

# Эконометрический ликбез: эффекты воздействия

## Оценивание эффекта воздействия<sup>\*</sup>

Рубен Ениколопов<sup>†</sup>

Российская экономическая школа, Москва, Россия

В настоящем эссе содержится краткий обзор методов оценивания среднего эффекта воздействия программ, когда интересующая нас независимая переменная является бинарной.

### 1 Введение

В эмпирических исследованиях часто оценивают эффект бинарного воздействия одной переменной на другую, контролируя на определенный набор третьих переменных. Подобные ситуации возникают, например, когда требуется оценить эффект воздействия лекарства, контролируя на характеристики пациентов, или эффект экономической программы, контролируя на характеристики объектов, на которые направлена данная программа (фирм, людей, регионов и т.д.). В подобной ситуации все наблюдения распадаются на две группы – группу активного воздействия (*treatment group*) и контрольную группу (*control group*). В первую попадают объекты, подвергшиеся воздействию интересующей нас программы, лекарства и т.п., в то время как во вторую группу попадают объекты, не подвергшиеся такому воздействию. В случае, когда включение в качестве контрольных переменных конечного набора переменных позволяет полностью нивелировать не относящиеся к эффекту программы различия между экспериментальной и контрольной группой, сравнение результатов двух групп могут быть истолкованы с точки зрения наличия причинно-следственной связи между воздействием и интересующим нас исходом.

### 2 Потенциальные исходы

Данный подход разработан в работах Рубина (Rubin, 1974, 1977, 1978).

#### 2.1 Определения

Пусть мы наблюдаем  $N$  объектов, случайно выбранных из популяции, где каждый объект обозначен индексом  $i = 1, \dots, N$ . Мы предполагаем, что для каждого объекта  $i$  определена пара потенциальных исходов:  $Y_i(0)$  для исхода в случае, если объект попадает в контрольную группу, и  $Y_i(1)$  для исхода в случае, если объект попадает в экспериментальную группу (группу активного воздействия).

Стоит сразу отметить два важные ограничения в рассматриваемой ситуации. Во-первых, предполагается, что интенсивность воздействия на объекты в группе воздействия предполагается неизменной, что позволяет объединить все объекты в одну экспериментальную группу. Во-вторых, в данном подходе для каждого объекта потенциальные исходы фиксированы и

\*Данное эссе в значительной мере основывается на статье Imbens & Wooldridge (2008), а также на лекции, прочитанной Гвидо Имбенсом в курсе “What’s New in Econometrics”, видеозапись и текст которой можно найти по адресу [www.nber.org/minicourse3.html](http://www.nber.org/minicourse3.html). Цитировать как: Ениколопов, Рубен (2009) «Оценивание эффекта воздействия», Квантиль, №6, стр. 3–14. Citation: Enikolopov, Ruben (2009) “Estimation of treatment effects,” Quantile, No.6, pp. 3–14.

<sup>†</sup>Адрес: 117418, г. Москва, Нахимовский проспект, 47, офис 1717. Электронная почта: [REnikolopov@nes.ru](mailto:REnikolopov@nes.ru)

не зависят от того, какие другие объекты подвергаются воздействию. Данное предположение известно как предположение о стабильности эффекта воздействия на объект (*stable unit treatment value assumption, SUTVA*) и может нарушаться при наличие внешних эффектов от воздействия между объектами (см. Angrist, Imbens & Rubin, 1996).

Для каждого объекта  $i$  определен вектор характеристик  $X_i$ , называемых ковариатами. Важным свойством ковариат является то, что изучаемое воздействие не оказывает на них никакого влияния. Примером ковариат является набор характеристик, которым обладал объект до того, как на него было оказано воздействие.

Каждый объект подвержен одному из двух типов воздействия:  $W_i = 0$ , если объект  $i$  подвергнут контролльному воздействию, и  $W_i = 1$ , если объект  $i$  подвергнут активному воздействию. Таким образом, для каждого объекта  $i$  мы наблюдаем тройку  $(W_i, Y_i, X_i)$ , где  $Y_i$  – реализовавшийся исход

$$Y_i \equiv Y_i(W_i) = \begin{cases} Y_i(0), & \text{если } W_i = 0, \\ Y_i(1), & \text{если } W_i = 1. \end{cases}$$

Следует отметить, что в реальности мы наблюдаем только один из этих исходов в зависимости от того, попал ли объект в контрольную или экспериментальную группу, в то время как второй (ненаблюдаемый) исход отвечает на вопрос «что бы было, если бы объект попал в другую группу».

*Мера склонности (propensity score)* определена как условная вероятность того, что объект будет подвергнут активному воздействию:

$$e(x) = \mathbb{P}\{W = 1|X = x\} = \mathbb{E}[W|X = x].$$

Также определим для  $w \in \{0, 1\}$  регрессии среднего и дисперсии

$$\mu_w(x) = \mathbb{E}[Y(w)|X = x]$$

и

$$\sigma_w^2(x) = \mathbb{V}[Y(w)|X = x].$$

## 2.2 Оцениваемый параметр

Для каждого объекта определен эффект воздействия  $\tau_i = Y_i(1) - Y_i(0)$ . В качестве параметра, который мы пытаемся оценить, чаще всего используется популяционный средний эффект воздействия

$$\tau_P = \mathbb{E}[Y(1) - Y(0)].$$

Также в качестве оцениваемого параметра может использоваться популяционный средний эффект воздействия на подвергшихся воздействию

$$\tau_{P,T} = \mathbb{E}[Y(1) - Y(0)|W = 1],$$

а также выборочные, а не популяционные, средние эффекты. Стоить отметить, что разница между этими параметрами имеет значение только в случае неоднородности эффекта воздействия. В том случае, когда эффект воздействия предполагается одинаковым для всех объектов, разница между этими оцениваемыми параметрами полностью нивелируется. К сожалению, в реальных ситуациях предположение об однородности эффектов практически всегда оказывается слишком сильным.

## 2.3 Предположения

Чтобы было возможно идентифицировать средний эффект воздействия, делаются следующие два предположения:

**Предположение 1. Несмешиваемость (unconfoundedness):** Пара  $(Y(0), Y(1))$  независима от  $W$  условно на  $X$ , т.е.  $(Y(0), Y(1)) \perp W|X$ .

Предположение о независимости означает, что, условно на ковариатах, распределение объектов по группам не зависит от потенциальных исходов для данного объекта и, в частности, не зависит от эффекта воздействия для данного объекта. Таким образом, исключаются случаи в которых, например, пациенты, которые больше нуждаются в получение лекарства (контролируя на ковариаты), будут с большей вероятностью включены в экспериментальную группу. Тот факт, что независимость предполагается условной на ковариатах, позволяет использовать данный подход в случаях, когда на распределение по подгруппам оказывают влияние определенные наблюдаемые характеристики, которые также могут быть связаны с потенциальными исходами.

Данное предположение также известно как предположение об условной независимости (Lechner, 1999) или отбор по наблюдаемым характеристикам (Heckman & Robb, 1985). По сути, данное предположение очень близко к предположению экзогенности в стандартных регрессионных моделях.

**Предположение 2. Пересечение (overlap):**  $0 < \mathbb{P}\{W = 1|X\} < 1$ .

Интуитивно, данное предположение означает, что не должно существовать такого значения ковариат, при котором мы можем однозначно утверждать, что объект будет принадлежать либо к контрольной группе, либо к группе воздействия. В случае нарушения данного предположения мы не можем оценить средний эффект воздействия для всей популяции, хотя мы можем оценить его для подмножества объектов, для которых данное предположение выполняется.

## 2.4 Общий подход

Для оценки эффекта воздействия тем или иным способом приходится сравнивать исходы в контрольной и экспериментальной группах. В чистом виде такое сравнение дает следующий результат:

$$\begin{aligned}\Delta &= \mathbb{E}[Y|W = 1] - \mathbb{E}[Y|W = 0] \\ &= \mathbb{E}[Y(1) - Y(0)|W = 1] + \mathbb{E}[Y(0)|W = 1] - \mathbb{E}[Y(0)|W = 0].\end{aligned}$$

Первый член в этом выражении,  $\mathbb{E}[Y(1) - Y(0)|W = 1]$ , – это средний эффект воздействия на подвергшихся воздействию. Второй член,  $\mathbb{E}[Y(0)|W = 1] - \mathbb{E}[Y(0)|W = 0]$ , – это смещение из-за отбора (selection bias), который указывает, насколько отличались бы исходы в контрольной и экспериментальной группе, даже если никакого активного воздействия не было бы произведено. Таким образом, сравнение исходов в контрольной и экспериментальной группах позволяет оценить средний эффект воздействия в случае, если, во-первых, нет смещения из-за отбора, и, во-вторых, эффект воздействия на подвергшихся воздействию не отличается от эффекта воздействия на не подвергшихся воздействию ( $\tau_P = \mathbb{E}[Y(1) - Y(0)|W = 0]$ ).<sup>1</sup> Предположение о несмешиваемости обеспечивает выполнение обоих этих условий, что позволяет идентифицировать средний эффект воздействия. При этом предположении выполняется следующее равенство:

$$\mu_w(x) = \mathbb{E}[Y(w)|X = x] = \mathbb{E}[Y(w)|W = w, X = x] = \mathbb{E}[Y|W = w, X = x].$$

<sup>1</sup> В случае, если нарушается последнее условие, сравнение средних даст верную оценку среднего эффекта воздействия на подвергшихся воздействию, но не среднего эффекта воздействия.

Поскольку последнее выражение содержит только наблюдаемые величины, мы можем идентифицировать  $\mu_w(x)$ . Таким образом, для того, чтобы оценить средний эффект воздействия, мы можем вначале оценить средний эффект воздействия для подмножества с ковариатами  $X = x$ , а затем усреднить по всем таким подмножествам:

$$\begin{aligned}\tau(x) &= \mathbb{E}[Y(1) - Y(0)|X = x] = \mathbb{E}[Y(1)|X = x] - \mathbb{E}[Y(0)|X = x] \\ &= \mathbb{E}[Y(1)|W = 1, X = x] - \mathbb{E}[Y(0)|W = 0, X = x] \\ &= \mathbb{E}[Y|W = 1, X = x] - \mathbb{E}[Y|W = 0, X = x], \\ \tau_P &= \mathbb{E}[\tau(x)].\end{aligned}$$

### 3 Оценивание среднего эффекта воздействия

Существует целый ряд различных способов оценивания среднего эффекта воздействия. Основными подходами являются регрессионный, на основе мэтчинга, на основе меры склонности, а также их разные комбинации.

#### 3.1 Регрессии

Данный подход основан на получении состоятельной оценки двух регрессионных функций  $\mu_w(x)$ ,  $w \in \{0, 1\}$ . Пусть мы получили такие оценки  $\hat{\mu}_w(x)$ . В таком случае средний эффект воздействия оценивается как их разность, усредненная по эмпирическому распределению ковариат:

$$\hat{\tau}_{reg} = \frac{1}{N} \sum_{i=1}^N (\hat{\mu}_1(X) - \hat{\mu}_0(X)).$$

Таким образом, оценки регрессионных функций используются для вычисления вмененного (*imputed*) значения ненаблюданного потенциального исхода для каждого из объектов ( $Y_i(0)$  для объектов из экспериментальной группы и  $Y_i(1)$  для объектов из контрольной группы).

Наиболее простым способом оценки  $\mu_w(x)$  является параметрическое оценивание, например, при помощи линейной регрессии (Rubin, 1977). В частности, если мы используем регрессионную функцию  $\mu_w(x) = \beta'x + \tau\mu$ , то средний эффект воздействия может быть оценен при помощи простой регрессии  $Y_i = \alpha + \beta'X_i + \tau W_i + \varepsilon_i$ . Можно обобщить данный подход, оценивая раздельно регрессии для двух групп  $\mu_w(x) = \beta'_w x$ . Можно также использовать различные непараметрические методы оценивания регрессионной функции (Imbens, Newey & Ridder, 2005; Chen, Hong & Tarozzi, 2005; Heckman, Ichimura & Todd, 1997, 1998).

#### 3.2 Мэтчинг

Как и в случае регрессионного подхода, в оценках, использующих метод мэтчинга, при оценке эффекта воздействия для каждого из объектов вычисляются вмененные значения ненаблюдаемых потенциальных исходов. Однако, в случае мэтчинга в качестве вмененного значения используются наблюдаемые исходы объектов из другой группы воздействия, обладающих наиболее похожими значениями ковариат. Таким образом, для каждого объекта из экспериментальной группы ставится в соответствие один или несколько объектов из контрольной группы, с максимально похожими значениями ковариат. В качестве вмененного значения  $Y_i(0)$  для этого объекта используется усредненный исход этих объектов из контрольной группы. Аналогично, для каждого объекта из контрольной группы находится объект из экспериментальной группы с максимально похожим значением ковариат, и их усредненный исход используется в качестве вмененного значения  $Y_i(1)$ .

В простейшем случае дискретных ковариат можно добиться полного совпадения ковариат для различных объектов, и в качестве вмененного значения используется среднее значение исходов для всех объектов из противоположной группы воздействия, обладающих точно такими же значениями ковариат. Когда хотя бы одна ковариата является непрерывной, в общем случае добиться полного совпадения значений ковариат для разных объектов невозможно. В этом случае вводится метрика на пространстве ковариат и каждому объекту ставится в соответствие один или несколько объектов из противоположной группы, для которых расстояние до объекта минимально. При таком подходе исследователю необходимо выбрать используемую метрику, а также количество поставленных в соответствие объектов из противоположной группы. В подавляющем большинстве приложений используется метрика Махalanобиса, в соответствии с которой расстояние между точками вычисляется как  $d(x, y) = (x - y)' \Sigma^{-1} (x - y)$ , где  $\Sigma$  – ковариационная матрица ковариат. Основным достоинством этой метрики является то, что она не зависит от используемых единиц измерения.

Таким образом, единственным параметром, который остается выбрать исследователю, становится количество поставленных в соответствие объектов из противоположной группы. К сожалению, однозначных рекомендаций по выбору количества поставленных в соответствие объектов нет. Увеличивая их количество, мы увеличиваем эффективность оценки, одновременно увеличивая ее смещение. Abadie & Imbens (2006) показывают, что потери в эффективности от небольшого количества поставленных в соответствие объектов не очень велики, так что во многих приложениях оказывается достаточно ставить в соответствие лишь один объект. В прикладных исследованиях хорошим тоном считается проверка результатов на устойчивость по отношению к данному параметру.

Говоря более формально, оценка методом мэтчинга происходит следующим образом. Пусть у нас есть выборка  $\{(Y_i, X_i, W_i)\}_{i=1}^N$ . Обозначим через  $\ell_m(i)$  индекс объекта, находящегося на  $m$ -ом месте по расстоянию от объекта  $i$  среди объектов в противоположной группе. Формально,  $\ell_m(i)$  удовлетворяет следующим условиям:  $W_{\ell_m(i)} = 1 - W_i$ , и

$$\sum_{j:W_j=1-W_i} I\{\|X_j - X_i\| < \|X_{\ell_m(i)} - X_i\|\} = m,$$

где  $I\{\cdot\}$  – индикатор-функция, принимающая значение 1, если выражение в фигурных скобках истинно, и 0 в противном случае. Обозначим через  $\mathfrak{J}_M(i)$  множество индексов для первых  $M$  объектов, поставленных в соответствие объекту  $i$ :  $\mathfrak{J}_M(i) = \{\ell_1(i), \dots, \ell_M(i)\}$ . Определим вмененные потенциальные исходы как

$$\begin{aligned}\hat{Y}_i(0) &= \begin{cases} Y_i, & \text{если } W_i = 0, \\ M^{-1} \sum_{j \in \mathfrak{J}_M(i)} Y_j, & \text{если } W_i = 1, \end{cases} \\ \hat{Y}_i(1) &= \begin{cases} M^{-1} \sum_{j \in \mathfrak{J}_M(i)} Y_j, & \text{если } W_i = 0, \\ Y_i, & \text{если } W_i = 1. \end{cases}\end{aligned}$$

Простейшая мэтчинг-оценка – это

$$\hat{\tau}_M = \frac{1}{N} \sum_{i=1}^N (\hat{Y}_i(1) - \hat{Y}_i(0)).$$

Неприятным свойством простейшей мэтчинг-оценки является то, что она обладает смещением порядка  $O(N^{-1/K})$ , где  $K$  – количество непрерывных ковариат, использованных в мэтчинге (Abadie & Imbens, 2006). Таким образом, при  $K > 2$  оценка перестает быть  $N^{1/2}$ -состоятельной. Однако сочетание мэтчинга с регрессионными методами позволяет избавиться от этого смещения (см. ниже).

### 3.3 Мера склонности

Оценки с использованием меры склонности основаны на следующем результате (Rosenbaum & Rubin, 1983а). Пусть предположение о несмешиваемости верно. Тогда

$$(Y(0), Y(1)) \perp W | e(X). \quad (1)$$

Таким образом, чтобы избавиться от смещения в оценке, вместо контроля на полный набор ковариат достаточно контролировать лишь на меру склонности, условную вероятность того, что объект будет подвергнут активному воздействию. Существует несколько способов реализации данного метода, описанные ниже.

На практике оценивание с использованием меры склонности происходит в два этапа. На первом этапе оценивается сама мера склонности. Чаще всего это происходит путем оценивания пробит- или логит-модели, где зависимой величиной является индикаторная переменная, принимающая значение 1, если объект попал в экспериментальную группу, и 0, если объект попал в контрольную группу.<sup>2</sup> Затем предсказанное значение из оцененной регрессии используется в качестве меры склонности для дальнейшего оценивания среднего эффекта воздействия. Подобный метод оценивания реализован в пакете STATA (см. Becker & Ichino, 2002).

#### 3.3.1 Мера склонности и взвешивание

Использование меры склонности для взвешивания основано на следующих равенствах:

$$\mathbb{E} \left[ \frac{WY}{e(X)} \right] = \mathbb{E} [Y(1)]$$

и

$$\mathbb{E} \left[ \frac{(1 - W)Y}{1 - e(X)} \right] = \mathbb{E} [Y(0)],$$

из которых следует, что

$$\tau_P = \mathbb{E} \left[ \frac{WY}{e(X)} - \frac{(1 - W)Y}{1 - e(X)} \right].$$

Используя метод аналогий, можно использовать это неравенство для построения оценки

$$\tilde{\tau} = \frac{1}{N} \sum_{i=1}^N \left[ \frac{W_i Y_i}{\hat{e}(X_i)} - \frac{(1 - W_i) Y_i}{1 - \hat{e}(X_i)} \right].$$

Однако сумма весов в подобной оценке на конечных выборках может отличаться от единицы, что является нежелательным свойством. От этого свойства легко избавиться, скорректировав соответствующим образом веса, в результате чего получаем следующую оценку среднего эффекта воздействия (Hirano, Imbens & Ridder, 2003):

$$\hat{\tau}_{weight} = \left( \sum_{i=1}^N \frac{W_i}{\hat{e}(X_i)} \right)^{-1} \sum_{i=1}^N \frac{W_i Y_i}{\hat{e}(X_i)} - \left( \sum_{i=1}^N \frac{(1 - W_i)}{1 - \hat{e}(X_i)} \right)^{-1} \sum_{i=1}^N \frac{(1 - W_i) Y_i}{1 - \hat{e}(X_i)}.$$

<sup>2</sup> В более продвинутых методах может производиться непараметрическая оценка меры склонности (например, см. Hirano, Imbens & Ridder, 2003).

### 3.3.2 Мера склонности и блокирование

В данном методе после оценивания меры склонности все наблюдения разбиваются на  $M$  блоков, внутри которых объекты обладают примерно одинаковой вероятностью быть подвергнутым активному воздействию. В простейшем случае единичный интервал разбивается на  $M$  блоков одинакового размера с границами  $t/M$ , где  $t = 1, \dots, M - 1$ . Обозначим как  $J_{im}$  индикатор того, что объект  $i$  попал в блок  $m$ . В этом случае

$$J_{im} = I\{(m-1)/M < e(X_i) \leq m/M\}.$$

Обозначим число объектов из группы  $w \in \{0, 1\}$ , попавших в блок  $m$ , как  $N_{wm}$ . Внутри каждого блока эффект воздействия оценивается так, как если бы распределение по группам происходило случайным образом:

$$\hat{\tau}_m = \frac{1}{N_{1m}} \sum_{i=1}^N J_{im} W_i Y_i - \frac{1}{N_{0m}} \sum_{i=1}^N J_{im} (1 - W_i) Y_i.$$

Средний эффект воздействия оценивается как

$$\hat{\tau}_{block} = \sum_{i=1}^M \hat{\tau}_m \frac{N_{1m} + N_{0m}}{N}.$$

В данном подходе единственным параметром, который необходимо выбрать исследователю, является количество блоков. На практике оказывается, что уже пять блоков оказывается достаточным количеством, чтобы избавиться от большей части смещения в оценке (Cochran, 1968; Rosenbaum & Rubin, 1983b; Dehejia & Wahba, 1999). Количество блоков может быть увеличено при наличие достаточного количества наблюдений, особенно если внутри блоков распределение ковариат у контрольной и экспериментальной групп существенно отличается.

## 3.4 Смешанные методы

### 3.4.1 Мэтчинг и регрессия

Наиболее интересным из смешанных методов является сочетание мэтчинга и регрессии. В данном подходе в простую оценку, получаемую при помощи мэтчинга, вносится поправка, учитывающая разницу в ковариатах между поставленными в соответствие объектами. Формально, в качестве вмененных исходов используются

$$\begin{aligned} \hat{Y}_i(0) &= \begin{cases} Y_i, & \text{если } W_i = 0, \\ M^{-1} \sum_{j \in \mathfrak{J}_M(i)} (Y_j + \hat{\mu}_0(X_i) - \hat{\mu}_0(X_j)), & \text{если } W_i = 1, \end{cases} \\ \hat{Y}_i(1) &= \begin{cases} M^{-1} \sum_{j \in \mathfrak{J}_M(i)} (Y_j + \hat{\mu}_1(X_i) - \hat{\mu}_1(X_j)), & \text{если } W_i = 0, \\ Y_i, & \text{если } W_i = 1, \end{cases} \end{aligned}$$

после чего эти вмененные исходы используются для построения оценки среднего эффекта воздействия так же, как и при простом мэтчинге. Основным достоинством данного метода по сравнению с простым мэтчингом является то, что он позволяет (асимптотически) избавиться от смещения, делая оценку  $N^{1/2}$ -состоятельной (Abadie & Imbens, 2006). Данный метод реализован в пакете STATA (см. Abadie, Drukker, Herr & Imbens, 2003).

### 3.4.2 Взвешивание и регрессия

Оценивание с использованием взвешивания может быть переформулировано как оценивание методом наименьших квадратов функции

$$Y_i = \alpha + \tau W_i + \varepsilon_i$$

с весами, равными

$$\lambda_i = \sqrt{\frac{W_i}{e(X_i)} + \frac{1 - W_i}{1 - e(X_i)}}.$$

В данной формулировке мы можем легко обобщить данный подход и включить дополнительные ковариаты, чтобы увеличить точность оценок. В этом случае оценивается следующая регрессия:

$$Y_i = \alpha + \beta' X_i + \tau W_i + \varepsilon_i$$

с использованием тех же самых весов  $\lambda_i$ . Данный подход описан в Robins & Ritov (1997) и Hirano & Imbens (2001). Одним из достоинств этого и большинства других смешанных методов является так называемая «двойная устойчивость» – полученная оценка является состоятельной, если хотя бы один из используемых подходов верен. В данном случае оценка состоятельна, если регрессионная модель или мера склонности верно специфицированы.

### 3.4.3 Блокирование и регрессия

Оценка с использованием блокирования может быть записана как среднее оценок по каждому из блоков, которые оцениваются в регрессиях

$$Y_i = \alpha_m + \tau_m W_i + \varepsilon_i,$$

с использованием только наблюдений из блока  $m$ . Данный подход также легко обобщается с целью учесть эффект ковариат и увеличить точность оценки. В этом случае эффект внутри каждого из блоков оценивается как

$$Y_i = \alpha_m + \beta'_m X_i + \tau_m W_i + \varepsilon_i,$$

также с использованием только наблюдений из блока  $m$ . Затем оценки, полученные на разных блоках, усредняются, как и в обычном методе блокирования.

### 3.4.4 Мера склонности и регрессия

В некоторых прикладных работах мера склонности учитывается лишь в качестве дополнительного контроля в регрессии исхода  $Y_i$  на индикаторе принадлежности объекта к экспериментальной группе  $W_i$ . Асимптотические свойства подобных оценок не изучены. Кроме того, не совсем понятны преимущества данного метода по сравнению с простой регрессией на ковариаты, используемые при оценки меры склонности. По указанным выше причинам использование данного метода не рекомендуется.

### 3.4.5 Мера склонности и мэтчинг

Еще одним методом оценивания эффекта воздействия является мэтчинг, в котором в качестве единственной ковариаты используется мера склонности. Поскольку в этом случае размерность ковариат равна единице, получающаяся оценка является  $N^{1/2}$ -состоятельной и асимптотически нормальной. Если истинное значение меры склонности известно, то дисперсия этой оценки может быть оценена методом, предложенном в Abadie & Imbens (2006) и описанному в следующем разделе. К сожалению, дисперсия оценки, использующей оценку меры склонности, а не ее истинное значение, на данный момент не известна, что затрудняет использование этого метода на практике.

### 3.5 Оценивание дисперсии

Наиболее распространенным подходом к оцениванию дисперсии является бутстррап (Efron & Tibshirani, 1993; Horowitz, 2001). В большинстве случаев этот метод дает разумные оценки дисперсии. Однако для оценок с использованием мэтчинга при фиксированном числе объектов, ставящихся в соответствие, бутстррап дает неверные оценки (Abadie & Imbens, 2008).

Альтернативный метод получения оценок дисперсии описан в Abadie & Imbens (2006). Он основан на том, что большинство описанных выше оценок могут быть записаны в виде

$$\hat{\tau} = \sum_{i=1}^N \lambda_i Y_i, \text{ где } \sum_{i:W_i=1} \lambda_i = 1 \text{ и } \sum_{i:W_i=0} \lambda_i = -1,$$

и веса  $\lambda_i$  являются функцией ковариат и индикаторов групповой принадлежности для всех наблюдений. В этом случае дисперсия оценки равна

$$\mathbb{V}[\hat{\tau}|X_1, \dots, X_N, W_1, \dots, W_N] = \sum_{i=1}^N \lambda_i^2 \sigma_{W_i}^2(X_i).$$

Таким образом, для нахождения оценки дисперсии мы должны построить оценку  $\hat{\sigma}_{W_i}^2(X_i)$  для всех наблюдений. Для построения этих оценок Abadie & Imbens (2006) предлагают использовать мэтчинг. Идея заключается в том, что каждому объекту  $i$  мы ставим в соответствие объект  $\nu(i)$  из той же самой группы (т.е.  $W_i = W_{\nu(i)}$ ) с максимально похожими ковариатами. В качестве оценки  $\hat{\sigma}_{W_i}^2(X_i)$  используется

$$\hat{\sigma}_{W_i}^2(X_i) = \frac{(Y_i - Y_{\nu(i)})^2}{2}.$$

Получающаяся оценка  $\hat{\sigma}_{W_i}^2(X_i)$  для конкретного  $i$  не является состоятельной, однако агрегированная оценка

$$\hat{V} = \sum_{i=1}^N \lambda_i^2 \hat{\sigma}_{W_i}^2(X_i)$$

является состоятельной оценкой для дисперсии оценки среднего эффекта воздействия.

## 4 Оценка предположений

В предыдущем разделе описан ряд методов, позволяющих получить оценку среднего эффекта воздействия при условии выполнения предположений о несмешиваемости и пересечении. Ниже мы рассмотрим, каким образом можно попытаться оценить степень достоверности этих предположений.

### 4.1 Несмешиваемость

Предположение о несмешиваемости является принципиально нетестируемым, так как оно касается ненаблюдаемых характеристик (нереализованных исходов). Однако существует методы, которые хоть и не доказывают данное предположение, но делают его более достоверным (Heckman & Hotz, 1989; Rosenbaum, 1987). Подобные методы основаны на тестировании гипотезы о равенстве нулю эффекта воздействия в тех случаях, когда этот эффект должен быть равен нулю. В случае, если эта гипотеза отвергается, предположение о несмешиваемости становится более уязвимым. Существуют два основных класса подобных тестов.

К первому классу относятся тесты, оценивающие эффект воздействия, которое заведомо не должно отразиться на исходе. Данный подход основывается на наличие двух или

более контрольных групп, одна из которых используется в качестве фиктивной экспериментальной группы. Если сравнение двух контрольных групп указывает на наличие эффекта воздействия, то это означает, что как минимум одна из контрольных групп не является валидной и обладает системным смещением. Если гипотеза о нулевом эффекте воздействия не отвергается, предположение о несмешиваемости все равно может не выполняться, так как сравниваемые контрольные группы могут обладать одинаковым смещением. Именно поэтому следует выбирать для сравнения такие контрольные группы, относительно которых можно предполагать, что они обладают различным смещением. Например, если мы изучаем воздействие некоторой экономической программы на индивидов, мы можем разделить людей, не подвергшихся воздействию данной программы, на тех, кто не мог участвовать в программе по условиям программы, и тех, кто сам решил не принимать в ней участия. Наличие значимых различий между такими контрольными группами может свидетельствовать о наличии смещения, вызванного эффектом самоотбора.

Формально: пусть у нас имеется индикатор принадлежности к группе  $G_i \in \{-1, 0, 1\}$ , где значения  $\{-1, 0\}$  соответствуют контрольным группам:

$$W_i = \begin{cases} 1, & \text{если } G_i \in \{-1, 0\}, \\ 0, & \text{если } G_i = 1. \end{cases}$$

Вместо нетестируемого предположения о несмешенности мы можем проверить более сильное утверждение

$$(Y(0), Y(1)) \perp G|X,$$

из которого следует не только несмешиваемость, но и условие

$$Y \perp G|X, G \in \{-1, 0\},$$

которое можно проверить при помощи тестирования гипотезы о том, что

$$\mathbb{E}[\mathbb{E}[Y|G = -1, X] - \mathbb{E}[Y|G = 0, X]] = 0.$$

Ко второму классу относятся тесты, тестирующие эффект воздействия, где в качестве исхода используется характеристика, которая заведомо не зависит от изучаемого воздействия. В большинстве случаев в качестве такого псевдо-исхода используется характеристика, которая определяется до момента активного воздействия. В частности, в качестве такой характеристики может выступать лагированное значение интересующего нас исхода. В случае, если оцениваемый эффект воздействия отличен от нуля, это означает, что объекты в контрольной группе значимо отличаются от объектов в экспериментальной группе даже в отсутствие воздействия. Если же эффект отсутствует, то это хоть и не доказывает предположение о несмешиваемости, но делает его более достоверным.

## 4.2 Пересечение

В отличие от предположения о несмешиваемости, предположение о пересечении может быть оценено напрямую. Для оценки степени пересечения можно прежде всего сравнить сводную статистику распределения ковариат у контрольной и экспериментальной групп. Одним из стандартных индикаторов является нормализованная разность между средними значениями ковариат в контрольной и экспериментальной группах:

$$\Delta_X = \frac{\bar{X}_1 - \bar{X}_0}{\sqrt{S_1^2 + S_0^2}},$$

где  $S_1^2$  и  $S_0^2$  – выборочные дисперсии  $X$  в экспериментальной и контрольной группах, соответственно. В случае хорошего пересечения нормализованная разность не должна превышать единицу ни по одной из ковариат.

Сравнение ковариат по отдельности во многих случаях оказывается недостаточным, так как оно не учитывает особенностей совместного распределения ковариат (т.е. определенное сочетание ковариат может встречаться только в экспериментальной или только в контрольной группе). Для того чтобы оценить пересечение в совместном распределении ковариат, можно смотреть на распределение оцененной меры склонности. В случае хорошего пересечения наблюдения не должны быть слишком близкими ни к нулю, ни к единице.

В том случае, если оказывается, что предположение о пересечении вызывает сомнения, существует ряд способов, позволяющих в той или иной степени исправить ситуацию. Одним из наиболее распространенных методов является урезание выборки. В этом подходе из рассмотрения исключаются наблюдения, попадающие в области, где не наблюдается хорошего пересечения. При таком подходе страдает внешняя валидность метода, так как эффект оценивается лишь на определенной подвыборке наблюдений. Однако при этом сохраняется внутренняя валидность, поскольку на этой подвыборке мы получаем достоверную оценку эффекта. На практике это означает, что после оценивания меры склонности из рассмотрения исключаются наблюдения со слишком большим или слишком маленьким значением меры склонности. Czimpr, Hotz, Imbens & Mitnik (2008) показывают, что достаточно хороших результатов можно добиться, исключив наблюдения со значением меры склонности меньше 0,1 и больше 0,9.

## 5 Заключение

В данном эссе мы рассмотрели ряд методов, позволяющих оценить средний эффект воздействия. На практике наиболее важным является проверка уместности предположений о несмешиваемости и пересечении. В том случае, если эти предположения выглядят убедительно, выбор конкретного метода оценивания оказывается не столь важным. Хорошим стилем является проверка получаемых результатов на устойчивость относительно метода оценивания.

В практических приложениях все большую популярность приобретают методы, основанные на мэтчинге. В течение долгого времени одним из препятствий на пути их развития была вычислительная сложность, которая становится все менее важной по мере развития компьютерной техники, хотя использование подобных методов при большом количестве наблюдений и ковариат по прежнему остается затруднительным.

## Список литературы

- Angrist, J.D., G.W. Imbens & D.B. Rubin (1996). Identification of causal effects using instrumental variables. *Journal of American Statistical Association* 91, 444–455.
- Abadie, A., D. Drukker, H. Herr & G. Imbens (2003). Implementing matching estimators for average treatment effects in STATA. *Stata Journal* 4, 290–311.
- Abadie, A. & G. Imbens (2006). Large sample properties of matching estimators for average treatment effects. *Econometrica* 74, 235–267.
- Abadie, A. & G. Imbens (2008). On the failure of the bootstrap for matching estimators. *Econometrica* 76, 1537–1557.
- Becker, S. & A. Ichino (2002). Estimation of average treatment effects based on propensity scores. *Stata Journal* 2, 358–377.
- Chen, X., H. Hong & A. Tarozzi (2005). Semiparametric efficiency in GMM models of non-classical measurement errors, missing data and treatment effects. Препринт, New York University.
- Cochran, W.G. (1968). The effectiveness of adjustment by subclassification in removing bias in observational studies. *Biometrics* 24, 295–314.

- Crump, R., V.J. Hotz, G. Imbens & O.Mitnik (2008). Dealing with limited overlap in estimation of average treatment effects. *Biometrika*, в печати.
- Dehejia, R. & S. Wahba (1999). Causal effects in nonexperimental studies: Reevaluating the evaluation of training programs. *Journal of American Statistical Association* 94, 1053–1062.
- Efron, B. & R. Tibshirani (1993). *An Introduction to the Bootstrap*. Chapman and Hall.
- Heckman, J. & J. Hotz (1989). Alternative methods for evaluating the impact of training programs (with discussion). *Journal of American Statistical Association* 84, 862–874.
- Heckman, J., H. Ichimura & P. Todd (1997). Matching as an econometric evaluation estimator: Evidence from evaluating a job training program. *Review of Economic Studies* 64, 605–654.
- Heckman, J., H. Ichimura & P. Todd (1998). Matching as an econometric evaluation estimator. *Review of Economic Studies* 65, 261–294.
- Heckman, J. & R. Robb (1985). Alternative methods for evaluating the impact of interventions. Глава в *Longitudinal Analysis of Labor Market Data* (под редакцией Heckman, J.J. & B.S. Singer). Cambridge University Press.
- Hirano, K. & G. Imbens (2001). Estimation of causal effects using propensity score weighting: An application of data on right heart catheterization. *Health Services and Outcomes Research Methodology* 2, 259–278.
- Hirano, K., G. Imbens & G. Ridder (2003). Mean-squared-error calculations for average treatment effects. Препринт, University of California–Berkeley.
- Horowitz, J.L. (2001). The bootstrap. Глава 52 в *Handbook of Econometrics* (под редакцией Heckman, J.J. & E.E. Leamer), том 5. Elsevier Science.
- Lechner, M. (1999). Earnings and employment effects of continuous off-the-job training in east Germany after unification. *Journal of Business & Economic Statistics* 17, 74–90.
- Imbens, G., W. Newey & G. Ridder (2005). Recent developments in the econometrics of program evaluation. NBER препринт №14251.
- Imbens, G. & J. Wooldridge (2008). Recent developments in the econometrics of program evaluation. NBER препринт №14251.
- Robins, J. & Y. Ritov (1997). Towards a curse of dimensionality appropriate (CODA) asymptotic theory for semi-parametric models. *Statistics in Medicine* 16, 285–319.
- Rosenbaum, P. (1987). The role of a second control group in an observational study (with discussion). *Statistical Science* 2, 292–316.
- Rosenbaum, P. & D. Rubin (1983a). The central role of the propensity score in observational studies for causal effects. *Biometrika* 70, 41–55.
- Rosenbaum, P. & D. Rubin (1983b). Assessing the sensitivity to an unobserved binary covariate in an observational study with binary outcome. *Journal of Royal Statistical Society Series B* 45, 212–218.
- Rubin, D. (1974). Estimating causal effects of treatments in randomized and non-randomized studies. *Journal of Educational Psychology* 66, 688–701.
- Rubin, D. (1977). Assignment to treatment group on the basis of a covariate. *Journal of Educational Statistics* 2, 1–26.
- Rubin, D. (1978). Bayesian inference for causal effects: The role of randomization. *Annals of Statistics* 6, 34–58.

## Estimation of treatment effects

**Ruben Enikolopov**

*New Economic School, Moscow, Russia*

The essay contains a short survey of methods used for estimation of average treatment effects, when the independent variable of interest is binary.

# Эффекты воздействия\*

Уитни К. Ньюи†

Массачусетский Технологический Институт, Кэмбридж, США

Данное эссе посвящено вопросам идентификации и оценивания среднего эффекта воздействия и среднего эффекта воздействия на подвергшихся воздействию.

## Введение

В работах, посвященных эффектам воздействия, исследуется, как на некоторый интересующий исследователя исход, например, на заработную плату, влияют некоторые другие параметры, такие как программы по обучению персонала. Очевидно, что эффекты воздействия имеют отношение к структурным моделям, в которых интересующий исследователя параметр находится в левой части регрессионного уравнения, а переменные, отвечающие за воздействия – в правой. Действительно, как мы увидим, модель с эффектами воздействия можно рассматривать как линейную структурную модель со случайными коэффициентами. Для облегчения восприятия в данной работе будет введена специальная терминология, общепринятая для моделей с эффектами воздействия.

Объекты мы будем нумеровать с помощью индекса  $i$ , а через  $D_i$  обозначим индикатор воздействия, принимающий значение 1, если объект был подвержен этому воздействию, и значение 0 в противном случае. Например,  $D_i = 1$  может означать, что индивид с номером  $i$  принимал участие в программе по обучению персонала или проходил медицинское лечение. Для того, чтобы описать эффект воздействия, необходимо ввести еще два параметра. Пусть  $Y_{i0}$  обозначает возможный исход, полученный в случае, если объект не был подвержен воздействию ( $D_i = 0$ ), а  $Y_{i1}$  – возможный исход в случае, если объект был подвержен воздействию ( $D_i = 1$ ). Ясно, что эти два параметра ненаблюдаемы. Один из них является «гипотетическим»: он обозначает исход, который мог бы быть получен, если бы применялось обратное воздействие. Тогда наблюдаемый исход будет выражаться как

$$Y_i = D_i Y_{i1} + (1 - D_i) Y_{i0}.$$

Эффект воздействия для объекта  $i$  определяется как

$$\beta_i = Y_{i1} - Y_{i0}.$$

Этот параметр неидентифицируем, поскольку наблюдается только один из возможных исходов. Но существуют некоторые другие параметры, которые при определенных условиях можно оценить. Один из них – это популяционный средний эффект воздействия (average treatment effect):

$$ATE \stackrel{\text{def}}{=} \mathbb{E}[\beta_i].$$

\*Перевод Е. Скиба и С. Анатольева. Эссе является материалом по курсу “New Econometric Methods,” прочитанного весной 2007 г. в Массачусетском Технологическом Институте, в рамках MIT OpenCourseWare (ocw.mit.edu). Цитировать как: Ньюи, Уитни К. (2009) «Эффекты воздействия», Квантиль, №6, стр. 15–23. Citation: Newey, Whitney K. (2009) “Treatment effects,” Quantile, No.6, pp. 15–23.

†Адрес: Department of Economics, Massachusetts Institute of Technology, 50 Memorial Drive, Building E52, Room 262D, Cambridge, MA 02142-1347, USA. Электронная почта: [whnewey@mit.edu](mailto:whnewey@mit.edu)

Он описывает эффект воздействия, усредненный по всей популяции объектов. Другой интересный параметр – это популяционный средний эффект воздействия на подвергшихся воздействию (average effect of treatment on treated):

$$ATT \stackrel{\text{def}}{=} \mathbb{E}[\beta_i | D_i = 1].$$

Он описывает эффект воздействия, усредненный по всей популяции подвергшихся воздействию объектов. Третий важный и интересный для исследования параметр называется локальным средним эффектом воздействия. Он будет введен нами в дальнейшем.

Для того чтобы лучше понять воздействия и разнообразные эффекты, которые они оказывают, установим связь между нашей моделью и регрессионной моделью со случайными коэффициентами. Из предыдущего уравнения для  $Y_i$  получаем:

$$Y_i = Y_{i0} + (Y_{i1} - Y_{i0})D_i = \alpha_i + \beta_i D_i,$$

$$\alpha_i = Y_{i0}, \quad \beta_i = Y_{i1} - Y_{i0}.$$

Таким образом,  $Y_i$  можно представить в виде линейной модели, в которой эффект воздействия  $\beta_i$  является коэффициентом при  $D_i$ , а константа  $\alpha_i$  и угол наклона  $\beta_i$  меняются в зависимости от объекта. Следовательно, ATE есть средний по всей популяции угол наклона, а ATT – угол наклона, усредненный по подмножеству всех объектов популяции, имеющих  $D_i = 1$ .

Определение этих случайных коэффициентов помогает понять историю возникновения теории эффектов воздействия. Коэффициент  $\beta_i = Y_{i1} - Y_{i0}$  иногда называют «гипотетическим», так как он объясняет, как менялся бы  $Y_i$  при изменении  $D_i$ . В моделях спроса и предложения используется понятие «движения вдоль кривой». Оно появилось в экономике благодаря Райту (Wright, 1928), который нашел ему оригинальное объяснение в рамках этой модели. Точно так же средний эффект воздействия – это просто ожидаемое значение случайного коэффициента в линейной модели, то есть средний угол наклона кривой.

Разнообразные допущения в модели позволяют оценить ATT и ATE. В данной работе будут обсуждаться некоторые условия, при которых возможно идентифицировать эти параметры. Доказательства будут проводиться путем демонстрации того, как эти параметры можно представить в виде ожидаемых значений данных.

Начнем с самого простого случая.

## Однородные эффекты воздействия

Простейший случай в этой модели – случай однородных эффектов воздействия, когда  $\beta_i = \bar{\beta}$ , то есть эффект воздействия один и тот же для всех объектов. Тогда ATT и ATE – это просто  $\bar{\beta}$ . В этом случае, обозначив  $\bar{\alpha} = \mathbb{E}[\alpha_i]$  и  $\varepsilon_i = \alpha_i - \bar{\alpha}$ , получаем

$$Y_i = \bar{\alpha} + \bar{\beta}D_i + \varepsilon_i.$$

Тогда модель сводится к обычной линейной модели с аддитивными ошибками и постоянными коэффициентами. В противоположность этому в базовую модель также входят аддитивные ошибки, но углы наклона случайны. Обратим внимание на то, что случайность  $\alpha_i$  эквивалентна ее представлению в виде суммы константы и возмущения:  $\alpha_i = \bar{\alpha} + \varepsilon_i$ .

Идентифицировать и оценить  $\bar{\beta}$  и  $\bar{\alpha}$  можно обычным способом, если у нас имеется инструмент  $Z_i$ , некоррелированный с  $\varepsilon_i$  и коррелированный с  $D_i$ , так что

$$0 = \mathbb{C}(Z_i, \varepsilon_i) = \mathbb{C}(Z_i, \alpha_i) = \mathbb{C}(Z_i, Y_{i0}),$$

$$\mathbb{C}(Z_i, D_i) \neq 0.$$

В этом случае коэффициенты можно идентифицировать через обычные инструментальные уравнения:

$$\bar{\beta} = \frac{\mathbb{C}(Z_i, Y_i)}{\mathbb{C}(Z_i, D_i)}.$$

Оценить эти коэффициенты можно стандартным образом, заменив популяционную ковариацию на выборочную. Если подвести итог, в данном разделе не было введено ничего нового, кроме использования терминологии из теории эффектов воздействия в стандартной модели с фиктивными переменными.

Предположение об однородности эффектов воздействия является слишком сильным во многих ситуациях. Например, можно считать, что влияние на заработную плату программ по повышению квалификации или влияние уменьшения числа учеников в классе на уровень образования одинаковы для каждого объекта. Однако непохоже, что эти предположения выполняются в действительности. Поэтому в дальнейшем будем считать, что коэффициент  $\beta_i$  меняется в зависимости от объекта.

### Случайное распределение

Случайное распределение означает, что исход не зависит от того, был ли объект подвержен воздействию или нет. Здесь мы делаем статистическое предположение

$$\mathbb{E}[Y_{i0}|D_i] = \mathbb{E}[Y_{i1}],$$

то есть среднее значение исхода по всем неподвергшимся воздействию объектам, не зависит от статуса подверженности воздействию. То же самое условие можно записать как  $\mathbb{E}[\alpha_i|D_i] = 0$ . Оно является более общим, чем условие независимости, поскольку позволяет моментам  $Y_{i0}$  более высокого порядка зависеть от  $D_i$ . Тем не менее, сложно представить ситуацию, в которой будет выполняться условие независимости среднего без полной независимости.

Для того чтобы понять, что происходит при этом предположении, заметим сначала, что

$$\mathbb{E}[\beta_i|D_i]D_i = \begin{cases} 0, & D_i = 0, \\ \mathbb{E}[\beta_i|D_i = 1], & D_i = 1, \end{cases} = \mathbb{E}[\beta_i|D_i = 1]D_i.$$

Тогда в условии независимости среднего получаем:

$$\begin{aligned} \mathbb{E}[Y_i|D_i] &= \mathbb{E}[\alpha_i + \beta_i D_i|D_i] = \mathbb{E}[\alpha_i] + \mathbb{E}[\beta_i|D_i]D_i \\ &= E[\alpha_i] + \mathbb{E}[\beta_i|D_i = 1]D_i. \end{aligned}$$

В данном случае фиктивная переменная в регрессии  $Y_i$  на константу и  $D_i$  имеет в качестве углового коэффициента ATT. Если кроме того мы предположим, что среднее значение  $Y_{i1}$  не зависит от  $D_i$ , то есть

$$\mathbb{E}[Y_{i1}|D_i] = \mathbb{E}[Y_{i1}],$$

то в результате имеем  $ATE = ATT$ , поскольку

$$\begin{aligned} \mathbb{E}[\beta_i|D_i = 1] &= \mathbb{E}[Y_{i1}|D_i = 1] - \mathbb{E}[Y_{i0}|D_i = 1] \\ &= \mathbb{E}[Y_{i1}] - \mathbb{E}[Y_{i0}] = \mathbb{E}[\beta_i]. \end{aligned}$$

В итоге мы получили, что когда  $Y_{i0}$  независимо от  $D_i$  в среднем, ATT представляется как дамми-коэффициент в регрессии исхода на константу и индикатор воздействия. Также мы показали, что если, кроме того,  $Y_{i1}$  независимо от  $D_i$  в среднем, ATE является тем же самым коэффициентом. Конечно, этот коэффициент можно оценить с помощью линейной регрессии  $Y_i$  на  $(1, D_i)$ . Более того, как и следовало ожидать, этот коэффициент в регрессии является единственным, что отличает средние значения  $Y_i$  для подвергшихся и не подвергшихся воздействию объектов.

## Обсуждение

Для многих приложений случайное распределение – слишком сильное допущение. Обычно объекты могут выбирать, хотят ли они подвергаться воздействию или нет, например, покидая выборку в случае, если условия воздействия их не устраивают. Люди могут уклоняться от программ по повышению квалификации или не пользоваться медицинским обслуживанием. Если эти решения связаны с  $(\alpha_i, \beta_i)$ , то мы не можем говорить о независимости  $(\alpha_i, \beta_i)$  и  $D_i$ . В рамках линейной модели  $Y_i = \alpha_i + \beta_i D_i$  возможна эндогенность, при которой  $D_i$  может коррелировать со случайными коэффициентами  $\alpha_i$  и  $\beta_i$ . Этот случай сложнее стандартного, поскольку угол наклона  $\beta_i$  также может коррелировать с  $D_i$ .

Существуют два подхода к этой проблеме. Первый (знакомый) подход состоит в применении инструментальных переменных. Второй подход получил название «отбор по наблюдаемым характеристикам». В этом случае благодаря анализу,циальному на некоторые наблюдаемые переменные, исчезает корреляция между  $D_i$  и  $(\alpha_i, \beta_i)$ . Поскольку использование инструментов является наиболее известным и распространенным способом решения этой проблемы, мы сначала его и рассмотрим.

## Инструментальная идентификация эффектов воздействия

В обычной линейной модели, для которой однородность эффектов воздействия – лишь частный случай, для нахождения угла наклона необходимо предположить некоррелируемость инструментов с возмущениями и их коррелируемость с  $D_i$ . Похожие условия будут использоваться для идентификации эффектов воздействия с помощью инструментов. Пусть  $Z_i$  – инструмент. Будем предполагать, что

$$\mathbb{E}[\alpha_i|Z_i] = \mathbb{E}[Y_{i0}|Z_i] = \mathbb{E}[Y_{i0}] = \mathbb{E}[\alpha_i],$$

то есть средний эффект у всех неподвергшихся воздействию объектов независим от инструментов.

Мы также рассмотрим случай, когда  $Z_i$  является фиктивной переменной, то есть когда  $Z_i \in \{0, 1\}$  с  $P = \mathbb{P}\{Z_i = 1\}$  и  $0 < P < 1$ . (Вопрос: зачем мы предполагаем  $0 < P < 1$ ?). Для дамми-инструмента существует полезная формула для ковариации между инструментом и любой другой случайной величиной  $W_i$ . В частности, можно получить, что

$$\begin{aligned} \mathbb{C}(W_i, Z_i) &= \mathbb{E}[W_i Z_i] - \mathbb{E}[W_i] \mathbb{E}[Z_i] = \left( \frac{\mathbb{E}[W_i Z_i]}{P} - \mathbb{E}[W_i] \right) P \\ &= (\mathbb{E}[W_i|Z_i = 1] - \mathbb{E}[W_i])P \\ &= \{\mathbb{E}[W_i|Z_i = 1] - (P\mathbb{E}[W_i|Z_i = 1] + (1 - P)\mathbb{E}[W_i|Z_i = 0])\}P \\ &= (\mathbb{E}[W_i|Z_i = 1] - \mathbb{E}[W_i|Z_i = 0])P(1 - P). \end{aligned}$$

То есть ковариация между  $W_i$  и  $Z_i$  представляется в виде разности двух условных средних величин при различных значениях  $Z_i$ , умноженной на  $P(1 - P)$ .

Из этой формулы можно сделать два полезных вывода. Во-первых, независимость среднего  $Y_{i0}$  от  $Z_i$  эквивалентна некоррелированности  $Y_{i0}$  и  $Z_i$ , что верно поскольку  $\mathbb{C}(Y_{i0}, Z_i) = 0$  тогда и только тогда, когда  $\mathbb{E}[Y_{i0}|Z_i = 1] = \mathbb{E}[Y_{i0}|Z_i = 0]$ . Во-вторых, из этой формулы можно получить выражение для предела инструментальной оценки угла наклона:

$$\frac{\mathbb{C}(Z_i, Y_i)}{\mathbb{C}(Z_i, D_i)} = \frac{\mathbb{E}[Y_i|Z_i = 1] - \mathbb{E}[Y_i|Z_i = 0]}{\mathbb{E}[D_i|Z_i = 1] - \mathbb{E}[D_i|Z_i = 0]}.$$

Этот результат называют Вальдовской формулой для инструментальных переменных, ссылаясь на работу Wald (1940), в которой Вальд использовал фиктивные переменные в качестве инструмента для решения проблемы ошибок измерения.

Непохоже, что при условии независимости в среднем  $\alpha_i$  от  $Z_i$  инструментальная формула идентифицируют ATT, ATE или вообще что-либо полезное. Подстановка  $Y_i = \alpha_i + \beta_i D_i$ , и использование независимости в среднем  $\alpha_i$  дает

$$\begin{aligned} \frac{\mathbb{C}(Z_i, Y_i)}{\mathbb{C}(Z_i, D_i)} &= \frac{\mathbb{E}[\alpha_i | Z_i = 1] - \mathbb{E}[\alpha_i | Z_i = 0] + \mathbb{E}[\beta_i D_i | Z_i = 1] - \mathbb{E}[\beta_i D_i | Z_i = 0]}{\mathbb{E}[D_i | Z_i = 1] - \mathbb{E}[D_i | Z_i = 0]} \\ &= \frac{\mathbb{E}[\beta_i D_i | Z_i = 1] - \mathbb{E}[\beta_i D_i | Z_i = 0]}{\mathbb{E}[D_i | Z_i = 1] - \mathbb{E}[D_i | Z_i = 0]}. \end{aligned}$$

Проблема заключается в коррелированности  $\beta_i$  и  $D_i$ , что в общем случае не позволяет их разделить. Тем не менее, существуют два особых случая, в которых кое-что важное идентифицируемо: случай случайной склонности к воздействию и случай локальных средних эффектов воздействия.

### Случайная склонность к воздействию

Стандартен случай в медицинской практике, когда людям назначают лечение случайным образом, но не все его принимают. Тогда параметр  $Z_i$  отвечает за назначение, то есть  $Z_i = 1$ , если индивиду  $i$  назначено лечение, и  $Z_i = 0$  в противном случае. В такой постановке только те проходят лечение (то есть для кого  $D_i = 1$ ), кому это лечение было случайным образом прописано. Оказывается, что в этом случае инструменты позволяют получить ATT. Этот результат благодаря Имбенсу и Рубину привело к широкому использованию инструментов в биостатистике.

Прежде чем показать, как инструменты позволяют получить ATT, отметим, что все объекты, у которых  $Z_i = 0$ , не будут подвержены воздействию, то есть из того, что  $D_i = 0$  следует, что  $Z_i = 0$ . Тогда

$$\frac{\mathbb{C}(Z_i, Y_i)}{\mathbb{C}(Z_i, D_i)} = \frac{\mathbb{E}[\beta_i D_i | Z_i = 1] - 0}{\mathbb{E}[D_i | Z_i = 1] - 0} = \frac{\mathbb{E}[\beta_i D_i | Z_i = 1]}{\mathbb{E}[D_i | Z_i = 1]}.$$

Также заметим, что из условия  $D_i = 1$  следует условие  $Z_i = 1$ , то есть  $\{D_i = 1\} \subset \{Z_i = 1\}$ . Следовательно,  $\mathbb{E}[\beta_i | D_i = 1, Z_i = 1] = \mathbb{E}[\beta_i | D_i = 1] = ATT$ . С помощью рассуждений, аналогичных приведенным выше, получаем

$$D_i \mathbb{E}[\beta_i | D_i, Z_i = 1] = D_i \mathbb{E}[\beta_i | D_i = 1, Z_i = 1] = D_i \cdot ATT.$$

Используем закон повторных математических ожиданий:

$$\mathbb{E}[\beta_i D_i | Z_i = 1] = \mathbb{E}[D_i \mathbb{E}[\beta_i | D_i, Z_i = 1] | Z_i = 1] = ATT \cdot \mathbb{E}[D_i | Z_i = 1].$$

В итоге, разделив на  $\mathbb{E}[D_i | Z_i = 1]$ , получаем

$$\frac{\mathbb{C}(Z_i, Y_i)}{\mathbb{C}(Z_i, D_i)} = \frac{\mathbb{E}[\beta_i D_i | Z_i = 1]}{\mathbb{E}[D_i | Z_i = 1]} = \frac{ATT \cdot \mathbb{E}[D_i | Z_i = 1]}{\mathbb{E}[D_i | Z_i = 1]} = ATT.$$

### Локальный средний эффект воздействия

Во втором интересном случае, когда эффект воздействия можно идентифицировать с помощью инструментальных переменных, появляются условия независимости и монотонности. Рассмотрим следующие условия:

Независимость:  $D_i = \Pi(Z_i, V_i)$ , и вектор  $(\beta_i, V_i)$  независим от  $Z_i$ .

Монотонность:  $\Pi(1, V_i) \geq \Pi(0, V_i)$  и  $\mathbb{P}\{\Pi(1, V_i) > \Pi(0, V_i)\} > 0$ .

Условие независимости означает, что существует приведенная форма  $\Pi(z, v)$  с возмущением  $V_i$ , которое может быть вектором и может входить в модель нелинейно. В качестве примера можно привести модель пересечения порога, в которой  $D_i = \mathbb{I}\{Z_i + V_i > 0\}$ . Условие монотонности означает, что изменение инструмента влечет изменение воздействия в одном и том же направлении. Это условие выполняется в модели пересечения порога. Приведенную форму этой модели иногда называют уравнением выбора, согласно которому объект подвергают воздействию, когда  $\Pi(z, v) = 1$ .

Оказывается, что в этих условиях инструменты позволяют найти среднее значение  $\beta_i$  по некоторому подмножеству популяции, называемое локальным средним эффектом воздействия (local average treatment effect). Этот эффект можно определить как

$$LATE = \mathbb{E}[\beta_i | \Pi(1, V_i) > \Pi(0, V_i)].$$

LATE – это средний эффект воздействия среди тех объектов, чье поведение было бы другим, если бы изменились инструменты. Этот параметр может представлять интерес, например, в модели, где  $Y_i$  – логарифм заработной платы,  $D_i$  – индикатор окончания средней школы,  $Z_i$  – фиктивная переменная, соответствующая кварталу рождения, а LATE – средний эффект от образования среди всех отчисленных из школы, которые бы остались в школе, если бы имели другой квартал рождения, и среди всех оставшихся в школе, которые были бы отчислены, если бы имели другой квартал рождения. Таким образом, инструменты оценивают среднюю полезность от получения образования для потенциально отчисленных. LATE – интересный параметр, хотя он и не отражает доходность образования для всей популяции.

Покажем, что инструменты позволяют получить LATE при условиях независимости и монотонности. Пусть  $T_i = \Pi(1, V_i) - \Pi(0, V_i)$ . Тогда

$$\begin{aligned} \mathbb{E}[\beta_i D_i | Z_i = 1] - \mathbb{E}[\beta_i D_i | Z_i = 0] &= \mathbb{E}[\beta_i \Pi(1, V_i) | Z_i = 1] - \mathbb{E}[\beta_i \Pi(1, V_i) | Z_i = 0] \\ &= \mathbb{E}[\beta_i \Pi(1, V_i)] - \mathbb{E}[\beta_i \Pi(1, V_i)] = \mathbb{E}[\beta_i T_i]. \end{aligned}$$

Похожим образом можно получить, что

$$\mathbb{E}[D_i | Z_i = 1] - \mathbb{E}[D_i | Z_i = 0] = \mathbb{E}[T_i].$$

По условию монотонности,  $T_i$  – фиктивная переменная, принимающая значения 0 или 1. Следовательно,

$$\frac{\mathbb{C}(Z_i, Y_i)}{\mathbb{C}(Z_i, D_i)} = \frac{\mathbb{E}[\beta_i T_i]}{\mathbb{E}[T_i]} = \mathbb{E}[\beta_i | T_i = 1] = \mathbb{E}[\beta_i | \Pi(1, V_i) > \Pi(0, V_i)].$$

## Эмпирический пример применения LATE

Приведем эмпирический пример применения LATE из работы Ангриста и Кругера (Angrist & Krueger, 1991), в которой была получена оценка доходности образования при использовании кварталов рождения в качестве инструментов. Данные взяты из переписи населения США 1980-го года, как и в работе Дональда и Ньюи (Donald & Newey, 2001). Двухшаговый метод наименьших квадратов с тремя инструментами дает результат 0,1077 со стандартной ошибкой 0,0195, а оценивание по Фуллеру со 180 инструментами дает результат 0,1063 со стандартной ошибкой (скорректированной на множественность инструментов) 0,0143. Таким образом, получаем, что доходность обучения для «потенциально отчисленных» составляет около 11 процентов.

## Отбор по наблюдаемым характеристикам

Для идентификации эффекта воздействия используется другой тип модели, в которой анализ условно на наблюдаемых (или идентифицируемых) переменных  $X_i$  заставляет эффект воздействия вести себя как если бы он задавался случайно. Аналогичный подход применялся для удаления эндогенности в линейном уравнении добавлением регрессоров. Условные переменные похожи на пропущенные регрессоры, при включении которых в регрессионное уравнение эндогенность исчезает. Делается специальное предположение:

$$\mathbb{E}[Y_{i0}|X_i, D_i] = \mathbb{E}[Y_{i0}|X_i],$$

то есть  $Y_{i0}$  независимо в среднем от  $D_i$  условно на  $X_i$ . Такое предположение похоже на используемое ранее предположение  $\mathbb{E}[Y_{i0}|D_i] = \mathbb{E}[Y_{i0}]$  и является его «условной» версией.

Проблема здесь в том, что неясно, откуда взять переменные  $X_i$ . Существует несколько экономических моделей, в которых такие переменные заложены в самой модели. Однако во многих практических случаях эти переменные выбираются без ссылок на модель. Вопрос идентификации тонкий, и важно подобрать правильные  $X_i$ . Условная независимость в среднем, которая должна выполняться для  $X_i$ , может не выполняться ни для подмножества  $X_i$ , ни когда к  $X_i$  добавлены дополнительные переменные.

Такое предположение позволяет идентифицировать ATT при наличии еще одного дополнительного условия. Пусть  $\mathcal{X}$  обозначает носитель  $X_i$  (наименьшее замкнутое множество, имеющее единичную вероятность), а  $\mathcal{X}_0$  и  $\mathcal{X}_1$  – носители  $X_i$  условно на  $D_i = 0$  и  $D_i = 1$  соответственно. Тогда дополнительное условие – это условие общего носителя

$$\mathcal{X} = \mathcal{X}_0 = \mathcal{X}_1.$$

Такое предположение является необходимым и достаточным условием для существования  $\mathbb{E}[Y_i|X_i, D_i = 1]$  и  $\mathbb{E}[Y_i|X_i, D_i = 0]$  для всех  $X_i$ . Всегда можно проверить, выполняется ли оно на практике или нет.

Из условия общего носителя и условия условной независимости в среднем получаем:

$$\begin{aligned} \mathbb{E}[Y_i|X_i, D_i = 1] - \mathbb{E}[Y_i|X_i, D_i = 0] &= \mathbb{E}[\alpha_i|X_i, D_i = 1] - \mathbb{E}[\alpha_i|X_i, D_i = 0] \\ &\quad + \mathbb{E}[\beta_i|X_i, D_i = 1] = \mathbb{E}[\beta_i|X_i, D_i = 1]. \end{aligned}$$

Здесь  $\mathbb{E}[\beta_i|X_i, D_i = 1]$  – это условная версия ATT. С помощью закона повторных математических ожиданий ATT определяется как математическое ожидание этой разницы по  $X_i$  условно на  $D_i = 1$ , то есть

$$ATT = \mathbb{E}[\beta_i|D_i = 1] = \mathbb{E}[(\mathbb{E}[Y_i|X_i, D_i = 1] - \mathbb{E}[Y_i|X_i, D_i = 0])|D_i = 1].$$

ATE также можно получить, если мы предположим, что  $Y_{i1}$  условно независимо в среднем от  $D_i$  условно на  $X_i$ . В этом случае

$$\begin{aligned} \mathbb{E}[\beta_i|X_i, D_i = 1] &= \mathbb{E}[Y_{i1}|X_i, D_i = 1] - \mathbb{E}[Y_{i0}|X_i, D_i = 1] \\ &= \mathbb{E}[Y_{i1}|X_i] - \mathbb{E}[Y_{i0}|X_i] = \mathbb{E}[\beta_i|X_i]. \end{aligned}$$

Следовательно,

$$ATE = \mathbb{E}[\beta_i] = \mathbb{E}[\mathbb{E}[Y_i|X_i, D_i = 1] - \mathbb{E}[Y_i|X_i, D_i = 0]].$$

В отличие от безусловного случая, ATE является отличной от ATT функцией от распределения данных. ATE получается путем усреднения  $\mathbb{E}[Y_i|X_i, D_i = 1] - \mathbb{E}[Y_i|X_i, D_i = 0]$  по всем  $X_i$ , в то время как ATT получается с помощью усреднения только при  $D_i = 1$ .

Оценивание ATT и ATE при этих условных ограничениях – сложная задача. Заметим, что эти параметры зависят от условных ожиданий. Обычно не предполагается, что условные

ожидания имеют какую-то определенную функциональную форму. Следовательно, необходимо использовать непараметрическое регрессионное оценивание.

Непараметрическое оценивание проводить сложно, когда у  $X_i$  большая размерность. Обычно такую ситуацию называют «проклятием размерности». Были попытки ослабить проклятие размерности с помощью «меры склонности» – функции  $P(X)$ , заданной как вероятность оказаться подверженным воздействию (или оказаться «выбранным») условно на  $X$ , то есть

$$P(X_i) = \mathbb{P}\{D_i = 1|X_i\} = \mathbb{E}[D_i|X_i].$$

Оказывается, что условная независимость в среднем  $Y_{i0}$  условно на  $X_i$  влечет условную независимость в среднем условно на  $P(X_i)$ . Таким образом, если бы  $P(X_i)$  было известно, то представлялось бы возможным найти и оценить ATT и ATE, используя одномерную условную переменную, а не многомерную величину  $X_i$ . А именно, если  $\mathbb{E}[Y_{i0}|X_i, D_i] = \mathbb{E}[Y_{i0}|X_i]$  и  $0 < P(X_i) < 1$  с вероятностью единица, то  $\mathbb{E}[Y_{i0}|P(X_i), D_i] = \mathbb{E}[Y_{i0}|P(X_i)]$ , так что рассуждения, приведенные выше, позволяют получить:

$$ATT = \mathbb{E}[(\mathbb{E}[Y_i|P(X_i), D_i = 1] - \mathbb{E}[Y_i|P(X_i), D_i = 0])|D_i = 1].$$

Если, кроме того,  $\mathbb{E}[Y_{i0}|X_i, D_i] = \mathbb{E}[Y_{i0}|X_i]$ , то

$$ATE = \mathbb{E}[\mathbb{E}[Y_i|P(X_i), D_i = 1] - \mathbb{E}[Y_i|P(X_i), D_i = 0]].$$

Таким образом, ATT и ATE есть математические ожидания от непараметрической функции от двух переменных,  $P(X_i)$  и  $D_i$ .

Если  $P(X_i)$  полностью неизвестна и неспецифицирована, то никакой пользы от анализа условно на «мере склонности» нет, поскольку  $P(X_i)$  тоже является функцией многомерного аргумента. Таким образом, положительный эффект от использования «меры склонности» возникает тогда, когда о  $P(X)$  известно больше, чем о  $\mathbb{E}[Y_i|X_i, D_i]$ .

Остается доказать, что из независимости условно на  $X$  следует независимость условно на  $P(X)$ . Обозначим ради простоты  $P_i = P(X_i)$ . Мы получим результат для произвольной переменной  $W_i$ , и его можно будет применить и к  $Y_{i0}$ , и к  $Y_{i1}$ . Для того чтобы доказать, что из  $\mathbb{E}[W_i|X_i, D_i] = \mathbb{E}[W_i|X_i]$  следует  $\mathbb{E}[W_i|P_i, D_i] = \mathbb{E}[W_i|P_i]$ , заметим, что по закону повторных математических ожиданий

$$\begin{aligned} \mathbb{E}[W_i|P_i, D_i = 1] &= \mathbb{E}[\mathbb{E}[W_i|X_i, D_i = 1]|P_i, D_i = 1] = \mathbb{E}[\mathbb{E}[W_i|X_i]|P_i, D_i = 1] \\ &= \frac{\mathbb{E}[D_i \mathbb{E}[W_i|X_i]|P_i]}{\mathbb{E}[D_i|P_i]} = \frac{\mathbb{E}[P_i \mathbb{E}[W_i|X_i]|P_i]}{P_i} \\ &= \mathbb{E}[\mathbb{E}[W_i|X_i]|P_i] = \mathbb{E}[W_i|P_i]. \end{aligned}$$

Точно таким же способом можно получить, что  $\mathbb{E}[W_i|P_i, D_i = 0] = \mathbb{E}[W_i|P_i]$ , так что нужное нам утверждение следует из предыдущего равенства.

## Отсутствие непрерывности в регрессии

Существуют два таких случая: в первом случае переменная воздействия меняется скачками, а во втором случае функция вероятности эффекта воздействия имеет разрывы.

Предположим,  $D_i = \mathbb{I}\{X_i \geq c\}$ . В этом случае  $\mathbb{E}[Y_{i0}|D_i, X_i] = \mathbb{E}[Y_{i0}|X_i]$  и  $\mathbb{E}[Y_{i1}|D_i, X_i] = \mathbb{E}[Y_{i1}|X_i]$  по построению. Условие общего носителя не выполняется, поскольку  $\mathcal{X}_0$  и  $\mathcal{X}_1$  не пересекаются.

Применим другой подход для идентификации параметров и положимся только на условие непрерывности для  $\mathbb{E}[Y_{i0}|X_i = x]$  и  $\mathbb{E}[Y_{i1}|X_i = x]$ .

ПРЕДПОЛОЖЕНИЕ:  $\mathbb{E}[Y_{i0}|X_i = x]$  и  $\mathbb{E}[Y_{i1}|X_i = x]$  непрерывны по  $x$  в точке  $c$ .

Заметим, что  $Y_i = Y_{i0}$  при  $X_i < c$  и  $Y_i = Y_{i1}$  при  $X_i \geq c$ . Тогда

$$\mathbb{E}[Y_{i0}|X_i = c] = \lim_{x \uparrow c} \mathbb{E}[Y_{i0}|X_i = x] = \lim_{x \uparrow c} \mathbb{E}[Y_i|X_i = x],$$

$$\mathbb{E}[Y_{i1}|X_i = c] = \lim_{x \downarrow c} \mathbb{E}[Y_{i1}|X_i = x] = \lim_{x \downarrow c} \mathbb{E}[Y_i|X_i = x].$$

Отсюда следует, что

$$\mathbb{E}[\beta_i|X_i = c] = \mathbb{E}[Y_{i1} - Y_{i0}|X_i = c] = \lim_{x \downarrow c} \mathbb{E}[Y_i|X_i = x] - \lim_{x \uparrow c} \mathbb{E}[Y_i|X_i = x].$$

Таким образом, условный эффект воздействия  $\mathbb{E}[Y_{i1} - Y_{i0}|X_i = c]$  определяется как скачок  $\mathbb{E}[Y_i|X_i = x]$  в точке  $x = c$ .

Можно интерпретировать этот эффект по-другому. Аналогично манипуляциям выше,

$$\mathbb{E}[\beta_i|X_i = c] = \mathbb{E}[Y_i|D_i = 1, X_i = c] - \mathbb{E}[Y_i|D_i = 0, X_i = c].$$

Заметим, что  $\mathbb{E}[Y_i|D_i = 1, X_i = c]$  и  $\mathbb{E}[Y_i|D_i = 0, X_i = c]$  представляют собой непараметрические регрессионные функции, оцененные на границах их носителей: первая – на нижней границе, а вторая – на верхней. Значит, в данной ситуации нельзя применять стандартную ядерную регрессию, но можно применить локальную линейную регрессию.

## Литература

- Angrist, J.D. & A.B. Krueger (1991). Does compulsory school attendance affect schooling and earning? *Quarterly Journal of Economics* 106, 979–1014.
- Donald, S. & W. Newey (2001). Choosing the number of instruments. *Econometrica* 69, 1161–1191.
- Wald, A. (1940). The fitting of straight lines if both variables are subject to error. *Annals of Mathematical Statistics* 11, 284–300.
- Wright, P.G. (1928). *The Tariff on Animal and Vegetable Oils*. New York: MacMillan.

## Treatment effects

**Whitney K. Newey**

*Massachusetts Institute of Technology, Cambridge, USA*

This essay discusses the issues of identification and estimation of the average treatment effect and the average effect of treatment on the treated.



# Оценивание методом «разность разностей»<sup>\*</sup>

Джеффри М. Вулдридж<sup>†</sup>

Университет штата Мичиган, Ист Лэнсинг, США

Настоящее эссе представляет собой обзор оценивания методом «разность разностей», в котором сначала излагается базовая методология, затем более детально обсуждаются последние достижения в области инференции, и в заключение рассматриваются новые методы оценивания эффектов воздействия в различных нелинейных и полупараметрических моделях.

## 1 Введение и обзор базовой методологии

Начиная с работы Ashenfelter & Card (1985), оценивание методом «разность разностей» при анализе экономической политики получило широкое распространение. В простейшей постановке наблюдаются некоторые исходы для двух групп и двух временных периодов. Одна из групп подвержена воздействию, или участвует в некоторой программе, во втором периоде, но не в первом. Вторая группа не подвержена воздействию ни в одном из периодов. В случае, когда одни и те же объекты внутри групп наблюдаются в каждом периоде, среднее изменение исхода во второй (контрольной) группе вычитается из среднего изменения исхода в первой (опытной) группе. Это устраняет смещение при сравнении исходов в опытной и контрольной группах только во втором периоде, которое может быть следствием постоянных различий между этими группами, а также смещение при сравнении во времени, которое может быть вызвано временными трендами, никак не связанными с программой.

При наличии повторяющихся выборок за два периода времени модель для типичного представителя каждой из четырех групп можно записать следующим образом:

$$y = \beta_0 + \beta_1 dB + \delta_0 d2 + \delta_1 d2 \cdot dB + u, \quad (1)$$

где  $y$  – представляющий интерес исход,  $d2$  – фиктивная переменная для второго периода, а  $dB$  – фиктивная переменная для опытной группы. Фиктивная переменная  $dB$  улавливает возможные различия между опытной и контрольной группами до осуществления программы. Фиктивная переменная для второго периода  $d2$  улавливает факторы, которые бы вызвали изменения в  $y$  даже при отсутствии воздействия или программы. Представляющий интерес коэффициент  $\delta_1$  находится при переменной взаимодействия  $d2 \cdot dB$ , которая совпадает с фиктивной переменной, равной единице для наблюдений в опытной группе во втором периоде. Оценка  $\delta_1$  методом «разность разностей» (РР-оценка) – это обычная МНК-оценка для уравнения (1) на основе случайных выборок по четырем группам. Ее можно записать в виде

$$\hat{\delta}_1 = (\bar{y}_{B,2} - \bar{y}_{B,1}) - (\bar{y}_{A,2} - \bar{y}_{A,1}),$$

где  $A$  обозначает контрольную группу. Инференция даже при умеренных размерах выборки для каждой из четырех групп очень проста, и ее легко сделать робастной к гетероскедастичности по группам или временными периодам в рамках модели регрессии.

\*Перевод Б. Гершмана. Эссе является предварительной версией материала, подготовленного для *Курса прикладной эконометрики* Гвидо В. Имбенса и Джеффри М. Вулдриджа, издательство Кембриджского университета. Цитировать как: Вулдридж, Джеффри М. (2009) «Оценивание методом „разность разностей“», Квантиль, №6, стр. 25–47. Citation: Wooldridge, Jeffrey M. (2009) “Difference-in-differences estimation,” Quantile, No.6, pp. 25–47.

<sup>†</sup>Адрес: Department of Economics, Michigan State University, East Lansing, MI 48824-1038, USA. Электронная почта: [wooldri1@msu.edu](mailto:wooldri1@msu.edu)

В некоторых случаях более убедительный анализ эффекта программы доступен при тщательном выборе опытной и контрольной групп. Предположим, например, что штат осуществляет программу в области здравоохранения для пожилых людей, скажем, в возрасте 65 лет и старше, и зависимая переменная  $y$  – это некий показатель здоровья. Одна из возможностей состоит в том, чтобы использовать данные только по жителям штата, в котором реализуется программа, как до, так и после ее внедрения, и в качестве контрольной группы взять жителей в возрасте до 65 лет (или, например, в возрасте от 55 до 64 лет), а в качестве опытной группы – жителей в возрасте 65 лет и старше. Потенциальная проблема такого РР-анализа состоит в том, что другие факторы, не связанные с новой программой штата, могут повлиять на уровень здоровья пожилых людей по сравнению с молодыми, например, изменения политики в области здравоохранения на федеральном уровне. Иная стратегия РР-анализа заключается в использовании другого штата для формирования контрольной группы, то есть в рассмотрении пожилых жителей штата, в котором программа отсутствует, в качестве контрольной группы. В данном случае проблема в том, что *изменения* в уровне здоровья пожилых людей могут систематически различаться по штатам, скажем, из-за различий в уровнях дохода и богатства, не связанных с реализацией программы.

Более устойчивого анализа по сравнению с обеими РР-стратегиями, описанными выше, можно добиться, сравнивая РР-оценку для штата, где была реализована программа, с аналогичной оценкой для контрольного штата. Если обозначить два временных периода за 1 и 2, штат, в котором проводится программа, за  $B$ , а группу пожилого населения за  $E$ , то расширенная версия уравнения (1) примет вид

$$y = \beta_0 + \beta_1 dB + \beta_2 dE + \beta_3 dB \cdot dE + \delta_0 d2 + \delta_1 d2 \cdot dB + \delta_2 d2 \cdot dE + \delta_3 d2 \cdot dB \cdot dE + u. \quad (2)$$

Теперь интерес представляет коэффициент  $\delta_3$  при переменной тройного взаимодействия  $d2 \cdot dB \cdot dE$ . МНК-оценку  $\hat{\delta}_3$  можно записать в виде

$$\hat{\delta}_3 = [(\bar{y}_{B,E,2} - \bar{y}_{B,E,1}) - (\bar{y}_{B,N,2} - \bar{y}_{B,N,1})] - [(\bar{y}_{A,E,2} - \bar{y}_{A,E,1}) - (\bar{y}_{A,N,2} - \bar{y}_{A,N,1})], \quad (3)$$

где индекс  $A$  снова относится к штату, где программа отсутствует, а индекс  $N$  – к группе молодых жителей. Оценку (3) обычно называют оценкой методом «разность в разностях разностей» (PPP-оценкой). Первый член в квадратных скобках – это РР-оценка, полученная только для штата  $B$  при использовании молодого населения в качестве контрольной группы и данных для обоих периодов. Для уверенности в том, что РР-оценка не просто улавливает различие трендов в уровнях здоровья между пожилыми и молодыми, из РР-оценки вычитается аналогичная оцененная разность трендов для контрольного штата (второй член в квадратных скобках). Если систематические различия в трендах между пожилым и молодым населением в штате  $A$  отсутствуют, PPP-оценка будет близкой к РР-оценке, полученной только по данным для штата  $B$ .

При реализации оценивания в рамках модели регрессии легко получить стандартную ошибку для  $\hat{\delta}_3$ , в том числе рабастную к гетероскедастичности. Как и в случае РР-оценки, можно легко добавить в уравнение (2) дополнительные регрессоры, а также проводить инференцию, рабастную к произвольной форме гетероскедастичности.

Только что изложенный стандартный подход предполагает, что вся вариация при инференции происходит из-за выборочных ошибок при оценивании средних для каждой комбинации группы и периода. Этот подход имеет долгую историю в статистике, поскольку он эквивалентен дисперсионному анализу (ANOVA). Коротко говоря, сначала в соответствии с временными периодами и статусом подверженности воздействию определяются различные подгруппы. Затем для каждой подгруппы берутся случайные выборки и подсчитываются соответствующие разности выборочных средних.

Недавно были предложены различные подходы, основанные на других источниках вариации, нежели выборочная ошибка, возможно в дополнение к выборочной ошибке при оценивании средних. Bertrand, Duflo & Mullainathan (2004) (BDM), Donald & Lang (2007), Hansen

(2007a,b) и Abadie, Diamond & Hainmueller (2007) рассматривают дополнительные источники вариации. На самом деле, в большинстве случаев предполагается, что эти дополнительные источники поглощают выборочную ошибку при оценивании средних по группам и временными периодами. Один из взглядов на дополнительные источники вариации, как в Abadie, Diamond & Hainmueller (2007), состоит в учете неопределенности, связанной с качеством контрольных групп. Обоснованность такого подхода зависит от конкретного приложения. Например, если удается естественным образом определить контрольную и опытную группы и получить случайные выборки, сложно объяснить, почему неприменима модель дисперсионного анализа. С другой стороны, если имеется определенная опытная группа, но отсутствует естественная контрольная группа, имеет смысл учитывать неопределенность, связанную с выбором контрольной группы. Такой подход предложен в Abadie, Diamond & Hainmueller (2007) и кратко рассматривается далее в разделе 6.

Прежде чем перейти к общей постановке, полезно понять, является ли необходимым или желательным включение в РР-анализ чего-то иного, помимо выборочной ошибки. В разделе 2 описан подход, недавно предложенный в Donald & Lang (2007) (DL). Как мы увидим, подход DL не позволяет проводить инференцию в базовом случае сравнения средних для двух групп, даже при случайному распределении воздействия. В частности, хотя DL-оценка – это обычная разность средних из дисперсионного анализа, инференция недоступна. Кроме того, подход DL неприменим к стандартным ситуациям РР- и РРР-оценивания, изложенным выше. Можно ли утверждать, что в этих случаях нельзя построить доверительные интервалы? Во многих ситуациях подобный вывод кажется крайностью.

Возьмем пример из Meyer, Viscusi & Durbin (1995) (MVD), которые оценивают эффект размера выплат по безработице на продолжительность времени, проводимого на пособии. MVD располагают данными за два периода времени – до и после повышения потолка покрываемых доходов. Опытная группа включает работников с высоким доходом, а контрольная – работников с низким доходом, то есть тех, кто не должен был быть затронут изменением потолка. По данным для штата Кентукки при совокупном размере выборки 5626 наблюдений MVD получают РР-оценку эффекта данного вмешательства, равную 19,2%-му повышению продолжительности времени, проводимого на пособии. *t*-статистика равна 2,76 и, как и сама оценка, мало меняется при добавлении контрольных переменных. MVD также изучают данные для штата Мичиган. Применяя тот же РР-подход, они находят почти идентичный эффект – 19,1%. Тем не менее, при «всего лишь» 1524 наблюдениях *t*-статистика равна 1,22. Похоже, в этом примере имеет место большая выборочная ошибка при подсчете средних, и нельзя получить точную оценку при отсутствии достаточно больших выборок. Неясно, какую выгоду дает заключение о том, что, поскольку эффект вмешательства точно идентифицируем, инференция в таких случаях недоступна.

## 2 Подход DL и метод минимального расстояния при малом числе групп

Начнем этот раздел с изложения подхода Donald & Lang (2007) (DL). Постановка DL применима к общему случаю РР-анализа, когда число групп (контрольных и опытных) достаточно мало, и для каждой из них доступны довольно большие выборки. Это такая же постановка, как и при традиционном подходе, рассмотренном в разделе 1, но предполагаемая структура модели отличается, что ведет к иному подходу к инференции.

Для иллюстрации вопросов, поднятых в DL, рассмотрим случай с единственным регрессором, меняющимся только по группам:

$$y_{gm} = \alpha + \beta x_g + c_g + u_{gm} \quad (4)$$

$$= \delta_g + \beta x_g + u_{gm}, \quad m = 1, \dots, M_g; \quad g = 1, \dots, G. \quad (5)$$

В простейшем случае  $x_g$  – единственный индикатор программы. Ключевой характеристикой

уравнения (4) является наличие переменной  $c_g$ , эффекта группы или кластера. Иначе модель можно записать в виде (5) с общим коэффициентом наклона  $\beta$ , но зависящей от группы константой  $\delta_g$ . DL рассматривают модель в виде (4), предполагая, что  $c_g$  не зависит от  $x_g$  и имеет нулевое среднее. Они используют данную формулировку для выявления проблем, связанных с применением стандартной инференции к уравнению (4) при рассмотрении  $c_g$  как части составной ошибки  $v_{gm} = c_g + u_{gm}$ . Известно, что это неудачная мысль даже в случае большого  $G$  и малых  $M_g$ , поскольку стандартный подход не учитывает корреляцию ошибок внутри каждой группы. Более того, как следует из обсуждения результатов в Hansen (2007a), описанных в разделе 3, при малом  $G$  даже инференция, устойчивая к кластеризации, часто дает плохие результаты.

Один из способов увидеть проблему при применении стандартной инференции – заметить, что при  $M_g = M$  для всех  $g = 1, \dots, G$  обычная МНК-оценка  $\hat{\beta}$  совпадает с межгрупповой оценкой, полученной из регрессии

$$\bar{y}_g \text{ на } 1, x_g, g = 1, \dots, G.$$

Условно на  $x_g$ ,  $\hat{\beta}$  наследует свое распределение от  $\{\bar{v}_g : g = 1, \dots, G\}$ , внутригрупповых средних составных ошибок  $v_{gm} \equiv c_g + u_{gm}$ . Наличие  $c_g$  означает, что новые наблюдения внутри группы не дают дополнительной информации для оценивания  $\beta$ , помимо их эффекта на групповое среднее  $\bar{y}_g$ . По сути, имеются только  $G$  полезных носителей информации.

Если добавить несколько сильных предположений, у данной проблемы существует решение, но только при  $G > 2$ . Вдобавок к предпосылке о том, что  $M_g = M$  для всех  $g$ , предположим, что  $c_g | x_g \sim N(0, \sigma_c^2)$  и  $u_{gm} | x_g, c_g \sim N(0, \sigma_u^2)$ . Тогда  $\bar{v}_g$  не зависит от  $x_g$  и  $\bar{v}_g \sim N(0, \sigma_c^2 + \sigma_u^2/M)$  для всех  $g$ . Поскольку предполагается независимость по  $g$ , уравнение

$$\bar{y}_g = \alpha + \beta x_g + \bar{v}_g, g = 1, \dots, G, \quad (6)$$

удовлетворяет предположениям классической линейной модели. Следовательно, можно проводить инференцию на основе  $t_{G-2}$ -распределения для тестирования гипотез о  $\beta$  при условии, что  $G > 2$ . Если  $G$  очень мало, условия на значимость  $t$ -статистики при использовании  $t_{G-2}$ -распределения гораздо более строгие, чем для  $t_{M_1+M_2+\dots+M_G-2}$ -распределения, которое применялось бы в случае простой объединенной регрессии, как при стандартном РР-анализе.

Если  $x_g - 1 \times K$  вектор, чтобы использовать  $t_{G-K-1}$ -распределение для инференции, необходимо условие  $G > K + 1$ . Оно допускает случай множественности временных периодов и опытных групп, если предположить независимость выборок по всем группам и временным периодам.

Как отмечают DL, осуществление правильной инференции при наличии  $c_g$  – это не просто вопрос корректировки стандартных ошибок, получаемых при применении обычного МНК, на корреляцию внутри кластеров, которая все равно не работает в случае малого  $G$ . При одинаковом размере групп имеется только одна оценка: объединенная регрессия, модель со случайными эффектами и межгрупповая регрессия (6) – все они дают *одину и ту же* оценку  $\hat{\beta}$ . Регрессия в (6) при использовании  $t_{G-K-1}$ -распределения позволяет проводить инференцию с надлежащим размером теста.

Метод DL можно использовать и без предположения о нормальности  $u_{gm}$ , если общий размер групп  $M$  большой: согласно центральной предельной теореме,  $\bar{u}_g$  будет асимптотически нормально распределена при весьма общих предпосылках. Тогда, поскольку  $c_g$  нормально распределена, можно считать  $\bar{v}_g$  асимптотически нормальной с постоянной дисперсией. Более того, даже если размеры групп меняются, для очень больших размеров групп  $\bar{u}_g$  будет пренебрежимо малой частью  $\bar{v}_g$ , поскольку  $\mathbb{V}(\bar{v}_g) = \sigma_c^2 + \sigma_u^2/M_g$ . Если  $c_g$  нормально распределена и доминирует  $\bar{v}_g$ , анализ классической линейной модели (6) будет приблизительно верным.

Модель DL находит наиболее широкую сферу применения, когда среднее значение ошибок,  $\bar{u}_g$ , можно игнорировать, то есть либо  $\sigma_u^2$  мала по сравнению с  $\sigma_c^2$ , либо  $M_g$  велики, либо и то и другое. На самом деле, применение подхода DL с различными размерами групп или негауссовоыми  $u_{gm}$  равносильно игнорированию ошибки оценивания выборочных средних  $\bar{y}_g$ . Иными словами, это равносильно тому, как если бы простая модель регрессии  $\mu_g = \alpha + \beta x_g + c_g$  анализировалась при классических предположениях линейной модели (где  $\bar{y}_g$  используется вместо неизвестного внутригруппового среднего  $\mu_g$ ). Такой подход сильно отличается от традиционного, когда  $c_g$  отбрасывается и для построения доверительных интервалов и проведения инференции используется выборочная вариация в  $\bar{y}_g$ . Подход DL кажется разумным, когда при подсчете  $\bar{y}_g$  выборку составляет вся популяция для группы  $g$ , а  $\bar{y}_g$  рассматривается как зависимая, объясняемая переменная.

Если  $1 \times L$  вектор  $z_{gm}$ , меняющийся внутри группы, присутствует в исходной модели, как это имеет место во многих РР-приложениях, можно использовать усредненное уравнение

$$\bar{y}_g = \alpha + x_g \beta + \bar{z}_g \gamma + \bar{v}_g, \quad g = 1, \dots, G, \quad (7)$$

при условии, что  $G > K + L + 1$ . Если  $c_g$  не зависит от  $(x_g, \bar{z}_g)$ , имеет гомоскедастичное нормальное распределение, и размеры групп велики, инференция может быть реализована на основе  $t_{G-K-L-1}$ -распределения. Это довольно стандартный способ проверки устойчивости результатов, полученных по дезагрегированным данным, но часто он осуществляется для нескольких больших значений  $G$  (скажем,  $G = 50$ ). Когда некоторые регрессоры меняются внутри кластера, использовать усредненные данные, вообще говоря, неэффективно. Но использование средних означает, что стандартные ошибки не нужно корректировать на внутригрупповую корреляцию. Как обсуждается в следующем разделе, если  $G$  достаточно большое и размеры выборок не слишком велики, робастная к кластеризации инференция может быть приемлемой.

Для малого  $G$  и больших  $M_g$  инференция, реализуемая при рассмотрении (6) или (7) как классической линейной модели, будет очень консервативной в отсутствие кластеризации. Возможно, в некоторых случаях желательно учитывать этот источник вариации, но он отсекает некоторые широко применяемые методы анализа эффекта программ. Предположим, например, что имеются две популяции (например, мужчины и женщины, два разных города, или опытная и контрольная группы) со средними  $\mu_g$ ,  $g = 1, 2$ , и требуется получить доверительный интервал для их разности. Почти во всех случаях имеет смысл рассматривать данные как две случайные выборки, по одной для каждой подгруппы популяции. При случайной выборке для каждой группы и предположении о нормальности и равенстве дисперсий в популяциях, обычная тест-статистика на равенство средних имеет точное  $t_{M_1+M_2-2}$ -распределение при нулевой гипотезе о равных популяционных средних. Иначе говоря, можно построить точный 95%-ый доверительный интервал для разности популяционных средних. Даже при умеренных размерах  $M_1$  и  $M_2$ ,  $t_{M_1+M_2-2}$ -распределение близко к стандартному нормальному. Кроме того, можно ослабить предположение о нормальности для проведения асимптотической инференции, а  $t$ -статистику легко модифицировать для случая различных популяционных дисперсий. При контролируемом эксперименте стандартный анализ разности средних часто весьма убедителен. Тем не менее, изучать оценку в постановке DL невозможно, поскольку  $G = 2$ . Проблема очевидна из (5): по сути, имеется три параметра —  $\delta_1$ ,  $\delta_2$  и  $\beta$ , — но только два наблюдения.

DL критикуют Card & Krueger (1994) за сравнение средних изменений в заработной плате работников заведений быстрого питания по двум штатам, поскольку Card & Krueger не учитывают эффект штата (Нью-Джерси и Пенсильвания)  $c_g$  в составной ошибке  $v_{gm}$ . Но критика DL в случае  $G = 2$  выглядит немного странной. В постановке DL разность средних оценивает величину

$$\mu_2 - \mu_1 = (\delta_2 + \beta) - \delta_1 = (\alpha + c_2 + \beta) - (\alpha + c_1) = \beta + (c_2 - c_1).$$

При предположениях DL  $c_2 - c_1$  имеет нулевое среднее, так что оценивание этой величины не должно привести к смещению при анализе эффекта программы. DL предполагают, что  $\beta$  – интересующий параметр, но, если эксперимент основан на рандомизации (что также справедливо в DL, так как предполагается независимость  $c_g$  и  $x_g$ ), включение  $c_g$  в оцениваемый эффект безболезненно. Короче говоря, в постановке DL анализ в Card & Krueger не является систематически смещенным; DL просто утверждают, что инференция невозможна. Но если естественный эксперимент, лежащий в основе РР-анализа, надежен, то групповые эффекты просто должны быть составной частью оцениваемых средних.

Кроме того, не очевидно, следует ли использовать подход DL даже при достаточном большем числе степеней свободы. Допустим, например, что есть  $G = 4$  группы, две из которых контрольные ( $x_1 = x_2 = 0$ ) и две – опытные ( $x_3 = x_4 = 1$ ). Подход DL предполагает подсчет средних для каждой группы,  $\bar{y}_g$ , и оценивание регрессии  $\bar{y}_g$  на  $1, x_g, g = 1, \dots, 4$ . Инференция основана на  $t_2$ -распределении. Оценку  $\hat{\beta}$  в данном случае можно записать в виде

$$\hat{\beta} = \frac{\bar{y}_3 + \bar{y}_4}{2} - \frac{\bar{y}_1 + \bar{y}_2}{2}. \quad (8)$$

Объединенная регрессия для дезагрегированных данных дает взвешенную среднюю ( $p_3\bar{y}_3 + p_4\bar{y}_4 - (p_1\bar{y}_1 + p_2\bar{y}_2)$ ), где  $p_1 = M_1/(M_1 + M_2)$ ,  $p_2 = M_2/(M_1 + M_2)$ ,  $p_3 = M_3/(M_3 + M_4)$ , и  $p_4 = M_4/(M_3 + M_4)$  – относительные доли в контрольных и опытных группах, соответственно. Когда  $\hat{\beta}$  имеет вид (8), неясно, зачем использовать  $t_2$ -распределение для инференции. Каждое  $\bar{y}_g$  обычно подсчитывается по большой выборке –  $M_g = 30$  или около того обычно достаточно для асимптотической нормальности стандартизированного среднего, – а значит, при должной стандартизации  $\hat{\beta}$  имеет асимптотически стандартное нормальное распределение при весьма общих условиях.

В данном приложении подход DL отвергает обычную инференцию на основе внутригрупповых средних, подсчитанных по большим выборкам, поскольку могут не выполняться условия  $\mu_1 = \mu_2$  и  $\mu_3 = \mu_4$ . Другими словами, контрольная группа может быть разнородной, как и опытная группа. Но этот факт сам по себе не делает неверной стандартную инференцию для модели (8). На самом деле, если определить объект интереса как

$$\tau = \frac{\mu_3 + \mu_4}{2} - \frac{\mu_1 + \mu_2}{2}, \quad (9)$$

то есть своего рода средний эффект воздействия, то оценка  $\hat{\beta}$  состоятельна для  $\tau$  и (при должной нормировке) асимптотически нормальна по мере роста  $M_g$ .

Уравнение (9) намекает на иной способ взглянуть на случай малого  $G$  и больших  $M_g$ . В этом конкретном приложении два параметра,  $\alpha$  и  $\beta$ , оцениваются на основе четырех моментов, которые можно оценить по данным. МНК-оценки из (6) в этом случае являются оценками минимального расстояния (MP) – см. Wooldridge (2002, Глава 14) – при ограничениях  $\mu_1 = \mu_2 = \alpha$  и  $\mu_3 = \mu_4 = \alpha + \beta$ . Если взять единичную матрицу  $4 \times 4$  в качестве взвешивающей, можно получить  $\hat{\beta}$  как в (8) и  $\hat{\alpha} = (\bar{y}_1 + \bar{y}_2)/2$ . При применении MP-подхода ясно, что имеются два сверхидентифицирующих ограничения, которые легко тестиовать. Но даже их отвержение всего лишь означает, что по крайней мере одна пара средних среди всех контрольных и опытных групп различается.

При больших размерах групп даже при небольших  $G$  можно сформулировать задачу в рамках модели минимального расстояния, как это делается, например, в Loeb & Bound (1996), у которых имелось  $G = 36$  возрастных групп и множество наблюдений для каждой группы. Для каждой группы  $g$  запишем

$$y_{gm} = \delta_g + z_{gm}\gamma_g + u_{gm}, \quad m = 1, \dots, M_g, \quad (10)$$

предполагая случайность выборок внутри групп и независимость выборок по группам. Предположим также справедливость всех стандартных условий для состоятельности (при  $M_g \rightarrow$

$\infty)$  и  $\sqrt{M_g}$ -асимптотической нормальности МНК-оценки; см, например, Wooldridge (2002, Глава 4). Наличие переменных  $x_g$  группового уровня в «структурной» модели можно рассматривать как наложение ограничений на константы  $\delta_g$  в отдельных моделях для групп в (10). В частности,

$$\delta_g = \alpha + x_g\beta, \quad g = 1, \dots, G, \quad (11)$$

где  $x_g$  – фиксированные наблюдаемые характеристики разнородных групп. При  $K$  характеристиках для определения  $\alpha$  и  $\beta$  необходимо условие  $G \geq K + 1$ . Если  $M_g$  достаточно велики для точного оценивания  $\delta_g$ , простая двухшаговая стратегия оценивания напрашивается сама собой. Сначала надо оценить  $\hat{\delta}_g$  и  $\hat{\gamma}_g$  из МНК-регрессий для каждой группы. Если  $G = K + 1$ , то обычно можно однозначно выразить  $\hat{\theta} \equiv (\hat{\alpha}, \hat{\beta}')'$  в терминах  $G \times 1$  вектора  $\hat{\delta}$ :  $\hat{\theta} = X^{-1}\hat{\delta}$ , где  $X = (K + 1) \times (K + 1)$  матрица с  $g$ -й строкой  $(1, x_g)$ . Если  $G > K + 1$ , то на втором шаге можно использовать подход минимального расстояния, изложенный в Wooldridge (2002, Раздел 14.6). Если в качестве взвешивающей матрицы  $I_G$  взять единичную матрицу  $G \times G$ , то оценку минимального расстояния можно подсчитать из МНК-регрессии

$$\hat{\delta}_g \text{ на } 1, x_g, \quad g = 1, \dots, G. \quad (12)$$

При асимптотике с  $M_g = \rho_g M$ , где  $0 < \rho_g \leq 1$  и  $M \rightarrow \infty$ , оценка минимального расстояния  $\hat{\theta}$  состоятельна и  $\sqrt{M}$ -асимптотически нормальна. Тем не менее, эта конкретная оценка минимального расстояния является асимптотически неэффективной, если не делать сильных предположений. Поскольку выборки предполагаются независимыми, не значительно сложнее получить эффективную МР-оценку, также известную как оценка «минимального хи-квадрат».

Рассмотрим сначала случай, когда  $z_{gm}$  отсутствует на первом шаге оценивания, то есть  $\hat{\delta}_g$  – это просто  $\bar{y}_g$ , выборочное среднее для группы  $g$ . Пусть  $\hat{\sigma}_g^2$  обозначает обычную выборочную дисперсию для группы  $g$ . Поскольку  $\bar{y}_g$  независимы по  $g$ , эффективная МР-оценка использует диагональную взвешивающую матрицу. Ради легкости вычисления, оценку минимального хи-квадрат можно получить, используя взвешенный МНК (ВМНК) в (12), где в качестве весов для группы  $g$  берется  $M_g/\hat{\sigma}_g^2$  (группы с большим количеством данных и меньшей дисперсией получают больший вес). Что удобно, стандартные  $t$ -статистики из ВМНК-регрессии имеют асимптотическое стандартное нормальное распределение при больших размерах групп  $M_g$ . При фиксированном  $G$ , ВМНК – просто вычислительный метод; стандартная асимптотика для ВМНК-оценки предполагает  $G \rightarrow \infty$ . Подход минимального расстояния работает при малом  $G$ , если  $G \geq K + 1$  и каждое  $M_g$  достаточно велико, чтобы нормальность была хорошим приближением распределения (надлежащим образом нормированных) выборочных средних для каждой группы. В стандартной РР-постановке из раздела 1, МР-подход сводится к взвешиванию наименьших квадратов, где в качестве весов используются величины, обратные к оцененным внутригрупповым дисперсиям.

Если  $z_{gm}$  присутствует на первом шаге оценивания, в качестве весов при оценивании методом минимального хи-квадрат берутся величины, обратные асимптотическим дисперсиям для  $g$  оценок констант в  $G$  отдельных регрессиях. При больших  $M_g$  можно сделать их полностью робастными к гетероскедастичности в  $\mathbb{E}(u_{gm}^2|z_{gm})$ , используя оценку дисперсии в «сэндвичной» форме из White (1980). Даже при предположении о гомоскедастичности внутри групп хотелось бы как минимум разрешить разные  $\sigma_g^2$ . При наличии  $\widehat{Avar}(\hat{\delta}_g)$ , которые являются просто квадратами сообщаемых стандартных ошибок для  $\hat{\delta}_g$ , можно использовать веса  $1/\widehat{Avar}(\hat{\delta}_g)$  в вычислительно простой ВМНК-процедуре. По-прежнему для получения диагональной взвешивающей матрицы при МР-оценивании используется предположение о независимости по  $g$ .

Важным побочным продуктом ВМНК-регрессии является статистика минимального хи-квадрат, которую можно использовать для тестирования  $G - K - 1$  сверхидентифицирующих ограничений. Эту статистику легко подсчитать как взвешенную сумму квадратов остатков, скажем,  $SSR_w$ . При нулевой гипотезе в (11),  $SSR_w \stackrel{a}{\sim} \chi^2_{G-K-1}$  по мере роста размеров групп  $M_g$ . Если  $H_0$  отвергается при достаточно малом уровне значимости,  $x_g$  не хватает для характеризации изменений констант между группами. Если  $H_0$  не отвергается, появляется некоторая уверенность в правильности спецификации, и можно проводить инференцию, используя стандартное нормальное распределение для  $t$ -статистик при тестировании гипотез о линейных комбинациях популяционных средних.

MP-подход также применим, если предположить, что  $\gamma_g = \gamma$  для всех  $g$ . Получить сами  $\hat{\delta}_g$  легко. Сначала следует оценить объединенную регрессию

$$y_{gm} \text{ на } d1_g, d2_g, \dots, dG_g, z_{gm}, m = 1, \dots, M_g; g = 1, \dots, G, \quad (13)$$

где  $d1_g, d2_g, \dots, dG_g$  – групповые фиктивные переменные. Использование оценки  $\hat{\delta}_g$  из объединенной регрессии (13) в MP-оценивании осложнится тем фактом, что  $\hat{\delta}_g$  более не являются асимптотически независимыми; на самом деле,  $\hat{\delta}_g = \bar{y}_g - \bar{z}_g \hat{\gamma}$ , где  $\hat{\gamma}$  – вектор общих регрессионных коэффициентов, и присутствие  $\hat{\gamma}$  порождает корреляцию оценок констант. Пусть  $\hat{V} = G \times G$  оцененная (асимптотическая) дисперсионная матрица  $G \times 1$  вектора  $\hat{\delta}$ . Тогда MP-оценка имеет вид  $\hat{\theta} = (X' \hat{V}^{-1} X)^{-1} X' \hat{V}^{-1} \hat{\delta}$ , а ее асимптотическая дисперсия равна  $(X' \hat{V}^{-1} X)^{-1}$ . Если оценивается МНК-регрессия (12) или ее ВМНК-версия, обычные стандартные ошибки будут неправильными, поскольку они не учитывают межгрупповую корреляцию между оценками.

Если сверхидентифицирующие ограничения отвергаются, по сути это означает, что  $\delta_g = \alpha + x_g \beta + c_g$ , где  $c_g$  можно интерпретировать как отклонение от ограничений в (11) для группы  $g$ . По мере того как  $G$  растет относительно  $K$ , вероятность отвержения ограничений растет. Одна из возможностей состоит в применении подхода DL, то есть в анализе МНК-регрессии (12) в контексте классической линейной модели (КЛМ), где инференция основана на  $t_{G-K-1}$ -распределении. Почему КЛМ-анализ оправдан в данном случае? Поскольку  $\hat{\delta}_g = \delta_g + O_p(M_g^{-1/2})$ , можно игнорировать ошибку оценивания в  $\hat{\delta}_g$  для больших  $M_g$  (то же предположение о «больших»  $M_g$  лежит в основе MP-подхода.) Это равносильно оцениванию уравнения  $\delta_g = \alpha + x_g \beta + c_g$ ,  $g = 1, \dots, G$ , с помощью МНК. Если  $c_g$  имеют нормальное распределение, классический анализ применим, так как предполагается независимость  $c_g$  и  $x_g$ . Этот подход желателен, когда невозможно или не хочется искать регрессоры на уровне групп, которые полностью идентифицируют  $\delta_g$ . Он основан на предположении о том, что прочие факторы в  $c_g$  систематически не связаны с  $x_g$ , что разумно, если, скажем,  $x_g$  – случайно назначаемая на групповом уровне программа, как в случае, рассмотренном в Angrist & Lavy (2002).

### 3 РР-анализ при большом числе групп

Обратимся теперь к случаю РР-оценивания, когда число групп «велико». Введем также временное измерение в явном виде и положим, что интервал времени достаточно долгий. Такая структура является хорошим описанием многих РР-моделей, когда группы представлены географическими регионами и данные по этим регионам доступны для большого числа временных периодов.

При большом числе периодов и групп полезна общая модель, рассмотренная в BDM (2004) и Hansen (2007a). На индивидуальном уровне уравнение имеет вид

$$y_{igt} = \lambda_t + \alpha_g + \mathbf{x}_{gt} \boldsymbol{\beta} + \mathbf{z}_{igt} \boldsymbol{\gamma}_{gt} + v_{gt} + u_{igt}, \quad i = 1, \dots, M_{gt}, \quad (14)$$

где  $i$  индексирует объект,  $g$  – группу, а  $t$  – время. В этой модели имеется полный набор временных эффектов  $\lambda_t$ , групповых эффектов  $\alpha_g$ , регрессоров на уровне группы/периода

$x_{gt}$  (это переменные воздействия), регрессоров индивидуального уровня  $\mathbf{z}_{igt}$ , ненаблюдаемых эффектов на уровне группы/периода  $v_{gt}$ , и ошибок на индивидуальном уровне  $u_{igt}$ . Интерес представляет оценивание  $\beta$ .

Полезно записать (14) с константами, меняющимися по группам и времени:

$$y_{igt} = \delta_{gt} + \mathbf{z}_{igt}\gamma_{gt} + u_{igt}, \quad i = 1, \dots, M_{gt}, \quad (15)$$

что дает модель на индивидуальном уровне, тогда как константы и регрессионные коэффициенты могут различаться в зависимости от пары  $(g, t)$ . В этом случае

$$\delta_{gt} = \lambda_t + \alpha_g + \mathbf{x}_{gt}\beta + v_{gt}. \quad (16)$$

Можно воспринимать (16) как регрессионную модель на уровне группы/временного периода.

Как обсуждается в BDM, обычный метод оценивания и инференции для (14) – игнорировать  $v_{gt}$ , то есть считать независимыми наблюдения на индивидуальном уровне. Когда  $v_{gt}$  присутствует, подобная инференция может оказаться весьма обманчивой. BDM и Hansen (2007a) допускают серийную корреляцию для  $\{v_{gt} : t = 1, 2, \dots, T\}$  и предполагают независимость по группам  $g$ .

Далее будем считать для простоты, что (16) представляет конечный интерес. Регрессоры  $\mathbf{x}_{gt}$  наблюдаются,  $\lambda_t$  учитываются с помощью годовых фиктивных переменных, а  $\alpha_g$  – с помощью групповых фиктивных переменных. Тогда проблема в том, что не наблюдаются  $\delta_{gt}$ . Но для оценивания  $\delta_{gt}$  можно использовать данные на индивидуальном уровне, если размеры выборок на уровне группы/периодов  $M_{gt}$  достаточно велики. При случайных выборках внутри каждой пары  $(g, t)$  естественная оценка  $\delta_{gt}$  получается из МНК-оценивания (15) для каждой пары  $(g, t)$  при предположении, что  $\mathbb{E}(\mathbf{z}'_{igt}u_{igt}) = \mathbf{0}$ . В большинстве РР-приложений это предположение выполняется почти по определению, поскольку для улучшения оценки  $\delta_{gt}$  включаются контрольные переменные на индивидуальном уровне. Если напрашивается конкретная форма гетероскедастичности и предполагается, что  $\mathbb{E}(u_{it}|\mathbf{z}_{igt}) = 0$ , можно использовать ВМНК-процедуру. Иногда хочется предположить однородность регрессионных коэффициентов – скажем,  $\gamma_{gt} = \gamma_g$  или даже  $\gamma_{gt} = \gamma$ , – и для наложения подобных ограничений данные объединяются. В любом случае, предположим, что  $M_{gt}$  достаточно велики, чтобы можно было игнорировать ошибку оценивания в  $\delta_{gt}$ ; будем считать, что вариация в уравнении (16) исходит от  $v_{gt}$ . Hansen (2007a) рассматривает корректировку инференции, которая учитывает выборочную ошибку в  $\hat{\delta}_{gt}$ , но методы становятся более сложными. Альтернативой является применение метода минимального расстояния, как в разделе 2. МР-подход по сути устраняет  $v_{gt}$  из уравнения (16) и рассматривает  $\delta_{gt} = \lambda_t + \alpha_g + \mathbf{x}_{gt}\beta$  как множество ограничений, накладываемых на  $\delta_{gt}$ . Инференция на основе МР-оценки использует только выборочную вариацию в оценках  $\hat{\delta}_{gt}$ , которые независимы по всем парам  $(g, t)$ , если оцениваются по отдельности, или коррелированы, если данные объединяются.

Поскольку ошибка оценивания в  $\hat{\delta}_{gt}$  игнорируется, рассмотрим просто уравнение для панельных данных

$$\hat{\delta}_{gt} = \lambda_t + \alpha_g + \mathbf{x}_{gt}\beta + v_{gt}, \quad t = 1, \dots, T, \quad g = 1, \dots, G, \quad (17)$$

где ошибка сохраняет вид  $v_{gt}$ , поскольку  $\hat{\delta}_{gt}$  и  $\delta_{gt}$  считаются взаимозаменяемыми. При таком предположении можно напрямую применить результаты из BDM и Hansen (2007a) к этому уравнению. А именно, если оценить (17) с помощью МНК, что подразумевает полные эффекты времени и группы наряду с  $x_{gt}$ , эта оценка имеет удовлетворительные свойства по мере роста  $G$  и  $T$ , если  $\{v_{gt} : t = 1, 2, \dots, T\}$  – слабо зависимый (с перемешиванием) временной ряд для всех  $g$ . Симуляции в BDM и Hansen (2007a) показывают, что инференция, рабочая к кластеризации, где каждый кластер – это множество временных периодов, работает достаточно хорошо, если  $\{v_{gt}\}$  следует стационарному AR(1)-процессу и  $G$  умеренно велико.

Hansen (2007b), замечая, что МНК-оценка (оценка с фиксированными эффектами) для (17) неэффективна, если  $v_{gt}$  серийно некоррелированы (и, возможно, гетероскедастичны), предлагает доступную ОМНК-оценку. Как хорошо известно, если  $T$  недостаточно велико, оценка параметров дисперсионной матрицы  $\Omega_g = \mathbb{V}(\mathbf{v}_g)$ , где  $\mathbf{v}_g - T \times 1$  вектор ошибок для каждого  $g$ , затруднительна после удаления групповых эффектов. Иными словами, применение остатков из модели с фиксированными эффектами  $\hat{v}_{gt}$  для оценки  $\Omega_g$  может давать серьезное смещение при малых  $T$ . Solon (1984) обратил внимание на эту проблему для гомоскедастичной AR(1) модели. Конечно, смещение исчезает, когда  $T \rightarrow \infty$ , и программные пакеты, такие как STATA, имеющие встроенную команду для оценивания модели с фиксированными эффектами и AR(1)-ошибками, используют обычную оценку AR(1)-коэффициента  $\hat{\rho}$ , полученную из регрессии

$$\hat{v}_{gt} \text{ на } \hat{v}_{g,t-1}, \quad t = 2, \dots, T, \quad g = 1, \dots, G.$$

Как обсуждается в Wooldridge (2003) и Hansen (2007b), один из способов учета смещения в  $\hat{\rho}$  – использовать полностью робастную оценку дисперсионной матрицы. Но симуляции Хансена показывают, что этот подход весьма неэффективен по сравнению с его предложением, заключающимся в корректировке смещения оценки  $\hat{\rho}$  и ее последующем использовании при доступном ОМНК-оценивании (Хансен работает с общей AR( $p$ ) моделью). Хансен доказывает множество привлекательных теоретических свойств своей оценки. Итеративная процедура с корректировкой смещения имеет то же самое асимптотическое распределение, что и  $\hat{\rho}$ , в случае, когда оценка  $\hat{\rho}$  должна хорошо работать: при  $G$  и  $T$ , стремящимся к бесконечности. Что наиболее важно при применении к РР-задачам, доступная ОМНК-оценка на основе итеративной процедуры имеет то же самое асимптотическое распределение, что и ОМНК-оценка при  $G \rightarrow \infty$  и фиксированном  $T$ . Когда  $G$  и  $T$  велики, нет необходимости в итерировании для достижения эффективности.

Далее Хансен показывает, что даже при больших  $G$  и  $T$ , когда нескорректированные AR-коэффициенты дают асимптотическую эффективность, скорректированные на смещение оценки дают улучшения с точки зрения асимптотики более высоких порядков. Одно из ограничений результатов Хансена состоит в предположении о строгой экзогенности регрессоров  $\{\mathbf{x}_{gt} : t = 1, \dots, T\}$ . Известно, что при использовании МНК, то есть обыкновенной оценки с фиксированными эффектами, строгая экзогенность не требуется для состоятельности при  $T \rightarrow \infty$ . ОМНК, используя корреляцию по разным временными периодам, склонен усугублять смещение, которое исходит от отсутствия строгой экзогенности. При анализе эффектов программ это повод для беспокойства, если программа может вводиться и отменяться с течением времени, поскольку тогда необходимо понять, связано ли решение о реализации или приостановке программы с ее результатами в прошлом.

При большом  $G$  и малом  $T$  можно оценить дисперсионную матрицу  $\Omega_g$  без ограничений и далее применить ОМНК – этот подход впервые был предложен в Kiefer (1980) и недавно изучен в Hausman & Kuersteiner (2005). Он эквивалентен отбрасыванию эффекта периода в уравнении с вычитенным средним по времени и реализации полного ОМНК (это также позволяет избежать вырожденности дисперсионной матрицы ошибок с вычитенным средним по времени). Hausman & Kuersteiner показывают, что подход Кифера работает достаточно хорошо, когда  $G = 50$  и  $T = 10$ , хотя при  $G = 50$  и  $T = 20$  наблюдаются существенные искажения размера.

В частности, в случае, когда  $M_{gt}$  не особенно велики, игнорирование ошибки оценивания в  $\hat{\delta}_{gt}$  может вызывать беспокойство. Один из простых способов избежать этого – агрегировать уравнение (14) по объектам, что дает

$$\bar{y}_{gt} = \lambda_t + \alpha_g + \mathbf{x}_{gt}\beta + \bar{\mathbf{z}}_{gt}\gamma + v_{gt} + \bar{u}_{gt}, \quad t = 1, \dots, T, \quad g = 1, \dots, G.$$

Конечно, это уравнение можно оценить как модель с фиксированными эффектами, и полностью робастная инференция доступна по методу из Hansen (2007a), поскольку составная

ошибка  $\{r_{gt} \equiv v_{gt} + \bar{u}_{gt}\}$  слабо зависит. При большом  $G$  и малом  $T$  можно использовать ОМНК-оценку с фиксированными эффектами, используя дисперсионную матрицу без ограничений. Трудности с применением конкретной модели временного ряда для ошибки возникают из-за наличия  $\bar{u}_{gt}$ . При различных  $M_{gt}$   $\mathbb{V}(\bar{u}_{gt})$  почти наверняка гетероскедастична (конечно, она может быть таковой и при равных  $M_{gt}$ ). Так что даже если специфицировать, скажем, AR(1)-модель  $v_{gt} = \rho v_{g,t-1} + e_{gt}$ , дисперсионная матрица для  $\mathbf{r}_g$  становится более сложной. Один из возможных путей – просто предположить, что составная ошибка  $r_{gt}$  следует простой модели, реализовать методы Хансена, но затем применять полностью рабочую инференцию.

Подход из Donald & Land (2007) применим в данной постановке, если использовать анализ для конечных выборок для объединенной регрессии (17). Тем не менее, DL предполагают, что ошибки  $\{v_{gt}\}$  некоррелированы во времени, так что, несмотря на то что для небольших  $G$  и  $T$  в  $t$ -распределении мало степеней свободы, их подход не учитывает вариацию из-за серийной корреляции  $\{v_{gt} : t = 1, \dots, T\}$ .

#### 4 Панельные данные на индивидуальном уровне

Панельные данные на индивидуальном уровне позволяют применять мощные методы для оценки эффектов программ. В простейшем случае имеются два временных периода и бинарный индикатор программы,  $w_{it}$ , равный единице, если объект  $i$  участвует в программе в момент  $t$ . Простая эффективная модель имеет вид

$$y_{it} = \alpha + \eta d2_t + \tau w_{it} + c_i + u_{it}, \quad t = 1, 2, \quad (18)$$

где  $d2_t = 1$  при  $t = 2$  и нуль в противном случае,  $c_i$  – наблюдаемый эффект, а  $u_{it}$  – случайные ошибки. Коэффициент  $\tau$  – эффект воздействия. Простая процедура оценивания состоит во взятии первых разностей для удаления  $c_i$ :

$$(y_{i2} - y_{i1}) = \eta + \tau(w_{i2} - w_{i1}) + (u_{i2} - u_{i1}),$$

или

$$\Delta y_i = \eta + \tau \Delta w_i + \Delta u_i. \quad (19)$$

Если  $\mathbb{E}(\Delta w_i \Delta u_i) = 0$ , то есть изменения в статусе участия в программе некоррелированы с изменениями случайных ошибок, МНК-оценки уравнения (19) состоятельны. В самом распространенном случае  $w_{i1} = 0$  для всех  $i$ , то есть никто не участвует в программе в начальный период времени. Тогда МНК-оценка имеет вид

$$\hat{\tau} = \Delta \bar{y}_{treat} - \Delta \bar{y}_{control} \quad (20)$$

и представляет собой РР-оценку с отличием лишь в том, что берутся разности средних по времени для тех же объектов. Эту же самую оценку можно получить, не вводя разнородность, а просто записав уравнение для  $y_{it}$  с полным набором эффектов групп и времени. Кроме того, (20) дает иные оценки, нежели регрессия  $y_{i2}$  на 1,  $y_{i1}$ ,  $w_{i2}$ , то есть когда  $y_{i1}$  используется в качестве контрольной переменной в кросс-секционной регрессии. Оценки могут быть близкими, но их состоятельность основана на разных предположениях.

Полезно доказать несостоятельность оценки при включении  $y_{i1}$  в качестве регрессора при стандартных предположениях в модели с ненаблюдаемыми эффектами, когда  $w_{i1} \equiv 0$ . В этом случае можно записать:

$$\begin{aligned} y_{i1} &= \alpha + c_i + u_{i1}, \\ y_{i2} &= (\alpha + \eta) + \tau w_{i2} + c_i + u_{i2}. \end{aligned}$$

Стандартными предположениями – см. Wooldridge (2002, Глава 10) – являются

$$\mathbb{E}(u_{it}|c_i, w_{i2}) = 0, t = 1, 2, \quad (21)$$

$$\mathbb{E}(u_{i2}u_{i1}|w_{i2}, c_i) = 0, \quad (22)$$

то есть участие в программе (во втором периоде) строго экзогенно условно на  $c_i$  и ошибки условно серийно некоррелированы. Пусть  $\tilde{\tau}$  – МНК-оценка для регрессии  $y_{i2}$  на  $1, y_{i1}, w_{i2}$ ,  $i = 1, \dots, N$ . Тогда

$$\tilde{\tau} = \left( \sum_{i=1}^N \hat{r}_{i2}^2 \right)^{-1} \left( \sum_{i=1}^N \hat{r}_{i2} \Delta y_i \right),$$

где  $\hat{r}_{i2}$  – остатки регрессии  $w_{i2}$  на  $1, y_{i1}$ ,  $i = 1, \dots, N$ . После подстановки  $\Delta y_i = \eta + \tau w_{i2} + \Delta u_i$  и простых вычислений получаем

$$\tilde{\tau} = \tau + \left( N^{-1} \sum_{i=1}^N \hat{r}_{i2}^2 \right)^{-1} \left( N^{-1} \sum_{i=1}^N \hat{r}_{i2} \Delta u_i \right).$$

Запишем линейную проекцию  $w_{i2}$  на  $1, y_{i1}$  в виде  $w_{i2} = \pi_0 + \pi_1 y_{i1} + r_{i2}$ . Тогда предел по вероятности элемента в числителе равен

$$-\pi_1 \mathbb{E}(y_{i1} \Delta u_i) = -\pi_1 \mathbb{E}(y_{i1} u_{i2}) + \pi_1 \mathbb{E}(y_{i1} u_{i1}) = \pi_1 \mathbb{E}(y_{i1} u_{i1}).$$

Далее,  $\mathbb{E}(y_{i1} u_{i1}) = \sigma_{u_1}^2$ . Таким образом,

$$\text{plim}(\tilde{\tau}) = \tau + \pi_1 \frac{\sigma_{u_1}^2}{\sigma_{r_2}^2}.$$

Кроме того,

$$\pi_1 = \frac{\mathbb{C}(y_{i1}, w_{i2})}{\mathbb{V}(y_{i1})} = \frac{\mathbb{C}(c_i, w_{i2})}{\sigma_c^2 + \sigma_{u_1}^2}$$

и имеет тот же знак, что  $\mathbb{C}(c_i, w_{i2})$ . Чтобы использовать этот результат, предположим, что  $w_{i2}$  означает участие в программе профессиональной подготовки, а  $y_{it}$  – трудовой доход. Тогда, если участие в программе отрицательно связано с ненаблюдаемыми характеристиками  $c_i$ , ведущими к более высокому доходу,  $\pi_1 < 0$ , и оценка  $\tilde{\tau}$  смещена вниз. Таким образом, включение  $y_{i1}$  в качестве дополнительного регрессора ведет к недооценке эффекта в среднем. Если более производительные работники самоотбираются в программу, эффект будет переоценен. При предпосылках (21) и (22) простая оценка (20) состоятельна (и даже несмещена).

Конечно, предположение (22) может быть нежелательным, но с двумя периодами неясно, как можно отличить временную корреляцию, вызванную наличием  $c_i$  в (18) и корреляцию между  $u_{i1}$  и  $u_{i2}$ .

В общем случае с большим числом периодов и произвольным порядком действия программы можно использовать модель

$$y_{it} = \lambda_t + \tau w_{it} + \mathbf{x}_{it}\gamma + c_i + u_{it}, \quad t = 1, \dots, T, \quad (23)$$

которая учитывает агрегированные временные эффекты и включает контрольные переменные  $\mathbf{x}_{it}$ . Оценивание модели с фиксированными эффектами и взятие первых разностей для удаления  $c_i$  – стандартные процедуры при условии, что индикатор программы  $w_{it}$  строго экзогенен: корреляция между  $w_{it}$  и  $u_{ir}$  для любых  $t$  и  $r$  ведет к несостоятельности обеих оценок, хотя оценка с фиксированными эффектами обычно имеет меньшее смещение, когда

можно предположить экзогенность в текущем периоде,  $\mathbb{C}(w_{it}, u_{it}) = 0$ . Строгая экзогенность может нарушаться, если реализация программы меняется в зависимости от прежних исходов  $y_{it}$ . В случае, когда  $w_{it} = 1$  при  $w_{ir} = 1$  для  $r < t$ , строгая экзогенность обычно является разумным предположением.

Уравнение (23) допускает зависимость назначения программы от уровня индивидуального эффекта  $c_i$ , но, кроме того,  $w_{it}$  может коррелировать с индивидуальными временными трендами зависимой переменной. В таком случае имеет место модель с коррелированным случайным трендом:

$$y_{it} = c_i + g_i t + \lambda_t + \tau w_{it} + \mathbf{x}_{it}\gamma + u_{it}, \quad t = 1, \dots, T, \quad (24)$$

где  $g_i$  – коэффициент тренда для индивида  $i$ . Общий анализ допускает произвольную корреляцию между  $(c_i, g_i)$  и  $w_{it}$ , что требует  $T \geq 3$ . После взятия первых разностей получаем

$$\Delta y_{it} = g_i + \eta_t + \tau \Delta w_{it} + \Delta \mathbf{x}_{it}\gamma + \Delta u_{it}, \quad t = 2, \dots, T, \quad (25)$$

где  $\eta_t = \lambda_t - \lambda_{t-1}$  – это новый набор временных эффектов. Уравнение (25) можно оценить, снова взяв разности или используя оценку с фиксированными эффектами. Выбор зависит от характера серийной корреляции  $\{\Delta u_{it}\}$  (при предположении о строгой экзогенности программы и регрессоров). Если  $\Delta u_{it}$  почти не коррелируют, предпочтительна оценка с фиксированными эффектами. Если исходные ошибки  $\{u_{it}\}$  почти не коррелируют, предпочтительно применение оценки с фиксированными эффектами к (24) с целью удаления линейных трендов зависимой переменной, переменной воздействия и регрессоров. Полностью робастная инференция с использованием робастных к кластеризации оценок весьма проста. Конечно, может возникнуть желание разрешить эффекту программы меняться во времени, что легко сделать, добавив переменную взаимодействия между временными фиктивными переменными и индикатором программы.

Используя модель гипотетических исходов из литературы об эффектах воздействия, можно применять стандартные подходы на основе панельных данных,. Для каждой пары  $(i, t)$ , обозначим за  $y_{it}(1)$  и  $y_{it}(0)$  гипотетические исходы и предположим, что регрессоры отсутствуют. Один из способов формулировки предположения о несмещанности воздействия заключается в том, что для постоянной во времени разнородности  $\mathbf{c}_i$  выполняются условия

$$\mathbb{E}[y_{it}(0)|\mathbf{w}_i, \mathbf{c}_i] = \mathbb{E}[y_{it}(0)|\mathbf{c}_i] \quad (26)$$

$$\mathbb{E}[y_{it}(1)|\mathbf{w}_i, \mathbf{c}_i] = \mathbb{E}[y_{it}(1)|\mathbf{c}_i], \quad (27)$$

где  $\mathbf{w}_i = (w_{i1}, \dots, w_{iT})$  – последовательность всех воздействий. Подобного рода предположение о строгой экзогенности условно на латентных переменных упоминалось ранее. Оно позволяет воздействию быть коррелированным с постоянной во времени разнородностью, но не со случайными изменениями гипотетических исходов в какой-либо период времени. Далее предположим, что ожидаемый эффект воздействия зависит только от времени:

$$\mathbb{E}[y_{it}(1)|\mathbf{c}_i] = \mathbb{E}[y_{it}(0)|\mathbf{c}_i] + \tau_t, \quad t = 1, \dots, T. \quad (28)$$

Записывая  $y_{it} = (1 - w_{it})y_{it}(0) + w_{it}y_{it}(1)$  и используя (26), (27) и (28), получим

$$\mathbb{E}(y_{it}|\mathbf{w}_i, \mathbf{c}_i) = \mathbb{E}[y_{it}(0)|\mathbf{c}_i] + w_{it}\{\mathbb{E}[y_{it}(1)|\mathbf{c}_i] - \mathbb{E}[y_{it}(0)|\mathbf{c}_i]\} = \mathbb{E}[y_{it}(0)|\mathbf{c}_i] + \tau_t w_{it}.$$

Если предположить аддитивную структуру  $\mathbb{E}[y_{it}(0)|\mathbf{c}_i]$ , а именно

$$\mathbb{E}[y_{it}(0)|\mathbf{c}_i] = \alpha_{t0} + c_{i0},$$

то получим

$$\mathbb{E}(y_{it}|\mathbf{w}_i, \mathbf{c}_i) = \alpha_{t0} + c_{i0} + \tau_t w_{it}, \quad (29)$$

уравнение для оценивания, к которому применимы хорошо известные методы. Поскольку  $\{w_{it} : t = 1, \dots, T\}$  строго экзогенны условно на  $c_{i0}$ , можно применять модель с фиксированными эффектами или брать первые разности при полном наборе временных фиктивных переменных. Стандартный анализ предполагает  $\tau_t = \tau$ , но, разумеется, можно легко разрешить эффектам программы меняться во времени.

Можно брать математическое ожидание условно еще и на регрессорах  $\mathbf{x}_{it}$  и предположить линейность, скажем,  $\mathbb{E}[y_{it}(0)|\mathbf{x}_{it}, \mathbf{c}_i] = \alpha_{t0} + \mathbf{x}_{it}\boldsymbol{\gamma}_0 + c_{i0}$ . Если (26) принимает вид

$$\mathbb{E}[y_{it}(0)|\mathbf{w}_i, \mathbf{x}_i, \mathbf{c}_i] = \mathbb{E}[y_{it}(0)|\mathbf{x}_{it}, \mathbf{c}_i], \quad (30)$$

и похожую форму имеет (27), то в уравнение для оценивания (29) просто добавляется член  $\mathbf{x}_{it}\boldsymbol{\gamma}_0$ . Более интересные модели получаются, если разрешить зависимость эффекта воздействия от разнородности. Предположим, вдобавок к предположению об игнорируемости в (30) (и эквивалентному условию для  $y_{it}(1)$ ), что

$$\mathbb{E}[y_{it}(1) - y_{it}(0)|\mathbf{x}_{it}, \mathbf{c}_i] = \tau_t + a_i + (\mathbf{x}_{it} - \boldsymbol{\xi}_t)\boldsymbol{\delta}, \quad (31)$$

где  $a_i$  – функция от  $\mathbf{c}_i$ , нормализованная так, чтобы  $\mathbb{E}(a_i) = 0$  и  $\boldsymbol{\xi}_t = \mathbb{E}(\mathbf{x}_{it})$ . Уравнение (31) позволяет эффекту воздействия зависеть от времени, ненаблюдаемой разнородности и наблюдаемых регрессоров. Тогда

$$\mathbb{E}(y_{it}|\mathbf{w}_i, \mathbf{x}_i, \mathbf{c}_i) = \alpha_{t0} + \tau_t w_{it} + \mathbf{x}_{it}\boldsymbol{\gamma}_0 + w_{it}(\mathbf{x}_{it} - \boldsymbol{\xi}_t)\boldsymbol{\delta} + c_{i0} + a_i w_{it}.$$

Это модель с коррелированными случайными коэффициентами, поскольку коэффициент при  $w_{it}$  равен  $(\tau_t + a_i)$ , с математическим ожиданием  $\tau_t$ . В общем случае хотелось бы разрешить  $w_{it}$  коррелировать с  $a_i$  и  $c_{i0}$ . При малом  $T$  и большом  $N$  мы не пытаемся оценить  $a_i$  (и  $c_{i0}$ ). Но расширенное внутри-преобразование устраниет  $a_i w_{it}$ . Упростим ситуацию, предполагая  $\tau_t = \tau$  и опуская все иные регрессоры. Тогда регрессия, которая, казалось бы, страдает от проблемы шумовых параметров, позволяет состоятельно оценить  $\tau$ : следует регрессировать  $y_{it}$  на фиктивные переменные для лет, индивидов и переменные взаимодействия последних с  $w_{it}$ . Иными словами, следует оценить уравнение

$$\hat{y}_{it} = \hat{\alpha}_{t0} + \hat{c}_{i0} + \hat{\tau}_i w_{it}.$$

Хотя  $\hat{\tau}_i$  обычно являются плохими оценками  $\tau_i = \tau + a_i$ , их среднее является хорошей оценкой для  $\tau$ :

$$\hat{\tau} = N^{-1} \sum_{i=1}^N \hat{\tau}_i.$$

Стандартную ошибку можно найти, используя метод из Wooldridge (2002, Раздел 11.2) или применяя бутстррап.

Wooldridge (2005) дает простое достаточное условие, при котором обычная оценка с фиксированными эффектами, которая ведет себя как если бы эффекты воздействия были постоянными, состоятельно оценивает средний эффект воздействия. В дополнение к предположению о несмешанности достаточно предположить, что

$$\mathbb{E}(\tau_i|\ddot{w}_{it}) = \mathbb{E}(\tau_i) = \tau, \quad t = 1, \dots, T, \quad (32)$$

где  $\ddot{w}_{it} = w_{it} - \bar{w}_i$ . В сущности, эффекты воздействия на индивидуальном уровне могут коррелировать со средней склонностью быть подверженным воздействию  $\bar{w}_i$ , но не с отклонениями для какого-либо определенного периода времени.

Предположение (32) не является совсем общим, и интересно иметь простой способ определить, является ли эффект воздействия разнородным среди объектов. Для этого можно использовать корреляцию между  $\tau_i$  и воздействием. Вспоминая, что  $\tau_i = \tau + a_i$ , полезным

предположением (которое не обязательно должно выполняться для получения теста) является следующее:

$$\mathbb{E}(a_i|w_{i1}, \dots, w_{iT}) = \mathbb{E}(a_i|\bar{w}_i) = \rho(\bar{w}_i - \mu_{\bar{w}_i}),$$

где прочие регрессоры отброшены. Тогда можно оценить уравнение (с регрессорами)

$$y_{it} = \alpha_{t0} + \tau w_{it} + \mathbf{x}_{it}\gamma_0 + w_{it}(\mathbf{x}_{it} - \bar{\mathbf{x}}_t)\delta + \rho w_{it}(\bar{w}_i - \bar{w}) + c_{i0} + e_{it}$$

как стандартную модель с фиксированными эффектами. Далее к  $\hat{\rho}$  применим обычный  $t$ -тест, рабочий к гетероскедастичности и серийной корреляции. Если нулевая гипотеза отвергается, это не означает, что обычная оценка с фиксированными эффектами несостоятельна, но такое возможно.

## 5 Полупараметрический и непараметрический подходы

Вернемся к постановке с двумя группами и двумя периодами. Athey & Imbens (2006) (AI) обобщают стандартную РР-модель в нескольких направлениях. Чтобы соответствовать обозначениям в AI, будем называть два временных периода  $t = 0$  и  $t = 1$ , а две группы –  $g = 0$  и  $g = 1$ . Пусть  $Y_i(0)$  означает гипотетический исход при отсутствии воздействия, а  $Y_i(1)$  – при его наличии. AI предполагают, что

$$Y_i(0) = h_0(U_i, T_i), \quad (33)$$

где  $T_i$  – временной период и

$$h_0(u, t) \text{ строго возрастает по } u \text{ для } t = 0, 1. \quad (34)$$

Случайная величина  $U_i$  отражает все ненаблюдаемые характеристики индивида  $i$ . Из уравнения (33) следует, что исход для индивида с  $U_i = u$  будет одинаковым в данный период независимо от принадлежности к группе. Предположение о строгой монотонности (34) отсекает случай дискретной зависимой переменной, но Athey & Imbens (2006) приводят границы при слабой монотонности и показывают, как при дополнительных предположениях можно получить точечную идентификацию.

Распределение  $U_i$  может меняться по группам, но не во времени внутри групп, так что

$$D(U_i|T_i, G_i) = D(U_i|G_i). \quad (35)$$

Из этой предпосылки следует, что внутри группы популяционное распределение стабильно во времени.

Стандартную РР-модель в этих терминах можно записать в виде

$$h_0(u, t) = u + \delta \cdot t$$

и

$$U_i = \alpha + \gamma G_i + V_i, \quad V_i \perp (G_i, T_i),$$

хотя в силу линейности можно обойтись предположением  $\mathbb{E}(V_i|G_i, T_i) = 0$ . Если эффект воздействия постоянен среди индивидов,  $\tau = Y_i(1) - Y_i(0)$ , то

$$Y_i = \alpha + \beta T_i + \gamma G_i + \tau G_i T_i + V_i, \quad (36)$$

где  $Y_i = (1 - G_i T_i)Y_i(0) + G_i T_i Y_i(1)$  – реализация исхода. Так как  $\mathbb{E}(V_i|G_i, T_i) = 0$ , параметры в (36) можно оценить с помощью МНК.

Athey & Imbens называют расширение обычной РР-модели моделью «изменения изменений» (ИИ). Они не только показывают, как получить средний эффект воздействия, но и доказывают, что распределение гипотетического исхода условно на воздействии

$$D(Y_i(0)|G_i = 1, T_i = 1)$$

идентифицируемо. Распределение  $D(Y_i(1)|G_i = 1, T_i = 1)$  идентифицируемо по данным, поскольку  $Y_i = Y_i(1)$  при  $G_i = T_i = 1$ . Дополнительное условие, которое используют АИ, состоит в том, что носитель распределения  $D(U_i|G_i = 1)$  содержится в носителе  $D(U_i|G_i = 0)$ :

$$\mathbb{U}_1 \subseteq \mathbb{U}_0. \quad (37)$$

Пусть  $F_{gt}^0(y)$  обозначает кумулятивную функцию распределения  $D(Y_i(0)|G_i = g, T_i = t)$  для  $g = 0, 1$  и  $t = 0, 1$ , а  $F_{gt}(y)$  – КФР для наблюдаемого исхода  $Y_i$  условно на  $G_i = g$  и  $T_i = t$ . По определению,  $F_{gt}(y)$  обычно идентифицируема по данным в предположении случайных выборок для каждой пары  $(g, t)$ . АИ показывают, что при (33), (34), (35) и (37)

$$F_{11}^{(0)}(y) = F_{10}(F_{00}^{-1}(F_{01}(y))), \quad (38)$$

где  $F_{00}^{-1}(\cdot)$  – обратная функция для  $F_{00}$ , которая существует при предположении о строгой монотонности. Заметим, что все КФР в правой части (38) можно оценить по данным; это просто КФР наблюдаемых исходов условно на разных парах  $(g, t)$ . Поскольку  $F_{11}^{(1)}(y) = F_{11}(y)$ , можно оценить распределения обоих гипотетических исходов условно на воздействии,  $G_i = T_i = 1$ .

Средний эффект воздействия в рамках ИИ-модели имеет вид

$$\tau_{CIC} = \mathbb{E}[Y(1)|G = 1, T = 1] - \mathbb{E}[Y(0)|G = 1, T = 1] = \mathbb{E}(Y_{11}(1)) - \mathbb{E}(Y_{11}(0)),$$

где индекс  $i$  отброшен,  $Y_{gt}(1)$  – случайная величина, имеющая распределение  $D(Y(1)|G = g, t)$ , а  $Y_{gt}(0)$  – случайная величина с распределением  $D(Y(0)|G = g, t)$ . При тех же предположениях, что и выше,

$$\tau_{CIC} = \mathbb{E}(Y_{11}) - \mathbb{E}[F_{01}^{-1}(F_{00}(Y_{10}))],$$

где  $Y_{gt}$  – случайная величина с распределением  $D(Y|G = g, t)$ . При наличии случайных выборок для каждой подгруппы, состоятельная оценка  $\tau_{CIC}$  имеет вид

$$\hat{\tau}_{CIC} = N_{11}^{-1} \sum_{i=1}^{N_{11}} Y_{11,i} - N_{10}^{-1} \sum_{i=1}^{N_{10}} \hat{F}_{01}^{-1}(\hat{F}_{00}(Y_{10,i}))$$

при состоятельных оценках КФР  $\hat{F}_{00}$  и  $\hat{F}_{01}$  для контрольных групп в начальный и последующий моменты времени, соответственно. Теперь  $Y_{11,i}$  обозначает реализацию наблюдаемого исхода для группы  $g = 1, t = 1$ ; аналогично для  $Y_{10,i}$ . Athey & Imbens (2006) установили слабые условия, при которых  $\hat{\tau}_{CIC}$  является  $\sqrt{N}$ -асимптотически нормальной (естественно, число наблюдений должно расти внутри каждой группы). В случае, когда распределения  $Y_{10}$  и  $Y_{00}$  совпадают, оценка представляет собой простую разность средних для опытной группы по времени.

Описанный подход применим как в случае повторяющихся кросс-секций, так и в случае панельных данных. Athey & Imbens (2006) обсуждают, какие предположения можно ослабить в случае панельных данных и какие доступны альтернативные стратегии оценивания. В частности, если  $U_{i0}$  и  $U_{i1}$  представляют ненаблюдаемые характеристики объекта  $i$  в начальный и последующий периоды времени, соответственно, то (35) можно привести к виду

$$D(U_{i0}|G_i) = D(U_{i1}|G_i),$$

что позволяет структуру ненаблюдаемых компонент  $U_{it} = C_i + V_{it}$ , где  $V_{it}$  имеет одно и то же распределение в каждом периоде.

Как обсуждают AI, при панельных данных доступны другие подходы к оцениванию. Altonji & Matzkin (2005) используют предположения о взаимозаменяемости для идентификации средних частных эффектов. Для иллюстрации их подхода предположим, что гипотетические исходы удовлетворяют предположению об игнорируемости

$$\mathbb{E}(Y_{it}(g)|W_{i1}, \dots, W_{iT}, U_i) = h_{tg}(U_i), \quad t = 1, \dots, T, \quad g = 0, 1. \quad (39)$$

Эффект воздействия для объекта  $i$  в период  $t$  равен  $h_{t1}(U_i) - h_{t0}(U_i)$ , а средний эффект воздействия –

$$\tau_t = \mathbb{E}[h_{t1}(U_i) - h_{t0}(U_i)], \quad t = 1, \dots, T.$$

Предположим, что

$$D(U_i|W_{i1}, \dots, W_{iT}) = D(U_i|\bar{W}_i), \quad (40)$$

то есть только интенсивность воздействия коррелирует с разнородностью. При условиях (39) и (40) можно показать, что

$$\mathbb{E}(Y_{it}|W_i) = \mathbb{E}[\mathbb{E}(Y_{it}|W_i, U_i)|W_i] = \mathbb{E}(Y_{it}|W_{it}, \bar{W}_i).$$

Ключевая особенность состоит в том, что  $\mathbb{E}(Y_{it}|W_i)$  не зависит от  $\{W_{i1}, \dots, W_{iT}\}$  произвольным образом; это функция только от  $(W_{it}, \bar{W}_i)$ . Если  $W_{it}$  непрерывны или принимают множество значений, для оценки  $\mathbb{E}(y_{it}|W_{it}, \bar{W}_i)$  можно применить методы локального сглаживания. В случае эффектов воздействия оценивание очень простое, поскольку  $(W_{it}, \bar{W}_i)$  может принимать только  $2T$  значений. Средний эффект воздействия можно оценить как

$$\hat{\tau}_t = N^{-1} \sum_{i=1}^n (\hat{\mu}_t^Y(1, \bar{W}_i) - \hat{\mu}_t^Y(0, \bar{W}_i)).$$

Если объединить данные по  $t$  (и по  $i$ ) и оценить линейную регрессию  $Y_{it}$  на  $1, d2_t, \dots, dT_t, W_{it}, \bar{W}_i, t = 1, \dots, T, i = 1, \dots, N$ , получим обычную оценку с фиксированными эффектами  $\hat{\tau}_{FE}$  как коэффициент при  $W_{it}$ . Wooldridge (2005) описывает другие случаи и сравнивает эту стратегию с другими подходами. С помощью условного ММП для логит-модели можно оценить параметры, но обычно не средние эффекты воздействия, и требуется условная независимость. В пребит-модели Чемберлена с коррелированными случайными коэффициентами разнородность выражается в том, что  $U_i|W_i \sim N(\xi_0 + \xi_1 W_{i1} + \dots + \xi_T W_{iT}, \eta^2)$ , и это позволяет идентифицировать средние эффекты воздействия без предположения о взаимозаменяемости, но сохраняя предположение о распределении (и функциональной форме вероятности для зависимой переменной).

Для основного случая двух периодов, когда воздействие не происходит в начальный период времени ни для одного из объектов, но происходит для некоторых объектов во второй период, Heckman, Ichimura & Todd (1997) (HIT) и Abadie (2005) предлагают методы как для повторяющихся кросс-секций, так и для панельных данных, которые накладывают предположение о несмешанности на изменения во времени. Пусть  $Y_t(w)$  обозначает гипотетический исход в момент времени  $t$ ,  $t = 0, 1$ , соответствующий статусу подверженности воздействию  $w$ ,  $w = 0, 1$ . Поскольку в начальный период воздействие отсутствует,  $Y_0(1) = Y_0(0)$ , что просто означает, что в начальный период времени гипотетические исходы отсутствуют.

Как в HIT (1997) и Abadie (2005), рассмотрим сначала оценивание

$$\tau_{att} = \mathbb{E}[Y_1(1) - Y_1(0)|W = 1].$$

Поскольку нет объектов, подверженных воздействию в начальный период времени,  $W = 1$  означает наличие воздействия во втором периоде. Чтобы оценить  $\tau_{att}$ , ключевым предположением о несмешанности является

$$\mathbb{E}[Y_1(0) - Y_0(0)|X, W] = \mathbb{E}[Y_1(0) - Y_0(0)|X], \quad (41)$$

так что, условно на  $X$ , статус подверженности воздействию не связан с изменениями во времени при отсутствии программы. Вдобавок, сделаем предположение о пересечении:

$$0 < \mathbb{P}\{W = 1|X = x\} < 1 \quad (42)$$

для всех  $x$ . Для оценки  $\tau_{att}$  можно ослабить (42) до  $\mathbb{P}\{W = 1|X = x\} < 1$ . Используя регрессионный подход, можно оценить  $\tau_{att}$ , сперва оценив  $\mathbb{E}[Y_1(1) - Y_1(0)|X, W = 1]$ . Как показано в НИТ, это математическое ожидание идентифицируемо при условии (41). Пусть  $Y_1 = (1 - W) \cdot Y_1(0) + W \cdot Y_1(1)$  – наблюдаемый исход для  $t = 1$ , а  $Y_0 = Y_0(0) = Y_0(1)$  – в момент  $t = 0$ . Тогда

$$\begin{aligned} & \{\mathbb{E}(Y_1|X, W = 1) - \mathbb{E}(Y_1|X, W = 0)\} - \{\mathbb{E}(Y_0|X, W = 1) - \mathbb{E}(Y_0|X, W = 0)\} = \\ & \{\mathbb{E}[Y_1(1)|X, W = 1] - \mathbb{E}[Y_1(0)|X, W = 0]\} - \{\mathbb{E}[Y_0(1)|X, W = 1] - \mathbb{E}[Y_0(0)|X, W = 0]\} = \\ & \{\mathbb{E}[Y_1(1)|X, W = 1] - \mathbb{E}[Y_1(0)|X, W = 1]\} + \{\mathbb{E}[Y_1(0)|X, W = 1] - \mathbb{E}[Y_1(0)|X, W = 0]\} - \\ & - \{\mathbb{E}[Y_0(1)|X, W = 1] - \mathbb{E}[Y_0(0)|X, W = 0]\} = \\ & \{\mathbb{E}[Y_1(1) - Y_1(0)|X, W = 1] - \mathbb{E}[Y_0(1) - Y_0(0)|X, W = 1]\} + \\ & + \{\mathbb{E}[Y_1(0) - Y_0(0)|X, W = 1] - \mathbb{E}[Y_1(0) - Y_0(0)|X, W = 0]\} = \\ & \mathbb{E}[Y_1(1) - Y_1(0)|X, W = 1] - \mathbb{E}[Y_0(1) - Y_0(0)|X, W = 1], \end{aligned}$$

где последнее равенство выполняется в силу (41). Но  $Y_0(1) = Y_0(0)$ , то есть

$$\begin{aligned} & \{\mathbb{E}(Y_1|X, W = 1) - \mathbb{E}(Y_1|X, W = 0)\} - \{\mathbb{E}(Y_0|X, W = 1) - \mathbb{E}(Y_0|X, W = 0)\} = \\ & \mathbb{E}[Y_1(1) - Y_1(0)|X, W = 1]. \end{aligned} \quad (43)$$

Каждое из четырех математических ожиданий по левую сторону (43) можно оценить, имея случайные выборки для двух периодов. Например, можно использовать гибкие параметрические модели или даже непараметрическое оценивание, чтобы оценить  $\mathbb{E}(Y_1|X, W = 1)$  по данным для объектов, подверженных воздействию в момент  $t = 1$ .

Анализ для

$$\tau_{ate} = \mathbb{E}[Y_1(1) - Y_1(0)]$$

аналогичный. Теперь добавим к (41) дополнительное предположение о несмешиваемости:

$$\mathbb{E}[Y_1(1) - Y_0(1)|X, W] = \mathbb{E}[Y_1(1) - Y_0(1)|X], \quad (44)$$

то есть о том, что статус подверженности воздействию не связан с эффектом воздействия. При (41) и (44)

$$\begin{aligned} & \{\mathbb{E}(Y_1|X, W = 1) - \mathbb{E}(Y_1|X, W = 0)\} - \{\mathbb{E}(Y_0|X, W = 1) - \mathbb{E}(Y_0|X, W = 0)\} = \\ & \mathbb{E}[Y_1(1) - Y_1(0)|X], \end{aligned} \quad (45)$$

так что теперь можно оценить средний эффект воздействия условно на  $X$ , используя оценки условных средних для четырех групп в соответствии с индикаторами периода и статуса подверженности воздействию. Если требуется  $\tau_{ate}$ , можно просто усреднить разности подогнанных значений по регрессорам (вспомним, что имеются разные случайные выборки в каждый период времени). Оценка принимает вид

$$\hat{\tau}_{ate, reg} = N_1^{-1} \sum_{i=1}^{N_1} (\hat{\mu}_{11}(X_i) - \hat{\mu}_{10}(X_i)) - N_0^{-1} \sum_{i=1}^{N_0} (\hat{\mu}_{01}(X_i) - \hat{\mu}_{00}(X_i)), \quad (46)$$

где  $\hat{\mu}_{tw}(x)$  – оцененная регрессионная функция для периода времени  $t$  и статуса подверженности воздействию  $w$ ,  $N_1$  – общее число наблюдений для  $t = 1$ , а  $N_0$  – общее число наблюдений для нулевого периода. Базовый РР-подход с регрессорами просто предполагает линейность и постоянство коэффициентов по  $t$  и статусу подверженности воздействию. Конечно, эти предположения можно легко ослабить в контексте обычной модели линейной регрессии. Строго говоря, (45) ведет к  $\tau_{ate}$  (после усреднения относительно распределения  $X$ ) только если распределение регрессоров не меняется во времени. Конечно, одна из причин включения регрессоров – учет возможных изменений структуры рассматриваемых популяций во времени. Обычный РР-подход избегает этой проблемы, предполагая, что эффект воздействия не зависит от регрессоров. Уравнение (46) позволяет эффектам воздействия различаться в зависимости от  $X$ , но два средних значения обязательно подсчитываются для различных временных периодов.

Abadie (2005) показывает, как с помощью взвешивания на основе оцениваемой вероятности воздействия можно получить  $\tau_{att}$  в случае повторяющихся кросс-секций при условии стационарности. Оценку можно записать способом, похожим на (46). В частности,

$$\hat{\tau}_{att,ps} = N_1^{-1} \sum_{i=1}^{N_1} \frac{(W_i - \hat{p}(X_i))Y_{i1}}{\hat{p}(1 - \hat{p}(X_i))} - N_0^{-1} \sum_{i=1}^{N_0} \frac{(W_i - \hat{p}(X_i))Y_{i0}}{\hat{p}(1 - \hat{p}(X_i))}, \quad (47)$$

где  $\{Y_{i1} : i = 1, \dots, N_1\}$  – данные для  $t = 1$ , а  $\{Y_{i0} : i = 1, \dots, N_0\}$  – для  $t = 0$ . Уравнение (47) имеет очевидную интерпретацию. Первое среднее – стандартная взвешенная оценка на основе оцениваемой вероятности воздействия, если использовать только  $t = 1$  и предположить несмешиваемость в уровнях; см., например, Dehejia & Wahba (1999) и Wooldridge (2002, Глава 18). Второе среднее – та же оценка, но на данных для  $t = 0$  (конечно, эта оценка сама по себе несет мало смысла, поскольку в период  $t = 0$  нет индивидов, подверженных воздействию). Как и в (46), оцененный эффект воздействия – это разность двух оценок в разные периоды времени.

При наличии панельных данных можно брать разности для тех же объектов во времени. Например, (45) можно записать в форме

$$\mathbb{E}(\Delta Y | X, W = 1) - \mathbb{E}(\Delta Y | X, W = 0) = \mathbb{E}[Y_1(1) - Y_1(0)|X],$$

где  $\Delta Y = Y_1 - Y_0$  – изменение в наблюдаемом исходе для типичного представителя популяции. Но это просто означает, что можно применить регрессионную корректировку или методы на основе оцениваемой вероятности воздействия к изменениям в  $Y$ . Регрессионная корректировка требует оценивания  $\mu_1^\Delta(X) \equiv \mathbb{E}(\Delta Y | X, W = 1)$  и  $\mu_0^\Delta(X) \equiv \mathbb{E}(\Delta Y | X, W = 0)$  с использованием опытной и контрольной групп, соответственно, а затем  $\tau_{ate}$  как

$$N^{-1} \sum_{i=1}^N (\hat{\mu}_1^\Delta(X_i) - \hat{\mu}_0^\Delta(X_i)),$$

где  $N$  – общее число индивидов в панельных данных. Abadie (2005) показывает, что

$$\tau_{att} = (\mathbb{P}\{W = 1\})^{-1} \mathbb{E} \left[ \frac{(W - p(X))\Delta Y}{1 - p(X)} \right], \quad (48)$$

где  $p(X) = \mathbb{P}\{W = 1|X\}$  – вероятность воздействия. Величины в (48) наблюдаются или, в случае  $p(X)$  и  $\rho = \mathbb{P}\{W = 1\}$ , оцениваются. Как в Hirano, Imbens & Ridder (2003), для оценки  $p(X)$  можно использовать гибкую логит-модель; в качестве  $\hat{p}$  используется доля объектов, подверженных воздействию. Тогда

$$\hat{\tau}_{att,ps} = N^{-1} \sum_{i=1}^N \frac{(W_i - \hat{p}(X_i))\Delta Y_i}{\hat{p}(1 - \hat{p}(X_i))}$$

состоятельна и  $\sqrt{N}$ -асимптотически нормальна. HIR обсуждают оценивание дисперсии. Wooldridge (2007) приводит простую корректировку, доступную в случае, когда  $\hat{p}(\cdot)$  рассматривается как параметрическая модель.

При условии (44) получаем выражение, взвешенное на обратную вероятность

$$\tau_{ate} = \mathbb{E} \left[ \frac{(W - p(X))\Delta Y}{p(X)(1 - p(X))} \right],$$

берущее начало в работе Horvitz & Thompson (1952). Чтобы оценить средний эффект воздействия для определенной популяции, необходимо предположение о полном пересечении (42), и тогда

$$\hat{\tau}_{ate,ps} = N^{-1} \sum_{i=1}^N \frac{(W_i - \hat{p}(X_i))\Delta Y_i}{\hat{p}(X_i)(1 - \hat{p}(X_i))}. \quad (49)$$

Hirano, Imbens & Ridder (2003) изучают эту оценку в деталях, когда  $\hat{p}(x)$  – серийная логит-оценка. Если воспринимать эту оценку параметрически, простая корректировка делает легким проведение правильной инференции для  $\hat{\tau}_{ate}$ . Пусть  $\hat{K}_i$  – слагаемое из (49) за вычетом  $\hat{\tau}_{ate}$ , а  $\hat{D}_i = h(X_i)(W_i - \Lambda(h(X_i)\hat{\gamma}))$  – градиент (вектор-строка) логит-оценивания. Подсчитаем остатки  $\hat{R}_i$  МНК-регрессии  $\hat{K}_i$  на  $\hat{D}_i$ ,  $i = 1, \dots, N$ . Тогда, состоятельная оценка  $Avar\sqrt{N}(\hat{\tau}_{ate,ps} - \tau_{ate})$  – это просто выборочная дисперсия  $\hat{R}_i$ . Она никогда не превышает дисперсию, которая была бы получена при игнорировании оценивания  $p(x)$  и простом использовании выборочной дисперсии самих  $\hat{K}_i$ .

Методы, которые сочетают регрессионную корректировку и взвешивание с помощью оцениваемой вероятности воздействия, также применимы к разностям при наличии панельных данных. Подробности можно найти в Imbens (2004), Wooldridge (2007), и Imbens & Wooldridge (2009).

## 6 Методы синтетической контрольной группы для сравнительных кейсов

В разделе 3 обсуждались РР-методы, игнорирующие выборочную вариацию при подсчете в средних по группам и временным периодам (в более общем случае, в регрессионных коэффициентах). Abadie, Diamond & Hainmueller (2007), основываясь на работе Abadie & Gardeazabal (2003), утверждают, что при анализе программ на общем уровне нет неточности оценивания: цель – определить эффект программы для всей популяции, скажем, штата, а совокупные величины измеряются без ошибки (или с очень маленькой ошибкой).

Конечно, один из источников вариации в каждом исследовании с применением данных, меняющихся во времени, – изменение исходов во времени, даже если те являются совокупными величинами, измеряемыми без ошибки. Методология кейс-стади – один из таких примеров: часто регрессии для временных рядов по одному объекту, такому как штат, применяются для определения эффекта программы (изменения скоростных ограничений, программы по контролю курения табака и так далее) на совокупный исход. Но недостатком таких кейсов является то, что в них не используется контрольная группа для учета совокупных эффектов, не имеющих ничего общего с определенной программой в штате.

В контексте исследований «случай-контроль», когда временной ряд доступен для конкретного объекта – опытной группы – часто бывает много потенциальных контрольных групп. Скажем, в примере с программой по контролю курения табака каждый штат США является потенциальной контрольной группой для Калифорнии (при условии, что он не проводил аналогичную программу). ADH изучают такую постановку и подчеркивают важность вариации, связанной с выбором подходящих контрольных групп. Они обращают внимание на то, что даже при отсутствии выборочной ошибки при анализе программ на уровне штата необходимо учитывать подобную неопределенность.

Поход ADH состоит в том, чтобы выбирать синтетическую контрольную группу из набора возможных контрольных групп. Например, в случае контроля курения табака в Калифорнии ADH выделяют 38 штатов, в которых подобные программы не проводились в исследуемый временной период. Вместо того чтобы использовать стандартный анализ с фиксированными эффектами (который фактически предполагает, что каждый штат одинаково хорош в качестве контрольной группы) б) ADH предлагают выбирать взвешенное среднее потенциальных контрольных групп. Конечно, выбор подходящей контрольной группы или групп часто делается неформально, включая сопоставление на основе значений регрессоров в предпрограммный период. ADH формализуют процедуру выбора оптимальным образом выбирая веса, и предлагают способы проведения инференции.

Рассмотрим простой пример с двумя временными периодами: одним до реализации программы и одним после. Пусть  $y_{it}$  – исход для объекта  $i$  в периоде  $t$ , где  $i = 1$  – объект, подверженный воздействию во втором периоде. Предположим, имеется  $J$  возможных контрольных групп, индексируемых как  $\{2, \dots, J+1\}$ . Пусть  $\mathbf{x}_i$  – наблюдаемые регрессоры для объекта  $i$ , которые не затрагиваются (или не были бы затронуты) программой;  $\mathbf{x}_i$  может содержать регрессоры периода  $t = 2$ , если на них не влияет программа. Обычно эффект программы можно оценить как

$$y_{12} - \sum_{j=2}^{J+1} w_j y_{j2},$$

где  $w_j$  – неотрицательные веса, в сумме дающие единицу. Вопрос заключается в следующем: как выбрать веса, то есть синтетическую контрольную группу, чтобы получить лучшую оценку эффекта программы? ADH предлагают выбирать веса, минимизирующие, в простейшем случае, расстояние между  $(y_{11}, \mathbf{x}_1)$  и  $\sum_{j=2}^{J+1} w_j \cdot (y_{j1}, \mathbf{x}_j)$  или некоторую линейную комбинацию элементов  $(y_{11}, \mathbf{x}_1)$  и  $(y_{j1}, \mathbf{x}_j)$ . Оптимальные веса – которые различаются в зависимости от определения расстояния – дают синтетическую контрольную группу, чьи исходы в период перед программой и регрессоры в период проведения программы «наиболее близки». При наличии более чем двух периодов можно использовать средние значения исходов в период перед программой или взвешенные средние, которые дают больший вес более недавним исходам в предпрограммный период.

ADH предлагают методы перестановки для проведения инференции, которые требуют оценки гипотетических эффектов воздействия для каждого региона (потенциальной контрольной группы), используя тот же метод синтетической контрольной группы, что и для региона, в котором проводилась программа. Таким способом можно сравнить, является ли оценка эффекта воздействия при использовании метода синтетической контрольной группы существенно больше оценки этого эффекта при случайном выборе региона. Инференция является точной даже в случае, когда совокупные исходы оцениваются с ошибкой по данным на индивидуальном уровне.

## Литература

- Abadie, A. (2005). Semiparametric difference-in-differences estimators. *Review of Economic Studies* 72, 1–19.
- Abadie, A. & J. Gardeazabal (2003). Economic costs of conflict: A case study of the Basque Country. *American Economic Review* 93, 113–132.
- Abadie, A., A. Diamond & J. Hainmueller (2007). Synthetic control methods for comparative case studies: Estimating the effect of California's tobacco control program. *NBER Technical Working Paper* No. 335.
- Altonji, J.G. & R.L. Matzkin (2005). Cross section and panel data estimators for nonseparable models with endogenous regressors. *Econometrica* 73, 1053–1102.
- Angrist, J.D. & V. Lavy (2002). The effect of high school matriculation awards: Evidence from randomized trials. *NBER Working Paper* No. 9389.

- Ashenfelter, O. & D. Card (1985). Using the longitudinal structure of earnings to estimate the effect of training programs. *Review of Economics and Statistics* 67, 648–660.
- Athey, S. & G.W. Imbens (2006). Identification and inference in nonlinear difference-in-differences models. *Econometrica* 74, 431–497.
- Bertrand, M., E. Duflo & S. Mullainathan (2004). How much should we trust differences-in-differences estimates? *Quarterly Journal of Economics* 119, 249–275.
- Card, D. & A.B. Krueger (1994). Minimum wages and employment: A case study of the fast-food industry in New Jersey and Pennsylvania. *American Economic Review* 84, 772–793.
- Dehejia, R.H. & S. Wahba (1999). Causal effects in nonexperimental studies: Reevaluating the evaluation of training programs. *Journal of American Statistical Association* 94, 1053–1062.
- Donald, S.G. & K. Lang (2007). Inference with difference-in-differences and other panel data. *Review of Economics and Statistics* 89, 221–233.
- Hansen, C.B. (2007a). Asymptotic properties of a robust variance matrix estimator for panel data when  $T$  is large. *Journal of Econometrics* 141, 597–620.
- Hansen, C.B. (2007b). Generalized least squares inference in panel and multilevel models with serial correlation and fixed effects. *Journal of Econometrics* 140, 670–694.
- Hausman, J.A. & G. Kuersteiner (2005). Difference in difference meets generalized least squares: Higher order properties of hypotheses tests. Working Paper No. 2005-010, Boston University.
- Heckman, J., H. Ichimura & P. Todd (1997). Matching as an econometric evaluation estimator: Evidence from evaluating a job training programme. *Review of Economic Studies* 64, 605–654.
- Hirano, K., G.W. Imbens & G. Ridder (2003). Efficient estimation of average treatment effects using the estimated propensity score. *Econometrica* 71, 1161–1189.
- Horvitz, D. & D. Thompson (1952). A generalization of sampling without replacement from a finite universe. *Journal of American Statistical Association* 47, 663–685.
- Imbens, G.W. (2004). Nonparametric estimation of average treatment effects under exogeneity: A review. *Review of Economics and Statistics* 86, 1–29.
- Imbens, G.W. & J.M. Wooldridge (2009). Recent developments in the econometrics of program evaluation. *Journal of Economic Literature*, forthcoming.
- Kiefer, N.M. (1980). Estimation of fixed effect models for time series of cross-sections with arbitrary intertemporal covariance. *Journal of Econometrics* 14, 195–202.
- Loeb, S. & J. Bound (1996). The effect of measured school inputs on academic achievement: Evidence from the 1920s, 1930s and 1940s birth cohorts. *Review of Economics and Statistics* 78, 653–664.
- Meyer, B.D., W.K. Viscusi & D.L. Durbin (1995). Workers' compensation and injury duration: Evidence from a natural experiment. *American Economic Review* 85, 322–340.
- Solon, G. (1984). Estimating autocorrelations in fixed-effects models. *NBER Technical Working Paper* No. 032.
- White, H. (1980). A heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity. *Econometrica* 48, 817–838.
- Wooldridge, J.M. (2002). *Econometric Analysis of Cross Section and Panel Data*. MIT Press: Cambridge, MA.
- Wooldridge, J.M. (2003). Cluster-sample methods in applied econometrics. *American Economic Review* 93, 133–138.
- Wooldridge, J.M. (2005). Fixed effects and related estimators for correlated random-coefficient and treatment effect panel data models. *Review of Economics and Statistics* 87, 385–390.
- Wooldridge, J.M. (2007). Inverse probability weighted M-estimation for general missing data problems. *Journal of Econometrics* 141, 1281–1301.

## Difference-in-differences estimation

**Jeffrey M. Wooldridge**

*Michigan State University, East Lansing, USA*

This article provides an overview of difference-in-differences estimation, starting with a review of the basic methodology, discussing in some detail recent advances in inference, and concluding with new methods for estimating treatment effects in various nonlinear and semiparametric models.

