

Tópicos em resultados preliminares

Análise Exploratória de Dados

Felipe Figueiredo

Instituto Nacional de Traumatologia e Ortopedia

Sumário

1 Análise Exploratória

- EDA
- Tabelas
- Figuras
- Exercício
- Resumo
- Referências

2 Aprofundamento

- Aprofundamento

Discussão da aula passada

Discussão da leitura obrigatória da aula passada

Evidências

"It is a capital mistake to theorize before one has data. Insensibly one begins to twist facts to suit theories, instead of theories to suit facts."

Sherlock Holmes

Estudos quantitativos requerem coleta e análise de dados

- EDA – Análise Exploratória de Dados
- CDA – Análise Confirmatória de Dados

- Formalizado por John W. Tukey nos anos 1970
- Objetivo: formular perguntas com base nos dados disponíveis
- Perguntas que podem ser respondidas pela análise dos dados

O que é

Uma filosofia/approach para

- insight sobre um dataset
- descobrir estruturas/padrões
- identificar variáveis importantes
- detectar outliers e anomalias

NIST Handbook (1998)

Do resumo...

“Ideas come from previous exploration more often than from lightning strokes. Important questions can demand the most careful planning for confirmatory analysis. (...) Finding the question is often more important than finding the answer. Exploratory data analysis is an attitude, (...) NOT a bundle of techniques (...).”

Tukey, 1980

Mapa



- 1 Um paradigma incompleto
- 2 Origem das ideias
- 3 Perguntas importantes
- 4 A investigação abrangente
- 5 Uma máxima
- 6 Análise confirmatória

Tukey, 1980

Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

Paradigma linear – incompleto



(*) question → design → collection →
analysis → answer

Este paradigma simplista presume que...

- Sabemos a pergunta “correta” no início
- Ignora questões importantes sobre o processo investigativo
 - Como as perguntas são geradas?
 - Como os desenhos (experimentais) são guiados?
 - Como a coleta de dados é monitorada?

Tukey, 1980

Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

Paradigma linear – incompleto



(*) question → design → collection →
analysis → answer

Como as perguntas são geradas?

Geralmente por *insights* teóricos e a exploração de dados anteriores (e.g., pesquisa bibliográfica)

Tukey, 1980

Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

Paradigma linear – incompleto



(*) question → design → collection →
analysis → answer

Como os desenhos (experimentais) são guiados?

Geralmente por informação qualitativa disponível obtida da exploração de dados anteriores

Tukey, 1980

Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

Paradigma linear – incompleto



(*) question → design → collection →
analysis → answer

Como a coleta de dados é monitorada?

Geralmente pela exploração dos dados, conforme são obtidos, buscando comportamento “inesperado”

Tukey, 1980

Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

Explorar...



- A chave então é explorar os dados
- Explorar antes, durante e depois da análise confirmatória
- Busca de pistas, ideias e eventualmente conclusões preliminares (*hipóteses!*)

Tukey, 1980

Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

A origem das ideias



(*) idea → $\left. \begin{array}{l} \uparrow \text{question} \\ \downarrow \text{design} \end{array} \right\} \rightarrow \text{collection} \rightarrow$
analysis → answer

Tukey sugere que:

- Antes de termos uma pergunta, temos uma ideia (a ser formalizada)¹
- Pergunta formal depende dos dados disponíveis
- Questão pragmática, independente do desejo ou vontade

Tukey, 1980

Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

A origem das ideias



Exemplo

- Ideia: uma certa droga ajuda em uma doença
- Queremos testar/confirmar isso...
- ... com consistência estatística na resposta

- Ideia preliminar informal, vaga
- Geralmente em termos de linguagem coloquial
- Não pode ser avaliada com suporte estatístico

Tukey, 1980

Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

¹ Assim como sua “proposta de pergunta 1/2”

A origem das ideias



Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

Desejo: pergunta geral, de amplo espectro e implicações profundas

Exemplo

“Dos pacientes que morreriam em até três anos desta doença, que proporção poderia ser salva por este tratamento?”

- Dificuldade técnica²...
- ... nenhum design pode isolar essas pessoas para um experimento

Tukey, 1980

²Neste exemplo, questão ética

A origem das ideias



Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

O que **pode** ser perguntado está limitado por:

- Idade e sexo dos pacientes
- conjunto mínimo de sintomas
- ausência de outras condições potencialmente fatais
- tipos de pacientes que podem ser encontrados/observados
- etc.

Tukey, 1980

A origem das ideias



Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

- o que pode concretamente ser perguntado
- que desenhos são viáveis
- chance de um certo design resultar em resposta útil

“Como eu estudo o que está acontecendo aqui?”

Tukey, 1980

Por onde começar?



Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

- tabelas
- gráficos dos dados brutos
- estatísticas descritivas simples
- procurar padrões

Exemplo

Table 2. Patient Clinical Characteristics

Characteristics	Median Sterotomy (n = 84)	Right Minithoracotomy (n = 119)	P Value
Patient characteristics:			
Age, years (median, IQR)	80 (78–84)	79 (77–83)	0.12
Males (%)	37 (44)	47 (39)	0.18
Body mass index (IQR)	26.2 (23.9–29.2)	26.5 (23.1–29.7)	0.95
Preoperative creatinine (IQR)	1.02 (0.87–1.3)	1.02 (0.86–1.25)	0.65
Ejection fraction (median, IQR)	0.55 (0.46–0.60)	0.58 (0.50–0.63)	0.29
Diabetes mellitus (%)	20 (23.8)	32 (26.9)	0.31
Hypertension (%)	80 (95.2)	109 (91.6)	0.62
Peripheral vascular disease (%)	8 (9.5)	7 (5.9)	0.33
Cerebrovascular disease (%)	9 (10.7)	19 (16)	0.29
Prior coronary bypass graft surgery (%)	10 (11.9)	12 (10.1)	0.68
Prior valve surgery (%)	8 (9.5)	8 (6.7)	0.47
Prior heart failure (%)	47 (56)	43 (36.1)	0.005
Procedural characteristics:			
Mitral valve surgery	49%	51%	0.75
Aortic valve surgery	51%	49%	0.75
Cardiopulmonary bypass time minutes (IQR)	86 (39–268)	118 (67–186)	<0.001
Cross-clamp time minutes (IQR)	61 (25–156)	84 (40–154)	<0.001

IQR = interquartile range.

Lamelas, et al; 2011

Tabelas

Exemplo

Pacientes que tem uma enfermidade grave, podem ser submetidos a um tratamento cirúrgico.

	Óbito	não óbito	Total
Cirurgia	3	1	4
não cirurgia	2	5	7
Total	5	6	11


Exercício

Formule uma pergunta sobre este contexto.

Histograma


- Gráfico de barras com frequências dos dados
- visualização prática da distribuição dos dados
- identificar simetria, tendência central, dispersão, etc

Exemplo




Behrens, Yu (2003)

- Mensurações mais frequentes no centro
- Mensurações altas/baixas menos frequentes...
- ... com frequências semelhantes (simetria)
- Ideia da variabilidade das mensurações ("largura")



Distribuições de dados podem ter várias formas




Boxplot

- Mensurações feitas em dois ou mais grupos³
- caixa que contém 50% dos dados. . .
- . . . e segmentos verticais que englobam a maior parte dos dados
- mensurações fora dos limites \Rightarrow investigar possíveis outliers⁴
- Ideal para grandes quantidades de dados

Dotplot

Exemplo



³ e.g., exposição/tratamento 1, tratamento 2, controle...

⁴ erros de mensuração, imputação, viés de seleção/amostragem, observações raras...?

Boxplot




Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

Exemplo



Behrens, Yu (2003)




Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento



Gráficos de dispersão



Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

- visualizar os dados pontuais diretamente
- identificar possíveis padrões ou tendências
- identificar visualmente possíveis outliers
- desenhar possíveis relações (modelos) sobre os dados

A álgebra mente...

... portanto figuras são necessárias

Behrens, Yu (2003)




Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento


Datasets didáticos de Anscombe, 1973




Quatro datasets com perfis completamente diferentes \Rightarrow mesma reta de melhor ajuste

Behrens, Yu (2003)
NIST Handbook (1998)


- Relação "claramente" linear...
- ... alguma dispersão
 - Não há justificativa para um modelo mais complexo (quadrático, etc...)
- Não há outliers
- Distância vertical à reta (Y) semelhante ao longo da faixa (X)
 - Não é necessário aplicar ponderações ou transformações



- Relação claramente não é linear
- Relação "claramente" quadrática




- "Claramente" possui um outlier
- ... que "puxa" a reta para cima



- CLARAMENTE vítima de um desenho experimental infeliz^a
- Um único ponto afastado do cluster de dados
- "cauda abanando o cachorro"

^aNão assistiu a aula de Planejamento/Protocolo



RESUMO

Objetivos: Mensurar em exames de ressonância magnética (RM) o tamanho da origem, a inserção e o comprimento do ligamento cruzado anterior (LCA) e seus possíveis enxertos para cirurgia de reconstrução em caso de lesão. Além desse, fez-se o cruzamento estatístico entre os dados para testar a hipótese de relação proporcional entre essas medidas anatômicas.

Materiais e métodos: Foram feitos 52 exames de RM entre 2008 e 2011 e avaliados de maneira aleatória em um estudo epidemiológico longitudinal retrospectivo. Para a mensuração da largura do LCA foi usado o corte coronal oblíquo, para o comprimento o corte sagital, para a inserção tibial o corte coronal e para a inserção femural o corte coronal oblíquo.

REV BRAS ORTOP. 2013;48(5): 441-447

Artigo Original

Enxerto ideal para ligamento cruzado anterior: correlação em ressonância magnética entre LCA, isquiotibiais, tendão patelar e tendão quadríceps[☆]


Fabiano Kupczik^a, Marlus Eduardo Gunia Schiavon^b, Bruno Sbrissia^b, Rodrigo Caldonazzo Fávaro^b e Rafael Valério^{c,*}

Tabela 2 – Correlação LCA e tendão patelar

Variável	Coef. correl.	Valor de p
LCA fêmur		
T. patelar LL	0,438	0,001
T. patelar AP	0,283	0,042
LCA tibia		
T. patelar LL	0,233	0,096
T. patelar AP	0,173	0,221
LCA largura		
T. patelar LL	0,415	0,002
T. patelar AP	0,099	0,487
LCA comprimento		
T. patelar LL	0,451	0,001
T. patelar AP	0,476	<0,001

AP, ântero-posterior; LCA, ligamento cruzado anterior; LL, látero-lateral.

Que pergunta este gráfico lhe motiva?



dados simulados com base no artigo


Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

O Gênero parece influenciar?



dados simulados com base no artigo


Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

E a idade?



dados simulados com base no artigo

Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

Resumo



- 1 Não há escolha entre exploratória OU confirmatória – ambas são importantes
- 2 É preciso pensar em ciência no sentido amplo, e não no paradigma linear
- 3 Para uma confirmação adequada, precisamos de um desenho cuidadosamente randomizado
- 4 Pensar em exploratória como uma atitude, não apenas como um conjunto de técnicas – e usá-la antes da confirmatória

Tukey, 1980

Tópicos em resultados preliminares

Felipe Figueiredo

Análise Exploratória
EDA
Tabelas
Figuras
Exercício
Resumo
Referências

Aprofundamento

- Tukey (1980), We need both exploratory and confirmatory, <http://www-ece.rice.edu/~fk1/classes/ELEC697/TukeyEDA.pdf> (Acessado em 10/09/2015)
- NIST Handbook (1998), Exploratory Data Analysis, cap 1 – <http://www.itl.nist.gov/div898/handbook/eda/section1/eda1.htm> (Acessado em 10/09/2015)
- Behrens, Yu (2003), Exploratory Data Analysis, cap 2 – Research Methods in Psychology

Leitura obrigatória

Não há.

Leitura recomendada

Tukey (1980), We need both exploratory and confirmatory, <http://www-ece.rice.edu/~fk1/classes/ELEC697/TukeyEDA.pdf> (Acessado em 10/09/2015)