

Técnicas Econométricas para Avaliação de Impacto

Introdução aos Métodos Quase-Experimentais

Rafael Perez Ribas
Centro Internacional de Pobreza

Brasília, 23 de abril de 2008

Introdução

- Breve descrição de métodos para estimar o **efeito de um tratamento**, quando este:
 - É derivado de uma **auto-escolha**. Exemplo:
 - Trabalhador que escolhe o setor de atividade;
 - É derivado da **escolha de quem está provendo o tratamento**. Exemplos:
 - Bolsas de estudos destinados aos melhores alunos;
 - Investimentos na infra-estrutura de áreas pobres.
 - Ou existem **fatores omitidos** por trás da relação. Exemplo:
 - Retornos da escolaridade sobre o salário;
 - Discriminação no mercado de trabalho.

- A escolha pela metodologia não-experimental depende de **três fatores**:
 - O tipo de informação disponível;
 - O modelo causal;
 - O parâmetro de interesse.
- É necessário ainda saber sobre quais condições o parâmetro de interesse é identificado.
- A distinção entre resultados de uma mesma avaliação pode decorrer da imposição de **falsas suposições sobre a distribuição** das variáveis.
 - Vantagem dos modelos não-paramétricos (Heckman, 1990).

Modelo Causal

- Um modelo de efeito do tratamento pode ser descrito como um *switching model regression*:

$$D_i^*(s) = Z_i\gamma + v_i, \quad E[v] = 0$$

$$D_i^*(s) \geq 0 \rightarrow D_i(s) = 1$$

$$D_i^*(s) < 0 \rightarrow D_i(s) = 0$$

$$s \in S$$

$$Y_i(s) = X_i(s)\beta(s) + u_i(s), \quad E[u(s)] = 0$$

- Para facilitar, suponha que existem só dois estados (com e sem tratamento),
 $s \in \{0, 1\}$.

- Assim:

$$D^* = Z\gamma + v, \quad E[v] = 0$$

$$D^* \geq 0 \rightarrow D = 1$$

$$D^* < 0 \rightarrow D = 0$$

$$Y_1 = X_1\beta_1 + u_1, \quad E[u_1] = 0$$

$$Y_0 = X_0\beta_0 + u_0, \quad E[u_0] = 0$$

- Além disso, suponha que exista um conjunto de **características observáveis comum** a todas as equações:

$$D^* = (X_c, Z)\gamma + v, \quad E[v] = 0$$

$$Y_1 = (X_c, X_1)\beta_1 + u_1, \quad E[u_1] = 0$$

$$Y_0 = (X_c, X_0)\beta_0 + u_0, \quad E[u_0] = 0$$

- Relembrando, o problema da avaliação de impacto é não observamos a mesma unidade em ambos os estados.

Só observamos:

$$Y = Y_1 D + Y_0 (1 - D),$$

ou ainda:

$$Y = [(X_c, X_1)\beta_1]D + [(X_c, X_0)\beta_0](1 - D) + u_1 D + u_0 (1 - D)$$

- Para facilitar, assuma que **X não varia com D** :

$$(X_c, X_1)\beta_1 = \alpha_1 + X\beta \quad \text{e} \quad (X_c, X_0)\beta_0 = \alpha_0 + X\beta$$

- Assim:

$$Y = \alpha_0 + D(\alpha_1 - \alpha_0) + X\beta + u_1 D + u_0 (1 - D)$$

$$Y = \alpha_0 + D\tau + X\beta + (u_1 - u_0)D + u_0, \quad u = (u_1 - u_0)D + u_0$$

- **Problema:** apesar de

$$E[u] = E[u_1]D + E[u_0](1 - D) = 0,$$

$$u \perp D$$

- Ou seja, D é endógeno.
- Neste caso, uma **diferença de médias** ou uma simples **regressão** gera o seguinte resultado **enviesado**:

$$E[Y_1 | D = 1] - E[Y_0 | D = 0] = (\alpha_1 - \alpha_0) + [E(u_1 | D = 1) - E(u_0 | D = 0)]$$

os termos entre colchetes **não necessariamente se anulam**

- Mais especificamente, D é endógeno porque

$$v \perp u,$$

$$B = [E(u_1 | v \geq -(X_c, Z)\gamma) - E(u_0 | v < -(X_c, Z)\gamma)]$$

- Fatores não-observados, v , que determinaram a seleção influenciam o resultado, Y .
- **Solução:** fazer com que

$$v \perp u$$
- **Como?**
 - **Incorporando mais variáveis**, o suficiente para que os termos não-observados sejam ortogonais.
- **Três formas** de fazer isso:
 - Mais variáveis em X_c para eliminar o viés de variáveis omitidas (seleção sobre observáveis);
 - Incluir uma variável $Z \perp u$ na equação de seleção (seleção sobre não-observáveis);
 - Incluir uma variável $Z \perp u$ na equação de seleção (seleção sobre observáveis).

- **Importante:** Mesmo quando D é exógeno, se há heterogeneidade no impacto,

$$\tau_i = \bar{\tau} + \xi_i,$$

os coeficientes de uma regressão podem não representar os parâmetros de interesse:

$$E[\tau | D = 1] = \bar{\tau} + E[\xi | D = 1] \neq E[\tau | D = 0] = \bar{\tau} + E[\xi | D = 0]$$

- **Exemplos:**

- Diferenças salariais entre homens e mulheres;
- Ou entre negros e brancos;
- Ou entre os anos de 2006 e 2007;
- Não existe uma escolha por trás destas variáveis, mas é impossível tratá-las como aleatórias.

- Por maior que seja o controle sobre observáveis, **a composição dos grupos é distinta.**

Parâmetros de Interesse

- O parâmetro de interesse mais comum é o ATE:

$$Y_1 = \alpha_1 + X\beta + u_1 \rightarrow E[Y_1] = \alpha_1 + E[X]\beta$$

$$Y_0 = \alpha_0 + X\beta + u_0 \rightarrow E[Y_0] = \alpha_0 + E[X]\beta$$

$$\tau = E[Y_1 - Y_0] = (\alpha_1 - \alpha_0)$$

que representa o impacto médio do tratamento na

população como um todo

(independente de quem foram os tratados).

- Outro parâmetro de interesse é o ATT ou ATET:

$$E[Y_1 | D = 1] = \alpha_1 + E[X | D = 1]\beta + E[u_1 | D = 1]$$

$$E[Y_0 | D = 1] = \alpha_0 + E[X | D = 1]\beta + E[u_0 | D = 1]$$

$$\tau_T = E[Y_1 - Y_0 | D = 1] = (\alpha_1 - \alpha_0) + E[u_1 - u_0 | D = 1]$$

o ATT mostra como o **grupo que recebeu** (ou escolheu) o tratamento foi afetado.

- De maneira equivalente, o ATU é definido como:

$$E[Y_1 | D = 0] = \alpha_1 + E[X | D = 0]\beta + E[u_1 | D = 0]$$

$$E[Y_0 | D = 0] = \alpha_0 + E[X | D = 0]\beta + E[u_0 | D = 0]$$

$$\tau_U = E[Y_1 - Y_0 | D = 0] = (\alpha_1 - \alpha_0) + E[u_1 - u_0 | D = 0]$$

isso representa o quanto o **grupo que não está sendo tratado** seria afetado caso fosse tratado.

- Não confundir com externalidades do programa

- O ATU é de interesse, por exemplo:

- Estimação do impacto da expansão de um programa para além do grupo já tratado.

- Um caso onde ATU é geralmente estimado, porém ele não é de interesse:

- Decomposições à la Oaxaca-Blinder.

- Por definição:

$$ATE = \Pr(D = 1) \cdot ATT + \Pr(D = 0) \cdot ATU$$

$$\tau = \tau + \Pr(D = 1)E(u_1 - u_0 | D = 1) + \Pr(D = 0)E(u_1 - u_0 | D = 0)$$

Se $u_1, u_0 \perp D$

ou

$$E[u_1 - u_0 | D = 1] = 0,$$

$$ATT = ATU = ATE$$

○ Idéia implícita de homogeneidade do impacto.

- **Importante:** para que o ATU e, por consequência, o ATE sejam de interesse, é relevante que a amostra de não-tratados represente uma **população de interesse**.

- O estimador pode ainda ser representativo de um efeito local (LATE):

$$LATE = \frac{E[Y | Z'] - E[Y | Z]}{E[D(Z')=1] - E[D(Z)=1]}, \text{ onde } Z' = Z + \varepsilon$$

- Se o impacto do tratamento é **homogêneo**, LATE=ATE.
- **Contudo**, é muito provável que a escolha de Z influencie o estimador.
- Correção para **erros de medida** pode ser um exemplo de quando o LATE é o parâmetro de interesse:
 - Renda de uma transferência predita pela composição domiciliar;
 - Renda permanente predita por bens duráveis.

- Um exemplo de LATE

- Efeito de Tratamento para Pessoas na Margem da Indiferença (ou Eligibilidade), EOTM:

$$EOTM(s, s') = E \left(Y(s) - Y(s') \left| \begin{array}{l} R(Y(s)) = R(Y(s')) \\ R(Y(s)) \\ R(Y(s')) \end{array} \right. \geq R(Y(l)) \right)$$

$$l \neq s, s'$$

Modelo de Seleção sobre Observáveis

- Assume que os fatores não-observados, u e v , não estão correlacionados.
- **Suposição de independência na média condicional:**
$$E[Y_0 | D = 1, X_c, Z] = E[Y_0 | D = 0, X_c, Z] = E[Y_0 | X_c, Z],$$
 - Se o parâmetro de interesse é de **efeito médio**.
- Se existem outros parâmetros de interesse (mediana, desvio-padrão, etc.):
 - Devemos assumir uma condição mais restritiva (versão condicional da SUTVA):
$$Y_0 \perp D | X_c, Z .$$

- **Modelo mais comum** de seleção sobre observáveis:
 - **Regressão multivariada.**
 - Se u não é correlacionado com v ,
é porque X_c explica a correlação de D com Y_0 .
 - Exemplo típico: seleção amostral.
- **Problema** é quando X_c explica o efeito de D sobre Y .
Exemplos:
 - Resultados de testes de proficiência explicam escolaridade, mas também explicam a diferença entre salários das pessoas mais e menos escolaridade;
 - Renda domiciliar determina participação em programa social que determina gastos com alimentação, que também é determinada pela renda domiciliar.

- **Solução**, incorporar interações para melhorar o controle (Rubin, 1977):

$$Y = \alpha + D\tau + X_c\beta + (X_c \cdot D)\omega + u$$

- Contudo, se impacto é heterogêneo,

$$\hat{\tau} = E[Y_1 - Y_0 \mid X_c = 0]$$

- **Solução:**

$$Y = \alpha + D\tau + X\beta + (X - \bar{X})D\omega + u$$

ou

$$Y = \alpha + D\tau_T + X\beta + (X - \bar{X}_1)D\omega_T + u$$

- **Problema:** v não ser ortogonal a u e a condição de independência ser violada, mesmo incluindo o controle de X_c .
 - Ou então, ter que incluir uma série de outras variáveis junto com as respectivas interações (**perda dos graus de liberdade**).
- **Solução:** incluir uma variável $Z \perp u$.
 - Tal que esta variável explique em grande parte a correlação de v com u .
 - Ou seja, retira de v a parte que está correlacionada com u .
- **Problema:** não há como incluir Z diretamente na equação de interesse.
 - Pois é uma variável (fracamente) endógena e correlacionada com D .

- **Soluções:**

- Já conhecidas há muito tempo, porém não para corrigir o viés de seleção, mas para estimar um parâmetro de interesse (ATT ou ATE) sobre uma variável exógena.

- **Matching** (método não-paramétrico),

$$\tau = E \left[Y_{1i} - \sum_{j \in \{D=0\}} W(X_{c,i}, X_{c,j}, Z_i, Z_j) Y_{0j} \right];$$

- *Inverse Probability Weighting* (método semi-paramétrico),

$$W(X_c, Z) = \frac{D}{\Pr(D = 1 | X_c, Z)} + \frac{1 - D}{\Pr(D = 0 | X_c, Z)}$$

ou

$$W(X_c, Z) = \frac{D \cdot \Pr(D = 1 | X_c)}{\Pr(D = 1 | X_c, Z)} + \frac{(1 - D) \cdot \Pr(D = 0 | X_c)}{\Pr(D = 0 | X_c, Z)}$$

- Estas técnicas relaxam a imposição de formas funcionais.
- E possibilitam a estimação de parâmetros de interesse para sub-amostras. Exemplo:
 - No caso de diferenças salariais, um estimador de *Matching* ou *IPW* pode fornecer resultados distintos de uma microsimulação contrafactual à la Oaxaca-Blinder (DiNardo; Firpo e Ñopo possuem trabalhos sobre isso).

- **Importante:**

- Se, mesmo usando *Matching* ou *IPW*, não for incluído no modelo $Z \perp u$, os resultados tendem a não se distinguir da regressão de Rubin (1977).
 - A não ser devido à mudança na forma funcional.
- Portanto, se na regressão já havia um problema de **viés de seleção**, *matching* ou *IPW* não corrigirão este problema utilizando as mesmas variáveis X_c .
 - Estimador de *matching* **não é uma panacéia!**

Regressão Descontínua

- Um método de seleção sobre observáveis por definição.
- Ou seja, assume a mesma condição de independência.
- Porém, só gera um estimador LATE.
- Existe uma variável $Z \perp u$ que determina o tratamento, tal que

$$Z > z \rightarrow D = 1$$

$$Z \leq z \rightarrow D = 0$$

ou ainda

$$E[D | Z = z + \varepsilon] > E[D | Z = z - \varepsilon], \text{ mas}$$

$$E[Y_0 | Z = z + \varepsilon] = E[Y_0 | Z = z - \varepsilon]$$

- **Exemplos:**

- Bolsas de estudos distribuídas de acordo com testes de proficiência;
- Transferência de renda para pessoas abaixo da linha de pobreza.

- **Dois tipos de estimador:**

- *Sharp*

$$E[Y | Z = z + \varepsilon] - E[Y | Z = z - \varepsilon],$$

se $E[D | Z > z] = 1$ e $E[D | Z \leq z] = 0$

- *Fuzzy*

$$\frac{E[Y | Z = z + \varepsilon] - E[Y | Z = z - \varepsilon]}{E[D | Z = z + \varepsilon] - E[D | Z = z - \varepsilon]}$$

- **Formas de estimação:**

- Regressão paramétrica (*naïve*);
- Regressão não-paramétrica (consistente);

Modelo de Seleção sobre Não-Observáveis

- **Condição assumida:**

$Z \perp u$ e Z determina D .

- **Idéia:** retirar de u (ou D) o componente que está correlacionado com v .

- **Como fazer isso:**

- **Método IV**, consiste em utilizar uma variável $\hat{D} \perp u$;
- **Seleção de Heckman**, identificar em u o componente correlacionado com v ;
- **Modelo de efeitos fixos**, supondo que D é determinado somente por atributos fixos (muitas vezes invariável);
- **Modelo de Diferença-nas-Diferenças**; suposição idêntica a de modelos de efeitos fixos.

Método de Variáveis Instrumentais IV

- Duas formas de implementação:
 - Substituir o indicador de tratamento, D , na equação de interesse por $g(Z)$,
 - que pode ser o próprio Z .
 - Ou utilizar o valor predito $\hat{D}(X_c, Z)$ na equação de interesse no lugar de D .

- Dessa forma, utilizamos uma **proxy de D** que é ortogonal a u , pois $(X_c, Z) \perp u$.
- **Problema:** essa *proxy* varia com a escolha de Z .
 - Ou seja, estamos estimando um **parâmetro LATE:**
$$E[Y_1 - Y_0 | X_c, Z] = (\alpha_1 - \alpha_0) + E[u_1 - u_0 | Z = z]$$

Estimador de Seleção de Heckman

- Muito comum em análise com seleção amostral.
- Consiste em estimar a esperança condicionada de v (não-observado em modelos não-lineares), para posteriormente incluí-la na equação de interesse:

$$Y = \alpha_0 + D\tau + X_c\beta + \rho E[v | X_c, Z] + u$$

- Utilização da famosa razão inversa de Mills.
- Assim, $D \perp u$.

- Como no método IV, é possível estimar os coeficientes:
 - Em dois estágios;
 - Ou por meio de modelos multivariados (*joint likelihood*).
- E como no método IV, há o problema de encontrar uma variável **Z convincente**.
 - De fato, IV da Ms. Speedy (alocação da verba) não é convincente.
 - Seria mais interessante utilizá-la em um modelo de seleção sobre observáveis.
- **Muito importante:** Se $Z \not\perp u$, os estimadores resultantes podem ser ainda mais enviesados.

Estimador de Diferença-nas-Diferenças

- Mede a variação mais que proporcional no grupo de tratamento em relação ao grupo de controle.
- Para entendê-lo, vamos definir a seguinte equação:

$$Y_{D,t}(i) = \delta_t + \alpha_{D,t} + \eta_i + u_{i,t}$$

A primeira diferença (antes-e-depois) para cada grupo (tratamento e controle) é:

$$\begin{aligned} Y_{1,1}(i) - Y_{1,0}(i) &= (\delta_1 - \delta_0) + (\alpha_{1,1} - \alpha_{1,0}) + (\eta_i - \eta_i) + (u_{i,1} - u_{i,0}) \\ &= \delta \cdot t + \alpha_1 \cdot t + (u_{i,1} - u_{i,0}) \end{aligned}$$

$$\begin{aligned} Y_{0,1}(i) - Y_{0,0}(i) &= (\delta_1 - \delta_0) + (\alpha_{0,1} - \alpha_{0,0}) + (\eta_i - \eta_i) + (u_{i,1} - u_{i,0}) \\ &= \delta \cdot t + \alpha_0 \cdot t + (u_{i,1} - u_{i,0}) \end{aligned}$$

- Assim quando estimamos

a diferença das esperanças das diferenças:

$$E\left[Y_{1,1}(i) - Y_{1,0}(i) \mid D = 1\right] - E\left[Y_{0,1}(i) - Y_{0,0}(i) \mid D = 0\right]_{t=1}$$
$$= (\alpha_1 - \alpha_0) + E(u_{i,1} - u_{i,0} \mid D = 1) - E(u_{i,1} - u_{i,0} \mid D = 0)$$

- **Condição:** se

$$E(u_{i,1} - u_{i,0} \mid D = 1) = E(u_{i,1} - u_{i,0} \mid D = 0),$$

o estimador é consistente.

- Isso implica que:

- Toda diferença entre os grupos foi eliminada na

subtração dos efeitos fixos;

- A condição agora é que as **variações sejam ortogonais** à seleção para o tratamento.

- Esta condição sempre esteve implícita nos outros estimadores.

- A condição

$$E(u_{i,1} - u_{i,0} | D = 1) = E(u_{i,1} - u_{i,0} | D = 0)$$

pode ser **facilmente violada** dependendo do que está sendo investigado. Exemplo:

- Efeito de cotas em universidades sobre o desempenho de estudantes no segundo grau;
 - Grupo de tratamento: alunos com direito à cota;
 - Grupo de comparação: alunos sem direito à cota.
 - Condição é violada quando a trajetória média do desempenho de alunos é distinta.
- Por esta mesma razão, modelos de efeitos fixos podem não resolver o problema.

- **Solução**, assumir uma outra condição:

$$E(u_{i,1} - u_{i,0} | X, D = 1) = E(u_{i,1} - u_{i,0} | X, D = 0)$$

- Ou seja, assumir **independência nas trajetórias condicionadas**, por exemplo, às características dos alunos.
- Para fazer isso, **não basta incluir variáveis** de controle em uma regressão de diferença-nas-diferenças.
- **Soluções**:
 - Incluir interações, tais como em Rubin (1977);
 - Combinar método DD com outros métodos de seleção sobre observáveis (*Matching, IPW, RDD*);
 - Combinar método DD com outros métodos de seleção sobre não-observáveis (*IV* ou Seleção de Heckman);
 - Estimar um modelo de diferenças com efeito fixo (inviável).

- Para os casos de *Matching* e *RDD*, a solução é mais simples do que parece:
 - Basta estimar o parâmetro **antes e depois** da implementação do tratamento e eliminar as diferenças identificadas previamente das diferenças posteriores.
- **Importante é não confundir** o papel do estimador de Diferença-nas-Diferenças com o papel dos estimadores quase-experimentais:
 - O estimador de DD garante uma forma mais consistente de se estimar um impacto, podendo ou não ser combinado com técnicas experimentais ou quase-experimentais de avaliação.

Coleta de Dados

- Métodos quase-experimentais exigem **amostras maiores** que métodos experimentais.
 - Pois somente parte da variação nas variáveis de interesse é utilizada na estimação.
 - Geralmente, o grupo de tratados tende a ser mais homogêneo, do ponto de vista da investigação, que o grupo de controle;
 - Portanto, a regra 50%-50% utilizada na amostra de experimentos não é válida nos quase-experimentos.
- Base de dados secundárias:
 - Pesquisas para cobrir uma série de outros propósitos;
 - Informações de relevância para avaliação podem estar ausentes;
 - Exemplo: Avaliação de impacto do PBF utilizando a PNAD.

- Por isso, muitas pesquisas coletam seus próprios dados:
 - Problema é que estas pesquisas podem não ter representatividade.
- Registro administrativo:
 - Contém uma grande amostra de tratados e de controle;
 - É possível observar de fato quem foi, ou está sendo, tratado e quem não foi, além de muitas das condições que determinaram esta escolha (baseline);
 - Problema é que estas informações só são representativas da população registrada.

- A busca pela representatividade não é o mais importante;
 - E pode incorrer em aumento desnecessário dos custos;
 - O foco é, primeiro, como estimar o ATT da maneira mais consistente;
 - Validade interna vem antes da externa, apesar das duas serem importantes.
- **Muito importante:**
 - Em qualquer avaliação quase-experimental (X_c, Z) deve ser completamente exógeno a D .
 - A única forma de garantir isso é que (X_c, Z) seja coletado antes do tratamento (informação na linha de base);
 - Se (X_c, Z) e D são observados simultaneamente, existe uma grande risco de inconsistência interna na avaliação.