

Propensity score matching (PSM)

Jerzy Mycielski

Uniwersytet Warszawski

Maj 2010

- Ocena wpływu bodźca
 - Przykłady:
 - ocena skuteczności programów aktywizacji zawodowej
 - ocena skuteczności dotacji mających na celu zachęcanie do innowacyjności
 - Idealny eksperyment społeczny
- 1 jednostki należące do grupy eksperymentalnej i kontrolnej mają ten sam rozkład cech nieobserwowalnych
 - 2 jednostki należące do grupy eksperymentalnej i kontrolnej mają ten sam rozkład cech obserwowalnych
 - 3 ten sam kwestionariusz został zastosowany w przypadku grupy eksperymentalnej i kontrolnej - cechy i wyniki są mierzone w ten sam sposób
 - 4 obie grupy znajdują się w tym samym otoczeniu ekonomicznym

- Idealną metodą ewaluacyjną jest eksperyment zrandomizowany
 - w przypadku takiego eksperymentu założenia (1)-(4) są automatycznie spełnione
- Tradycyjna analiza ekonomiczna dotycząca problemów związanych z ewaluacją w przypadku danych nieeksperymentalnych koncentrowały się na problemie z założeniem (1) - np. model Heckmana
- w praktyce jednak ważniejsze wydają się problemy z założeniami (2), (3), (4).
- Metoda PSM umożliwia znaczną redukcję obciążenia estymacji efektu bodźca jeśli nie jest spełnione założenie (2).

- $i \in I_1$ grupa eksperymentalna
- $j \in I_0$ grupa kontrolna
- $D \in \{0, 1\}$
 - $D = 0$ jednostka nie została poddana działaniu bodźca (niebodźcowana - untreated)
 - $D = 1$ jednostka została poddana działaniu bodźca (bodźcowana - treated)
- \mathbf{X} - wektor charakterystyk jednostki
- $\Pr(\mathbf{X})$ prawdopodobieństwo znalezienia się w grupie eksperymentalnej (propensity score)
- Efekt przyczynowy mierzony jest za pomocą zmiennej wynikowej Y
 - Y_0 wynik w przypadku jednostki niebodźcowanej
 - Y_1 wynik w przypadku jednostki bodźcowanej

- Efekt przyczynowy (Treatment Effect) dla jednostki o charakterystykach \mathbf{X}

$$E (Y_1 - Y_0 | D = 1, \mathbf{X})$$

- Średni efekt przyczynowy (Average Treatment Effect - ATE)

$$ATE = E (Y_1 - Y_0)$$

- Średni efekt przyczynowy dla grupy eksperymentalnej (Average Treatment Effect on the treated - ATE₁)

$$ATE_1 = E (Y_1 - Y_0 | D = 1)$$

- Obserwujemy

$$Y = DY_1 + (1 - D) Y_0$$

- Każdej jednostce przypisany jest efekt zaobserwowany i konfaktyczny

	I_0	I_1
$D = 0$	Y_0	Y_1
$D = 1$	Y_0	Y_1

- Nie jest możliwe bezpośrednio zaobserwowanie efektu przyczynowego dla grupy kontrolnej $E(Y_0 | D = 1, \mathbf{X})$ (efektu kontrfaktycznego)

- Sprawdzamy jaka jest różnica między średnią wielkością zmiennej wynikowej dla jednostek bodźcowanych i podobnych niebodźcowanych.
- Im bardziej podobna jest jednostka niebodźcowana do jednostki bodźcowanej tym większą ma wagę w dokonywanym porównaniu
- Oszacowanie efektu przyczynowego dla jednostki i (Treatment Effect)

$$Y_{1i} - \sum_{j \in I_0} W_{N_0, N_1}(i, j) Y_{0j}$$

- Oszacowanie średniego efektu przyczynowego (ATE)

$$\sum_{i \in I_1} w_{N_0, N_1}(i) \left[Y_{1i} - \sum_{j \in I_0} W_{N_0, N_1}(i, j) Y_{0j} \right]$$

- Różne metody PSM są oparte na różnym doborze funkcji wag $w_{N_0, N_1}(i)$ i $W_{N_0, N_1}(i, j)$.

- Definicja

$$\Pr(D = 1 | Y_0, Y_1, \mathbf{X}) = \Pr(D = 1 | \mathbf{X}) \quad (1)$$

- Selekcja do próby następuje w oparciu jedynie o czynniki obserwowalne
- Zakładamy, że niewystępuje samoselekcja.
- Wykluczona selekcja w oparciu o czynniki nieobserwowalne wpływające na wynik bodźcowania - tak jak w modelu Heckmana
- Inna notacja

$$(Y_0, Y_1) \perp D | \mathbf{X}$$

- Stable Unit Treatment Assumption SUTVA - wynik dla poszczególnych jednostek nie zależy od wyników pozostałych jednostek

Silna statystyczna niezależność

- Jeśli dodatkowo prawdą założenie o wspólnej dziedzinie (common support):

$$0 < \Pr(\mathbf{X}) < 1 \quad (2)$$

- Jeśli warunki (1) (1), to mówimy o silnej statystycznej niezależności.
- Warunek (2) jest warunkiem stosowania PSM.
- Jeśli $\Pr(\mathbf{X}) = 0$ lub $\Pr(\mathbf{X}) = 1$, to jednostka jest nigdy bądź zawsze bodźcowana i dobrane dla niej odpowiedników w próbie kontrolnej jest niemożliwe.
- W przypadku, gdy niespełniony jest warunek (2) musimy ograniczyć się do podpopulacji, w której jest on spełniony
- Zdefiniujmy

$$S_0 = \text{Supp}(\mathbf{X} | D = 0)$$

$$S_1 = \text{Supp}(\mathbf{X} | D = 1)$$

- Wspólna dziedzina

$$S = S_0 \cap S_1$$

Dekompozycja obciążenia oszacowania w badaniach ewaluacyjnych

- Różnica średnich wyników w grupie eksperymentalnej i kontrolnej

$$E(Y_0 | D = 1, X \in S_1) - E(Y_0 | D = 0, X \in S_0) = B_1 + B_2 + B_3$$

- Obciążenie wynikające z niepokrywających się dziedzin

$$B_1 = E[E(Y_0 | D = 1, X \in S_1 \setminus (S_0 \cap S_1)) | D = 1] \\ - E[E(Y_0 | D = 0, X \in S_0 \setminus (S_0 \cap S_1)) | D = 0]$$

- Obciążenie wynikające z odmienności rozkładów w grupie eksperymentalnej i kontrolnej

$$B_2 = E[E(Y_0 | D = 0, X \in S_0 \cap S_1) | D = 1] \\ - E[E(Y_0 | D = 0, X \in S_0 \cap S_1) | D = 0]$$

Dekompozycja obciążenia oszacowania w badaniach ewaluacyjnych c.d.

- Obciążenie wynikające z różnic rozkładów charakterystyk nieobserwowalnych w grupie eksperymentalnej i kontrolnej

$$B_3 = E[E(Y_0 | D = 1) - E(Y_0 | D = 0) | D = 1, X \in S_0 \cap S_1]$$

- Zastosowanie PSM umożliwia skorygowanie obciążenia B_2 oraz określenie wspólnej dziedziny, dla której nie występuje obciążenie B_1

- Z silnej niezależności wynika, że średni efekt kontrfaktyczny można policzyć w następujący sposób

$$\begin{aligned} E(Y_0 | D = 1) &= E[E(Y_0 | D = 1, \mathbf{X}) | D = 1] \\ &= E[E(Y_0 | D = 0, \mathbf{X}) | D = 1] \end{aligned}$$

- Załóżmy, że udało nam się uzyskać parametryczne bądź nieparametryczne oszacowania $\hat{r}_0(\mathbf{X}_i) = E(Y_0 | D = 0, \mathbf{X}_i)$ i $\hat{r}_1(\mathbf{X}_i) = E(Y_1 | D = 1, \mathbf{X}_i)$
- Oszacowanie ATE_1 możemy uzyskać jako średnią

$$\frac{1}{N_1} \sum_{i \in I_1} (\hat{r}_1(\mathbf{X}_i) - \hat{r}_0(\mathbf{X}_i))$$

- Do przeprowadzenia tego przekształcenia wystarczy nam założenie, że

$$Y_0 \perp D | \mathbf{X}$$

- Do oszacowania ATE_1 wystarczy jeszcze słabsze założenie niezależności średnich

- Silna statystyczna niezależność implikuje, że (Resenbaum, Rubin 1983)

$$(Y_0, Y_1) \perp D | \Pr(\mathbf{X})$$

- Dowód

$$\begin{aligned} E[D | Y_0, Y_1, \Pr(\mathbf{X})] &= E\{E[D | Y_0, Y_1, \mathbf{X}] | \Pr(\mathbf{X})\} \\ &= E[E[D | Y_0, Y_1, \mathbf{X}] | \Pr(\mathbf{X})] \\ &= E[\Pr(D = 1 | Y_0, Y_1, \mathbf{X}) | \Pr(\mathbf{X})] \\ &= E\{\Pr(D = 1 | \mathbf{X}) | \Pr(\mathbf{X})\} \\ &= E\{\Pr(\mathbf{X}) | \Pr(\mathbf{X})\} = \Pr(\mathbf{X}) \\ &= E[D | \Pr(\mathbf{X})] \end{aligned}$$

- Wniosek Resenbauma i Rubina oznacza, że niezależność wyniku od przynależności do grupy kontrolnej zachodzi nie tylko warunkowo względem cech ale także warunkowo względem $\Pr(\mathbf{X})$
- Zauważmy, że jeśli mamy obserwacje z grupy eksperymentalnej i kontrolnej o identycznym $\Pr(\mathbf{X})$, to ATE_1 można oszacować jako:

$$E[Y_1 | D = 1, \Pr(\mathbf{X})] - E[Y_0 | D = 0, \Pr(\mathbf{X})] = E[Y_1 - Y_0 | \Pr(\mathbf{X})]$$

- Dobierając podobne jednostki nie musimy uwzględniać podobieństwa wszystkich cech a jedynie zbliżoną wartość $\Pr(\mathbf{X})$
- Procedura PSM korzysta z tej fundamentalnej własności:

W PSM grupa kontrolna dobierana jest z puli kontrolnej (zbioru obserwacji nie objętych działaniem bodźca) na podstawie podobieństwa oszacowanych wartości propensity score $\Pr(\mathbf{X})$

- Metody parametryczne (probit, logit)
- Metody nieparametryczne
- Kluczowym problemem przy szacowaniu $Pr(\mathbf{X})$ jest zwrócenie uwagi na to, czy spełnione jest założenie o wspólnej dziedzinie
 - zakres wartości dopasowanych prawdopodobieństw powinien być zbliżony
 - nie powinny występować predyktory doskonale przewidyujące wynik
- Z tego powodu w literaturze pojawia się pogląd, że model dla $Pr(\mathbf{X})$ nie powinien być "zbyt dobry"

PSM - dobieranie obserwacji do grupy kontrolnej

- Dobieranie bez zwracania lub ze zwracaniem
- Liczba jednostek z grupy kontrolnej przypadająca na jednostkę bodźcowaną: 1 do 1, 1 do n
- Algorytm dobierania:
 - najbliższy sąsiad (nearest neighbor)
 - najbliższy sąsiad z limitem (nearest neighbor with caliper)
 - metoda z promieniem (radius matching)
 - metoda jądrowa

$$w_{ij} = \frac{K \left(\frac{\text{Pr}(X_i) - \text{Pr}(X_j)}{h} \right)}{\sum_{j \in I_0} \left(\frac{\text{Pr}(X_i) - \text{Pr}(X_j)}{h} \right)}$$

przy czym h jest szerokością okna

- Dobór algorytmu dobierania odpowiedników zależy głównie od wielkości próby

- W idealnym przypadku grupa kontrolna uzyskana na podstawie PSM powinna być duża i mieć identyczny rozkład charakterystyk obserwowalnych jak grupa eksperymentalna
- Przy doborze algorytmu doboru obserwacji powinniśmy brać pod uwagę dwa elementy:
 - obciążenie oszacowania efektu przyczynowego: tym mniejsze im podobniejsze obserwacje w grupie kontrolnej
 - wariancję oszacowania efektu przyczynowego: tym mniejsza im większa grupa kontrolna
- Do zbadania jakości łączenia można porównać średnie wartości charakterystyk w grupie eksperymentalnej i grupie kontrolnej
- Można procedurę tę sformalizować przeprowadzając testy równości średnich

- Zalety

- W przypadku stosowania PSM nie musimy przyjmować parametrycznych postaci zależności między efektem przyczynowym a charakterystykami jednostek - zależność $E(Y_1 | D = 1, \mathbf{X})$ i $E(Y_0 | D = 1, \mathbf{X})$ może mieć całkiem ogólną formę
- eliminuje najważniejsze źródła obciążenia

- Ograniczenia

- muszą być spełnione założenia silnej statystycznej niezależności
 - brak samoselekcji
 - brak selekcji w oparciu o cechy nieobserwowalne
- duże wymagania w odniesieniu do wielkości zbioru danych - aby dobrać podobne obserwacje do grupy kontrolnej musimy mieć dużą pulę kontrolną