

Ocenzurowanie i selekcja

- Metoda największej wiarygodności pozwala na oszacowanie szerszej klasy modeli niż z dyskretnymi zmiennymi zależnymi

- Metoda największej wiarygodności pozwala na oszacowanie szerszej klasy modeli niż z dyskretnymi zmiennymi zależnymi
- W szczególności pozwala na uzyskanie zgodnych estymatorów w przypadku, gdy próba empiryczna nie jest generowana przez proces losowy

- Metoda największej wiarygodności pozwala na oszacowanie szerszej klasy modeli niż z dyskretnymi zmiennymi zależnymi
- W szczególności pozwala na uzyskanie zgodnych estymatorów w przypadku, gdy próba empiryczna nie jest generowana przez proces losowy
- Próbę nazywamy **losową**, gdy prawdopodobieństwo wybrania obserwacji do próby nie zależy (warunkowo) od jej cech

- Metoda największej wiarygodności pozwala na oszacowanie szerszej klasy modeli niż z dyskretnymi zmiennymi zależnymi
- W szczególności pozwala na uzyskanie zgodnych estymatorów w przypadku, gdy próba empiryczna nie jest generowana przez proces losowy
- Próbę nazywamy **losową**, gdy prawdopodobieństwo wybrania obserwacji do próby nie zależy (warunkowo) od jej cech
- Próby, których używamy w badaniach empirycznych nie zawsze spełniają to założenie

- Niech s_i będzie zmienną decydującą o selekcji obserwacji do próby

- Niech s_i będzie zmienną decydującą o selekcji obserwacji do próby
- Przyjmujemy, że:
 - $s_i = 0$, gdy obserwacja nie należy do próby
 - $s_i = 1$, gdy obserwacja należy do próby

- Niech s_i będzie zmienną decydującą o selekcji obserwacji do próby
- Przyjmujemy, że:
 - $s_i = 0$, gdy obserwacja nie należy do próby
 - $s_i = 1$, gdy obserwacja należy do próby
- Zakładamy, że zjawisko jest opisywane przez model

$$E(y_i|X_i) = X_i\beta + \varepsilon_i \quad E(\varepsilon_i|X_i) = 0$$

- Niech s_i będzie zmienną decydującą o selekcji obserwacji do próby
- Przyjmujemy, że:
 - $s_i = 0$, gdy obserwacja nie należy do próby
 - $s_i = 1$, gdy obserwacja należy do próby
- Zakładamy, że zjawisko jest opisywane przez model

$$E(y_i|X_i) = X_i\beta + \varepsilon_i \quad E(\varepsilon_i|X_i) = 0$$

- Przez losowość próby rozumiemy

$$E(\varepsilon_i|s_i, x_i)$$

- Mechanizm selekcji może przyjmować różne formy

- Mechanizm selekcji może przyjmować różne formy
- Selekcja może dokonywać się na podstawie wartości cech obserwowanych lub nieobserwowanych

- Mechanizm selekcji może przyjmować różne formy
- Selekcja może dokonywać się na podstawie wartości cech obserwowanych lub nieobserwowanych
- Selekcja może mieć charakter cenzurowania rozkładu zmiennej objaśniającej lub objasnianej

- Mechanizm selekcji może przyjmować różne formy
- Selekcja może dokonywać się na podstawie wartości cech obserwowanych lub nieobserwowanych
- Selekcja może mieć charakter cenzurowania rozkładu zmiennej objaśniającej lub objasnianej
- Gdy występuje selekcja to

$$E(y_i|X_i, s_i) = X_i\beta + E(\varepsilon_i|s_i) \neq X_i\beta$$

- Mechanizm selekcji może przyjmować różne formy
- Selekcja może dokonywać się na podstawie wartości cech obserwowanych lub nieobserwowanych
- Selekcja może mieć charakter cenzurowania rozkładu zmiennej objaśniającej lub objasnianej
- Gdy występuje selekcja to

$$E(y_i|X_i, s_i) = X_i\beta + E(\varepsilon_i|s_i) \neq X_i\beta$$

- Zatem estymator MNK może być obciążony

- Jeżeli selekcja dokonuje się na podstawie wartości cech obserwowanych, oraz jest warunkowo niezależna od zmiennych nieobserwowanych to jeżeli zbudujemy model dla wyselekcjonowanej części próby to

$$E(y_i|X_i, s_i = 1) = E(X_i\beta|X_i, s_i = 1) + \underbrace{E(\varepsilon|X_i, s_i = 1)}_0 = X_i\beta$$

- Jeżeli selekcja dokonuje się na podstawie wartości cech obserwowanych, oraz jest warunkowo niezależna od zmiennych nieobserwowanych to jeżeli zbudujemy model dla wyselekcjonowanej części próby to

$$E(y_i|X_i, s_i = 1) = E(X_i\beta|X_i, s_i = 1) + \underbrace{E(\varepsilon|X_i, s_i = 1)}_0 = X_i\beta$$

- Jeżeli selekcja zależy od wartości zmiennych egzogenicznych lub składnika losowego to

$$E(y_i|X_i, s_i = 1) = E(X_i\beta + \varepsilon|X_i, s_i = 1) + \underbrace{E(\varepsilon|X_i, s_i = 1)}_{\neq 0}$$

- Selekcja zależna od składnika losowego jest często spotykanym typem selekcji, np w skład próby wchodzi obserwacje dla których $y^* > 0$, wówczas

- Selekcja zależna od składnika losowego jest często spotykanym typem selekcji, np w skład próby wchodzi obserwacje dla których $y^* > 0$, wówczas
- $s_i = \mathbb{I}[y_i > 0]$

$$E(y_i | X_i, s_i = 1) = E(X_i \beta | X_i, y_i > 0) = X_i \beta + E(\varepsilon_i | \varepsilon_i > X_i \beta)$$

- Selekcja zależna od składnika losowego jest często spotykanym typem selekcji, np w skład próby wchodzi obserwacje dla których $y^* > 0$, wówczas
- $s_i = \mathbb{I}[y_i > 0]$

$$E(y_i | X_i, s_i = 1) = E(X_i \beta | X_i, y_i > 0) = X_i \beta + E(\varepsilon_i | \varepsilon_i > X_i \beta)$$

- Zazwyczaj prawy składnik sumy jest różny od zera

- Selekcja zależna od składnika losowego jest często spotykanym typem selekcji, np w skład próby wchodzi obserwacje dla których $y^* > 0$, wówczas
- $s_i = \mathbb{I}[y_i > 0]$

$$E(y_i | X_i, s_i = 1) = E(X_i \beta | X_i, y_i > 0) = X_i \beta + E(\varepsilon_i | \varepsilon_i > X_i \beta)$$

- Zazwyczaj prawy składnik sumy jest różny od zera
- Szacując parametry modelu MNK pomijamy ten składnik co prowadzi do braku zgodności

- Model Tobit, zaproponowany przez Jamesa Tobina (1958) do opisu związku między nieujemną zmienną zależną y_i i zmiennymi objaśniającymi X_i

- Model Tobit, zaproponowany przez Jamesa Tobina (1958) do opisu związku między nieujemną zmienną zależną y_i i zmiennymi objaśniającymi X_i
- W modelu przyjmujemy że wartości zmiennej zależnej są ograniczone do przedziału $y \in [y_1, y_2]$, przy czym może być, że $y_1 = -\infty$ albo $y_2 = \infty$

- Model Tobit, zaproponowany przez Jamesa Tobina (1958) do opisu związku między nieujemną zmienną zależną y_i i zmiennymi objaśniającymi X_i
- W modelu przyjmujemy że wartości zmiennej zależnej są ograniczone do przedziału $y \in [y_1, y_2]$, przy czym może być, że $y_1 = -\infty$ albo $y_2 = \infty$
- Ten typ ograniczenia możliwych wartości zmiennej zależnej nazywamy **ocenzuowaniem**

- Model Tobit, zaproponowany przez Jamesa Tobina (1958) do opisu związku między nieujemną zmienną zależną y_i i zmiennymi objaśniającymi X_i
- W modelu przyjmujemy że wartości zmiennej zależnej są ograniczone do przedziału $y \in [y_1, y_2]$, przy czym może być, że $y_1 = -\infty$ albo $y_2 = \infty$
- Ten typ ograniczenia możliwych wartości zmiennej zależnej nazywamy **ocenzuowaniem**
- Występują dwa mechanizmy powstania tego typu danych
 - cenzurowanie
 - rozwiązanie brzegowe

- Model Tobit, zaproponowany przez Jamesa Tobina (1958) do opisu związku między nieujemną zmienną zależną y_i i zmiennymi objaśniającymi X_i
- W modelu przyjmujemy że wartości zmiennej zależnej są ograniczone do przedziału $y \in [y_1, y_2]$, przy czym może być, że $y_1 = -\infty$ albo $y_2 = \infty$
- Ten typ ograniczenia możliwych wartości zmiennej zależnej nazywamy **ocenzuowaniem**
- Występują dwa mechanizmy powstania tego typu danych
 - cenzurowanie
 - rozwiązanie brzegowe
- W obu przypadkach parametry szacowane są MNW, jednak inna jest ich interpretacja ekonomiczna

- O zmiennej mówimy, że jest **ocenzurowana** jeżeli znamy rzeczywistą wartość zmiennej pod warunkiem, że należy ona do przedziału $[y_1, y_2]$

- O zmiennej mówimy, że jest **ocenzurowana** jeżeli znamy rzeczywistą wartość zmiennej pod warunkiem, że należy ona do przedziału $[y_1, y_2]$
- Jeżeli zmienna przyjmuje wartość mniejszą niż y_1 obserwujemy y_1

- O zmiennej mówimy, że jest **ocenzurowana** jeżeli znamy rzeczywistą wartość zmiennej pod warunkiem, że należy ona do przedziału $[y_1, y_2]$
- Jeżeli zmienna przyjmuje wartość mniejszą niż y_1 obserwujemy y_1
- Jeżeli zmienna przyjmuje wartość większą niż y_2 obserwujemy y_2

- O zmiennej mówimy, że jest **ocenzurowana** jeżeli znamy rzeczywistą wartość zmiennej pod warunkiem, że należy ona do przedziału $[y_1, y_2]$
- Jeżeli zmienna przyjmuje wartość mniejszą niż y_1 obserwujemy y_1
- Jeżeli zmienna przyjmuje wartość większą niż y_2 obserwujemy y_2
- Obserwacje dla których zamiast rzeczywistych wartości znamy krańce przedziału nazywamy ocenzurowanymi

Przykłady

- Zmiany cen akcji na GPW w latach 90-tych były ograniczone do korytarza $\pm 10\%$. Zatem wiedząc, że nastąpiła zmiana dokładnie o 10% inwestorzy nie znali rzeczywistej wyceny

Przykłady

- Zmiany cen akcji na GPW w latach 90-tych były ograniczone do korytarza $\pm 10\%$. Zatem wiedząc, że nastąpiła zmiana dokładnie o 10% inwestorzy nie znali rzeczywistej wyceny
- Często pytając o dochody zamiast zadawać pytanie wprost pyta się o wskazanie przedziału dochodów, przy czym górny przedział jest nieograniczony (naturalną granicą dla dolnego jest 0)

- O **rozwiązaniu brzegowym** z reguły mówimy, gdy zmienna zależna przyjmuje wartości rzeczywiste (dodatnie) oraz dla znacznej liczby obserwacji obserwowana jest wartość 0 (lub inna brzegowa)

- O **rozwiązaniu brzegowym** z reguły mówimy, gdy zmienna zależna przyjmuje wartości rzeczywiste (dodatnie) oraz dla znacznej liczby obserwacji obserwowana jest wartość 0 (lub inna brzegowa)
- Występowanie wartości brzegowej jest skutkiem decyzji jednostki

- O **rozwiązaniu brzegowym** z reguły mówimy, gdy zmienna zależna przyjmuje wartości rzeczywiste (dodatnie) oraz dla znacznej liczby obserwacji obserwowana jest wartość 0 (lub inna brzegowa)
- Występowanie wartości brzegowej jest skutkiem decyzji jednostki
- Jednak optymalne rozwiązanie może znajdować się poza wartością brzegową, w takim przypadku będziemy w danych obserwować wartość brzegową, a rozwiązanie nazwiemy rozwiązaniem brzegowym

Przykłady

- Wydatki gospodarstw domowych na środki trwałe. Środki trwałe są zakupami rzadkimi, więc dla dużej liczby gospodarstw wartość zero będzie rezultatem powstrzymania się od zakupu

Przykłady

- Wydatki gospodarstw domowych na środki trwałe. Środki trwałe są zakupami rzadkimi, więc dla dużej liczby gospodarstw wartość zero będzie rezultatem powstrzymania się od zakupu
- Zakup akcji na rynku pierwotnym. Bardzo często występuje nadmierny popyt i wielkość zakupionego pakietu akcji wynika z narzuconego ograniczenia przez emitenta.

- W przypadku ocenowania lub rozwiązywania brzegowego dla części obserwacji nie znamy rzeczywistej wartości zmiennej zależnej

- W przypadku ocenowania lub rozwiązania brzegowego dla części obserwacji nie znamy rzeczywistej wartości zmiennej zależnej
- Zakładamy istnienie zmiennej ukrytej której wartości są częściowo obserwowane

$$y_i = \begin{cases} y_i^* & y_i^* > 0 \\ 0 & y_i^* \leq 0 \end{cases}$$

- W przypadku ocenowania lub rozwiązania brzegowego dla części obserwacji nie znamy rzeczywistej wartości zmiennej zależnej
- Zakładamy istnienie zmiennej ukrytej której wartości są częściowo obserwowane

$$y_i = \begin{cases} y_i^* & y_i^* > 0 \\ 0 & y_i^* \leq 0 \end{cases}$$

- Zjawisko jest opisane modelem liniowym

$$y_i = X_i\beta + \varepsilon_i \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$

- Parametry funkcji są szacowane MNW

- Parametry funkcji są szacowane MNW
- Korzystając z własności rozkładu normalnego

- Parametry funkcji są szacowane MNW
- Korzystając z własności rozkładu normalnego

$$Pr(y_i = 0|X) = Pr(y_i^* \leq 0) = Pr(\varepsilon_i < -X_i\beta) =$$

- Parametry funkcji są szacowane MNW
- Korzystając z własności rozkładu normalnego

$$\begin{aligned} Pr(y_i = 0|X) &= Pr(y_i^* \leq 0) = Pr(\varepsilon_i < -X_i\beta) = \\ &= 1 - \Phi\left(\frac{X_i\beta}{\sigma}\right) \quad \text{dla } y_i = 0 \end{aligned}$$

- Parametry funkcji są szacowane MNW
- Korzystając z własności rozkładu normalnego

$$Pr(y_i = 0|X) = Pr(y_i^* \leq 0) = Pr(\varepsilon_i < -X_i\beta) =$$

$$= 1 - \Phi\left(\frac{X_i\beta}{\sigma}\right) \quad \text{dla } y_i = 0$$

$$Pr(y_i > 0|X) = Pr(y_i|X) = \frac{1}{\sigma} \Phi\left(\frac{y - X_i\beta}{\sigma}\right) \quad \text{dla } y_i > 0$$

- Zatem funkcja wiarygodności przyjmuje postać

$$L(\theta, X) = \left[1 - \Phi\left(\frac{X_i\beta}{\sigma}\right)\right]^{\mathbb{I}(y_i=0)} \left[\frac{1}{\sigma}\Phi\left(\frac{y - X_i\beta}{\sigma}\right)\right]^{\mathbb{I}(y_i \geq 0)}$$

- Zatem funkcja wiarygodności przyjmuje postać

$$L(\theta, X) = \left[1 - \Phi\left(\frac{X_i\beta}{\sigma}\right)\right]^{\mathbb{I}(y_i=0)} \left[\frac{1}{\sigma}\Phi\left(\frac{y - X_i\beta}{\sigma}\right)\right]^{\mathbb{I}(y_i\geq 0)}$$

- Estymator będzie zgodny przy spełnionym założeniu o rozkładzie normalnym reszt

- Zatem funkcja wiarygodności przyjmuje postać

$$L(\theta, X) = \left[1 - \Phi\left(\frac{X_i\beta}{\sigma}\right)\right]^{\mathbb{I}(y_i=0)} \left[\frac{1}{\sigma}\Phi\left(\frac{y - X_i\beta}{\sigma}\right)\right]^{\mathbb{I}(y_i \geq 0)}$$

- Estymator będzie zgodny przy spełnionym założeniu o rozkładzie normalnym reszt
- Zatem zmienna zależna powinna w nieocenzurowanej części próby mieć rozkład zbliżony do uciętego normalnego

- W przypadku oceniania parametry mają standardową interpretację

- W przypadku oceniania parametry mają standardową interpretację
- W przypadku rozwiązania brzegowego zmienna ukryta nie posiada interpretacji ekonomicznej

- W przypadku oceniania parametry mają standardową interpretację
- W przypadku rozwiązania brzegowego zmienna ukryta nie posiada interpretacji ekonomicznej
- Jednak dużo ciekawszych obserwacji dostarczają efekty częściowe

- W przypadku oceniania parametry mają standardową interpretację
- W przypadku rozwiązania brzegowego zmienna ukryta nie posiada interpretacji ekonomicznej
- Jednak dużo ciekawszych obserwacji dostarczają efekty częściowe
- Można obliczyć trzy typy efektów częściowych

- W przypadku oceniania parametry mają standardową interpretację
- W przypadku rozwiązania brzegowego zmienna ukryta nie posiada interpretacji ekonomicznej
- Jednak dużo ciekawszych obserwacji dostarczają efekty częściowe
- Można obliczyć trzy typy efektów częściowych
 - Wpływ zmiennej objaśniającej na prawdopodobieństwo nieoceniania zmiennej zależnej

- W przypadku oceniania parametry mają standardową interpretację
- W przypadku rozwiązania brzegowego zmienna ukryta nie posiada interpretacji ekonomicznej
- Jednak dużo ciekawszych obserwacji dostarczają efekty częściowe
- Można obliczyć trzy typy efektów częściowych
 - Wpływ zmiennej objaśniającej na prawdopodobieństwo nieoceniania zmiennej zależnej
 - Wpływ zmiennej objaśniającej na wartość oczekiwaną zmiennej zależnej

- W przypadku oceniania parametry mają standardową interpretację
- W przypadku rozwiązania brzegowego zmienna ukryta nie posiada interpretacji ekonomicznej
- Jednak dużo ciekawszych obserwacji dostarczają efekty częściowe
- Można obliczyć trzy typy efektów częściowych
 - Wpływ zmiennej objaśniającej na prawdopodobieństwo nieoceniania zmiennej zależnej
 - Wpływ zmiennej objaśniającej na wartość oczekiwaną zmiennej zależnej
 - Wpływ zmiennej objaśniającej na bezwarunkową wartość oczekiwaną zmiennej zależnej

- Można pokazać, że

$$Pr(y_i^* > 0 | X_i) = 1 - \Phi\left(-\frac{X_i\beta}{\sigma}\right) = \Phi\left(\frac{X_i\beta}{\sigma}\right)$$

- Można pokazać, że

$$Pr(y_i^* > 0 | X_i) = 1 - \Phi\left(-\frac{X_i\beta}{\sigma}\right) = \Phi\left(\frac{X_i\beta}{\sigma}\right)$$

- Zatem

$$E(y_i | X_i) = \left[X_i\beta + \sigma\lambda\left(\frac{X_i\beta}{\sigma}\right) \right] \Phi\left(\frac{X_i\beta}{\sigma}\right)$$

- Wpływ zmiennej objaśniającej na prawdopodobieństwo nieocenzurowania zmiennej zależnej

$$\frac{\partial Pr(y_i > 0 | X_i)}{\partial x_k} = 1 - \phi\left(\frac{X_i \beta}{\sigma}\right) \frac{\beta_k}{\sigma}$$

- Wpływ zmiennej objaśniającej na prawdopodobieństwo nieocenzurowania zmiennej zależnej

$$\frac{\partial Pr(y_i > 0 | X_i)}{\partial x_k} = 1 - \phi\left(\frac{X_i \beta}{\sigma}\right) \frac{\beta_k}{\sigma}$$

- Pokazuje wpływ jednostkowej zmiany zmiennej objaśniającej na prawdopodobieństwo nieocenzurowania

- Wpływ zmiennej objaśniającej na wartość oczekiwaną zmiennej zależnej

$$\frac{\partial E(y_i | X_i, y_i > 0)}{\partial x_k} = \left\{ 1 - \lambda\left(\frac{X_i\beta}{\sigma}\right) \left[\frac{X_i\beta}{\sigma} + \lambda\left(\frac{X_i\beta}{\sigma}\right) \right] \right\} \beta_k$$

- Wpływ zmiennej objaśniającej na wartość oczekiwaną zmiennej zależnej

$$\frac{\partial E(y_i | X_i, y_i > 0)}{\partial x_k} = \left\{ 1 - \lambda\left(\frac{X_i\beta}{\sigma}\right) \left[\frac{X_i\beta}{\sigma} + \lambda\left(\frac{X_i\beta}{\sigma}\right) \right] \right\} \beta_k$$

- Pokazuje wpływ jednostkowej zmiany zmiennej objaśniającej na wielkość wartości oczekiwanej

- Wpływ zmiennej objaśniającej na bezwarunkową wartość oczekiwaną zmiennej zależnej

$$\frac{\partial E(y_i|X_i)}{\partial x_k} = \Phi\left(\frac{X_i\beta}{\sigma}\right)\beta_k$$

- Wpływ zmiennej objaśniającej na bezwarunkową wartość oczekiwaną zmiennej zależnej

$$\frac{\partial E(y_i|X_i)}{\partial x_k} = \Phi\left(\frac{X_i\beta}{\sigma}\right)\beta_k$$

- Pokazuje wpływ jednostkowej zmiany zmiennej objaśniającej na wartość oczekiwaną nie uwzględniająca selekcji

- Różnice między oszacowaniami MNK a oszacowaniami MNW dla modelu Tobit zależą od prawdopodobieństwa ocenzurowania obserwacji

- Różnice między oszacowaniami MNK a oszacowaniami MNW dla modelu Tobit zależą od prawdopodobieństwa ocenzurowania obserwacji
- Jeżeli to prawdopodobieństwo jest bliskie zero, to oszacowania praktycznie nie różnią się

- Różnice między oszacowaniami MNK a oszacowaniami MNW dla modelu Tobit zależą od prawdopodobieństwa ocenzurowania obserwacji
- Jeżeli to prawdopodobieństwo jest bliskie zero, to oszacowania praktycznie nie różnią się
- Literatura sugeruje, by stosować model Tobit, gdy ocenzurowaniu podlega 25%-75% obserwacji

- Różnice między oszacowaniami MNK a oszacowaniami MNW dla modelu Tobit zależą od prawdopodobieństwa ocenzurowania obserwacji
- Jeżeli to prawdopodobieństwo jest bliskie zero, to oszacowania praktycznie nie różnią się
- Literatura sugeruje, by stosować model Tobit, gdy ocenzurowaniu podlega 25%-75% obserwacji
- Statystyka pseudo- R^2 informuje o ile poprawiony został model w stosunku do regresji

- Różnice między oszacowaniami MNK a oszacowaniami MNW dla modelu Tobit zależą od prawdopodobieństwa oceniania obserwacji
- Jeżeli to prawdopodobieństwo jest bliskie zero, to oszacowania praktycznie nie różnią się
- Literatura sugeruje, by stosować model Tobit, gdy ocenianiu podlega 25%-75% obserwacji
- Statystyka pseudo- R^2 informuje o ile poprawiony został model w stosunku do regresji
- Można również obliczyć pseudo- R^2 McKelveya i Zavoiny

Tobit estimates

Number of obs = 4491
LR chi2(7) = 820.66
Prob > chi2 = 0.0000
Pseudo R2 = 0.0115

Log likelihood = -35389.266

placa	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
plec	-524.0464	24.88645	-21.06	0.000	-572.8361	-475.2566
wiek	6.038907	1.972661	3.06	0.002	2.171519	9.906296
_Iwyksz_2	-512.9047	34.33607	-14.94	0.000	-580.2203	-445.589
_Iwyksz_3	-542.0837	51.97027	-10.43	0.000	-643.9711	-440.1963
_Iwyksz_4	-738.1943	32.42502	-22.77	0.000	-801.7633	-674.6253
_Iwyksz_5	-925.8875	53.63196	-17.26	0.000	-1031.033	-820.7424
wies	-77.34221	25.01756	-3.09	0.002	-126.389	-28.29545
_cons	2572.548	88.21266	29.16	0.000	2399.607	2745.488
_se	800.0181	8.676744	(Ancillary parameter)			

Obs. summary: 150 left-censored observations at placa<=0
4341 uncensored observations

Variable	reg	tobit
plec	-525.13535***	-524.04635***
wiek	5.9430255**	6.0389071**
_Iwyksz_2	-513.24299***	-512.90466***
_Iwyksz_3	-543.93432***	-542.0837***
_Iwyksz_4	-742.76735***	-738.19428***
_Iwyksz_5	-926.10454***	-925.88752***
wies	-83.270289***	-77.342209**
_cons	2592.3574***	2572.5476***

legend: * p<0.05; ** p<0.01; *** p<0.001

Marginal Effects: Latent Variable

variable	dF/dx	Std. Err.	z	P> z	X_at	[	95% C.I.	]
plec*	-524.0464	24.88645	-21.06	0.000	0 --> 1	-572.823	-475.27	
wiek	6.038907	1.972661	3.06	0.002	40.3206	2.17256	9.90525	
Iwyksz_2*	-512.9047	34.33607	-14.94	0.000	0 --> 1	-580.202	-445.607	
Iwyksz_3*	-542.0837	51.97027	-10.43	0.000	0 --> 1	-643.944	-440.224	
Iwyksz_4*	-738.1943	32.42502	-22.77	0.000	0 --> 1	-801.746	-674.642	
Iwyksz_5*	-925.8875	53.63196	-17.26	0.000	0 --> 1	-1031	-820.771	
wies*	-77.34221	25.01756	-3.09	0.002	0 --> 1	-126.376	-28.3087	
_cons	2572.548	88.21266	29.16	0.000	1	2399.65	2745.44	

Marginal Effects: Unconditional Expected Value

variable	dF/dx	Std. Err.	z	P> z	X_at	[	95% C.I.	]
plec*	-508.1908	24.13349	-21.06	0.000	0 --> 1	-555.492	-460.89	
wiek	5.856194	1.912976	3.06	0.002	40.3206	2.10683	9.60556	
Iwyksz_2*	-489.3018	33.2972	-14.69	0.000	0 --> 1	-554.563	-424.04	
Iwyksz_3*	-509.5186	50.39787	-10.11	0.000	0 --> 1	-608.297	-410.741	
Iwyksz_4*	-705.0421	31.44397	-22.42	0.000	0 --> 1	-766.671	-643.413	
Iwyksz_5*	-836.458	52.00928	-16.08	0.000	0 --> 1	-938.394	-734.522	
wies*	-74.94205	24.26063	-3.09	0.002	0 --> 1	-122.492	-27.3921	
_cons	2494.713	85.5437	29.16	0.000	1	2327.05	2662.38	

Marginal Effects: Conditional on being Uncensored

variable	dF/dx	Std. Err.	z	P> z	X_at	[	95% C.I.	]
plec*	-451.9238	21.46142	-21.06	0.000	0 --> 1	-493.987	-409.86	
wiek	5.207795	1.701171	3.06	0.002	40.3206	1.87356	8.54203	
Iwyksz_2*	-422.329	29.61053	-14.26	0.000	0 --> 1	-480.365	-364.293	
Iwyksz_3*	-429.176	44.8178	-9.58	0.000	0 --> 1	-517.017	-341.335	
Iwyksz_4*	-612.7882	27.96248	-21.91	0.000	0 --> 1	-667.594	-557.983	
Iwyksz_5*	-678.6117	46.25079	-14.67	0.000	0 --> 1	-769.262	-587.962	
wies*	-66.5236	21.57449	-3.08	0.002	0 --> 1	-108.809	-24.2384	
_cons	2218.497	76.07227	29.16	0.000	1	2069.4	2367.6	

Marginal Effects: Probability Uncensored

variable	dF/dx	Std. Err.	z	P> z	X_at	[	95% C.I.	]
plec*	-.0448854	.0021316	-21.06	0.000	0 --> 1	-.049063	-.040708	
wiek	.0005172	.000169	3.06	0.002	40.3206	.000186	.000848	
Iwyksz_2*	-.0608583	.0029409	-20.69	0.000	0 --> 1	-.066622	-.055094	
Iwyksz_3*	-.0793157	.0044513	-17.82	0.000	0 --> 1	-.08804	-.070591	
Iwyksz_4*	-.0844902	.0027773	-30.42	0.000	0 --> 1	-.089934	-.079047	
Iwyksz_5*	-.1880455	.0045937	-40.94	0.000	0 --> 1	-.197049	-.179042	
wies*	-.0067624	.0021428	-3.16	0.002	0 --> 1	-.010962	-.002563	
_cons	.2203427	.0075556	29.16	0.000	1	.205534	.235151	

(*) dF/dx is for discrete change of dummy variable from 0 to 1

- Zakładamy, że selekcja jest efektem decyzji badanych jednostek

- Zakładamy, że selekcja jest efektem decyzji badanych jednostek
- Proces decyzyjny jest modelowany na podstawie egzogenicznych cech jednostek

- Zakładamy, że selekcja jest efektem decyzji badanych jednostek
- Proces decyzyjny jest modelowany na podstawie egzogenicznych cech jednostek
- Model składa się z dwóch równań

- Zakładamy, że selekcja jest efektem decyzji badanych jednostek
- Proces decyzyjny jest modelowany na podstawie egzogenicznych cech jednostek
- Model składa się z dwóch równań
 - równania opisującego mechanizm selekcji

- Zakładamy, że selekcja jest efektem decyzji badanych jednostek
- Proces decyzyjny jest modelowany na podstawie egzogenicznych cech jednostek
- Model składa się z dwóch równań
 - równania opisującego mechanizm selekcji
 - równania opisującego zjawisko

- Zakładamy, że celem jest oszacowanie parametrów równania płacy

- Zakładamy, że celem jest oszacowanie parametrów równania płacy
- Płacę obserwujemy wyłącznie dla osób pracujących

$$\ln w^0 = X_i\beta + \varepsilon_i$$

$$w^0 > w_r$$

- Zakładamy, że celem jest oszacowanie parametrów równania płacy
- Płacę obserwujemy wyłącznie dla osób pracujących

$$\ln w^0 = X_i\beta + \varepsilon_i$$

$$w^0 > w_r$$

- Minimalna akceptowalna płaca w_r nie jest bezpośrednio obserwowana

- Zakładamy, że celem jest oszacowanie parametrów równania płacy
- Płacę obserwujemy wyłącznie dla osób pracujących

$$\ln w^0 = X_i\beta + \varepsilon_i$$

$$w^0 > w_r$$

- Minimalna akceptowalna płaca w_r nie jest bezpośrednio obserwowana
- Wiadomo jedynie czy respondent pracuje czy nie

- Zakładamy, że płaca progowa nie zależy od cech respondenta

- Zakładamy, że płaca progowa nie zależy od cech respondenta
- Oraz, że prawdopodobieństwo pojęcia pracy jest efektem jego decyzji

- Zakładamy, że płaca progowa nie zależy od cech respondenta
- Oraz, że prawdopodobieństwo pojęcia pracy jest efektem jego decyzji
- Równanie selekcji

$$\mathbb{I}(w^0 > w_r) = Z_i\gamma + u$$

- Podstawowymi różnicami między modelem Tobit a modelem selekcji Heckmana są

- Podstawowymi różnicami między modelem Tobit a modelem selekcji Heckmana są
 - równanie opisujące selekcję

- Podstawowymi różnicami między modelem Tobit a modelem selekcji Heckmana są
 - równanie opisujące selekcję
 - brak "wspólnego" miejsca oceniania zmiennej zależnej

- Podstawowymi różnicami między modelem Tobit a modelem selekcji Heckmana są
 - równanie opisujące selekcję
 - brak "wspólnego" miejsca oceniania zmiennej zależnej
- Jeżeli $Z = X$ to model redukuje się do modelu Tobitowego

- Podstawowymi różnicami między modelem Tobit a modelem selekcji Heckmana są
 - równanie opisujące selekcję
 - brak "wspólnego" miejsca oceniania zmiennej zależnej
- Jeżeli $Z = X$ to model redukuje się do modelu Tobitowego
- Estymacja parametrów odbywa się z wykorzystaniem MNW lub dwustopniowej MNK

- Podstawowymi różnicami między modelem Tobit a modelem selekcji Heckmana są
 - równanie opisujące selekcję
 - brak "wspólnego" miejsca oceniania zmiennej zależnej
- Jeżeli $Z = X$ to model redukuje się do modelu Tobitowego
- Estymacja parametrów odbywa się z wykorzystaniem MNW lub dwustopniowej MNK
- Dużo częściej stosuje się metody dwustopniowej z uwagi na jej odporność

Heckman selection model
(regression model with sample selection)

Log likelihood = -36666.7

Number of obs	=	7208
Censored obs	=	3195
Uncensored obs	=	4013

Wald chi2(7)	=	1207.67
Prob > chi2	=	0.0000

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
placa						
plec	-780.1829	30.01417	-25.99	0.000	-839.0096	-721.3563
wiek	4.116212	2.357133	1.75	0.081	-.5036833	8.736108
_Iwyksz_2	-512.6602	43.35801	-11.82	0.000	-597.6403	-427.68
_Iwyksz_3	-648.883	62.88358	-10.32	0.000	-772.1325	-525.6334
_Iwyksz_4	-865.6179	40.71703	-21.26	0.000	-945.4218	-785.814
_Iwyksz_5	-1364.136	60.44625	-22.57	0.000	-1482.609	-1245.664
wies	-98.77527	30.08302	-3.28	0.001	-157.7369	-39.81362
_cons	2502.327	106.7599	23.44	0.000	2293.082	2711.573

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
praca						
plec	-.6302567	.0302559	-20.83	0.000	-.6895572	-.5709562
wiek	-.0003733	.0023445	-0.16	0.874	-.0049685	.0042219
_Iwyksz_2	-.2989861	.0456145	-6.55	0.000	-.3883889	-.2095834
_Iwyksz_3	-.4779271	.0632869	-7.55	0.000	-.6019672	-.353887
_Iwyksz_4	-.5904052	.0424826	-13.90	0.000	-.6736696	-.5071408
_Iwyksz_5	-1.068106	.0576135	-18.54	0.000	-1.181026	-.9551852
wies	-.1284711	.0301009	-4.27	0.000	-.1874679	-.0694744
_cons	1.625344	.1106395	14.69	0.000	1.408495	1.842193

/athrho		1.706701	.0354152	48.19	0.000	1.637289	1.776114
/lnsigma		6.961857	.0143343	485.68	0.000	6.933762	6.989952
rho		.9362416	.0043721			.9270926	.9442756
sigma		1055.592	15.13114			1026.348	1085.669
lambda		988.2892	17.32057			954.3415	1022.237
LR test of indep. eqns. (rho = 0): chi2(1) = 838.89 Prob > chi2 = 0.0000							