

Regressão com Descontinuidade - RDD

Rafael Terra

Universidade de Brasília-Unb

05 de Maio, 2016

O Básico sobre Causalidade: Endogeneidade

- A relação causal entre a educação (s) e o salário (w) é objeto de estudo constante em economia do trabalho. Jacob Mincer propôs uma relação causal simplificada:

$$\ln w_i = \ln w_{0i} + \beta s + \gamma_1 X_i + \gamma_2 X_i^2 + \varepsilon_i \quad (1)$$

- em que $\ln w_0$ representa o salário do trabalho sem qualificação e experiência.
- s denota os anos de educação.
- X representa o tempo de experiência.
- ε representa outros fatores que afetam $\ln w$.

- suponha a seguinte estimativa:

$$\ln w_i = \underset{(1.122)}{6.684} + \underset{(0.081)}{0.252}s_i + \underset{(0.021)}{0.053}X_i - \underset{(0.0005)}{0.001}X_i^2 \quad (2)$$

- Você acredita nessa estimação?

O Básico sobre Causalidade: Endogeneidade

- Não!
- Sabemos hoje em dia que ao menos um fator importante para explicar o salário, a habilidade (q) do indivíduo, não se encontra no modelo, i.e. é não observável.
- Há uma correlação condicional positiva entre habilidade e salário γ_3 . Logo, se esta não é observável, ela recairá no erro $\varepsilon = \gamma_3 q + u$
- Como habilidade tem uma relação positiva com a escolaridade, a estimativa do efeito da escolaridade sobre o salário estará superestimada. O modelo correto seria

$$\ln w_i = \underset{(1.08)}{6.355} + \underset{(0.031)}{0.102} s_i + \underset{(0.019)}{0.051} X_i - \underset{(0.0003)}{0.0009} X_i^2 + \underset{(0.014)}{0.457} q_i \quad (3)$$

- em que a nova estimativa de um ano adicional de escolaridade seria bem menor.

O Básico sobre Causalidade: Endogeneidade

- O que observamos nesse caso é o clássico problema de endogeneidade.
- $E[s\varepsilon] \neq 0$.
- A consequência da violação da hipótese de ortogonalidade entre o erro e o regressor é o viés da estimativa de β .
- Esse é o principal problema em Econometria de Avaliação de Programas.

O Básico sobre Causalidade: Endogeneidade

- Há basicamente três fontes de endogeneidade que fazem com que $E[s\varepsilon] \neq 0$
 - Omissão no modelo de regressores relevantes.
 - Regressores medidos com erro.
 - Simultaneidade entre as variáveis —a causalção é bidirecional entre regressando w e regressor s .
- Omissão de variáveis relevantes costuma ser a principal fonte de endogeneidade em Econometria de Avaliação de Programas.

O Básico sobre Causalidade: Endogeneidade

- Há várias formas de lidar com o problema de endogeneidade. Se o problema é de variável omitida– correlacionada com regressores incluídos no modelo.
 - 1 A inclusão da variável no modelo resolve o problema de endogeneidade.
 - 2 Se é impossível obter/medir essa variável omitida, pode-se tentar encontrar uma variável “proxy” que capture a correlação entre a variável omitida e o regressando w .
 - 3 Se tal “proxy” não existe, mas um conjunto de variáveis de controle x “exaure” essa correlação entre a variável omitida e o regressando w , pode-se estimar consistentemente β .

O Básico sobre Causalidade: Endogeneidade

- **4** Se você sabe que essa variável omitida é invariante no tempo, e se dispõe de dados em painel, pode-se usar o estimador de efeitos fixos ou primeiras diferenças (que remove essa parte fixa de cada unidade seccional).
- **5** Se a variável omitida não for invariante no tempo, podemos tentar encontrar uma variável instrumental z correlacionada com a variável endógena s , mas não correlacionada com a variável dependente w — a não ser por meio de s .

O Básico sobre Causalidade: Endogeneidade

- As estratégias de 1 a 4 listadas se baseiam em hipóteses muito fortes.
 - A variável omitida pode ser encontrada/medida?
 - A “proxy” é boa?
 - As variáveis de controle realmente “exaurem” essa relação entre a variável omitida e o regressor de interesse?
 - A variável omitida é realmente invariante no tempo?
- Se tivermos uma variável instrumental “evidentemente” exógena, esta será a forma mais robusta de estimar β consistentemente.

O Básico sobre Causalidade: Variáveis Instrumentais

- Uma variável instrumental z é uma variável correlacionada diretamente com a variável endógena s , mas não correlacionada diretamente com w uma vez controlado o efeito de s sobre w .
- No exemplo em questão poderíamos sugerir como variável instrumental para o nível educacional a “educação dos pais”. Será que seria uma de fato uma boa variável instrumental?

O Básico sobre Causalidade: Variáveis Instrumentais

- A estimação de β via variáveis instrumentais pode ser realizada pelo método 2SLS (Mínimos Quadrados em Dois Estágios).
- O primeiro estágio consiste em:

$$s_i = \delta_0 + \rho z_i + \lambda_1 X_i + \lambda_2 X_i^2 + \eta_i \quad (4)$$

- Devemos observar $\rho \neq 0$.
- Para identificação requeremos ainda que a própria variável instrumental seja exógena no primeiro estágio, i.e. $E(z'\eta) = 0$.

- obtemos \hat{s} e inserimos no lugar de s .

$$\ln w = \ln w_0 + \beta \hat{s} + \gamma_1 X + \gamma_2 X^2 + \varepsilon \quad (5)$$

- Regredindo $\ln w$ sobre \hat{s} obtemos β^{2SLS} , uma estimativa consistente de β .

- A Econometria de Avaliação de Programas busca estimar o efeito causal de um programa. Pode ser um programa educacional, de transferência de renda, de atendimento médico, de incentivos fiscais, etc.
- Dizemos que os participantes do programa são “Tratados” (T) e os não participantes são os “Controles” (C).

Econometria de Avaliação de Programas: Efeito Médio do Tratamento (ATE)

- Gostaríamos de estimar o Efeito Médio do Tratamento:

$$ATE = E[Y_i(T) - Y_i(C)] \quad (6)$$

- em que $Y_i(T)$ e $Y_i(C)$ são ditos contrafactuais da variável de interesse, e.g. salário.
- Se o tratamento é um programa de treinamento, $Y_i(T)$ seria o salário do indivíduo “i” se fosse tratado e $Y_i(C)$ seria o salário do mesmo indivíduo “i” se não fosse tratado.
- Não é possível observar estes dois estados, daí a denominação “contrafactual”.

Econometria de Avaliação de Programas: Viés da simples diferença de médias observadas

- Nós observamos $E[Y_i^T|T]$ e $E[Y_i^C|C]$.
- Mas a diferença $E[Y_i^T|T] - E[Y_i^C|C]$ é uma medida enviesada do Efeito Médio do Tratamento, pois as pessoas se auto-selecionam ao tratamento.
- Se somarmos e subtrairmos o contrafactual $E[Y_i^C|T]$ — ou em outra notação $E[Y_i(C)|T]$ — essa diferença observada será

$$\begin{aligned} E[Y_i^T|T] - E[Y_i^C|C] &= E[Y_i^T|T] - E[Y_i^C|C] + E[Y_i^C|T] - E[Y_i^C|T] \\ &= \underbrace{E[Y_i^T|T] - E[Y_i^C|T]}_{\text{ATT}} + \underbrace{E[Y_i^C|T] - E[Y_i^C|C]}_{\text{viés}} \end{aligned} \quad (7)$$

- ATT é o efeito médio do tratamento sobre os tratados, e o viés decorre de diferenças comportamentais ou inatas entre tratados e controles.

Econometria de Avaliação de Programas: Eliminando o viés via experimentos randomizados

- Podemos eliminar esse viés com a realização de um experimento que randomize o tratamento entre os indivíduos avaliados.
- Em caso de randomização do tratamento garantiríamos que $E[Y_i^C|C] = E[Y_i^C|T]$ e $E[Y_i^T|T] = E[Y_i^T|C]$.

Econometria de Avaliação de Programas: Eliminando o viés via experimentos randomizados

- Colocando o problema em termos de regressão, após a randomização do tratamentos entre os indivíduos estimamos

$$Y_i = \alpha + \beta T_i + \varepsilon_i \quad (8)$$

- A randomização garante que não haja correlação entre o status de tratamento T e fatores não observáveis ε , i.e. $E[T\varepsilon] = 0$. Logo, os coeficientes estimados são todos consistentes.
- O efeito do tratamento é $E[Y_i | T_i = 1] - E[Y_i | T_i = 0] = (\alpha + \beta) - \alpha = \beta$

Econometria de Avaliação de Programas: A randomização da designação ao tratamento como variável instrumental

- Podemos colocar o mesmo problema em dois estágios.
- Em um primeiro momento, os indivíduos são sorteados entre tratados e controles. O status de sorteio é dado por z_i . Assim, o primeiro estágio consistiria em

$$T_i = \delta_0 + \rho z_i + \eta \quad (9)$$

- O segundo estágio seria o

$$Y_i = \alpha + \beta \hat{T}_i + \varepsilon_i \quad (10)$$

- Se sempre que sorteada a pessoa for realmente tratada e o controle não, dizemos que há “perfect compliance”. Nesse caso $T_i = z_i$ e o segundo estágio será simplesmente a equação 8 já apresentada

Econometria de Avaliação de Programas: O uso de Experimentos Naturais

- Nem sempre a realização de um experimento social é viável. Custos muito altos, problemas éticos, dificuldade de garantir que não haja contaminação entre indivíduos tratados e controles, são problemas comuns.
- Mas podemos tentar encontrar experimentos naturais que nos forneçam variáveis instrumentais ideais.
- Um exemplo de experimento natural foi o sorteio realizado entre jovens americanos para irem à Guerra do Vietnam. Angrist(1990) usa esse experimento natural como variável instrumental para estimar o efeito da ida à Guerra sobre os rendimentos futuros.

Econometria de Avaliação de Programas: Experimentos Naturais e Mínimos Quadrados Indiretos (ou 2 Estágios)

- Essas variáveis instrumentais são fornecidas pela natureza e consistem em variações naturalmente randomizadas na designação ao tratamento.
- Normalmente, os indivíduos não são obrigados a aderir ao tratamento. Nesse caso há “imperfect compliance”, e a estimação tem ser feita em dois estágios .
- Podemos usar Mínimos Quadrados em Dois Estágios, ou uma forma alternativa de representar o problema — que é didática para o nosso caso— denominada Mínimos Quadrados Indiretos.
- Esse procedimento consiste em estimar uma equação regredindo o instrumento z_i sobre a variável dependente Y_i e sobre o tratamento T_i .

$$\begin{aligned} Y_i &= \gamma_0 + \gamma_1 z_i + \eta_i \\ T_i &= \pi_0 + \pi_1 z_i + \nu_i \end{aligned} \tag{11}$$

Econometria de Avaliação de Programas: Experimentos Naturais e Mínimos Quadrados Indiretos (ou 2 Estágios)

- $\gamma_1 = E[Y_i|z_i = 1] - E[Y_i|z_i = 0]$ nos dá a diferença de resultados Y_i entre quem foi e não sorteado — a “Intenção de Tratar”.
- Esse não é o efeito do tratamento, pois nem todos que são sorteados pela natureza ($z = 1$) são tratados ($T_i = 1$).
- $\pi_1 = E[T_i|z_i = 1] - E[T_i|z_i = 0]$ nos dá a proporção de pessoas que aderem ao tratamento se sorteados e não aderem se não forem. São os “compliers”.
- O efeito do tratamento “Local” — porque só é válido para os compliers— é dado pela razão entre γ_1 e π_1 .

$$\beta = \frac{\gamma_1}{\pi_1} = \frac{E[Y_i|z_i = 1] - E[Y_i|z_i = 0]}{E[T_i|z_i = 1] - E[T_i|z_i = 0]} \quad (12)$$

Regression Discontinuity Design (RDD)

- No fundo consiste em um experimento natural que nos fornece variáveis instrumentais para estimar o efeito causal local do tratamento.
- Gráficos ajudam muito a entender o problema e encontrar as respostas do efeito causal local.
- Há várias formas de se chegar a estimativas graficamente e via regressões lineares locais e regressões paramétricas.

Regression Discontinuity Design (RDD)

- Em um desenho RDD observamos a quádrupla (Y_i, T_i, X_i, Z_i) .
- Y_i é a variável de resultado.
- T_i é a variável que indica se o indivíduo foi ou não tratado.
- X_i desempenha um papel especial no desenho *RDD*. Denominamo-a *forcing variable*. Ela determina quem será designado ao tratamento.
- E.g., são designados ao tratamento os indivíduos com valores de $X_i \geq c$, em que c é o *threshold* definido pela natureza (leis, regras, etc).
- Z_i é uma variável dummy que informa em qual lado do threshold c se encontra o indivíduo. Isto é, nos informa quem será “designado ao tratamento”.

Regression Discontinuity Design (RDD)

- A intuição é a de que ao redor desse threshold $X_i = c$ os indivíduos, em média, são muito parecidos, inclusive em termos de variáveis não observáveis.
- A única característica que difere aqueles à direita daqueles à esquerda do threshold é a presença de tratamento — caso RDD Sharp — ou, caso não haja obrigatoriedade de adesão ao tratamento, a diferença reside somente na proporção de tratados.
- Essa é justamente a condição de exogeneidade que precisamos para estimar o efeito causal do tratamento.
- As probabilidades dos indivíduos se encontrarem do lado esquerdo ou direito de $X_i = c$ nas proximidades do threshold tendem a ser as mesmas.

Regression Discontinuity Design (RDD)

- Indivíduos do lado esquerdo e ao redor do cutoff são bons “contrafactuais” para os indivíduos à direita e ao redor.
- X_i pode ou não ser correlacionado com os resultados potenciais $Y_i(T_i)$, mas essa associação é “suave” (contínua).
- Qualquer descontinuidade na distribuição do resultado Y_i ao redor desse *threshold* é interpretada como evidência de um efeito causal do tratamento.

- No desenho do tipo *Sharp* (SRD), a designação do tratamento determinada por X_i (*forcing variable*) segue a regra de que todas as unidades com um valor de X_i maior ou igual a c são designados para o grupo de tratamento $Z_i = 1$, e aqueles com valor menor ou igual a c são designados para o grupo de controle $Z_i = 0$.
- Como o “compliance” é perfeito, $Z_i = T_i = 1$ para aqueles com valores de X_i acima de c e $Z_i = T_i = 0$ para aqueles abaixo.
- Esse efeito pode ser interpretado como o efeito causal médio no ponto de descontinuidade

$$\tau_{SRD} = E[Y_i(1) - Y_i(0)|X_i = c] \quad (13)$$

- O Efeito Médio Local do Tratamento é dado por:

$$\lim_{x \downarrow c} E[Y_i|X_i = x] - \lim_{x \uparrow c} E[Y_i|X_i = x] \quad (14)$$

- A figura 1 plota a probabilidade condicional de receber o tratamento $Pr(T = 1|X = x)$ contra a forcing variable X .
- Na figura 1, no cutoff — $x = c = 6$ — a probabilidade salta de 0 para 1.
- Essa é uma característica específica do Sharp RDD.




Fig. 1. Assignment probabilities (SRD).




Fig. 2. Potential and observed outcome regression functions.

Designação de probabilidades e resultados potenciais

- Na figura 2, a linha de baixo representa o resultado potencial se o indivíduo não fosse tratado.
- A linha de cima representa o resultado potencial se o indivíduo fosse tratado.
- A linha sólida reflete o resultado observado.
- As diferenças nos resultados potenciais sugerem que o tratamento tem efeito sobre Y_i .
- Esse efeito é local, como mostra a figura, e só vale para o entorno do ponto de corte.

- Por definição não há unidades com $X_i = c$ para as quais observamos $Y_i(0)$.
- Mas observamos $Y_i(0)$ para unidades $X_i < c$ com valores arbitrariamente próximos de c .
- Para justificar o cálculo do efeito médio ao redor de $x = c$ precisamos da hipótese sobre resultados potenciais :

1

$$E[Y(0)|X = c] \text{ e } E[Y(1)|X = x] \text{ são contínuas em } x. \quad (15)$$

- Sob quaisquer hipóteses, o valor do contrafactual esperado se não houvesse tratamento no ponto c é igual ao limite pela esquerda do valor esperado de y observado condicional em x , i.e.

$$E[Y(0)|X = c] = \lim_{x \uparrow c} E[Y(0)|X = x] = \lim_{x \uparrow c} E[Y(0)|T = 0, X = x] = \lim_{x \uparrow c} E[Y|X = x] \quad (16)$$

- De forma similar

$$E[Y(1)|X = c] = \lim_{x \downarrow c} E[Y(1)|X = x] = \lim_{x \downarrow c} E[Y(1)|T = 1, X = x] = \lim_{x \downarrow c} E[Y|X = x] \quad (17)$$

- Portanto, o efeito médio do tratamento em c satisfaz

$$\tau_{SRD} = \lim_{x \downarrow c} E[Y_i|X_i = x] - \lim_{x \uparrow c} E[Y_i|X_i = x] \quad (18)$$


- Na prática podemos usar uma regressão linear local para estimar o efeito do tratamento.
- Esta consiste em uma diferença de médias de Y_i de observações à direita e à esquerda de c dentro de um intervalo $x \in [c - h; c + h]$.
- Em uma regressão, dado que $Z_i = T_i$ deve-se calcular

$$Y_i = \alpha + \beta T_i + \gamma_1(X_i - c) + \gamma_2 T_i(X_i - c) + \varepsilon_i$$
$$i : c \leq X_i < c + h$$
(19)

- em que o efeito do tratamento em $X_i = c$ é β .
- h deve ser suficientemente pequeno.

Sharp RDD: Estimando o efeito local

- Veja um exemplo gráfico de uma regressão RDD Sharp — não local.



Efeito Local do Tratamento

- A probabilidade de receber o tratamento não precisa mudar de 0 para 1 no *threshold* c .
- O desenho do tipo *Fuzzy* ocorre quando há “imperfect compliance”. Neste caso há um salto descontínuo menor do que 1 na probabilidade de tratamento no *threshold*:

$$\lim_{x \downarrow c} Pr[T_i = 1 | X_i = x] \neq \lim_{x \uparrow c} Pr[T_i = 1 | X_i = x] \quad (20)$$

- Essa situação pode ocorrer quando em determinado *threshold* há uma mudança descontínua nos incentivos para participar de um programa, sem que esses incentivos sejam fortes o suficiente para mover todas as unidades da situação de não-participantes para participantes.

- A razão entre o salto observado nos resultados em torno do *threshold* e o salto observado na probabilidade de participação no programa consiste no Efeito Causal Médio Local.

$$\tau_{FRD} = \frac{\lim_{x \downarrow c} E[Y_i | X_i = x] - \lim_{x \uparrow c} E[Y_i | X_i = x]}{\lim_{x \downarrow c} E[T_i | X_i = x] - \lim_{x \uparrow c} E[T_i | X_i = x]} \quad (21)$$

- Note a similaridade com o estimador de variáveis instrumentais (ou Mínimos Quadrados Indiretos).
- Se a regra de tratamento determina que sejam tratados indivíduos com $X_i \geq c$ e não tratados indivíduos com $X_i < c$, no caso do desenho FRD, deve ser possível desrespeitar o *threshold* em alguma medida.



$$\begin{aligned} TFRD &= \frac{\lim_{x \downarrow c} E[Y|X = x] - \lim_{x \uparrow c} E[Y|X = x]}{\lim_{x \downarrow c} E[T|X = x] - \lim_{x \uparrow c} E[T|X = x]} \\ &= E[Y_i(1) - Y_i(0) | \text{complier}, X_i = c] \end{aligned} \quad (22)$$

- O efeito estimado é uma média do efeito do tratamento entre *compliers* com $X_i = c$.

- Na figura 3 podemos ver que a probabilidade de receber o tratamento não é 0 ou 1, i.e. o *cut-off* é manipulável. A probabilidade ainda pula no ponto $x = 6$, mas para um valor entre 0 e 1.
- Na figura 4 vemos a esperança dos resultados potenciais dada a covariada X e o tratamento, $E[Y(T)|T = T, X = x]$, representadas pelas linhas tracejadas, e a esperança condicional do resultado observado dada a covariada, representada pela linha sólida.
- A linha tracejada não precisa coincidir com a linha cheia, pois a probabilidade não é 0 ou 1, mas um valor intermediário, que determina resultados médios esperados diferentes dos resultados potenciais.




Fig. 3. Assignment probabilities (FRD).




Fig. 4. Potential and observed outcome regression (FRD).

Figure : Designação de probabilidades e resultados potenciais ▶

- A regressão linear local no caso Fuzzy pode ser estimada por

$$Y_i = \alpha + \beta T_i + \gamma_r(X_i - c)Z_i + \gamma_l(X_i - c)(1 - Z_i) + \varepsilon_i$$
$$i : c \leq X_i < c + h$$
(23)

- O primeiro estágio consistiria em

$$T_i = \theta + \rho Z_i + \lambda_r(X_i - c)Z_i + \lambda_l(X_i - c)(1 - Z_i) + \eta_i$$
$$i : c \leq X_i < c + h$$
(24)

Validade Externa do RDD

- Os desenhos SRD e FRD, na melhor das hipóteses, proveem uma estimativa do efeito médio para uma subpopulação, marcadamente aquela com covariada igual a $X_i = c$.
- O desenho FRD restringe ainda mais a análise, pois só é válido para a subpopulação de *compliers*.
- Sem fortes hipóteses para justificar a extrapolação para outras subpopulações (e.g. homogeneidade do efeito do tratamento), os desenhos nunca permitirão ao pesquisador estimar o efeito médio total do tratamento.
- A vantagem dos desenhos do tipo RDD comparativamente à outros métodos não experimentais é que aqueles têm maior validade interna. Por outro lado, têm menor validade externa.

- A análise gráfica é uma parte integral da análise por RDD.
- Para avaliar a validade dessa estratégia é importante analisar vários gráficos.
- O primeiro gráfico de interesse se baseia no valor médio do resultado para diferentes valores da *forcing variable*.

- Para algum *binwidth* (largura do bin) m , e para um número específico de bins K_0 e K_1 para a esquerda e para a direita do *cutoff*, respectivamente, construa bins $[b_k, b_{k+1}]$ para $k = 1, \dots, K = K_0 + K_1$.
- O número de observações em cada bin é dado por:


$$N_k = \sum_{i=1}^N 1\{b_k < X_i \leq b_{k+1}\} \quad (25)$$

- e o resultado médio no bin é dado por

$$\bar{Y}_k = \frac{1}{N_k} \cdot \sum_{i=1}^N Y_i \cdot 1\{b_k < X_i \leq b_{k+1}\} \quad (26)$$

- O primeiro gráfico de interesse é aquele que plota \bar{Y}_k para $k = 1, \dots, K$ contra os pontos médios de cada bin $\frac{b_k + b_{k+1}}{2}$, e ajusta uma reta de regressão de cada lado do cutoff.
- Queremos ver se em volta do *threshold* c há evidência de descontinuidade (e.g. um salto). Se não observarmos descontinuidade nesse gráfico, muito provavelmente não acharemos descontinuidade usando os demais métodos.
- Bins muito “estritos” atrapalham a visualização da relação entre a *forcing variable* e a variável de resultado Y , i.e. o “ruído” dificulta a identificação do “sinal”. Bins mais “largos” permitem visualização do salto em torno do *cut-off*. Mas se forem muito largos, não poderemos visualizar o “salto”.

Análise Gráfica: Salto na variável de resultado Y_i




Gráficos suavizados por bins

Análise Gráfica: Gráficos de covariadas e da variável de tratamento

- No segundo gráfico devemos calcular médias para outras covariadas X_{im} do modelo para os k bins.
- Plotamos \bar{X}_{km} para $k = 1, \dots, K$ contra os pontos médios de cada bin.
- No caso do FRD também vale a pena plotar um terceiro gráfico com o valor médio de T em cada bin, para verificar se de fato há um salto em torno de c .

Figura 3 – Indicador de Infraestrutura em 2011 ao longo do %PBF: ajuste quadrático, escolas urbanas.




● Fonte: elaboração dos autores.

Descontinuidade em covariadas (infraestrutura) no % de alunos no Bolsa Família- Oliveira (2015)

Análise Gráfica: Gráfico da variável de tratamento

Figura 4 – Probabilidade de tratamento ao longo de PBF(%): ajuste linear, escolas urbanas nos anos iniciais (a) e nos anos finais (b).

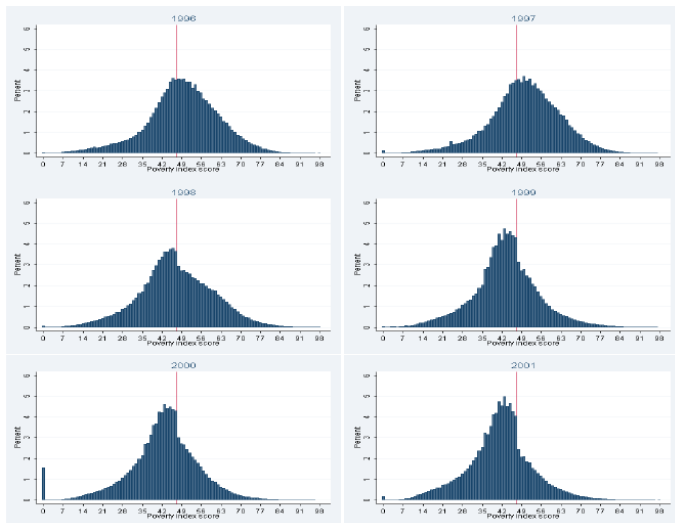


Descontinuidade do Programa Mais Educação no % de alunos no Bolsa Família - Oliveira (2015)

Análise Gráfica: A densidade da *forcing variable*

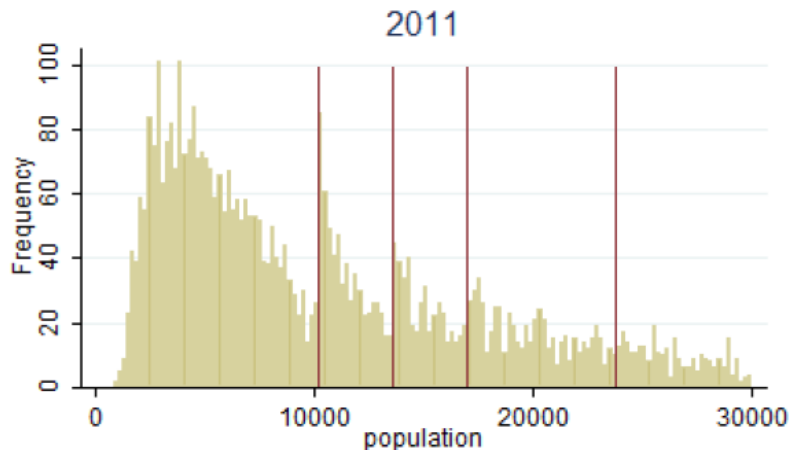
- Para verificar se não há uma descontinuidade na própria *forcing variable* X , podemos plotar o número de observações em cada bin.
- Se houver um “salto” nessa variável é sinal de que o valor de X é manipulável, i.e. a localização em volta do cutoff não é aleatória.
- Um exemplo nesse sentido é a manipulação do índice de pobreza usado como critério de elegibilidade para programas sociais na Colômbia (ver Camacho e Conover, 2010).
- O algoritmo para criar o índice de pobreza se tornou público no segundo semestre de 1997.

Análise Gráfica: A densidade da *forcing variable*



Densidade do Índice de Pobreza na Colômbia

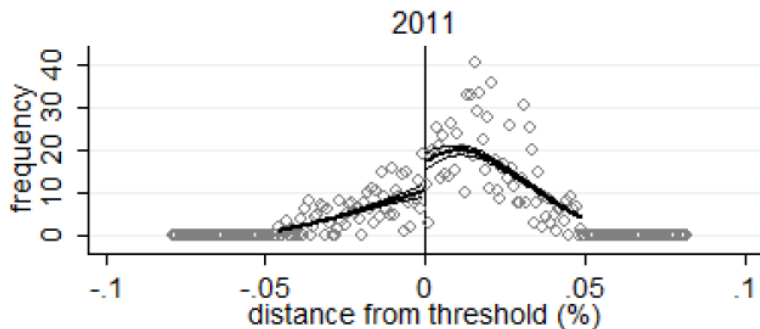
Análise Gráfica: A densidade da *forcing variable*



População Municipal e a regra de população do FPM - Castro (2016)

- Existe um teste, proposto por Justin McCrary (2008) que compara as densidades da *forcing variable* — $\lim_{x \downarrow c} f(X|X = x) - \lim_{x \uparrow c} f(X|X = x)$ — à direita e a esquerda do cutoff. Se essa diferença for estatisticamente significativa, então temos evidência de manipulação do cutoff.

Análise Gráfica: A densidade da *forcing variable*



O teste de densidade de McCrary (2008) - Castro (2016)

Checklist da implantação de RD - ver Lee e Lemieux

- 1 Para checar se houve manipulação, mostre a distribuição da variável X .
- 2 Apresente os principais gráficos de RD usando médias locais.
- 3 Caso use uma especificação polinomial, faça o gráfico.
- 4 Mostre sensibilidade dos resultados a diversas escolhas de h (bandwidth) on ordem do polinômio escolhido.
- 5 Conduza um RD em paralelo para as covariadas.
- 6 Mostre a sensibilidade dos resultados em relação a introdução de variáveis controle.
- 7 Faça testes de robustez/falsificação da variável Y_i em períodos pré-tratamento.

Material sobre avaliação de programas no site da disciplina de avaliação

Avaliação de Programas Sociais

O curso de Econometria do Setor Público buscará apresentar o aluno aos métodos de avaliação de programas sociais por meio de métodos econométricos específicos. O curso terá um enfoque prático, com uso intensivo de pacotes estatísticos. Até metade do tempo de aula se destinará a aulas práticas com uso de softwares e apresentação pelos alunos de trabalhos aplicados com uso de diferentes métodos. Se houver tempo, serão ensinados métodos econométricos específicos para Economia do Setor Público, como Econometria Espacial e Mensuração de Eficiência.

Arquivos

Ementa da disciplina

- [Aula 1 - Introdução e Revisão MOO, GLS e erros padrão robustos](#)
- [Aula 2 - Revisão Var Instrumentais](#)
- [Aula 3 - Revisão Painel](#)
- [Aula 4 - Modelo de Roy](#)
- [Aula 5 - Experimentos Sociais - Parte 1](#)
- [Aula 6 - Experimentos Sociais - Parte 2](#)
- [Aula 7 - Propensity Score Matching](#)
- [Aula 8 - Tratamentos contínuos e Múltiplos Tratamentos - GPS](#)
- [Aula 9 - Controle Sintético](#)
- [Aula 10 - Experimentos Naturais e Diferenças em Diferenças](#)
- [Aula 11 - Local Average Treatment Effect](#)
- [Aula 12 - Regression Discontinuity Design](#)
- [Aula 13 - Quantile Treatment Effect](#)

Listas

- [Lista 1](#)
- [Base lista 1](#)
- [Lista 2](#)
- [Base lista 2](#)
- [Lista 3](#)
- [Base lista 3](#)

Aulas Práticas

- [Dicas para escrever papers em economia \(John H. Cochrane\)](#)
- [Instrumentos Fracos - Weak IV \(Jörn-Steffen Pischke\)](#)
- [Aula Introdutória Stata](#)
- [Aula Stata III](#)

- Duflo, Esther, Rachel Glennerster, and Michael Kremer. 2008. "Using Randomization in Development Economics Research: A Toolkit." T. Schultz and John Strauss, eds., Handbook of Development Economics. Vol. 4. Amsterdam and New York: North Holland, 4.
- Imbens, G.W., Lemieux, T., (2007). Regression discontinuity designs: A guide to practice, Journal of Econometrics, *in press*, doi:10.1016/j.jeconom.2007.05.001.
- Jacob; R.,Zhu, P.; Somers, M.A.; Bloom, H. (2008). A Practical Guide to Regression Discontinuity. MDRC.