input type="text"/>	+ <input type="text"/>	<input type="text"/>
REFLEXOS (DESTREZA)	<input type="text"/>	= <input type="text"/>	+ <input type="text"/>	+ <input type="text"/>	+ <input type="text"/>	+ <input type="text"/>	<input type="text"/>
VONTADE (SABEDORIA)	<input type="text"/>	= <input type="text"/>	+ <input type="text"/>	+ <input type="text"/>	+ <input type="text"/>	+ <input type="text"/>	<input type="text"/>

BÔNUS BASE DE ATAQUE **RESISTÊNCIA A MAGIA**

AGARRAR MODIFICADOR = (BÔNUS BASE) + (MOD. DE FORÇA) + (MOD. DE TAMANHO) + (OUTROS) **TOTAL** _____

PERÍCIA	PERÍCIAS		GRADUAÇÃO MÁXIMA (CLASSE / OUTRA CLASSE)			
	NOME DA PERÍCIA	HABILIDADE CHAVE	MOD. DE PERÍCIAS	MOD. DE HABILIDADE	CONDIÇÃO	OUTROS
<input type="checkbox"/>	ABRIR FECHADURAS	DES	=	+	+	+
<input type="checkbox"/>	ACROBACIA	DES ^R	=	+	+	+
<input type="checkbox"/>	ADESTRAR ANIMAIS	CAR	=	+	+	+
<input type="checkbox"/>	ARTE DA FUGA	DES ^R	=	+	+	+
<input type="checkbox"/>	ÁTUAÇÃO (_____)	CAR	=	+	+	+
<input type="checkbox"/>	ÁTUAÇÃO (_____)	CAR	=	+	+	+
<input type="checkbox"/>	ÁTUAÇÃO (_____)	CAR	=	+	+	+
<input type="checkbox"/>	AVALIAÇÃO	INT	=	+	+	+
<input type="checkbox"/>	BLEFAR	CAR	=	+	+	+
<input type="checkbox"/>	CAVALGAR (_____)	DES	=	+	+	+
<input type="checkbox"/>	CONCENTRAÇÃO	CON	=	+	+	+
<input type="checkbox"/>	CONHECIMENTO (_____)	INT	=	+	+	+
<input type="checkbox"/>	CONHECIMENTO (_____)	INT	=	+	+	+
<input type="checkbox"/>	CONHECIMENTO (_____)	INT	=	+	+	+

Malcolm Gladwell - Outliers



O que um Cientista de Dados Precisa Saber?

ESTatística: coletar, organizar, analisar e interpretar dados, provar teoremas e manipular expressões algébricas

EST

O que um Cientista de Dados Precisa Saber?

SIStemas: ser proficiente em computação em geral, sabendo como usar diferentes programas e sistemas operacionais

EST

SIS

O que um Cientista de Dados Precisa Saber?

ALGORITMOS: ser capaz de traduzir procedimentos e instruções para a realização de uma tarefa em alguma linguagem de programação

EST

SIS

ALG

O que um Cientista de Dados Precisa Saber?

COMunicação: entender problemas de outras áreas e comunicar suas conclusões para outras pessoas

EST

SIS

ALG

COM

O que um Cientista de Dados Precisa Saber?

PERsistência: tentar diferentes maneiras de encarar os problemas, mesmo quando eles parecem sem solução

EST

SIS

ALG

COM

PER

O que um Cientista de Dados Precisa Saber?

SORte: estar no lugar certo e na hora certa
e ter as habilidades necessárias
quando esta hora chegar

EST

SIS

ALG

COM

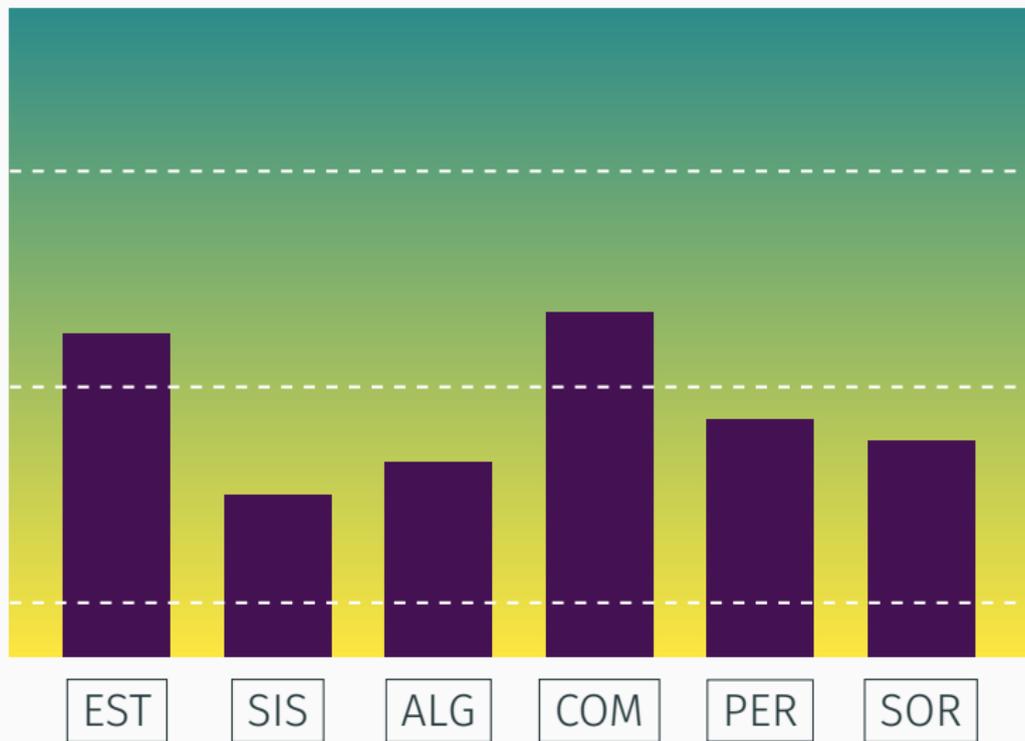
PER

SOR

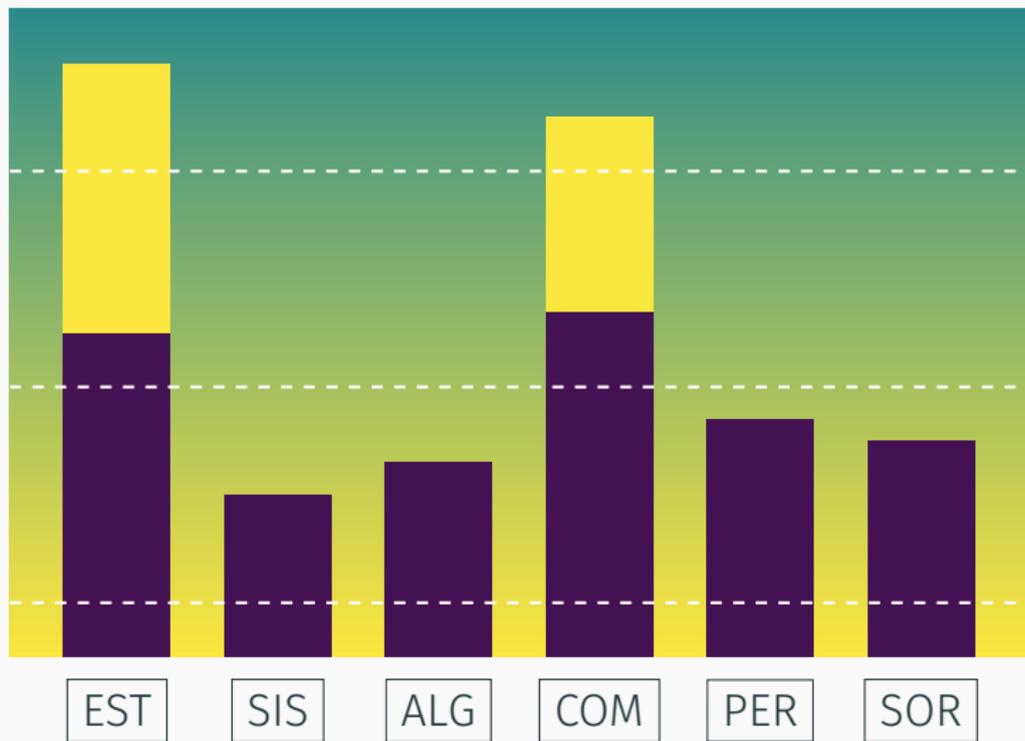
O que Eu Sei



Não é Bom Estar na Média



Seja Muito Bom em Algumas Áreas



Considerações Finais

Considerações Finais

- Dá pra fazer Ciência de Dados sozinho? Sim
- É melhor fazer em equipe? Evidentemente que sim
- Afinal, diferentes habilidades trarão conhecimentos diferentes para quem for trabalhar na área

Ciência de Dados e Multidisciplinaridade

II Seminário de Aplicações em Ciência de Dados

Marcus Nunes

7 de Dezembro de 2018

Universidade Federal do Rio Grande do Norte