

Regressão Discontínua

Raphael Corbi

Universidade de São Paulo

Maio 2015

Inferência Causal

- ▶ grande objetivo da econometria aplicada
- 1. **Dados experimentais (padrão ouro)**
 - 1.1 mais confiável, mais caro, mais difícil de implementar
- 2. **Dados não-experimentais I**
 - 2.1 problema da seleção
 - 2.2 seleção em observáveis (matching, DID, controle sintético)
- 3. **Dados não-experimentais II (quasi-experimentais)**
 - 3.1 seleção em não-observáveis (IV, DID, RDD)

Problema de Seleção

- ▶ Pergunta: **Pronto-Socorro torna pacientes mais saudáveis?**
- ▶ hospitais oferecem tratamento, mas também contato com doentes
- ▶ dados da National Health Interview Survey
- ▶ 2 perguntas: foi ao pronto-socorro? condição de saúde 1 a 5?

	Sample size	Mean Health Status	Std Error
No Hospital	90,049	3.93	0,003
Hospital	7,774	3.21	0.014
Difference	—	0.72	0.000

Problema de Seleção - formalizando...

- ▶ dummy de tratamento $D_i = 0, 1$
- ▶ Resultado Potencial Y_{0i}, Y_{1i}

$$Y_i = \begin{cases} Y_{1,i} & \text{if } D_i = 1 \\ Y_{0,i} & \text{if } D_i = 0 \end{cases}$$

$$Y_i = Y_{0,i} + (Y_{1,i} - Y_{0,i})D_i$$

- ▶ porém não observamos ambos estados para o mesmo indivíduo

Problema de Seleção - formalizando...

$$\underbrace{E[Y_i|D_i = 1] - E[Y_i|D_i = 0]}_{\text{diferença observada em saúde média}} = \underbrace{E[Y_{1,i}|D_i = 1] - E[Y_{0,i}|D_i = 1]}_{\text{efeito tratamento médio nos tratados}} + \underbrace{E[Y_{0,i}|D_i = 1] - E[Y_{0,i}|D_i = 0]}_{\text{viés de seleção}}$$

- ▶ viés de seleção mascara o efeito causal do tratamento
- ▶ grande objetivo da pesquisa empírica é superar este viés

Inferência Causal

- como superar então o viés?

1. Dados experimentais (padrão ouro)

1.1 não há problema de seleção

1.2 tratamento aleatório = $\{Y_{0,i}, Y_{1,i}\} \perp\!\!\!\perp D_{0,i}$

2. Dados não-experimentais I

2.1 Hipótese da Independência Condicional (HIC)

2.2 $HIC = \{Y_{0,i}, Y_{1,i}\} \perp\!\!\!\perp D_{0,i} | X_i$

3. Dados não-experimentais II (quasi-experimentais)

3.1 hipótese IV: parte exógena da variação de X identificada por Z

3.2 hipótese RDD: tratamento é 'localmente' aleatório

Regressão descontínua desde 1960

- ▶ Thistlethwaite Campbell (1960)
 - ▶ prêmios excelência acadêmica em publicações
- ▶ set-up não experimental
- ▶ regra de alocação descontínua, baseada em uma variável contínua
- ▶ forcing (running) variable
- ▶ abaixo do cutoff = bom controle para acima do cutoff
- ▶ método esquecido até fim dos 1990's

Regressão descontínua nos 2000's

- ▶ primeiras aplicações (educação):
 - ▶ financial aid (van der Klaauw (2002))
 - ▶ class size (Angrist Lavy (1999))
 - ▶ school districts (Black (1999))
- ▶ outros tópicos:
 - ▶ efeito de seguridade social sobre a oferta de trabalho
 - ▶ Medicaid sobre saúde
 - ▶ reforço e desempenho escolar
 - ▶ economia política (median voter models)
 - ▶ sindicalização sobre salário e emprego

Vantagens da Regressão descontínua

- ▶ RD requer hipótese relativamente fracas para identificação
 - ▶ Hahn, Todd, and van der Klaauw (2001)
- ▶ inferência causal é potencialmente mais crível que DID e IV
 - ▶ Lee (2008)
 - ▶ RDD não assume que o tratamento é "aleatório"
 - ▶ tal variação aleatória é consequência da incapacidade dos agentes de controlar com precisão a *forcing variable* próximo ao cutoff
 - ▶ logo, não é só mais uma estratégia de identificação

Objetivo desta aula

- ▶ sumário do conhecimento atual de RDD
 - ▶ quando (não) vale, pontos fortes e fracos
- ▶ guia prático de implementação para um paper aplicado
 - ▶ técnica ainda não faz parte da maioria dos livros-texto
- ▶ discussão de questões de *identificação, interpretação e estimação*

Principais pontos da aula:

1. H1: indivíduos não controlam precisamente X (running variável)
 - 1.1 mecanismo gera incentivos para indivíduos tentarem controlar X
2. como consequência, a variação ao redor da discontinuidade é aleatória (come se fosse gerada por experimento aleatório)
 - 2.1 indivíduos têm a mesma probabilidade de ter um X t.q. $T=0$ ou 1
3. diferença crucial em relação ao IV:
 - 3.1 IV: instrumento é aleatório por hipótese (difícil de justificar)
 - 3.2 RDD: aleatoriedade como consequência do controle impreciso

Principais pontos da aula:


- 4. RDD podem ser analisados e testados como experimentos aleatórios
 - 4.1 teste das co-variadas acima/abaixo do cutoff
 - 4.2 IV: temos que assumir a exogeneidade condicional
- 5. exposição gráfica do efeito causal (transparência)
- 6. forma funcional paramétrica e não-paramétrica (complementos)

RDD set-up


- ▶ impacto dos prêmios de excelência acadêmica sobre resultados futuros
- ▶ prêmios ($D=1$) somente para alunos com notas $X > c$
- ▶ H2: resultados são funções não-contínuas somente devido ao prêmio
- ▶ importância da formal funcional

$$Y = \alpha + D\tau + X\beta + \epsilon$$

RD Linear




Importância da formas funcionais



RDD e a abordagem dos resultados potenciais

- ▶ Hahn, Todd, and van der Klaauw (2001)
- ▶ formalização do RDD na linguagem da literatura de tratamento
- ▶ H1: todos outros fatores são *contínuos* em X
- ▶ abordagem dos resultados potenciais:
 - ▶ para cada i , existem Y_{0i} e Y_{1i} não-observáveis
 - ▶ $[Y_{0i} - Y_{1i}] =$ efeito causal do tratamento
 - ▶ podemos pensar em duas relações entre Y e X
 - ▶ $E[Y_{0i}|X]$ e $E[Y_{1i}|X]$ contínuos dado H1
 - ▶ porém somente observamos Y_{0i} caso $X < c$ ou Y_{1i} caso $X > c$
 - ▶ observamos: $Y_i = Y_{0i} + DY_{1i}$

Importância da hipótese de continuidade



RDD e a abordagem dos resultados potenciais

$$\begin{aligned} B - A &= \lim_{\epsilon \rightarrow 0^+} E[Y_i | X_i = c + \epsilon] - \lim_{\epsilon \rightarrow 0^-} E[Y_i | X_i = c + \epsilon] \\ &= E[Y_{1i} - Y_{0i} | X_i = c] \end{aligned}$$

Identificação e Interpretação

► Comparando IV e RDD:

1. Em qual contexto o RDD é plausível? (hipóteses de identificação)
2. Existe algum meio de testar tais hipóteses?
3. As estimativas de RDD são generalizáveis?

Identificação e Interpretação: RDD (1)

1. Em qual contexto o RDD é plausível? (hipóteses de identificação)
 - ▶ quando todos fatores não observados forem contínuos em X
2. Existe algum meio de testar tais hipóteses?
 - ▶ não podemos testar a condição *necessária* de continuidade
3. As estimativas de RDD são generalizáveis?
 - ▶ não pois o efeito estimado vale somente para a sub-população ao redor do cutoff

Identificação e Interpretação: **Variáveis Instrumentais**

1. Em qual contexto o RDD é plausível? (hipóteses de identificação)
 - ▶ quando o instrumento for não-correlacionado com o erro da eq. estrutural
2. Existe algum meio de testar tais hipóteses?
 - ▶ não podemos testar a condição *necessária* de exclusão
3. As estimativas de RDD são generalizáveis?
 - ▶ não pois o efeito estimado vale somente para a sub-população afetada pelo instrumento

Identificação e Interpretação: RDD (2)

1. Em qual contexto o RDD é plausível? (hipóteses de identificação)
 - ▶ quando X tiver um componente estocástico (indivíduos não têm controle preciso), a variação do tratamento ao redor da discontinuidade será aleatória
2. Existe algum meio de testar tais hipóteses?
 - ▶ como num experimento aleatório, a distribuição de covariadas não pode mudar abruptamente ao redor do cutoff
3. As estimativas de RDD são generalizáveis?
 - ▶ RDD pode ser interpretado como média ponderada do efeito tratamento, com pesos de probabilidade de estar próximos ao cutoff

Experimento Aleatório com seleção não-aleatória

- ▶ considere a seguinte formulação do RDD:

$$Y = D\tau + W\delta_1 + U$$

$$D = 1[X \geq c]$$

$$X = W\delta_2 + V$$

- ▶ parece um modelo de dummy endógeno, mas observamos X :
 - ▶ W pode ser endógeno, desde que determinado antes de V
 - ▶ elementos de δ_1, δ_2 podem ser zero
 - ▶ não há imposição sobre as correlações de W, U, V
- ▶ note que heterogeneidade individual em Y é completamente determinado por (W, U)

Densidade de X sobre diferentes hipóteses




Figure 4. Density of Assignment Variable Conditional on $W = w, U = u$

Controle Impreciso de X

- ▶ um indivíduo consegue via esforço deslocar a curva para a direita
- ▶ mas estamos somente assumindo que ele não tem controle total
- ▶ **Definição:** Indivíduos tem controle impreciso sobre X quando condicional $W=w$ e $U=u$, a densidade de V é contínua (**lousa**)
- ▶ **Aleatorização Local:** Se indivíduos tem controle impreciso sobre X , o tratamento é aleatório ao redor do cutoff

Consequências da Aleatorização Local

1. Identificação do Efeito Tratamento (**lousa**)
2. Teste da Validade do RDD
 - ▶ (i) testar se $Pr[W = w|X = x]$ é contínuo em x no cutoff (similar ao teste de balanceamento do experimento aleatório)
 - ▶ (ii) testar se a densidade de X é contínua no cutoff
3. Irrelevância das covariadas (**lousa**)
 - ▶ natureza aleatória do tratamento não é condicional
 - ▶ inclusão das co-variadas pre-determinadas reduz variância
4. Generalização: RDD como tratamento médio ponderado (**lousa**)
 - ▶ no caso de efeito de tratamento heterogêneo, RDD não se aplica somente a população ao redor do cutoff

Fuzzy RD


1. RDD com imperfect compliance

- ▶ no sharp RD, probabilidade de tratamento pula de 0 para 1 no cutoff
 - ▶ no fuzzy RD, probabilidade de tratamento muda menos de 1
 - ▶ $\lim_{\epsilon \rightarrow 0^+} \text{prob}(D = 1 | X = c + \epsilon) \neq \lim_{\epsilon \rightarrow 0^-} \text{prob}(D = 1 | X = c + \epsilon)$
-
- ▶ discontinuidade entre Y e X não é mais o efeito tratamento médio
 - ▶ temos que ajustar pela fração induzida pelo cutoff (Wald IV)


$$\tau_F = \frac{\lim_{\epsilon \rightarrow 0^+} E[Y_i | X_i = c + \epsilon] - \lim_{\epsilon \rightarrow 0^-} E[Y_i | X_i = c + \epsilon]}{\lim_{\epsilon \rightarrow 0^+} E[D_i | X_i = c + \epsilon] - \lim_{\epsilon \rightarrow 0^-} E[D_i | X_i = c + \epsilon]}$$

Comparando RDD com outras estratégias de avaliação...

A. Randomized Experiment





B. Regression Discontinuity Design






Comparando RDD com outras estratégias de avaliação...

C. Matching on Observables



D. Instrumental Variables



Apresentação, Estimação e Inferência

1. Análise Gráfica
2. Análise de Regressão (especificação, (não) paramétrica)
3. Questões Práticas de Implementação
 - ▶ covariadas, running variable discreta, testes de validação
4. Guia Prático de Implementação

Análise Gráfica

- ▶ (i) dividir X em intervalos e plotar contra média de Y
- ▶ (ii) plotar a regressão prevista $E[Y|X]$
- ▶ vantagens da análise gráfica:
 - ▶ visualizar a forma funcional
 - ▶ regressão não-paramétrica (bom guia para a análise paramétrica)
 - ▶ o jump da ideia da magnitude do efeito tratamento
 - ▶ checar se existem outros jumps fora do cutoff
- ▶ bandwidth ótimo vs inspeção visual?

Intervalo de 2%




Figure 6. Share of Vote in Next Election, Bandwidth of 0.02 (50 bins)

Intervalo de 1%




Figure 7. Share of Vote in Next Election, Bandwidth of 0.01 (100 bins)

Intervalo de 0.5%




Figure 8. Share of Vote in Next Election, Bandwidth of 0.005 (200 bins)

Análise de Regressão

$$Y = \alpha + D\tau + X\beta + \epsilon$$

- ▶ até agora focamos no caso de regressão paramétrica linear
- ▶ porém a hipótese de linearidade não é garantida
- ▶ já vimos que isso é particularmente importante no caso de RDD
- ▶ qual a solução? trade-off entre eficiência e viés...

Análise de Regressão

1. Regressão Paramétrica com polinômios flexíveis (RD Global)
 - ▶ usamos todas as observações, mesmo longe do cutoff
 - ▶ polinomios de até 3a-5a ordem (Imbens e Gelman (2014))
 - ▶ (i) muito peso para observações longe do cutoff
 - ▶ (ii) resultados sensíveis a ordem do polinômio
 - ▶ (iii) inferência ruim - $\Pr(\text{erro tipo I})$ aumenta
2. Regressão Não-Paramétrica Local (RD Local)
 - ▶ usamos observações próximas do cutoff (ineficiência)
 - ▶ viés caso inclinação não-nula
3. Combinar tendência linear (1) com regressão local (2)
 - ▶ Hahn, Todd, and van der Klaauw (2001)

Teste de Validação

- ▶ hipótese: indivíduos não controlam precisamente X
- ▶ não podemos testar pois somente observamos uma realização, mas podemos testar a densidade agregada (McCrary (2008))
- ▶ problema: alguns pulam pra cima, alguns pra baixo...
- ▶ pode não ser um problema. ex: professor empurrando aluno aleatoriamente

Teste de McCrary




Figure 16. Density of the Forcing Variable (Vote Share in Previous Election)

Inspecionando as Covariadas

- ▶ teste alternativo da validade do RDD
- ▶ covariadas são localmente balanceadas?
 - ▶ (i) replicar o gráfico da descontinuidade para cada W
 - ▶ (ii) replicar a regressão principal para cada W
- ▶ como W é determinado antes do tratamento, descontinuidade não pode afetar W caso RD seja válido
- ▶ caso W seja grande, alguns coeficientes serão significantes
- ▶ usar SUR com teste χ^2 de significância conjunta

Checklist

1. To assess the possibility of manipulation of the assignment variable, show its distribution.
2. Present the main RD graph using binned local averages
3. Graph a benchmark polynomial specification
4. Explore the sensitivity of the results to a range of bandwidths, and a range of orders to the polynomial.
5. Conduct a parallel RD analysis on the baseline covariates
6. Explore the sensitivity of the results to the inclusion of baseline covariates.