

Introdução à Inferência Causal

IBM0288 - 2026.2

Prof. Raphael Gouvea

1 Para reflexão



Hisrael Passarelli ✓ • 2º

Consultor sênior em análise de dados | Especialista em est...

3 sem • 🔒

[+ Seguir](#) ...

Uma coisa que aprendi transitando entre universidade, setor público e projetos com organizações privadas: a academia ensina a fazer a pergunta certa; o mercado ensina a responder no tempo certo.

Formação em pesquisa te obriga a estruturar o problema antes de rodar qualquer modelo:

o que exatamente queremos saber?

para quem essa resposta importa?

o que muda dependendo do resultado?

No trabalho aplicado, isso faz ainda mais diferença, porque as decisões não esperam a análise perfeita. Ter clareza sobre a pergunta evita horas de código desnecessário e aumenta muito a chance de a análise ser realmente usada.

Nem sempre o gargalo está na técnica ou no modelo estatístico escolhido. Muitas vezes, está na pergunta.



2 Pesquisa Empírica: perguntas e objetivos

- Responder perguntas sobre como o mundo funciona usando dados.
- Produzir respostas **claras, úteis e interpretáveis e precisas.**

- Ir além de descrições: buscar evidência sistemática.

3 Modelos e Causalidade

Um dos principais objetivos da pesquisa econômica é realizar inferências causais, ou seja, fazer inferência de relações de causa e efeito.

Qual é o papel dos modelos nesse processo?

- uma visão (por exemplo, Heckman): a causalidade é baseada em teoria, ou seja, a causalidade só existe **dentro da estrutura de uma teoria** que diz “x causa y”.
- uma visão oposta (por exemplo, Holland): a causalidade é baseada em desenho de pesquisa, ou seja, uma afirmação de causalidade exige que seja possível **realizar uma manipulação** na qual “x causa y”.

4 Inferência causal: uma definição

“Causal inference is the leveraging of **theory** and deep **knowledge of institutional details** to **estimate the impact** of events and choices on a given **outcome of interest**.”

Fonte: Cunningham [p. 4.]

5 Credibility Revolution

“Empirical microeconomics has experienced a **credibility revolution**, with a consequent increase in **policy relevance and scientific impact**. Sensitivity analysis played a role in this, but as we see it, the **primary engine driving improvement** has been a focus on the quality of **empirical research designs**.”

Fonte: Angrist e Pischke (2009) [p. 3]

6 Desenho de pesquisa: definição

- Um desenho de pesquisa (causal) é uma descrição estatística e/ou econômica de como um artigo empírico estimará a relação entre duas (ou mais) variáveis que é de natureza causal: como X causa Y?

- Como veremos logo mais, obter estimativas de efeitos causais exigem a estimação de um **contrafactual não observável**: um desenho de pesquisa descreve **quais pressupostos** são necessários para estimar contrafactuais para um determinado modelo estatístico.
- Como discutiremos em aula, esses desenhos de pesquisa podem ser divididos em dois tipos de pressupostos:
 - baseados em modelos: identificação obtida por pressupostos sobre a modelagem dos resultados potenciais.
 - baseados em desenho: identificação obtida por pressupostos sobre variável de tratamento.

7 Identificação:

Identificação é o processo de determinar **qual parte da variação dos dados** responde à sua pergunta de pesquisa.

- Garante que o cálculo realizado **isole um único mecanismo teórico de interesse**.
- Evita interpretações enganosas: separa o que realmente importa do que é apenas ruído.

Qual o papel da identificação no processo científico:

- Pergunta de pesquisa leva da teoria à hipótese garantindo que a hipótese testada seja relevante para a teoria.
- Identificação leva da hipótese aos dados, garantindo que estamos testando a hipótese correta nos dados e evitando testar, inadvertidamente, outra hipótese.

8 Exemplo de visão ingênua sobre identificação e causalidade

- Alienígenas estimam um modelo mostrando que existe correlação sistemática entre mortes por COVID e ventiladores mecânicos.

- Eles concluem que os médicos estão matando os pacientes com os ventiladores. Logo, eles vêm à Terra para libertar os pacientes, piorando a situação.
- O erro dos alienígenas foi que eles confundiram correlação com causalidade. Pior que isso: eles não entenderam como o mundo funciona.

...

⚠ Aviso

Nós somos os alienígenas nas nossas pesquisas!

9 Causalidade e correlação não são a mesma coisa

- Pergunta causal: “Se o médico colocar o paciente no ventilador mecânico (D), os sintomas do paciente irão melhorar (Y)?”
- Correlação: $\rho_{D,Y} = \frac{\text{Cov}(D,Y)}{\sigma_D \sigma_Y}$
- Erros são extrapolados em modelos preditivos que não se baseiam em abordagens causais.

10 Antecedência não significa causalidade

- Toda manhã o galo canta quando o sol nasce
- O cantar do galo fez o sol nascer? ou O nascer do sol fez o galo cantar?
- E se uma raposa comer o galo?

11 Causalidade pode mascarar correlações




...

💡 Otimização e endogeneidade


O que aconteceria se o BACEN conseguisse antecipar e otimizar com 100% de precisão a política monetária?

12 E o curso?


Identification




Randomized Controlled Trials (RCTs)




Instrumental Variables ?




Fixed Effects ?




Probit




Difference-in-Differences




Regression Discontinuity ?



Event Studies ?



Machine Learning



Fonte: Economics Literature Search

13 Intervalo (5min)

14 Resultados Potenciais: modelo de Rubin




Figura 1: O caminho não escolhido

15 Tudo o mais constante...

Qual o impacto ou efeito causal de um determinado programa sobre uma variável de resultado de interesse?

- Necessário observar **a mesma unidade de observação** (pessoa, firma, etc) em dois estados da natureza: tratado e não tratado.
- Porém, só é possível observar **um dos estados** para cada unidade!
 - pelo menos não ao mesmo tempo e exatamente sob as mesmas circunstâncias.

16 Resultados Potenciais

Para cada unidade (indivíduo, firma, país, etc.) i em uma população, definimos dois *resultados potenciais*:

- Y_{i1} : resultado para a unidade i se ela recebesse o tratamento
- Y_{i0} : resultado para a unidade i se ela **não** recebesse o tratamento (controle)

! Resultados potenciais são contrafactuais

Para um dado indivíduo, apenas um dos resultados potenciais pode ser observado!

17 Atribuição de Tratamento

Seja D_i uma variável binária que indica o status de tratamento da unidade i :

- $D_i = 1$: a unidade i recebeu o tratamento
- $D_i = 0$: a unidade i **não** recebeu o tratamento (controle)

! Resultados observado

O resultado observado para a unidade i , denotado por Y_i , depende dos resultados potenciais e do status de tratamento: $Y_i = D_i Y_{i1} + (1 - D_i) Y_{i0}$

...

- Observamos Y_{i1} se $D_i = 1$
- Observamos Y_{i0} se $D_i = 0$

18 Efeito Tratamento Individual

- O efeito causal do tratamento para a unidade i é definido como: $\tau_i = Y_{i1} - Y_{i0}$
- É o efeito que **gostaríamos** de conhecer para cada unidade

! O efeito tratamento individual é não observável

Não é possível observar τ_i diretamente, pois apenas um dos resultados potenciais é observado para cada unidade.

19 Efeito Tratamento Médio (ATE)

- Existe uma distribuição dos efeitos de tratamento
- Podemos trabalhar com características dessa distribuição, como a média
- Interesse em estimar o **efeito tratamento médio**: $ATE = E[Y_1 - Y_0] = E[\tau_i]$
- Representa a diferença esperada nos resultados se toda a população recebesse o tratamento versus se ninguém recebesse

20 Efeito Tratamento Médio no Grupo Tratado (ATT)

- ATT: $ATT = E[Y_1 - Y_0 \mid D = 1]$
- Efeito médio do tratamento para aqueles que realmente receberam o tratamento

- Útil em avaliações de políticas
- Mede o efeito sobre os realmente afetados

21 Efeito Tratamento Médio no Grupo dos Não Tratados (ATU)

- ATU: $ATU = E[Y_1 - Y_0 \mid D = 0]$
- Efeito médio do tratamento para aqueles que não receberam o tratamento
- Menos intuitivo, mas importante para entender hipóteses de viés de seleção.

22 O Problema Fundamental da Inferência Causal

Não observamos os resultados contrafactuais, pois para qualquer unidade i , observamos:

- $Y_i = Y_{i1}$ se $D_i = 1$
- $Y_i = Y_{i0}$ se $D_i = 0$

Como nunca observamos ambos simultaneamente, não podemos calcular $\tau_i = Y_{i1} - Y_{i0}$ para nenhuma unidade específica.

...

💡 Necessidade de hipóteses

Inferir efeitos causais requer **hipóteses** adicionais (baseadas em modelos ou desenho, ver slide Seção 6)!

23 Suposições Chave para Identificação

SUTVA (Stable Unit Treatment Value Assumption): garante que os resultados potenciais sejam bem definidos

Não Interferência

- O tratamento de uma unidade não afeta os resultados potenciais de outra unidade
- Y_{i1} e Y_{i0} não dependem do tratamento de outras unidades
- Não existem *spillovers* ou efeitos de rede

Consistência do Tratamento

- Não há diferentes versões do tratamento
- $D_i = 1$ e $D_i = 0$ significam a mesma coisa para todas as unidades tratadas

24 Não-confundimento (Unconfoundedness) ou Independência Condicional

- Suposição crucial para identificação em muitos métodos causais:

$$(Y_{i0}, Y_{i1}) \perp D_i \mid X_i$$

- Condicionando em X_i , o tratamento é “como se fosse aleatório”
- Diferenças médias entre tratados e não tratados dentro de cada estrato de X_i podem ser atribuídas ao tratamento
- Sem essa suposição, a seleção para tratamento depende de fatores que também afetam os resultados
- Isso gera *viés de seleção*!