

Estimação do Impacto de Múltiplos Tratamentos e do
Efeito Dosagem:
Escore de Propensão Generalizado

Fabio Veras Soares
Centro Internacional de Pobreza (PNUD/IPEA)

Vimos nas aulas anteriores que o “escore de propensão” é utilizado para reduzir o viés de seleção na estimação de relações causais, quando a seleção (para participar do tratamento) é baseada em variáveis observáveis.

O viés seria derivado do fato dos grupos de tratamento e controle diferirem sistematicamente em termos de suas características observáveis.

Todos os procedimentos que vimos anteriormente relacionados ao escore de propensão se baseavam na idéia de uma variável de tratamento binária: tratados versus controles.

O tratamento era então representado por uma variável *dummy*.

Entretanto há casos em que o tratamento não pode ser representado por uma variável *dummy*. Nestes casos o parâmetro de interesse pode ser o impacto:

- a) da dosagem do tratamento: montante de transferência, anos de estudo, quantidade de cigarros consumidos por dia, números de anos em que a pessoa fumou cigarros, valor do prêmio da loteria, numero de dias de treinamento profissional, tipos de treinamento profissional.
- b) de diferentes tipos de tratamento: transferência de renda e/ou suplemento nutricional; computador e/ou professor adicional; diferentes tipos de grupo de controle (externalidade), diferentes tipos de treinamento profissional;

Imai and Dyk (2003)

Escore de Propensão:

Escore de Balanceamento: $T \perp X | P(X)$

- O tratamento é independente das variáveis observáveis, se controlamos pelo escore de propensão (condicional ao escore de propensão)

- Hipótese da Independência Condicional (CIA - unconfoundedness):

$$(Y_1, Y_0) \perp T | P(X)$$

- As técnicas de *matching* (empareamento), ponderação pelo inverso da probabilidade, e de subclassificação podem ser usadas em conjunto com o escore de propensão para diminuir o impacto do viés de seleção.

Vantagens do escore de propensão:

- Reduz o problema da dimensionalidade;
- Melhor do que se o escore fosse conhecido;

É possível generalizar o “escore de propensão” para avaliar situações onde o tratamento não é representado por uma variável *dummy*?

Sim. Através de uma função de propensão ou GPS (Escore de Propensão Generalizado)

Modelo Rubin: Tratamento Generalizado

Define-se um conjunto de resultados potenciais: $Y = (Y_i(t^p), t^p \in \tau$ para $i=1, \dots, n$,

Onde τ é um conjunto de possíveis valores de tratamento e $Y_i(t^p)$ é uma variável aleatória que relaciona um tratamento particular (t^p) a um resultado potencial.

Hipótese 1: SUTVA

- Ausência de equilíbrio geral e de externalidades:

$$p\{Y_i(t_i^p) | T_j^A = t_j^p, X_i\} = p\{Y_i(t_i^p) | X_i\} \text{ para qualquer } i \neq j \text{ e qualquer } t_i^p, t_j^p \in \tau$$

Hipótese 2: CIA (Ignorabilidade da alocação do tratamento):

- A distribuição do tratamento não depende do resultado potencial dados os observáveis.

$$p\{T^A | Y(t^p), X\} = p\{T^A | X\} \text{ para todo } X \in \mathcal{X} \text{ e conjuntos mensuráveis de } A \subset \tau.$$

Efeito médio causal:

$$E\{Y(t_1^p) - Y(t_2^p) | X\} = E\{Y(t_1^p) | T^A = t_1^p, X\} - E\{Y(t_2^p) | T^A = t_2^p, X\}$$

- Problema: dimensionalidade de X

A Função de Propensão

A função de propensão é a probabilidade condicional do tratamento -- seja ele binário, contínuo ou multivariado – dada as covariáveis observadas:

$$e_{\psi}(T^A | X) = P_{\psi}\{T^A | X_i\} \text{ onde } \psi \text{ parametriza a função.}$$

- A função de propensão, e_{ψ} , é desconhecida e sua distribuição condicional $P_{\psi}\{T^A | X_i\}$ deve ser modelada de modo a estimar os parâmetros desconhecidos, ψ (máximo verossimilhança).

Hipótese 3: Função de Propensão é unicamente parametrizada
Esta hipótese implica que a função de propensão depende de X apenas através de $\theta_{\psi}(X)$. Ou seja, a função propensão é efetivamente “sintetizada” no parâmetro θ que tipicamente tem uma dimensão menor que X .

Exemplo com uma variável de tratamento contínua:

Pode-se modelar a distribuição do tratamento (contínuo) dado um vetor de covariáveis (X) como:

$$T^A | X \sim N(X^T \beta, \sigma^2)$$

$$e (T^A | \theta_\psi(X)), \psi(\beta, \sigma^2), \theta_\psi(X) = X^T \beta$$

Dado ψ , a função de propensão é completamente determinada pelo escalar θ . Portanto, *matching* ou subclassificação de função de propensão podem ser realizados através de *matching* ou subclassificação de θ , independentemente da dimensão de X .

Teorema 1: Função de propensão com um escore de balanceamento

$$p\{T^A | e(.|X)\} = p\{T^A | X, e(.|X)\} = p\{T^A | X\}$$

Na prática este teorema pode ser checado através da regressão de cada uma das covariáveis (X) contra a variável de tratamento T^A , controlando-se pela função de propensão. Se o coeficiente estimado não for significativo, então a função de propensão foi bem especificada e balanceou a distribuição.

Teorema 2: CIA dada a função de propensão (unconfoundedness)

$$p\{Y(t^p) | T^A, e(.|X)\} = p\{Y(t^p) | e(.|X)\} \text{ para qualquer } t^p \in \tau$$

Dada a função de propensão, o resultado potencial, $Y(t^p)$, e o tratamento, T^A , são independentes.

Da teoria para a Prática

$P\{Y(t^p) | e(. | X)\}$ pode ter sua média calculada ao longo da distribuição da função de propensão de modo a obter a distribuição do resultado do tratamento, como uma função de valores específicos do tratamento (tipo ou intensidade).

Os autores advogam o seguinte método para calcular o impacto do tratamento a partir da integração de $P\{Y(t^p) | e(. | X)\}$ sobre a distribuição da função de propensão:

1° passo: Modelar $P_{\psi}\{T^A | X_i\}$ de modo a estimar os parâmetros de interesse $\hat{\psi}$.

2° passo: Calcular $\hat{\theta} = \theta_{\hat{\psi}}(X)$ para cada observação e subclassificar observações com valores similares de $\hat{\theta}$ em um número parcimonioso de subclasses de tamanho parecidos.

3º passo: Dentro de cada subclasse modelar: $P\{Y(t^P) | T^A = t^P\}$ e estimar o coeficiente da regressão de $Y(t^P)$ contra (t^P) . Na prática, um ajuste adicional pela função de propensão pode ser requerido:

$$P\{Y(t^P) | T^A = t^P, \hat{\theta}\}, \text{ e talvez por algum } X \text{ também.}$$

4º passo: Calcular o efeito causal médio como a média ponderada do efeito de cada uma das subclasses.

- *Matching* parece ser uma alternativa de mais difícil implementação neste caso.
- Hirano e Imbens (2003) não usam subclassificação. Eles utilizam uma regressão saturada na função de propensão e na variável de tratamento.

Há muita vantagem em usar este procedimento ao invés de usar uma regressão simples que meça diretamente o impacto do tratamento sobre o indicador de interesse?

O que dizem os experimentos de Monte Carlo?

- dosagem
- múltiplo tratamento

a) a função de propensão é mal especificada de propósito

b) o resultado de uma regressão de Y em T^A e X é reportado para fins de comparação.

Conclusão: o modelo com a função de propensão com subclassificação é menos sensível à má especificação do modelo.

Exemplos:

- 1) Efeitos de fumar sobre gastos médicos
- a) Variável de tratamento (interesse): carteira por dia x anos de fumo

Modelo de duas partes:

$T=0$ (logístico)

$T>0$ (regressão linha)

- b) Variável de interesse: carteira por dia (freq) e anos de fumo (duração)

Modelo de duas partes para cada uma das variáveis de tratamento

- 2) Efeito da educação sobre a renda:

Angrist e Krueger (1995):

Balancear a variável instrumental.

