

Journal Club em Causalidade Reunião 2

Statistics and Causal Inference – P. Holland

Widemberg da Silva Nobre, PhD

Pós-doc FAPESP - 2021/06057-0

INSPER

Instituto de Ensino e Pesquisa

24 de setembro de 2021

Introdução

- ▶ Neste encontro, o objetivo é entender um pouco da filosofia por trás do paradigma causal
- ▶ Esqueçamos a existência de dados e problemas de estimação, e foquemos no problema físico de interesse
- ▶ Ao introduzir alguns conceitos, esperamos deixar clara a diferença entre inferir associações e inferir causalidade

Modelagem de associações

- ▶ Construção do problema
- ⇒ Existência de uma população (ou universo) U
- ⇒ Possibilidade de atribuir variáveis à toda unidade de U , ou seja, atribuir uma função real para cada unidade em U
- ▶ A população e as variáveis definidas para cada unidade são os elementos básicos para inferir associação e causalidade
- ▶ Seja Y a variável de interesse científico, e $Y(u)$ o valor associado à unidade u
- ⇒ Por interesse científico, sugere-se que desejamos entender como os valores de Y variam entre as unidades em U
- ▶ Considere A uma segunda variável definida sobre as unidades de U .
- ⇒ Por simplicidade, considere que A corresponda a um atributo das unidades em U

- ▶ Todo cálculo de probabilidades, distribuições e valores esperados envolvendo as variáveis estão relacionadas ao universo U
- ⇒ Como exemplo, o valor esperado de uma variável é simplesmente a média dos valores associados a todas unidades de U
- ⇒ Valores esperados condicionais são médias sobre o subconjunto de unidades definido pelos valores da variável condicionante
- ▶ Desenho temporal dos dados
- ⇒ Quando falamos de inferir associações, o desenho temporal dos dados não parece ser de suma importância. Em particular, ele apenas afeta a interpretação operacional dos dados
- ⇒ Em contrapartida, no contexto de inferência causal, o desenho temporal tem papel primordial na discussão das quantidades de interesse (como princípio básico, temos que toda causa deve preceder o efeito)

- ▶ Parâmetros de associação são determinados pela distribuição conjunta $P(Y = y, A = a)$
- ▶ Um parâmetros de associação típico é a esperança condicional $E(Y|A = a)$ (modelo de regressão usual)
- ▶ Inferir associações consiste em realizar inferência estatística sobre os parâmetros da relação entre Y e A com base naquilo que foi observado

Modelo causal de Rubin

- ▶ Também presume uma população composta por unidades
- ⇒ Unidades são objetos cujas “causas” ou “tratamento” podem agir
- ▶ Como ponto crítico, sugere-se que cada unidade possa potencialmente ser exposta a qualquer possível valor da “causa”
- ▶ Como exemplo, bolsa de estudos pode ser interpretado como uma “causa” na performance de um teste, enquanto o gênero do estudante não pode (por quê?)
- ▶ Consideremos, por simplicidade, um tratamento com apenas dois valores possíveis (t para tratamento e c para controle)
- ⇒ $S = t$ indica que a unidade u é exposta a t ; enquanto $S = c$ indica que a unidade u é exposta à c

- ▶ Em um estudo controlado, S é construído pelo pesquisador, enquanto em estudos não-controlados, S é definido por fatores que vão além do pesquisador (potenciais confundidores)
 - ▶ A diferença entre S e A é que $S(u)$ indica a exposição de u a uma causa específica, enquanto $A(u)$ pode indicar uma propriedade ou característica de u . Sugerindo que o valor de $A(u)$ pode ser inalterável (não manipulável)
 - ▶ No contexto causal de Rubin assume-se que a variável resposta Y deve ser temporalmente observada após a exposição
 - ▶ A premissa da manipulação do valor de S em conjunto com a premissa temporal de observação da unidade resposta sugere a existência de duas variáveis respostas $Y_t(u)$ e $Y_c(u)$
- ⇒ A quantidade $Y_t(u)$ (ou $Y_c(u)$) é interpretada como o potencial valor que a variável resposta iria tomar caso a unidade u fosse exposta a t (ou c)

- ▶ O efeito do tratamento na unidade u quando medido através de Y é definido como

$$Y_t(u) - Y_c(u)$$

- ▶ **O problema Fundamental da Inferência Causal:** É impossível observar os valores $Y_t(u)$ and $Y_c(u)$ simultaneamente na mesma unidade e, portanto, é impossível calcular o efeito do tratamento na unidade u
- ▶ Existem duas possíveis soluções gerais para este problema (nomeadas pelo autor do artigo)
 1. Solução científica
 2. Solução estatística

- ▶ A solução científica explora conceitos de homogeneidade e invariância
- ▶ A solução estatística considera o Average Causal Effect (ACE), definido como o valor esperado da diferença $Y_t(u) - Y_c(u)$ sobre as unidades de U

$$\tau = E(Y_t(u)) - E(Y_c(u))$$

O ACE é também conhecido por average treatment effect (ATE)

- ▶ O cálculo de τ é sensível ao desenho experimental
- ▶ A solução estatística transforma o problema “impossível observar” em uma questão de estimação possível de resolver

► Como resumo, temos

1. A inferência de associações envolve a distribuição conjunta ou condicional de Y e A
2. Inferência causal concerne calcular $Y_t(u) - Y_c(u)$ para cada unidade. Uma vez que esse cálculo é impossível de ser feito, são necessárias suposições (não-testáveis) para que, através dos dados observados, seja possível contornar o problema fundamental da inferência causal
3. Inferência causal não necessariamente envolve inferência estatística, enquanto inferência de associações sempre envolve

Inferência Causal: Casos especiais

- ▶ Aplicação da solução científica
1. Cenários onde existe estabilidade temporal para $Y_c(u)$ e que $Y_t(u)$ não seja afetado por valores prévios do tratamento
 2. Cenários onde existe homogeneidade entre as unidades

Inferência Causal: Casos especiais

▶ Aplicação da solução estatística

1. Experimentos aleatorizados

- ⇒ Embora queiramos contrastar $E(Y_t)$ and $E(Y_c)$, os dados observados somente nos fornecem informação acerca

$$E(Y_S|S = t) = E(Y_t|S = t) \text{ e } E(Y_S|S = c) = E(Y_c|S = c)$$

Note que $E(Y_t|S = t) \neq E(Y_t)$. $E(Y_t)$ é o valor médio de $Y_t(u)$ para toda unidade u em U , enquanto $E(Y_t|S = t)$ é o valor médio de $Y_t(u)$ no subgrupo das unidades expostas ao tratamento

- ⇒ Quando a atribuição do tratamento para cada unidade é feita de forma aleatorizada, teremos
- $$E(Y_S|S = t) = E(Y_t)$$

2. Efeito constante

⇒ O efeito do tratamento é o mesmo para toda unidade

$$Y_t(u) = \tau + Y_c(u), \text{ for all } u$$

3. Experimentos não-aleatorizados (problemas de confundimento)

⇒ Covariáveis que afetam tratamento e resposta de forma simultânea

⇒ Veremos como lidar com esse problema nas reuniões 4 e 5

Comentários de alguns estatísticos

- ▶ Kempthorne (1952), em uma discussão sobre desenhos em blocos aleatorizados, introduziu o termo *yield* e fez a seguinte citação

In fact we do not observe the yield of treatment k on plot j but merely the yield of treatment k on a randomly chosen plot in the block. ... we denote the observed yield of treatment k in block i by y_{ik} .

- ⇒ Esse desenho abre uma porta para a interpretação de múltiplas versões da unidade resposta, Y_t e Y_c , assim como é no desenho causal de Rubin

- ▶ Considerando um experimento com dois tratamentos, T_1 e T_2 , David Cox (em 1958) definiu o *true treatment effect* como a diferença entre “the observation obtained on any unit when, say, T_1 is applied” e “the observation that would have been observed had, say T_2 been applied”
- ▶ Fisher nunca trabalhou o contexto de múltiplas versões da unidade resposta, embora tenha chegado perto ao discutir hipótese nula e aleatorização
- ▶ Em contrapartida, em 1935 Neyman promoveu explicitamente a ideia de múltiplas versões da unidade resposta; embora fale sobre erros associados à falta de acurácia do experimento agindo sobre a unidade resposta

O que pode ser uma causa?

► Observemos as três afirmações a seguir

A She did well on the exam because she is a woman

B She did well on the exam because she studied for it

C She did well on the exam because she was coached by her teacher

O que pode ser uma causa?

- ▶ Observemos as três afirmações a seguir

A She did well on the exam because she is a woman

B She did well on the exam because she studied for it

C She did well on the exam because she was coached by her teacher

- ▶ Em A, relaciona-se o fato dela ter ido bem no exame com o atributo dela ser mulher
- ▶ Em B, relaciona-se o fato dela ter ido bem no exame com a atividade voluntária (e não imposta ou manipulável) de estudar para o exame
- ▶ Em C, relaciona-se o fato dela ter ido bem no exame com uma atividade que foi imposta a ela

Causalidade de Granger

- ▶ Causalidade de Granger: Granger formulou sua teoria em torno da ideia de predição

“A cause ought to improve our ability to predict an effect in a probabilistic system.”

Na teoria de Granger, A causa B no sentido que os valores da variável A ajudam a prever valores futuros da variável B

- ▶ No encontro de Bad controls nós veremos que o fato de A ajudar na predição de B , não necessariamente garante que A causa B no sentido dos modelos de Rubin
- ▶ A interpretação causal de Granger não corrobora com um ambiente manipulável como visto na abordagem causal de Rubin

Resumo

- ▶ Associações derivam de um modelo conjunto, enquanto causalidade deriva de um experimento manipulável
- ▶ Em causalidade, o ambiente manipulável nos induz a ter múltiplas versões de uma unidade resposta, a saber Y_t e Y_c
- ▶ Exceto em alguns casos específicos, não temos porque assumir $E(Y_S|S = t) = E(Y_t)$; O experimento tem papel fundamental nessa discussão
- ▶ O ambiente manipulável revela a importância de discutirmos o que pode ser uma causa

- ▶ No próximo encontro iremos formalizar a linguagem causal em termos da proposta de Judea Pearl. Dois pontos de destaque:
 1. O contexto manipulável nos remeterá a procedimentos de intervenção em Directed Acyclic Graphs (DAGs) e estará linkado ao que chamaremos de *do operator*
 2. A identificação de efeitos causais estará usualmente linkado ao critério *backdoor*