

Técnicas Econométricas para Avaliação de Impacto

Análise de Causalidade e o Problema da Avaliação de Impacto

Rafael Perez Ribas
Centro Internacional de Pobreza

Brasília, 09 de abril de 2008

Introdução

“Que correlação não é causalidade é talvez a primeira coisa que deve ser dito” (Barnand, 1982).

- Na economia, o debate sobre análise de causalidade tem como pano de fundo a decisão entre políticas.
- Para tomar uma decisão, os chamados *policymakers* devem entender minimamente como as coisas funcionam e, principalmente, qual o efeito que algumas mudanças podem acarretar.

- Contudo, muitos estudos que visam a proposição de políticas usam métodos inapropriados para inferir sobre a chamada ‘causalidade’ entre dois eventos.
 - Confusão entre o que é uma **associação (correlação)** entre variáveis e o que pode ser inferido como **uma relação causal**.
- Frequentemente, verificamos em alguns estudos os seguintes avisos:
 - Apesar de esta análise parecer estar estritamente ligada à idéia de causalidade, ela, na realidade, não está;
 - A análise apresentada tem o objetivo de ser meramente descritiva;
 - Nenhuma inferência causal pode ser feita com base nos resultados.

- É óbvio que análises descritivas apresentadas na forma de correlações, condicionais ou incondicionais, entre variáveis possuem o seu valor.
- Contudo, há um risco em ir muito longe com análises descritivas por meio de regressões ou outros métodos que estimam correlações condicionais. Elas são facilmente interpretadas como causalidades.
- Os próprios pesquisadores, muitas vezes, examinam suas regressões pensando na causalidade entre eventos, sem especular sobre os mecanismos implícitos na correlação.
 - Exemplo: salários no setor público e no setor privado.

- Atualmente, muito dos principais avanços na econometria é incentivado pela discussão sobre inferência causal (Vide curso de Imbens e Wooldridge).
- Quando se fala em modelos estatísticos de causalidade, geralmente os associamos ao trabalho de Rubin (1974).
 - O chamado modelo causal de Rubin.
- Contudo, a idéia freqüentemente tida como original foi a de Neyman (1923, 1935).
- Na economia, os modelos de causalidade estão principalmente ligados aos nomes de Heckman e McFadden, ganhadores do Prêmio Nobel de 2000.

Definições

- Dowd e Town (2002) apontam 5 conceitos de causalidade:
 - **Causa:** Quando um resultado deriva da ocorrência de um evento;
 - **Determinação:** Quando uma variável influencia o resultado de outra variável;
 - **Antecedente:** Quando um evento precede outro evento;
 - **Razão:** Processo relacionando a causa ao resultado;
 - **Ocasão:** Quando o evento que causa um resultado é acionado por uma conjuntura.

- Avaliações de impacto se interessam pelas duas primeiras definições.
- A terceira definição está implícita na ‘causalidade de Granger’ (contestável) (Granger, 1969; Sims, 1972).
- A quarta é de interesse em modelos estruturais, defendidos por Heckman (2000, 2008).
- Noção Marshalliana de *ceteris paribus* ou **variação controlada**:
 - Análise do ponto de vista da variação no tratamento mantendo os demais fatores constantes.
- Isso difere da ‘causalidade de Granger’ que apenas trabalha com a idéia de predição através da antecedência.

- Formalmente, o efeito causal ou efeito do tratamento é definido como:

$$Y_i(s) - Y_i(s'), \quad s \neq s' \text{ e } s, s' \in S \text{ (conjunto finito de tratamentos)}$$

- Para um mesmo indivíduo i , a mudança *ceteris paribus* implica que somente s e s' estão variando.
- Uma outra forma de medir o efeito causal é através de um resultado subjetivo:

$$R(Y_i(s)) - R(Y_i(s')), \quad s \neq s' \text{ e } s, s' \in S,$$

onde $R(\cdot)$ é uma função de utilidade.

Modelos de Correlação ou Associação

- Em análises de correlação ou associação, o pesquisador está interessado e satisfeito em saber como os valores de uma variável de interesse Y estão associados com os valores de outras variáveis X .
- Probabilidades, esperanças e esperanças condicionais da variável Y podem ser calculadas sobre uma amostra, sem necessariamente inferir causalidade.
- Os parâmetros são determinados pela distribuição conjunta de Y e X , $\Pr(Y = y, X = x)$: proporção da amostra na qual $Y = y$ e $X = x$.

- A distribuição condicional de Y dado X , dada por $\Pr(Y = y | X = x) = \Pr(Y = y, X = x) / \Pr(X = x)$ descreve como a distribuição dos valores de Y muda quando X varia.

- No caso da regressão de Y sobre X ,

$$Y = X\beta + u$$

o parâmetro de associação poder ser

$$\beta = E[Y | X = x] - E[Y | X = x - 1]$$

- Neste caso, a inferência é simplesmente uma análise descritiva.

Porque Correlação não Implica Causalidade

- No mundo real, por trás de uma correlação entre Y e X nós temos a seguinte situação:

[Quadro]

- X , Y , W e Z são variáveis observáveis e u e v representam características não-observáveis.
- A omissão da variável W pode não ser um problema, pois ela representa uma das formas na qual X causa Y e isso pode não ser de interesse do pesquisador.

- A omissão da variável Z é um problema, pois resulta na estimação de uma **correlação espúria** entre X e Y .
 - Isto gera o chamado **viés por omissão de variáveis**, onde a variável X pode ser denominada como **fracamente exógena** (ou **fracamente endógena**).
- Outro problema na estimação é a **causalidade reversa**, que caracteriza X como **fortemente endógena**, ou simplesmente **endógena**, no modelo.
- Parêntesis:
 - Na causalidade de Granger, uma variável fracamente exógena é aquela correlacionada com os resíduos passados da variável Y ;
 - Já uma variável **fortemente endógena** é aquela correlacionada com os valores presentes e futuros de Y .

Variáveis Omitidas

- Se existe um Z que causa Y e este Z não está incluído no modelo, Z causa u .
- Se Z também causa X , u estará correlacionado com X .
- Intuitivamente, Z impõe um nível para X e outro para Y . A consequência é uma associação entre X e Y que não é necessariamente derivada de uma causalidade entre X e Y .
- A direção do viés depende se os efeitos de Z sobre X e Y são positivos ou negativos.

- A solução para estes casos são modelos que incorporam a correlação entre resíduos das funções de X e Y .
 - A função u seria decomposta em uma parte explicada e outra não-explicada por X , tal que esta última atende a exigência de não ser correlacionada com X .
- Outra solução é o uso de modelos com efeitos fixos, estimados por meio de um painel. Contudo, se Z não é fixo (atributo), o modelo não corrige o viés.
- Modelo de efeitos fixos não é uma panacéia, mas resolve muitos dos problemas de correlação (cross-section, espacial, temporal) entre resíduos.
- A variável W , interpretada como uma **razão** ou uma **forma** na qual X causa Y , não causa viés na análise. Mas implica uma limitação na extrapolação dos resultados.

Causalidade Reversa

- Por não ser causada pela omissão de variáveis, um modelo de efeitos fixos não corrige este tipo de viés.
- A única forma de estimar um parâmetro consistente é por meio da estimação de duas equações, uma para X e outra para Y .
- Tal que, na função Y , o componente de X explicado por outras variáveis que não Y possa ser isolado.

Soluções para Identificação da Causalidade

- A coleta de informações adicionais, antes não observadas, pode ser uma solução. Contudo, isso pode impor custos adicionais no levantamento das informações sem um retorno esperado.
 - Por mais que nossa ignorância sobre o mundo diminua, ainda resta muita coisa para se conhecer.
- Além disso, saturar o modelo incluindo um número maior de variáveis pode não ser a solução, por três razões:
 - O modelo perde em graus de liberdade, o que reduz a eficiência dos estimadores;
 - Uma das novas variáveis incluídas pode ser um W que acabará explicando parte do efeito de X sobre Y ;
 - Ou uma das variáveis incluídas pode derivar de uma causalidade reversa em relação a Y , enviesando completamente os demais parâmetros.

A Estimação de Modelos Contrafactuais

- A formulação de problemas de causalidade, em qualquer área, é baseada em análises contrafactuais.
- Contrafactuais são possíveis resultados em diferentes estados hipotéticos da natureza.
- Uma análise contrafactual busca contrastar resultados em diferentes estados, onde só a ocorrência do evento em questão diferencia estes estados.
 - Mesmo um modelo de regressão linear simples pode ser interpretado como uma análise contrafactual, desde que o coeficiente sobre X seja interpretado como a diferença que ocorreria em Y se houvesse uma mudança exógena em X .

- Heckman coloca que a definição de um conjunto de hipóteses ou, portanto, de contrafactuais é um exercício lógico;
 - Um modelo contrafactual será mais aceito quanto mais aceito forem as regras que o define;
 - Ou seja, isso depende da aceitação das premissas e da utilização de regras lógicas e matemáticas consistentes.
- Este exercício deve fornecer ainda a base para a especificação de fatores que possam ser creditados como exógenos ao resultado de interesse.

- Rubin (1986) aponta que uma condição necessária para identificação de um contrafactual é a Suposição de Valor Estável da Unidade de Tratamento (SUTVA, *Stable-Unit-Treatment-Value Assumption*).
 - O resultado Y de um indivíduo quando exposto ao tratamento s será o mesmo, não importa o mecanismo de seleção e qual tratamento as outras unidades recebem;
 $Y(0) \perp S$
 - SUTVA pode ser violado quando existem outras versões não representadas de tratamento ou quando há interação entre os indivíduos.
 - Outros autores se referem à SUTVA como suposição de **não-confundimento** ou **ignorabilidade**.

- Essa condição generaliza uma série de outras suposições suficientes, porém mais fortes, listadas por Holland (1986):
 - **Estabilidade temporal e transitoriedade causal;**
 - **Homogeneidade das unidades investigadas;**
 - **Independência do tratamento;**
 - **Efeito constante.**
- Uma outra condição necessária para identificação de um contrafactual é que exista um grupo de comparação ou controle:

$$0 < \Pr(D(s) = 1) < 1$$

O Problema Fundamental da Avaliação de Impacto

- O problema é que uma análise contrafactual, quase que por definição, só pode ser conduzida sobre um conjunto informacional **incompleto**.
 - Cada indivíduo é observado com somente um dos possíveis tratamentos. Seu contrafactual é *missing*.
- Além disso, existe o **problema de seleção**, quando somente parte dos indivíduos é observada sob determinado tratamento.
 - O resultado pós-tratamento só é observado entre os que escolheram ou foram escolhidos para receber o tratamento.

○ Portanto, o resultado representativo de um grupo tratado pode não convergir com o resultado representativo da população como um todo.

• Formalmente,

$Y(s)$ é observado se $D(s) = 1$,

mas $Y(s')$ não é observado, para $s \neq s'$

• Portanto, o pesquisador só observa

$$Y = \sum_{s \in S} D(s)Y(s)$$

• Conseqüentemente, sem a aplicação de suposições ou restrições (não-testáveis), a construção empírica de um contrafactual é **impossível**.

- Outro exemplo (clássico) é o modelo de Roy (1951):

$$D(1) = 1[Y(1) > Y(0)]$$

- O trabalhador só escolhe o setor com maior renda.
- O problema de seleção sempre surgirá quando os dados são gerados de acordo com a escolha dos agentes.
 - Sejam eles os próprios indivíduos ou os gestores de um programa social.

Negligenciando Fatores Não-Observáveis (Seleção sobre Observáveis)

- Negligenciar fatores não-observados significa supor que os mesmos não possuem efeito sobre a diferença nos possíveis resultados para um mesmo indivíduo.
- Uma condição necessária para a identificação de causalidade em um modelo de seleção sobre observáveis é uma versão condicional da SUTVA, onde:

$$Y(0) \perp S \mid X ,$$

- Isso implica uma independência condicional de $Y(0)$ e o tratamento.

- Uma versão mais fraca é suposição de **independência da média condicional**:

$$E[Y(0) | D(s) = 1, X] = E[Y(0) | D(s) = 0, X] = E[Y(0) | X].$$

- Além disso, é necessário que

$$0 < \Pr(D(s) = 1 | X) < 1$$

- Para cada valor de X , existe tanto um caso tratado por s quanto um caso não-tratado por s .

Restrição de Exclusão

(Seleção sobre Não-Observáveis)

- O modelo mais conhecido na economia que ilustra esta restrição é o modelo de oferta e demanda:

$$Q^D = Q^D(P^D, Z^D, U^D)$$

$$Q^S = Q^S(P^S, Z^S, U^S)$$

- Neste modelo P e Q são endógenos e estão em equilíbrio:

$$Q^D = Q^S = Q$$

$$P^D = P^S = P$$

- Supondo este equilíbrio, o modelo pode ser reescrito na seguinte forma reduzida:

$$P = P(Z^D, Z^S, U^D, U^S) \text{ e } Q = Q(Z^D, Z^S, U^D, U^S)$$

- Supondo que

$$Z^D \not\subset Z^S \text{ e } Z^S \not\subset Z^D,$$

- Os efeitos dos preços sobre as quantidades podem ser calculados da seguinte maneira:

$$\frac{\partial Q^D}{\partial P^D} = \left(\frac{\partial Q}{\partial z_e^S} \right) / \left(\frac{\partial P}{\partial z_e^S} \right) \text{ e } \frac{\partial Q^S}{\partial P^S} = \left(\frac{\partial Q}{\partial z_e^D} \right) / \left(\frac{\partial P}{\partial z_e^D} \right)$$

- O critério de exclusão deve ser suficiente para se contar apenas **uma** história (sem haver sobre-identificação)
- Problema é que cada critério de exclusão pode gerar um resultado distinto.

Parâmetros de Causalidade (ou Tratamento)

- Diferentes tipos de investigação requerem diferentes tipos de parâmetros a serem estimados.

- O parâmetro de interesse mais comum é o ATE:

$$ATE = E[Y(s) - Y(s')]$$

- Outros parâmetros de interesse são o ATT ou ATET e o ATU ou ATEU:

$$ATT = E[Y(s) - Y(s') | D(s) = 1]$$

$$ATU = E[Y(s) - Y(s') | D(s') = 1]$$

- Por definição:

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

- Nos modelos com restrição de exclusão, o parâmetro de interesse é outro:

$$LATE = \frac{E[Y | z'_e] - E[Y | z_e]}{\Pr[D(z'_e) = 1] - \Pr[D(z_e) = 1]}$$

- Um parâmetro próximo do LATE é o Efeito de Tratamento para Pessoas na Margem da Indiferença (ou Elegibilidade), EOTM:

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

- Uma outra distinção importante é entre retornos (ou impactos) médio e marginal.

Modelos Estruturais vs. Forma Reduzida

- Estimacões na forma reduzida são suficientes e exigem menos suposições que os modelos estruturais.
- Portanto, estimativas não-enviesadas são mais factíveis, ao custo de não aprender muito sobre o processo investigado.
- Muitos modelos causais são incompletos por não especificarem claramente os mecanismos por trás da relação de causalidade;
 - A crítica é particularmente voltada aos estudos experimentais e análises de séries temporais;
 - Afirmando que seus resultados não podem ser extrapolados (ocorrência em outros contextos, inferência sobre eventos nunca ocorridos).
- O objetivo dos modelos estruturais é investigar a **caixa preta** do modelo causal, estudando não só o ‘efeito das causas’ mas também a ‘causa dos efeitos’.