

# Avaliação de Políticas Públicas II: Métodos não experimentais

Paula Pereda (USP)

October 30, 2020

# Aula 3

[voltar](#)

# Resumo da Aula 2

## 1. Métodos para Seleção nas Observáveis

### 1.1 Análise de Regressão:

- ▶ CIA é a hipótese de média condicional zero (elimina viés de seleção)
- ▶ Vantagens: efeito médio, simples, heterogeneidades
- ▶ Desvantagens: forma funcional, falta de suporte comum

### 1.2 Modelo de Seleção de Heckman\*:

- ▶ Primeiro a estimar equação de seleção
- ▶ instrumentaliza a seleção e considera correlação entre eqs

### 1.3 Análise usando Propensity Score

- ▶ Eliminar desbalanceamento dos grupos
- ▶ reduz dimensionalidade das covariadas
- ▶ seleção nas observáveis  $\equiv$  Seleção no propensity

## 2. Testes de Balanceamento

# Teste de Balanceamento

- ▶ Teste Bivariado
- ▶ Teste de Distribuição (Kolmogorov-Smirnov)
- ▶ **Teste Ranksum (Wilcoxon-Mann-Whitney)**

Lousa

# Teste de Balanceamento e Análise de PS

- ▶ Teste de Balanceamento com amostra inicial
  - ▶ Se rej  $H_0$ , há desbalanceamento na variável, potencial inclusão no propensity score
- ▶ Realizar a Análise usando PS
- ▶ Repetir o teste de balanceamento após o uso do PS
  - ▶ Se não rej.  $H_0$ , PS resolveu a diferença entre os grupos
  - ▶ Se rej.  $H_0$ , reestruturar a análise até eliminar desbalanceamento (veremos os procedimentos de “bias correction” também)

# Estimando Propensity Scores

- ▶ Especificação do PS é crucial para identificar ATT/ATE
- ▶ Heckman 97 e 98: Relevância teórica das covariadas
- ▶ Para a estimação dos PS, podemos usar modelos de probabilidade:
  - ▶ Probit
  - ▶ Logit
  - ▶ Log da Odds Ratio
- ▶ Nos modelos de probabilidade:  $w_i$  é a dummy de tratamento;  $X_i$  o vetor de covariadas; e  $\beta$  o vetor de parâmetros.
- ▶ Estimação por Máxima Verossimilhança

# Estimando Propensity Scores por Odds Ratio

Como  $E(w_i) = P(w_i/X_i = x_i) = \frac{e^{x_i\beta}}{(1+e^{x_i\beta})}$ , podemos linearizar o modelo:

$$\ln\left(\frac{p}{1-p}\right) = x_i\beta + \varepsilon_i$$

t.q.  $p = P(w_i = 1)$ .

Estima-se por MLE (Newton-Raphson Method) ou OLS

# Estratégias para Especificação Correta do PS

- ▶ Melhor  $P(x)$ : Bom balanceamento entre os 2 grupos nas covariadas ( $X_1, X_0$ ).
- ▶ Usar muitos  $X$ 's: piora o problema de suporte comum (McCaffrey et al 2004)
- ▶ Estratégias para escolha de  $X$  e forma funcional: data-driven vs estruturais
  - ▶ data-driven: stepwise com cutoff para  $t$  (Rosenbaum e Rubin, 1984; Rosenbaum e Rubin, 1985; Dehejia Wahba, 1999, Hirano e Imbens, 2001).
  - ▶ estruturais: Heckman (literatura econômica + objetivos da política)



# Após estimação de PS

1. Parear observações usando  $e(x)$ : PS Matching
2. Estratificar amostra usando  $e(x)$ : PS Estratificado
3. Analisar  $Y$  usando pesos em função de  $e(x)$ : PS Weighting
4. Usar métodos combinados

# PS Matching

- ▶ Encontrar contrafactuais para tratados: Observações com probabilidades similares
- ▶ Método mais comum: Matching local (greedy)
- ▶ Várias métricas de pareamento

# PS Matching: Tipos de Pareamento

## 1) Métrica de Mahalanobis

- ▶ Ordena aleatoriamente participantes
- ▶ Calcula distância Mahalanobis entre as covariadas do 1o tratado e demais controles (j):  $d_{ij} = (X_1 - X_0)' V_{n \times n}^{-1} (X_1 - X_0)$ , em que  $X_1$  e  $X_0$  são as covariadas dos grupos de trat e controle, respectivamente, e  $V$  é a matriz de var-cov amostral das variáveis para toda a amostra
- ▶ Escolhe par de  $i$  com base em  $j$  de menor distância
- ▶ Retira par escolhido da amostra
- ▶ Repete o procedimento até que todos  $i$ 's estejam pareados
- ▶ Matching 1-1

Ilustração: Lousa

# PS Matching: Tipos de Pareamento

## 2) Métrica de Mahalanobis usando $e(x)$

- ▶ Mesmo procedimento usando  $e(x)$  no lugar de  $X$

## 3) Pareamento por vizinho mais próximo (NN)

- ▶ Sejam  $e_i$  e  $e_j$  as medidas de propensity score de tratados e controles, respectivamente, e  $I_1$  e  $I_0$  os conjuntos dos tratados e controles
- ▶ Uma **vizinhança**  $c(e_i)$  contém um participante  $i$  tratado ( $i \in I_1$ ) e um não tratado  $j$  ( $j \in I_0$ ) como par de  $i$  se a diferença absoluta dos  $e$ 's é a menor entre todos os possíveis pares de  $i$  e  $j$ :

$$c(e_i) = \text{Min}_j |e_i - e_j|$$

- ▶ Uma vez encontrado o par, as observações são retiradas da amostra e repete-se o processo

# PS Matching: Tipos de Pareamento

## 4) Caliper Matching: Pareamento com threshold

- ▶ NN pode gerar vizinhos distantes
- ▶ Podemos estipular uma tolerância ( $\epsilon$ ) para a vizinhança
- ▶  $j$  é vizinho de  $i$  se  $|e_i - e_j| < \epsilon$
- ▶ RR85 sugerem  $\epsilon < 0,25\hat{\sigma}_e$ , em que  $\hat{\sigma}_e$  é o erro-padrão amostral de  $e$

## 5) Vizinho mais próximo com threshold

- ▶ 3) + 4)

# PS Matching: Tipos de Pareamento

## 6) Vizinho mais próximo com threshold usando métrica de Mahalanobis

- ▶ Ordena aleatoriamente participantes
- ▶ Seleciona o primeiro tratado
- ▶ Encontra  $j$  tratados (dentro do threshold)
- ▶ Calcula distância Mahalanobis entre as  $e(x)$  dos participantes
- ▶ Escolhe par de  $i$  com base em  $j$  de menor distância
- ▶ Remove-se o par e repete-se o procedimento até que todos  $i$ 's estejam pareados
- ▶ Matching 1-1

Segundo RR85, 6) produz o melhor balanceamento entre as covariadas

# PS Matching

## Observações

- ▶ Todas as métricas e exemplos que vimos são de **matching local** (decisões ótimas localmente): Veremos exemplo de matching global
- ▶ Robustez: Testar diferentes thresholds e diferentes X's
- ▶ Pode ainda haver problema de suporte comum: TRIMMING

# Procedimento de Trimming

- ▶ Selecionar subamostra com maior sobreposição entre grupos
- ▶ Validade externa X Validade interna
- ▶ Ideia: quando  $e(x) \rightarrow 1$  ou  $e(x) \rightarrow 0$ , não há contrafactual
- ▶ Desafio: encontrar cutoff que determine o que é  $e(x) \rightarrow 1$  ou  $e(x) \rightarrow 0$



# Procedimento de Trimming

Caso 1:  $X$  binária (mais simples) Sejam

$X_i = f$ , se  $i$  é mulher  
m, se  $i$  é homem,

- ▶ População:  $N = N_f + N_m$
- ▶  $q$  é o share da população em que  $X_i = m$ :  $q = E(N_m/N)$
- ▶ Efeitos médios:  $ATE|_{X_i=x} = \tau(x)$  e, na população,  
 $ATE = (1 - q)\tau(f) + q\tau(m)$ .
- ▶ Números de controle e tratados com  $X_i = x$ :  
 $N_{cx} = \sum_{i: X_i=x} (1 - w_i)$  e  $N_{tx} = \sum_{i: X_i=x} (w_i)$
- ▶ Então o PS é:  $e(x) = N_{tx}/N_x$ , ou  $e(f) = N_{tf}/N_f$  e  $e(m) = N_{tm}/N_m$

# Procedimento de Trimming

## Caso 1: X binária (mais simples), cont.

- ▶ A média amostral das duas subpopulações é

$$\bar{Y}_{cx} = 1/N_{cx} \sum_{i: X_i=x} Y_i(1 - w_i)$$

$$\bar{Y}_{tx} = 1/N_{tx} \sum_{i: X_i=x} Y_i(w_i)$$

- ▶ Sendo  $V(Y_i(w)|X_i = x) = \sigma^2 \forall x, w$

$$\hat{\tau}(f) = (\bar{Y}_{tf} - \bar{Y}_{cf}) \text{ e } NV(\hat{\tau}(f)) \rightarrow \left( \frac{\sigma^2}{1 - q} \frac{1}{ef(1 - ef)} \right)$$

$$\hat{\tau}(m) = (\bar{Y}_{tm} - \bar{Y}_{cm}) \text{ e } NV(\hat{\tau}(m)) \rightarrow \left( \frac{\sigma^2}{q} \frac{1}{em(1 - em)} \right)$$

# Procedimento de Trimming

## Caso 1: X binária (mais simples), cont.

- ▶ Portanto,

$$\hat{\tau} = (N_f/N)\hat{\tau}(f) + (N_m/N)\hat{\tau}(m) \text{ e}$$
$$NV(\hat{\tau}) \rightarrow \sigma^2 \left( \frac{q}{em(1-em)} \frac{1-q}{ef(1-ef)} \right)$$

- ▶ Quando  $e(f) \rightarrow 1$  ou  $e(f) \rightarrow 0$ , estima-se  $\hat{\tau}(f)$  com baixa precisão
  - ▶ Solução para estimação mais eficiente: Dropar  $x_i = f$
- ▶ Quando  $e(f) = 1$  ou  $e(f) = 0$ ,  $NV(\hat{\tau})$  não existe

# Procedimento de Trimming

## Caso 1: X binária (mais simples), cont.

► Casos particulares:

$$(i) \left( \frac{em(1 - em)}{ef(1 - ef)} \leq \frac{1 - q}{1 - 2q} \right), V(\hat{\tau}(f)) \leq V(\hat{\tau}) \leq V(\hat{\tau}(m))$$

$$(ii) \left( \frac{1 + q}{q} \leq \frac{em(1 - em)}{ef(1 - ef)} \right), V(\hat{\tau}(m)) \leq V(\hat{\tau}) \leq V(\hat{\tau}(f))$$

$$(iii) \left( \frac{1 - q}{1 - 2q} < \frac{em(1 - em)}{ef(1 - ef)} < \frac{1 + q}{q} \right), V(\hat{\tau}) < \text{Min}[V(\hat{\tau}(m)), V(\hat{\tau}(f))]$$

► Trimming: Escolher subamostra  $A \in X$  tal que efeito é estimado com menor variância, neste exemplo:

$$A = f, \text{ se } \left( \frac{em(1 - em)}{ef(1 - ef)} \leq \frac{1 - q}{1 - 2q} \right)$$

$$A = m, \text{ se } \left( \frac{1 + q}{q} \leq \frac{em(1 - em)}{ef(1 - ef)} \right)$$

$$A = m, f, \text{ c.c.}$$

# Procedimento de Trimming

Excluimos  $i$ 's com  $X_i \notin A$ , portanto:  $\tau_A = E(\tau(x_i)|X_i \in A)$

Caso 2: Generalizando para matriz  $X$  de variáveis contínuas

$$V(\hat{\tau}) = E \left( \frac{\sigma_t^2(X_i)}{e(X_i)} + \frac{\sigma_c^2(X_i)}{1 - e(X_i)} \right)$$

- ▶ Quando  $e(X_i) \rightarrow 1$  ou  $e(X_i) \rightarrow 0$ , o limite da variância será alto
- ▶ Quando  $e(X_i) = 0.5$ , variância é mínima

# Procedimento de Trimming

Caso 2: Generalizando para matriz  $X$  de variáveis contínuas, cont.

$$\tau_A = E(\tau(x_i) | X_i \in A)$$
$$V(\tau_A) = \frac{1}{q_A} E \left( \frac{\sigma_t^2(X_i)}{e(X_i)} + \frac{\sigma_c^2(X_i)}{1 - e(X_i)} | X \in A \right)$$

▶ em que  $q_A = P(x \in A)$

▶ Supondo homocedasticidade:

▶  $V^*(\tau_{A^*}) = \frac{\sigma^2}{q_A} E \left( \frac{1}{e(X_i)(1-e(X_i))} | X \in A \right)$

▶  $A^* = \{x \in X | \alpha \leq e(x) \leq 1 - \alpha\}$ , em que  $\alpha = 1/2 - \sqrt{1/4 - 1/\gamma}$  e

$$\gamma = 2E \left( \frac{1}{e(X_i)(1-e(X_i))} | \frac{1}{e(X_i)(1-e(X_i))} < \gamma \right)$$

▶ Crump et al 2009 derivam  $\tilde{\alpha} = 0, 1$

# Aula 4

[voltar](#)