

Binarne zmienne zależne

- Zmienna zależna nie jest ciągła ale przyjmuje zero lub jeden
- **Przykład:** szukanie determinant bezrobocia (próba przekrojowa)
 - zmienna objaśniana: zerojedynekowa (pracujący, bezrobotny)
 - szukamy związku między charakterystykami ekonomiczno-społecznymi a byciem bezrobotnym
- W modelach dla zmiennych binarnych staramy się wyjaśnić prawdopodobieństwa stanów za pomocą zmiennych niezależnych
- Prawdopodobieństwo pojedynczego zdarzenia dane jest rozkładem

dwumianowym

$$\Pr(y_i | \mathbf{x}_i) = \begin{cases} 1 - p(\mathbf{x}_i) & \text{dla } y_i = 0 \\ p(\mathbf{x}_i) & \text{dla } y_i = 1 \end{cases}$$

gdzie $p(\mathbf{x}_i) = F(\mathbf{x}_i\boldsymbol{\beta})$ i $F(\cdot)$ jest zazwyczaj dystrybuantą jakiegoś rozkładu prawdopodobieństwa.

- Estymator parametru $\boldsymbol{\beta}$ liczymy za pomocą *MNW*.

Interpretacja ekonomiczna

Podejście indeksowe

- y^* jest użytecznością lub zyskiem netto
- y^* jest nieobserwowalne
- y^* jest losowe

$$y^* = \mathbf{x}\boldsymbol{\beta} + \varepsilon$$

gdzie ε ma symetryczną dystrybuantę z $E(\varepsilon) = 0$ i $\text{Var}(\varepsilon) = 1$

- Parametry modelu szacujemy na podstawie obserwowalnych wyborów y , na które zdeterminowane są nieobserwowalnym y^* .

- Wybór $y = 1$ jest podejmowany jeśli przyrost związanej z nim użyteczności (zysku) jest dodatni

$$\begin{aligned} y &= 0 & \text{dla} & \quad y^* \leq 0 \\ y &= 1 & \text{dla} & \quad y^* > 0 \end{aligned}$$

- Prawdopodobieństwo, że $y = 1$ jest równe

$$\begin{aligned} \Pr(y = 1 | \mathbf{x}) &= \Pr(y^* > 0 | \mathbf{x}) = \Pr\{\mathbf{x}\boldsymbol{\beta} + \varepsilon > 0\} \\ &= \Pr\{\varepsilon > -\mathbf{x}\boldsymbol{\beta}\} \end{aligned}$$

- Skoro dystrybuanta ε jest symetryczna, to

$$\Pr(y = 1 | \mathbf{x}) = \Pr\{\varepsilon < \mathbf{x}\boldsymbol{\beta}\} = F(\mathbf{x}\boldsymbol{\beta})$$

gdzie $F(\cdot)$ jest dystrybuantą ε

- W tym podejściu, wybór zależy jedynie od charakterystyk podmiotu i alternatywy wybranej

Losowa użyteczność

- Załóżmy, że y_0^* i y_1^* są użytecznościami z działań 0 i 1.
- y_0^* i y_1^* są nieobserwowalne i dane równaniami

$$y_0^* = \mathbf{x}_0\boldsymbol{\beta} + \varepsilon_0$$

$$y_1^* = \mathbf{x}_1\boldsymbol{\gamma} + \varepsilon_1$$

- Załóżmy, że $\varepsilon_0 - \varepsilon_1$ mają symetryczną dystrybuantę

- Obserwujemy y takie że

$$\begin{aligned} y = 0 & \text{ jeżeli } y_0^* > y_1^* \\ y = 1 & \text{ jeżeli } y_0^* \leq y_1^* \end{aligned}$$

- Podmiot podejmuje działanie 0 jeśli y_0^* jest lepsze niż y_1^* i 1 jeśli y_1^* jest lepsze niż y_0^* .
- Prawdopodobieństwo zaobserwowania 1 jest równe:

$$\begin{aligned} \Pr(y = 1 | \mathbf{x}) &= \Pr\{y_0^* \leq y_1^* | \mathbf{x}\} = \Pr\{\mathbf{x}_0\boldsymbol{\beta} + \varepsilon_0 \leq \mathbf{x}_1\boldsymbol{\gamma} + \varepsilon_1\} \\ &= \Pr\{\varepsilon_1 - \varepsilon_0 \geq \mathbf{x}_0\boldsymbol{\beta} - \mathbf{x}_1\boldsymbol{\gamma}\} = F(\mathbf{x}_1\boldsymbol{\gamma} - \mathbf{x}_0\boldsymbol{\beta}) \end{aligned}$$

- W modelu losowej użyteczności wybór zależy nie tylko od charakterystyk podmiotu, użyteczności alternatywy wybranej, ale też od użyteczności alternatywy niewybranej.

Interpretacja współczynników

- Wartość oczekiwana zmiennej zależnej w modelu dla zmiennej binarnej jest równa:

$$E(y_i | \mathbf{x}_i) = 0 [1 - F(\mathbf{x}_i \boldsymbol{\beta})] + 1 F(\mathbf{x}_i \boldsymbol{\beta}) = F(\mathbf{x}_i \boldsymbol{\beta}) = p(\mathbf{x}_i \boldsymbol{\beta})$$

- Ponieważ przyjęta jest konwencja, że 1 oznacza sukces a 0 porażkę więc, wartość oczekiwana zmiennej zależnej w modelu dla zmiennej binarnej równa jest prawdopodobieństwu sukcesu.
- Efekt cząstkowy jest równy:

$$\frac{\partial E(y | \mathbf{x})}{\partial \mathbf{x}} = \frac{\partial p(\mathbf{x}_i \boldsymbol{\beta})}{\partial \mathbf{x}} = f(\mathbf{x} \boldsymbol{\beta}) \boldsymbol{\beta}$$

- Efekt cząstkowy w tym przypadku interpretujemy jako wpływ jednostkowej zmiany zmiennej niezależnej na prawdopodobieństwo sukcesu.
- Ze wzoru widać, że wielkość efektu cząstkowego zależy od tego w jakim punkcie jest on liczony
- Zazwyczaj liczymy go dla średnich wartości zmiennych egzogenicznych.
- Dla zerojedynkowych zmiennych objaśniających efekt krańcowy definiuje się jako $\Delta F(\bar{x}\beta) = F(\bar{x}_1\beta) - F(\bar{x}_0\beta)$ - a więc różnicę między prawdopodobieństwem sukcesu dla zmiennej zerojedynkowej równej zero i równej 1 przy wszystkich pozostałych zmiennych ustalonych na poziomie średnich.
- Ponieważ funkcja gęstości $f(x_i\beta)$ jest zawsze dodatnia więc znak efektu cząstkowego jest równy znakowi współczynnika przy zmiennej. Wynika z

tego, że jakkolwiek same współczynniki nie są zazwyczaj interpretowalne to można interpretować ich znaki.

- Można jednak interpretować proporcje między współczynnikami ponieważ są one równe proporcjom między efektami krańcowymi

$$\frac{\partial E(y|\mathbf{x})}{\partial x_j} / \frac{\partial E(y|\mathbf{x})}{\partial x_k} = \frac{\beta_j}{\beta_k}$$

Miary dopasowania

- Często stosowaną miarą dopasowania jest

$$pseudo-R^2 = 1 - \frac{\ell(\tilde{\beta})}{\ell(\tilde{\beta}_R)}$$

gdzie $\tilde{\beta}_R$ zawiera jedynie stałą

- $pseudo-R^2$ spełnia

$$0 \leq pseudo-R^2 \leq 1$$

- $pseudo-R^2$ nie można jednak w pełni ściśle interpretować jako procent zmienności wyjaśnionej przez model.

- Innym sposobem mierzenia jakości dopasowania jest analiza tablicy częstości:

Prognozowane	Zaobserwowane			
		0	1	Razem
	0	n_{00}	n_{01}	$n_{00} + n_{01}$
	1	n_{10}	n_{11}	$n_{10} + n_{11}$
Razem	$n_{00} + n_{10}$	$n_{01} + n_{11}$		

- Arbitralnie zakładamy, że model przewiduje $y_i = 1$ jeśli $\hat{p}_i = \mathbf{x}_i \mathbf{b} > 0.5$

Liniowy model prawdopodobieństwa (*LPM*)

- W liniowym modelu prawdopodobieństwa *LPM* (**L**inear **P**robability **M**odel) zakładamy, że dystrybuanta rozkładu ma postać funkcji liniowej:

$$p(x_i) = F(x_i\beta) = x_i\beta$$

- W tym przypadku estymacja parametrów β sprowadza się do szacowania *MNK* równania

$$y_i = x_i \beta + \varepsilon_i$$

- Podejście to mimo swojej prostoty związane jest z dwoma poważnymi problemami:

1. Błędy losowe w równaniu regresji będą heteroskedastyczne. Zmienna ma rozkład dwumianowy więc:

$$E(y_i) = F(x_i\beta) = x_i\beta$$

$$E(y_i^2) = 0^2(1 - x_i\beta) + 1^2x_i\beta = x_i\beta$$

$$\begin{aligned} \text{Var}(y_i) &= E(x_i^2) - E(x_i)^2 = x_i\beta - (x_i\beta)^2 \\ &= x_i\beta(1 - x_i\beta) \end{aligned}$$

Wariancja y_i zależy od x_i .

2. Nie ma gwarancji, że $\hat{y}_i = x_i \mathbf{b} \in [0, 1]$. Ponieważ \hat{y}_i interpretujemy jako prawdopodobieństwa stanów - ujemne lub większe od 1 wartości dopasowane będą nieinterpretowalne

- Mimo tych wad liniowy model prawdopodobieństwa jest dość często

używany w praktycznych zastosowaniach ze względu na łatwość estymacji.

- Efekty cząstkowe w tym modelu równe są po prostu β
- Wpływu heteroskedastyczności na wyniki wnioskowania można wyeliminować stosując odporną macierz wariancji White'a
- Heteroskedastyczność można też wyeliminować za pomocą *UMNK*:
 - estymujemy *LPM* za pomocą *MNK*
 - liczymy wariancje $\hat{\sigma}_i^2 = \mathbf{x}_i \mathbf{b} [1 - \mathbf{x}_i \mathbf{b}] = \hat{y}_i (1 - \hat{y}_i)$ (wzór ten ma sens jedynie dla $\hat{y}_i \in [0, 1]$)
 - liczymy regresję $y_i / \hat{\sigma}_i$ na $x_{1i} / \hat{\sigma}_i, \dots, x_{Ki} / \hat{\sigma}_i$

Przykład Zależność aktywności zawodowej od wieku i wykształcenia:
 dane BAEL - pytanie: czy w ostatnim tygodniu wykonywał Pan(i) jakąkolwiek pracę?

Source	SS	df	MS			
Model	1827.14253	9	203.015837	Number of obs =	47860	
Residual	9776.79083	47850	.204321648	F(9, 47850) =	993.61	
Total	11603.9334	47859	.242460841	Prob > F =	0.0000	
				R-squared =	0.1575	
				Adj R-squared =	0.1573	
				Root MSE =	.45202	

_Iworks_1	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
wiek	-.0036288	.0001188	-30.55	0.000	-.0038616	-.0033961
_Iwyksz_2	-.1155233	.0141975	-8.14	0.000	-.1433507	-.087696
_Iwyksz_3	-.1575525	.0082029	-19.21	0.000	-.1736303	-.1414747
_Iwyksz_4	-.3616109	.0098378	-36.76	0.000	-.380893	-.3423287
_Iwyksz_5	-.196475	.0078076	-25.16	0.000	-.2117779	-.181172
_Iwyksz_60	-.7496461	.0163531	-45.84	0.000	-.7816984	-.7175937
_Iwyksz_61	-.4814629	.0077523	-62.11	0.000	-.4966576	-.4662683
_Iwyksz_70	-.5166902	.0162939	-31.71	0.000	-.5486266	-.4847539

_Iwyksz_71		-.594044	.0302346	-19.65	0.000	-.6533043	-.5347837
_cons		.8569807	.0084361	101.59	0.000	.8404459	.8735155

- Wyniki testu na heteroskedastyczność:

Breusch-Pagan / Cook-Weisberg test for heteroskedasticity

Ho: Constant variance

Variables: fitted values of _Iworks_1

chi2(1) = 961.62

Prob > chi2 = 0.0000

- Niektóre wartości przewidywane:

```

+-----+
|       yhat |
+-----+
1. | -.1974881 |
2. | -.1793439 |
3. | -.1720862 |

```


4. | -.1466843 |

5. | -.1398648 |

- Jednak z 47860 obserwacji tylko 144 $\notin (0, 1)$

Probit

- Dystrybuanta $F(\mathbf{x}_i\boldsymbol{\beta}) = \Phi(\mathbf{x}_i\boldsymbol{\beta})$, z rozkładu normalnego.
- Funkcja prawdopodobieństwa zajścia pojedynczego zdarzenia:

$$\begin{aligned}\Pr(y_i | \mathbf{x}_i) &= \begin{cases} 1 - \Phi(\mathbf{x}_i\boldsymbol{\beta}) & \text{dla } y_i = 0 \\ \Phi(\mathbf{x}_i\boldsymbol{\beta}) & \text{dla } y_i = 1 \end{cases} \\ &= [1 - \Phi(\mathbf{x}_i\boldsymbol{\beta})]^{1-y_i} \Phi(\mathbf{x}_i\boldsymbol{\beta})^{y_i}\end{aligned}$$

- Funkcja wiarygodności ma postać

$$L(\mathbf{y}, \mathbf{x}, \boldsymbol{\beta}) = \prod_{i=1}^n (1 - \Phi(\mathbf{x}_i\boldsymbol{\beta}))^{1-y_i} \Phi(\mathbf{x}_i\boldsymbol{\beta})^{y_i}$$

- Logarytm funkcji wiarygodności będzie miał postać

$$\ell(\mathbf{y}, \mathbf{x}, \boldsymbol{\beta}) = \sum_{i=1}^n [(1 - y_i) \ln(1 - \Phi(\mathbf{x}_i \boldsymbol{\beta})) + y_i \ln \Phi(\mathbf{x}_i \boldsymbol{\beta})]$$

- Często podaje się jedynie $\ell_i(\boldsymbol{\beta})$

$$\ell_i(\boldsymbol{\beta}) = (1 - y_i) \ln(1 - \Phi(\mathbf{x}_i \boldsymbol{\beta})) + y_i \ln \Phi(\mathbf{x}_i \boldsymbol{\beta}) .$$

- Efekt cząstkowy

$$\frac{\partial E(y | \mathbf{x})}{\partial \mathbf{x}} = \phi(\mathbf{x} \boldsymbol{\beta}) \boldsymbol{\beta}$$

Przykład Zależność aktywności zawodowej od wieku i wykształcenia: kontynuacja

- Współczynniki:

```
Probit estimates                                Number of obs   =      47860
                                                LR chi2(9)      =      8274.24
                                                Prob > chi2     =      0.0000
Log likelihood = -28311.095                    Pseudo R2      =      0.1275
```

<u>_Iworks_1</u>	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
wiek	-.0113366	.0003666	-30.93	0.000	-.012055	-.0106181
_Iwyksz_2	-.3254287	.0404874	-8.04	0.000	-.4047825	-.2460749
_Iwyksz_3	-.433603	.023857	-18.18	0.000	-.480362	-.3868441
_Iwyksz_4	-.9675114	.0286116	-33.82	0.000	-1.023589	-.9114338
_Iwyksz_5	-.5330219	.0227775	-23.40	0.000	-.5776649	-.4883789
_Iwyksz_60	-2.513776	.0730264	-34.42	0.000	-2.656905	-2.370647
_Iwyksz_61	-1.343109	.0233078	-57.62	0.000	-1.388792	-1.297427
_Iwyksz_70	-1.678283	.0650819	-25.79	0.000	-1.805842	-1.550725
_Iwyksz_71	-2.321871	.1804895	-12.86	0.000	-2.675624	-1.968118

_cons		1.027194	.0256271	40.08	0.000	.9769656	1.077422
-------	--	----------	----------	-------	-------	----------	----------

- Efekty krańcowe:

Probit estimates

Number of obs = 47860

LR chi2(9) = 8274.24

Prob > chi2 = 0.0000

Log likelihood = -28311.095

Pseudo R2 = 0.1275

_Iwork~1		dF/dx	Std. Err.	z	P> z	x-bar	[95% C.I.]
wiek		-.0043578	.0001406	-30.93	0.000	43.9481	-	.004633	-.004082
_Iwyks~2*		-.1181235	.0136421	-8.04	0.000	.027267	-	.144862	-.091385
_Iwyks~3*		-.1582424	.0081461	-18.18	0.000	.19135	-	.174209	-.142276
_Iwyks~4*		-.3006814	.0063921	-33.82	0.000	.082804	-	.31321	-.288153
_Iwyks~5*		-.1946251	.0077792	-23.40	0.000	.26728	-	.209872	-.179378
_Iwyk~60*		-.4090495	.0025428	-34.42	0.000	.020079	-	.414033	-.404066
_Iwyk~61*		-.4366777	.0058916	-57.62	0.000	.290639	-	.448225	-.42513
_Iwyk~70*		-.3783463	.0048507	-25.79	0.000	.020664	-	.387854	-.368839
_Iwyk~71*		-.3921597	.0035269	-12.86	0.000	.004952	-	.399072	-.385247

obs. P		.4131425	
pred. P		.3926327	(at x-bar)

(*) dF/dx is for discrete change of dummy variable from 0 to 1
 z and $P > |z|$ are the test of the underlying coefficient being 0

Logit

- Model logitowy otrzymujemy dla

$$F(\mathbf{x}_i\boldsymbol{\beta}) = \frac{e^{\mathbf{x}_i\boldsymbol{\beta}}}{1 + e^{\mathbf{x}_i\boldsymbol{\beta}}} = \Lambda(\mathbf{x}_i\boldsymbol{\beta})$$

- Funkcja prawdopodobieństwa dla pojedynczej obserwacji

$$\Pr(y_i) = \begin{cases} \frac{1}{1+e^{\mathbf{x}_i\boldsymbol{\beta}}} & \text{dla } y_i = 0 \\ \frac{e^{\mathbf{x}_i\boldsymbol{\beta}}}{1+e^{\mathbf{x}_i\boldsymbol{\beta}}} & \text{dla } y_i = 1 \end{cases}$$

- Logarytm funkcji wiarygodności

$$\begin{aligned}
 \ell(\mathbf{y}, \mathbf{x}, \boldsymbol{\beta}) &= \sum_{i=1}^n \left[(1 - y_i) \ln \left(\frac{1}{1 + e^{\mathbf{x}_i \boldsymbol{\beta}}} \right) + y_i \ln \left(\frac{e^{\mathbf{x}_i \boldsymbol{\beta}}}{1 + e^{\mathbf{x}_i \boldsymbol{\beta}}} \right) \right] \\
 &= \sum_{i=1}^n y_i \mathbf{x}_i \boldsymbol{\beta} - \sum_{i=1}^n \ln (1 + e^{\mathbf{x}_i \boldsymbol{\beta}})
 \end{aligned}$$

- Efekt cząstkowy:

$$\frac{\partial E(y | \mathbf{x})}{\partial \mathbf{x}} = \frac{\partial \Lambda(\mathbf{x}_i \boldsymbol{\beta})}{\partial \mathbf{x}} = \Lambda(\mathbf{x}_i \boldsymbol{\beta}) [1 - \Lambda(\mathbf{x}_i \boldsymbol{\beta})] \boldsymbol{\beta}$$

- W przypadku modelu logitowego można także bezpośrednio interpretować same parametry.

- Zdefiniujemy szansę sukcesu jako stosunek prawdopodobieństwa sukcesu do prawdopodobieństwa porażki:

$$Odds(\mathbf{x}_i) = \frac{\Pr(y_i = 1 | \mathbf{x}_i)}{\Pr(y_i = 0 | \mathbf{x}_i)} = \frac{\frac{e^{\mathbf{x}_i \boldsymbol{\beta}}}{1 + e^{\mathbf{x}_i \boldsymbol{\beta}}}}{\frac{1}{1 + e^{\mathbf{x}_i \boldsymbol{\beta}}}} = e^{\mathbf{x}_i \boldsymbol{\beta}}$$

Przykład Jeśli prawdopodobieństwo zdania egzaminu z ekonometrii jeśli się w ogóle nie uczyłem ($x_i = 0$) wynosi $\frac{1}{9}$ a szansa zdania egzaminu jest równa $Odds(0) = \frac{\frac{1}{9}}{1 - \frac{1}{9}} = \frac{1}{8}$

- Policzmy teraz iloraz, szansy dla zmiennej niezależnej równej x_i i szansy dla zmiennej niezależnej równej x_j :

$$\frac{Odds(\mathbf{x}_i)}{Odds(\mathbf{x}_j)} = \exp [(\mathbf{x}_i - \mathbf{x}_j) \boldsymbol{\beta}] = \exp (\Delta \mathbf{x} \boldsymbol{\beta})$$

Przykład Jeśli prawdopodobieństwo zdania egzaminu z ekonometrii jeśli się uczyłem jeden dzień ($x_i = 1$) wynosi $\frac{1}{3}$ to szansa zdania egzaminu w tym przypadku będzie równa $Odds(1) = \frac{\frac{1}{3}}{1 - \frac{1}{3}} = \frac{1}{2}$ a iloraz szans będzie równy

$$\frac{Odds(1)}{Odds(0)} = \frac{\frac{1}{2}}{\frac{1}{8}} = 4$$

Prawdopodobieństwo zdania egzaminu wzrosło więc 3 razy a szansa zdania egzaminu 4 razy.

- Ilorazy szans równe $\exp(\beta_k)$ interpretuje się w sposób następujący:
 - Dla zmiennej ciągłej jest to współczynnik, przez który należy przemnożyć szansę sukcesu dla x_{ik} , by otrzymać szansę sukcesu dla $x_{ik} + 1$.

- Dla zmiennej zerojedynkowej x_{ik} jest to współczynnik, przez który należy przemnożyć szansę sukcesu dla $x_{ik} = 0$, by otrzymać szansę sukcesu dla $x_{ik} = 1$.
- Dla małych β_k wielkości β_k można także zinterpretować, korzystając z tego, że $e^{\Delta x \beta} \approx 1 + \Delta x \beta$:
 - dla zmiennych ciągłych - ile procent zmieni się szansa sukcesu jeśli x_k zmieni się o 1
 - dla zmiennych zerojedynkowych - ile procent zmieni się szansa sukcesu jeżeli zmienna x_k przeskoczy z 0 na 1.

Przykład Zależność aktywności zawodowej od wieku i wykształcenia: kontynuacja

- Współczynniki

```
Logit estimates                                     Number of obs   =      47860
                                                    LR chi2(9)      =      8275.22
                                                    Prob > chi2     =      0.0000
Log likelihood = -28310.607                       Pseudo R2       =      0.1275
```

<u>_Iworks_1</u>	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
wiek	-.0186039	.0006038	-30.81	0.000	-.0197873	-.0174204
_Iwyksz_2	-.5221753	.0655267	-7.97	0.000	-.6506053	-.3937453
_Iwyksz_3	-.6942371	.0389682	-17.82	0.000	-.7706134	-.6178608
_Iwyksz_4	-1.561855	.0471004	-33.16	0.000	-1.65417	-1.46954
_Iwyksz_5	-.8542947	.0372593	-22.93	0.000	-.9273216	-.7812678
_Iwyksz_60	-4.372065	.1570768	-27.83	0.000	-4.67993	-4.0642
_Iwyksz_61	-2.207483	.0391494	-56.39	0.000	-2.284215	-2.130752
_Iwyksz_70	-2.88925	.1303508	-22.17	0.000	-3.144732	-2.633767
_Iwyksz_71	-4.194055	.416003	-10.08	0.000	-5.009406	-3.378704

_cons		1.666699	.0423531	39.35	0.000	1.583688	1.749709
-------	--	----------	----------	-------	-------	----------	----------

- Krańcowe efekty

Marginal effects after logistic
 $y = \text{Pr}(_Iworks_1)$ (predict)
 $= .38568338$

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
wiek	-.0044078	.00014	-30.94	0.000	-.004687 - .004129	43.9481
_Iwyks~2*	-.1148651	.06553	-1.75	0.080	-.243295 .013565	.027267
_Iwyks~3*	-.1539078	.03897	-3.95	0.000	-.230284 -.077532	.19135
_Iwyks~4*	-.2864085	.0471	-6.08	0.000	-.378724 -.194093	.082804
_Iwyks~5*	-.189642	.03726	-5.09	0.000	-.262669 -.116615	.26728
_Iwyk~60*	-.398101	.15708	-2.53	0.011	-.705966 -.090236	.020079
_Iwyk~61*	-.4279628	.03915	-10.93	0.000	-.504694 -.351231	.290639
_Iwyk~70*	-.3641805	.13035	-2.79	0.005	-.619663 -.108698	.020664
_Iwyk~71*	-.3810388	.416	-0.92	0.360	-1.19639 .434312	.004952

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

- Interpretacja efektów cząstkowych:

- wzrost wieku o 1 rok zmniejsza prawdopodobieństwo posiadania pracy o 0.4% w stosunku do prawdopodobieństwa dla średnich w próbie
- osoby z wykształceniem policealnym mają o 11% mniejsze prawdopodobieństwo posiadania pracy niż osoby z wykształceniem wyższym (poziom bazowy).

- Ilorazy szans

Logistic regression

Number of obs = 47860

LR chi2(9) = 8275.22

Prob > chi2 = 0.0000

Pseudo R2 = 0.1275

Log likelihood = -28310.607

-----+-----						
_Iworks_1	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
-----+-----						
wiek	.9815681	.0005927	-30.81	0.000	.9804071	.9827304
_Iwyksz_2	.5932287	.0388723	-7.97	0.000	.5217299	.6745259
_Iwyksz_3	.4994553	.0194629	-17.82	0.000	.4627292	.5390964
_Iwyksz_4	.2097466	.0098792	-33.16	0.000	.1912507	.2300313
_Iwyksz_5	.4255833	.0158569	-22.93	0.000	.3956119	.4578252
_Iwyksz_60	.0126251	.0019831	-27.83	0.000	.0092797	.0171767
_Iwyksz_61	.1099771	.0043055	-56.39	0.000	.101854	.118748
_Iwyksz_70	.0556179	.0072498	-22.17	0.000	.0430784	.0718075
_Iwyksz_71	.015085	.0062754	-10.08	0.000	.0066749	.0340916
-----+-----						

- Interpretacja współczynników:

- szansę posiadania pracy trzeba pomnożyć przez 0.98 aby uzyskać szansę posiadania pracy przy wieku większym o 1 - spadek o 2%
- szansę posiadania pracy dla wykształcenia wyższego (poziom bazowy) należy pomnożyć przez 0.58 aby uzyskać szansę posiadania pracy przy wykształceniu policealnym (poziom 1) - spadek o 42%

- Sukcesy i porażki przewidywane i zaobserwowane

Logistic model for `_Iworks_1`

Classified	True		Total
	D	~D	
+	12568	7211	19779
-	7205	20876	28081
Total	19773	28087	47860

Classified + if predicted $\Pr(D) \geq .5$

True D defined as `_Iworks_1 != 0`

Sensitivity	$\Pr(+ D)$	63.56%
Specificity	$\Pr(- \sim D)$	74.33%
Positive predictive value	$\Pr(D +)$	63.54%
Negative predictive value	$\Pr(\sim D -)$	74.34%
False + rate for true ~D	$\Pr(+ \sim D)$	25.67%
False - rate for true D	$\Pr(- D)$	36.44%
False + rate for classified +	$\Pr(\sim D +)$	36.46%


False - rate for classified -	$\Pr(D -)$	25.66%

Correctly classified		69.88%

- To na którą z tych policzonych częstości powinniśmy patrzeć zależy od zastosowania:
 - czy szczególnie ważne jest wyeliminowanie potencjalnych porażek (np. kontrola jakości)
 - czy szczególnie ważne jest uniknięcie fałszywej klasyfikacji (np. identyfikacja przestępców)

Różnice między probitem a logitem

- Inna interpretacja ale interpretacja efektów cząstkowych taka sama
- Oba rozkłady prawdopodobieństwa są symetryczne jednak rozkład logistyczny ma nieco grubsze ogony.




- W związku z tym istotne różnice między modelami będą powstawać dla prób, o nikłym odsetku odpowiedzi 0 albo odpowiedzi 1 i bardzo

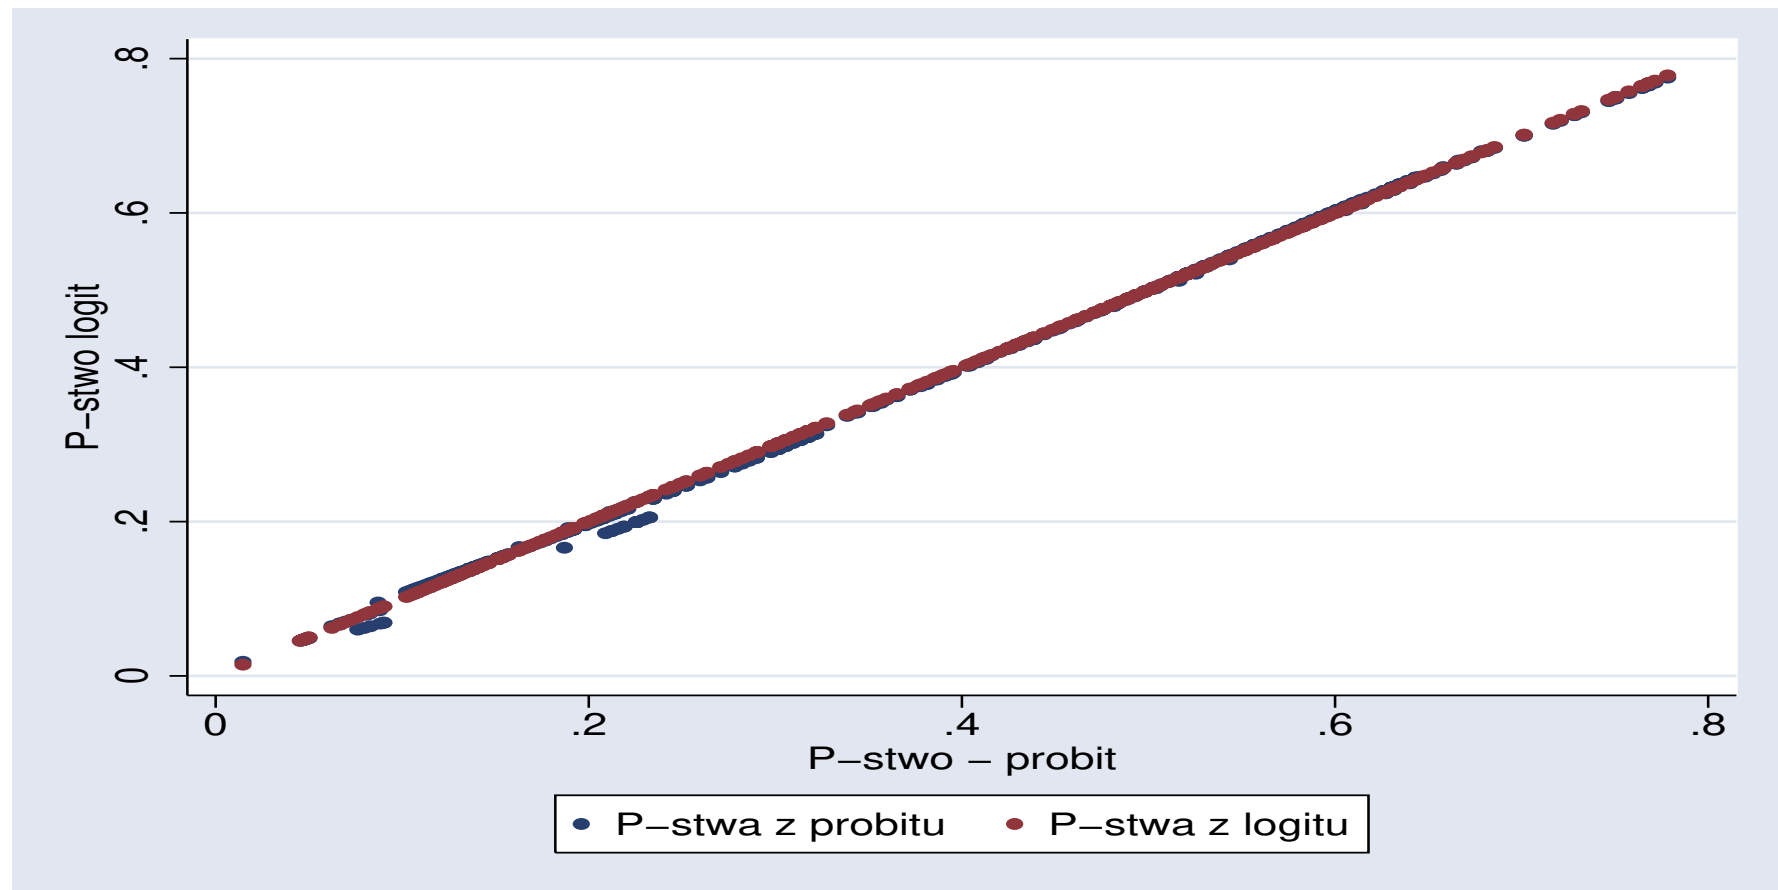
zróznicowanych zmiennych niezależnych.

- Dla $\bar{x}\beta$ bliskiego 0 funkcja gęstości $f(0) \approx .4$ dla logitu, $f(0) \approx .25$ dla probitu, i $g(0) = 1$ dla *LPM*. Z tego powodu często zdarza się, że $\beta_{\text{logit}} \approx 1.6\beta_{\text{probit}}$ i $\beta_{\text{logit}} \approx 4\beta_{\text{LPM}}$.
- Nie ma dobrej statystyki, która mogłaby posłużyć do wyboru między tymi modelami.
- W praktyce wybieramy ten, który jest analitycznie bardziej wygodny.

- Porównanie przewidywanych prawdopodobieństw z modelu liniowego i logitowego



- Porównanie przewidywanych prawdopodobieństw z modelu probitowego i logitowego



Modele dla zmiennych uporządkowanych

- Zmienna zależna przyjmuje wartości ze zbioru $\{0, 1, \dots, J\}$ i wartości te można uporządkować (n.p. oceny z egzaminu, poziomy wykształcenia itp.).
- Uporządkowany probit

$$y^* = x\beta + \varepsilon$$

i dystrybuanta ε jest dana przez $F(\varepsilon)$. Zakładamy, że istnieje J *nieznanych* punktów przecięć $\alpha_1 < \alpha_2 < \dots < \alpha_J$

$$\begin{array}{lll} y = 0 & \text{jeśli} & y^* \leq \alpha_1 \\ y = 1 & \text{jeśli} & \alpha_1 < y^* \leq \alpha_2 \\ & & \vdots \\ y = J & \text{jeśli} & y^* > \alpha_J \end{array}$$

Prawdopodobieństwa poszczególnych wyborów są równe

$$\Pr(y = 0 | \mathbf{x}) = \Pr(y^* \leq \alpha_1 | \mathbf{x}) = F(\alpha_1 - \mathbf{x}\beta)$$

$$\Pr(y = 1 | \mathbf{x}) = \Pr(\alpha_1 < y^* \leq \alpha_2 | \mathbf{x}) = F(\alpha_2 - \mathbf{x}\beta) - F(\alpha_1 - \mathbf{x}\beta)$$

⋮

$$\Pr(y = J | \mathbf{x}) = \Pr(y^* > \alpha_J | \mathbf{x}) = 1 - F(\alpha_J - \mathbf{x}\beta)$$

- Te prawdopodobieństwa możemy użyć do zdefiniowania funkcji wiarygodności
- Dla uporządkowanego probitu $F(\varepsilon) = \Phi(\varepsilon)$ a dla uporządkowanego logitu $F(\varepsilon) = \Lambda(\varepsilon)$

- Dla modelu dla zmiennych uporządkowanych efekt cząstkowy jest równy

$$\frac{\partial p_0(\mathbf{x})}{\partial \mathbf{x}} = -\beta_k f(\alpha_1 - \mathbf{x}\beta), \quad \frac{\partial p_J(\mathbf{x})}{\partial \mathbf{x}} = \beta_k f(\alpha_J - \mathbf{x}\beta)$$

$$\frac{\partial p_j(\mathbf{x})}{\partial \mathbf{x}} = \beta_k [f(\alpha_{j-1} - \mathbf{x}\beta) - f(\alpha_j - \mathbf{x}\beta)], \quad 1 < j < J$$

Znaki efektów cząstkowych są zdeterminowane przez znaki β tylko dla $j = 0$ i $j = J$. Dla pośrednich wyborów znak zależy także od znaku różnicy $\phi(\alpha_{j-1} - \mathbf{x}\beta) - \phi(\alpha_j - \mathbf{x}\beta)$

- Dla tych modeli możemy także policzyć procenty prawidłowych przewidywań (przewidywany wybór byłby tu wyborem najbardziej prawdopodobnym według modelu)

Przykład Czy pani minister Środa ma rację? (przemoc w rodzinie a religijność) Zmienna objaśniana: odpowiedź na pytanie Proszę powiedzieć,

czy się Pan(i) zdecydowanie zgadza, czy też zdecydowanie się Pan(i) nie zgadza ze stwierdzeniem, że czasami jest konieczne, by porządnym laniem przywołać dziecko do porządku. Możliwe odpowiedzi: zdecydowanie się zgadzam, zgadzam się, nie zgadzam się, zdecydowanie się nie zgadzam, nie wiem. Zmienne objaśniające: jak często chodzi do kościoła, wykształcenie, region zamieszkania, liczba dzieci, czy respondent nadużywa alkoholu, czy respondent jest szczęśliwy (odpowiedzi nie wiem zostały pominięte)

```
Ordered probit estimates                                Number of obs   =          7141
                                                       LR chi2(19)     =          145.53
                                                       Prob > chi2     =           0.0000
Log likelihood = -9160.8296                            Pseudo R2      =           0.0079
```

spanking	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
attend	-.0212552	.0062126	-3.42	0.001	-.0334317	-.0090787
educ	.0186807	.0044628	4.19	0.000	.0099338	.0274276
_Iregion8_2	-.015627	.0458017	-0.34	0.733	-.1053966	.0741426
_Iregion8_3	-.0547608	.042694	-1.28	0.200	-.1384396	.0289179
_Iregion8_4	-.022339	.0475385	-0.47	0.638	-.1155127	.0708348

_Iregion8_5		-.106774	.0498113	-2.14	0.032	-.2044024	-.0091457
_Iregion8_6		-.1000209	.0585965	-1.71	0.088	-.2148679	.0148261
_Iregion8_7		-.1936478	.0560845	-3.45	0.001	-.3035713	-.0837243
_Iregion8_8		-.1391899	.0460914	-3.02	0.003	-.2295274	-.0488525
childs		-.039004	.0087318	-4.47	0.000	-.0561181	-.0218899
_Idrink1_1		.1151006	.0363647	3.17	0.002	.0438271	.1863741
_Idrink1_2		.2352853	.039625	5.94	0.000	.1576217	.312949
_Ihapunhap_2		-.0617953	.0363861	-1.70	0.089	-.1331108	.0095201
_Ihapunhap_3		-.0669545	.0452502	-1.48	0.139	-.1556433	.0217344
_Ihapunhap_4		-.236623	.0808379	-2.93	0.003	-.3950625	-.0781835
_Ipgssy~1993		.101719	.0386854	2.63	0.009	.0258971	.1775409
_Ipgssy~1994		-.0125805	.0388896	-0.32	0.746	-.0888027	.0636417
_Ipgssy~1995		.0798399	.0390542	2.04	0.041	.0032951	.1563847
_Ipgssy~1997		.1065954	.0428122	2.49	0.013	.0226851	.1905057

_cut1		-.8671028	.0866442			(Ancillary parameters)	
_cut2		.2583954	.0864078				
_cut3		1.243044	.0871357				

- Rzeczywiście istnieje istotny statystycznie dodatni związek między prawdopodobieństwem odpowiedzi twierdzącej na pytanie, że zdecydowanie

się zgadzam z pytaniem i ujemny, że zdecydowanie się nie zgadzam a tym jak często respondent chodzi do kościoła.

- Uwaga 1: Związek jest statystycznie istotny ale nie trudno odczytać bezpośrednio z wyników na ile jest względnie ważny.

```

Ordered probit estimates                                Number of obs   =           7792
                                                       LR chi2(18)     =          3671.76
                                                       Prob > chi2     =           0.0000
Log likelihood =  -13018.18                            Pseudo R2       =           0.1236
    
```

degree	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
age	.0609912	.0042303	14.42	0.000	.0527	.0692824
age2	-.0008239	.0000429	-19.19	0.000	-.000908	-.0007397
_Isize_2	.4141903	.0532129	7.78	0.000	.309895	.5184856
_Isize_3	.5087877	.0438097	11.61	0.000	.4229222	.5946532
_Isize_4	.5838797	.0461496	12.65	0.000	.4934282	.6743312
_Isize_5	.5355975	.0441367	12.13	0.000	.449091	.6221039
_Isize_6	.571307	.0415982	13.73	0.000	.4897759	.6528381

_Isize_7		.7573527	.0488191	15.51	0.000	.661669	.8530364
_Isize_8		.8325512	.0432759	19.24	0.000	.747732	.9173703
_Ipadeg_1		.4402944	.0753946	5.84	0.000	.2925236	.5880651
_Ipadeg_2		.9115508	.0750879	12.14	0.000	.7643813	1.05872
_Ipadeg_3		1.175989	.080232	14.66	0.000	1.018737	1.33324
_Ipadeg_4		1.729912	.1116625	15.49	0.000	1.511057	1.948767
_Ipadeg_5		1.676097	.102199	16.40	0.000	1.475791	1.876403
_Ipadeg_6		1.612315	.0869192	18.55	0.000	1.441957	1.782674
_Ipadeg_7		2.077365	.1787112	11.62	0.000	1.727097	2.427632
_Ipadeg_8		2.153149	.1821429	11.82	0.000	1.796156	2.510143
_Ipadeg_9		2.18002	.1007946	21.63	0.000	1.982466	2.377573

_cut1		-1.382214	.1321335			(Ancillary parameters)	
_cut2		.0751018	.120416				
_cut3		1.595465	.1210239				
_cut4		2.457993	.1213689				
_cut5		2.552495	.12147				
_cut6		2.753064	.1217385				
_cut7		3.52315	.1230554				
_cut8		3.762048	.1235789				
_cut9		3.943192	.1241567				

- Wnioski:
 - Istnieje nieliniowa zależność między wiekiem a poziomem wykształcenia
 - Istnieje dodatnia zależność między wielkością miasta i wykształceniem rodziców a wykształceniem respondenta

Modele dla wyborów nieuporządkowanych (wielomianowy logit)

- Zmienna zależna przyjmuje wartości ze zbioru $\{0, 1, \dots, J\}$. Wartości tych nie da się uporządkować (np. wybór zawodu, wybór miejsca zamieszkania itd.)
- Najbardziej popularnym modelem w tym kontekście jest wielomianowy logit:

$$p_j(\mathbf{x}) = \Pr(y = j | \mathbf{x}) = \frac{\exp(\mathbf{x}\beta_j)}{1 + \sum_{h=1}^J \exp(\mathbf{x}\beta_h)} \quad \text{dla } j = 1, \dots, J$$
$$p_0(\mathbf{x}) = \Pr(y = 0 | \mathbf{x}) = \frac{1}{\left[1 + \sum_{h=1}^J \exp(\mathbf{x}\beta_h)\right]} \quad \text{dla } j = 0$$

- Poziom zero jest interpretowany jako poziom bazowy. Współczynniki interpretujemy w odniesieniu do poziomu bazowego.
- Najprościej interpretować współczynniki przy użyciu ilorazów szans (relatywnego szansy zdarzenia $y = j$ dla \mathbf{x}_1 względem szansy zdarzenia dla \mathbf{x}_0)

$$Odds_j(\mathbf{x}_i) = \frac{p_r(\mathbf{x}_i)}{p_0(\mathbf{x}_i)} = \exp(\mathbf{x}\beta_j)$$

$$\frac{Odds_j(\mathbf{x}_1)}{Odds_j(\mathbf{x}_0)} = \exp[(\mathbf{x}_1 - \mathbf{x}_0)\beta_j] = \exp(\Delta\mathbf{x}\beta_j)$$

- Dodanie β_j oznacza więc, że iloraz szans rośnie.
- Możliwe jest także policzenie efektów cząstkowych dla prawdopodobieństw poszczególnych alternatyw (wzory są dosyć skomplikowane)

- Liczba parametrów w modelu wielomianowym jest w takim modelu często bardzo duża: równa $J \times K$.

Przykład Stan cywilny a wiek, płeć i poziom wykształcenia.

```

Multinomial logistic regression           Number of obs   =           8894
                                           LR chi2(16)     =           3779.69
                                           Prob > chi2     =             0.0000
Log likelihood = -6972.1839              Pseudo R2       =             0.2133

```

marital	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
-----+-----						
malz / konk						
age	.0873834	.0030204	28.93	0.000	.0814636	.0933032
educ	.0998039	.0190436	5.24	0.000	.0624791	.1371287
_Isex_2	2.015474	.2663872	7.57	0.000	1.493365	2.537583
_IsexXeduc_2	-.1583433	.0236057	-6.71	0.000	-.2046096	-.1120769
_cons	-3.083293	.2413295	-12.78	0.000	-3.55629	-2.610296
-----+-----						
wdowi						
age	.1903022	.0045226	42.08	0.000	.1814382	.1991663

educ		.0798383	.0305318	2.61	0.009	.019997	.1396796
_Isex_2		3.665258	.3614685	10.14	0.000	2.956793	4.373723
_IsexXeduc_2		-.1435851	.034277	-4.19	0.000	-.2107668	-.0764034
_cons		-11.67067	.4211294	-27.71	0.000	-12.49607	-10.84527
-----+-----							
rozwiedz							
age		.1039853	.0046831	22.20	0.000	.0948066	.1131641
educ		.1544554	.0348377	4.43	0.000	.0861747	.2227361
_Isex_2		2.917523	.4353736	6.70	0.000	2.064207	3.77084
_IsexXeduc_2		-.1719227	.0378221	-4.55	0.000	-.2460526	-.0977928
_cons		-7.721986	.4648842	-16.61	0.000	-8.633142	-6.810829
-----+-----							
separacja							
age		.0950069	.0078496	12.10	0.000	.0796219	.1103919
educ		.0836903	.0636173	1.32	0.188	-.0409973	.208378
_Isex_2		2.245084	.7776824	2.89	0.004	.7208547	3.769313
_IsexXeduc_2		-.1169839	.0704979	-1.66	0.097	-.2551573	.0211894
_cons		-7.842432	.8270322	-9.48	0.000	-9.463385	-6.221479

(marital==kaw / panna is the base outcome)

marital	RRR	Std. Err.	z	P> z	[95% Conf. Interval]	
-----+-----						
malz / konk						
age	1.091315	.0032962	28.93	0.000	1.084874	1.097795
educ	1.104954	.0210423	5.24	0.000	1.064472	1.146976
_Isex_2	7.504284	1.999045	7.57	0.000	4.452051	12.64907
_IsexXeduc_2	.8535567	.0201488	-6.71	0.000	.8149654	.8939755
-----+-----						
wdowi						
age	1.209615	.0054706	42.08	0.000	1.19894	1.220385
educ	1.083112	.0330694	2.61	0.009	1.020198	1.149905
_Isex_2	39.06621	14.1212	10.14	0.000	19.23618	79.33847
_IsexXeduc_2	.8662471	.0296924	-4.19	0.000	.809963	.9264424
-----+-----						
rozwiedz						
age	1.109584	.0051963	22.20	0.000	1.099446	1.119816
educ	1.167022	.0406564	4.43	0.000	1.089997	1.249491
_Isex_2	18.49542	8.052418	6.70	0.000	7.879044	43.41651
_IsexXeduc_2	.8420443	.0318479	-4.55	0.000	.7818811	.9068368
-----+-----						
separacja						

age	1.099666	.008632	12.10	0.000	1.082878	1.116716
educ	1.087292	.0691706	1.32	0.188	.9598317	1.231679
_Isex_2	9.441209	7.342262	2.89	0.004	2.05619	43.35029
_IsexXeduc_2	.8895995	.0627149	-1.66	0.097	.7747946	1.021415

 (marital==kaw / panna is the base outcome)

Probabilistyczne modele wyboru optymalnego

- Jest możliwe zbudowanie modeli dla wyborów opartych na maksymalizacji użyteczności
- Załóżmy, że wybór, że użyteczność uzyskana dzięki wyborowi j dla osoby i jest równa

$$y_{ij}^* = \mathbf{x}_{ij}\beta + a_{ij}$$

gdzie a_{it} są nieobserwowalnymi czynnikami wpływającymi na wybór.

- Zakładamy, że \mathbf{x}_{ij} różnią się między osobami ale także między alternatywami

- Osoba maksymalizuje swoją użyteczność dokonując wyboru alternatywy y_i , która maksymalizuje jej użyteczność

$$y_i = \arg \max (y_{i1}^*, y_{i2}^*, \dots, y_{iJ}^*)$$

- Można pokazać, że jeśli a_{ij} są niezależne dla $j = 1, \dots, J$ i mają dystrybuantę daną $F(a_{ij}) = \exp[-\exp(-a_{ij})]$ (dystrybuanta wartości ekstremalnej I rodzaju), to

$$\Pr(y_i = j | \mathbf{x}_{ij}) = \frac{\exp(\mathbf{x}_{ij}\boldsymbol{\beta})}{\sum_{h=1}^J \exp(\mathbf{x}_{ih}\boldsymbol{\beta})}, \quad j = 1, \dots, J$$

- Taki model nazywany jest warunkowym logitem.
- Różnice między warunkowym logitem a wielomianowym logitem:

- obserwujemy charakterystyki osób ale także charakterystyki wyborów
- wektor parametrów jest taki sam dla wszystkich alternatyw

Przykład Modelujemy wybory dotyczące sposobu dojazdu do pracy (samochód, autobus). Możliwe wybory charakteryzują się różnymi kosztami (bilet, benzyna+opłata parkingowa) oraz czasem dojazdu. Osoby badane różnią się także dochodami. Dane mogą wyglądać następująco:

osoba	wybór	decyzja	koszt	czas	dochód
1	bus	1	2	25	2000
1	car	0	3	15	2000
2	bus	0	2	25	3000
2	car	1	3	15	3000
3	bus	1	2	25	1000
3	car	0	3	15	1000

- Zauważmy, że iloraz prawdopodobieństw dla alternatyw j i h jest równy:

$$\frac{p(\mathbf{x}_{ij})}{p(\mathbf{x}_{ih})} = \frac{\exp(\mathbf{x}_{ij}\boldsymbol{\beta})}{\exp(\mathbf{x}_{ih}\boldsymbol{\beta})} = \exp[(\mathbf{x}_{ij} - \mathbf{x}_{ih})\boldsymbol{\beta}]$$

względne prawdopodobieństwo alternatyw zależy więc wyłącznie od charakterystyk tych alternatyw

- Oznacza to, że warunkowy logit oparty jest na założeniu o niezależności od zewnętrznych alternatyw (**IIA Independence from Irrelevant Alternatives**): dodanie lub zmiana charakterystyk trzeciej alternatywy nie zmienia relacji prawdopodobieństw.
- Tego typu założenie jest często nierealistyczne dla przypadku podobnych alternatyw.

Przykład (McFadden 1974) Załóżmy, że pasażerowie mogą wybierać

między samochodem i czerwonym autobusem. Załóżmy, że prawdopodobieństwo wyboru tych dwóch alternatyw jest równe $p_{car} = p_{red\ bus} = \frac{1}{2}$ tak, że iloraz szans dla tych dwóch alternatyw jest równy $\frac{p_{car}}{p_{red\ bus}} = 1$. Dodajmy teraz trzecią alternatywę: niebieski autobus. Załóżmy, że dla pasażerów nie ma znaczenia kolor autobusu i w związku z tym $p_{red\ bus} = p_{blue\ bus}$. Jednak by utrzymać założenie o niezależności ilorazu szans między samochodem i czerwonym autobusem musimy teraz przyjąć, że $p_{car} = p_{red\ bus} = \frac{1}{3}$ - wprowadzenie dodatkowego koloru autobusu prowadzi do znaczącego spadku prawdopodobieństwa podróży samochodem!

Modele dla liczebności

- Liczebność jest to zmienna, która przyjmuje nieujemne wartości całkowite (np. liczba dzieci, liczba strajków ciągu roku w danej firmie, liczba papierosów wypalanych dziennie itd.)
- Czasami liczebność może mieć jakąś (zależną od obserwacji) logiczną górną granicę (np. liczba dzieci danej w rodzinie, które ukończyły wyższe studia nie może być wyższa niż ogólna liczba dzieci w tej rodzinie)
- W tych przypadkach zastosowanie modelu dla zmiennych uporządkowanych jest nieuprawnione, ponieważ zbiór możliwych wartości y nie jest z góry określony (naogół wyniki estymacji uzyskane tą metodą nie będą przy tym satysfakcjonujące)

- Najprostsza metoda estymacji w przypadku zmiennych to założyć, że $E(y|\mathbf{x}) = \mathbf{x}\beta$ i estymować model przy użyciu *OLS*.
- Wadą tej metody jest fakt, że niektóre z dopasowanych $\hat{y} = \mathbf{x}\mathbf{b}$ mogą się okazać ujemne, co nie ma sensu, ponieważ liczebność musi być zawsze dodatnia.
- Inna możliwość to dokonanie na zmiennych przekształcenia logarytmicznego i założenie, że $\log E[y|\mathbf{x}] = \mathbf{x}\beta$. Wartości dopasowane są w tym modelu równe $\hat{y} = \exp(\mathbf{x}\mathbf{b}) > 0$ i większe od zera. Te podejście jest jednak niemożliwe do zastosowanie jeśli dla istotnej części obserwacji $y = 0$ (np. liczba dzieci)

Model Poissona

- Najpopularniejszym modelem dla liczebności jest model Poissona
- Zakładamy, że warunkowa wartość oczekiwana y jest dana przez $E(y|x) = \mu(x)$ (najczęściej $\mu(x) = \exp(x\beta)$)
- Warunkowa dystrybuanta y jest dane przez rozkład Poissona dla $\lambda = \mu(x)$

$$f(y|x) = \frac{e^{-\lambda} \lambda^y}{y!} = \frac{\exp[-\mu(x)] [\mu(x)]^y}{y!}$$

- Rzeczywiście dla rozkładu Poissona $E(y|x) = \lambda = \mu(x)$

- Efekty cząstkowe w rozkładzie Poissona z $\mu(\mathbf{x}) = \exp(\mathbf{x}\boldsymbol{\beta})$ interpretujemy tak samo jak w modelu, w którym zmienna zależna jest zlogarytmowana a niezależne nie są zlogarytmowane (semielastyczności wartości oczekiwanej)

$$\frac{\partial \ln E(y|\mathbf{x})}{\partial \mathbf{x}} = \frac{\partial \ln \mu(\mathbf{x})}{\partial \mathbf{x}} = \boldsymbol{\beta}$$

a więc $\frac{\Delta \mu(\mathbf{x})}{\mu(\mathbf{x})} / \Delta x_j = \beta_j$.

- Jeśli zmienne niezależne są także zlogarytmowane to parametry będziemy interpretować jako elastyczności wartości oczekiwanej.
- Parametry tego modelu mogą być zgodnie i efektywnie oszacowane za pomocą *MNW*
- **Najważniejsze ograniczenie modelu Poissona.** Dla dystrybuanty

rozkładu Poissona:

$$E(y|\mathbf{x}) = \text{Var}(y|\mathbf{x}) = \lambda = \mu(\mathbf{x})$$


- Założenie to bardzo często nie jest spełnione w praktyce (rzadko kiedy można na podstawie rozważań teoretycznych uzasadnić równość wartości oczekiwanej i wariancji)
- Założenie o równości wartości oczekiwanej i wariancji można przetestować.
- Można pokazać, jeśli tylko dobrze jest wyspecyfikowany model dla warunkowej wartości oczekiwanej ($E(y|\mathbf{x}) = \mu(\mathbf{x})$), to nawet dla $\text{Var}(y|\mathbf{x}) \neq \mu(\mathbf{x})$, model Poissona będzie dawał zgodne oszacowania parametrów.
- W takim przypadku oszacowanie macierzy wariancji kowariancji będzie

jednak nieprawidłowe. Można jednak w tym przypadku zastosować macierz odporną wariancji kowariancji (*Pseudo – MNW*)

- Czasami zdarza się, że obserwujemy zbyt wysoką liczbę zer w danych (np. przy liczbie wypalanych papierosów wiąże się ro z tym, że ludzie najpierw wybierają palenie bądź nie a później, to ile będą palić). W takim przypadku powinno się stosować model *ZIP* (**Z**ero **I**nflated **P**oisson - rozdęty w zerze model Poissona)

Przykład Liczba telewizorów w gospodarstwie domowym a logarytm dochodu i liczba osób w rodzinie. Założono, że $\mu(x) = \exp(x\beta)$.

- Liczba telewizorów w gospodarstwie domowym (dane z budżetów gospodarstw domowych)



Poisson regression

Number of obs = 35952

LR chi2(7) = 655.67

Prob > chi2 = 0.0000

Log likelihood = -39036.892

Pseudo R2 = 0.0083


tv	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ldochg	.15787	.00923	17.10	0.000	.1397795	.1759604
los	.0289983	.0035735	8.11	0.000	.0219944	.0360021
_Ik1m_2	-.0091403	.0206934	-0.44	0.659	-.0496986	.0314181
_Ik1m_3	-.0225221	.02266	-0.99	0.320	-.0669348	.0218906
_Ik1m_4	.001201	.0183397	0.07	0.948	-.0347441	.0371461
_Ik1m_5	.0097115	.0199079	0.49	0.626	-.0293072	.0487301
_Ik1m_6	-.0873394	.0178009	-4.91	0.000	-.1222285	-.0524503
_cons	-1.137438	.0686759	-16.56	0.000	-1.272041	-1.002836

- Interpretacja parametrów:

- zwiększenie się dochodu o 1% powoduje zwiększenie wartości oczekiwanej liczby telewizorów w gospodarstwie o 0.15%

- zwiększenie się liczby osób o 1 zwiększa liczbę telewizorów o 2.9%
- zamieszkanie na wsi zmniejsza oczekiwaną liczbę telewizorów o 8.7%

- Liczba telewizorów w gospodarstwie domowym (liczebności rzeczywiste i dopasowane)



Model tobitowy

- Modele tobitowy używany jest w dwóch różnych kontekstach:
 - cenzurowania danych (*censored data*)
 - rozwiązań brzegowych (*corner solutions*)
- Dane ocenzurowane to dane dla których znamy wartość zmiennej poniżej danego progu a powyżej tego progu wiemy jedynie, że zmienna jest większa niż ten próg

Przykład Udało nam się uzyskać dane dotyczące wszystkich pracowników pewnej firmy. Jednak dla płac otrzymaliśmy dane dotyczące jedynie szeregowych pracowników a w stosunku do osób na kierowniczych stanowiskach wiemy jedynie, że zarabiają więcej niż XXX.

- W wielu przypadkach wynikiem decyzji podmiotów ekonomicznych jest albo zero albo jakaś liczba dodatnia (np. wydatki na dobro trwałego użytku, wydatki na ubezpieczenie, wydatki na badania i rozwój)
- Z tego powodu w próbie możemy zaobserwować dodatnie wartości zmiennej oraz pewną liczbę zer, które obserwujemy dla tych podmiotów, dla których wybór $y = 0$ był optymalny
- Tego rodzaju rozwiązania problemu optymalizacji funkcji celu nazywamy rozwiązaniami brzegowymi
- W tego rodzaju przypadku zastosowanie liniowej bądź nieliniowej regresji da nieprawidłowe wyniki, ponieważ:
 - w regresji liniowej $y = x\beta + \varepsilon$ nie ma sposobu by zagwarantować, by wszystkie wartości dopasowane były dodatnie
 - za pomocą regresji $\ln y = x\beta + \varepsilon$ nie da się modelować obserwacji $y = 0$

- w regresji nieliniowej $y = \exp(\mathbf{x}\beta) + \varepsilon$, zazwyczaj wystąpi heteroskedastyczność
- w żadnej z tych regresji nie da się oszacować dwóch ważnych własności y :
 - * $P(y > 0 | \mathbf{x})$ - prawdopodobieństwa, że nie zajdzie rozwiązanie brzegowe
 - * $E(y | \mathbf{x}, y > 0)$ - warunkowej wartości oczekiwanej y jeśli $y > 0$ (nie jest rozwiązaniem brzegowym)

- Ważne jest zauważenie, że choć dane otrzymane w wyniku ocenowania i dane związane z rozwiązaniami brzegowymi wyglądają identycznie, to jednak są różniące się sposobem powstawania. W pierwszym przypadku obserwujemy prawdziwe wartości jedynie dla części obserwacji, w drugim przypadku obserwujemy prawdziwe wyniki decyzji dla wszystkich obserwacji.

- Model tobitowy definiuje się w sposób następujący:

$$y^* = \mathbf{x}\boldsymbol{\beta} + \varepsilon$$

$$\varepsilon \sim N(0, 1)$$

$$y = \begin{cases} 0 & \text{dla } y^* \leq 0 \\ y^* & \text{dla } y^* > 0 \end{cases}$$

gdzie y^* nazywamy zmienną ukrytą (*latent variable*)

- W zależności od przypadku różne interesować nas będą różne własności tego modelu:
 - dla zmiennych ocenowanych bądź nas interesować $E(y^* | \mathbf{x}) = \mathbf{x}\boldsymbol{\beta}$ (model dla zmiennej ukrytej)
 - dla zmiennej związanej z rozwiązaniami brzegowymi, interesuje nas zazwyczaj $P(y > 0 | \mathbf{x})$ lub $E(y | \mathbf{x}, y > 0)$, ponieważ zmienna ukryta w tym kontekście nie ma zazwyczaj interpretacji

- Zmienna y^* powinna być z grubsza ciągła, homoskedastyczna i mieć rozkład normalny - aby uzyskać rozkład zbliżony do normalnego można zastosować przekształcenie logarytmiczne do $y_i > 0$
- Można pokazać, że:

$$\begin{aligned}
 P(y > 0 | \mathbf{x}) &= \Phi(\mathbf{x}\boldsymbol{\beta} / \sigma) \\
 E(y | \mathbf{x}, y > 0) &= \mathbf{x}\boldsymbol{\beta} + \sigma \lambda(\mathbf{x}\boldsymbol{\beta} / \sigma) \\
 E(y | \mathbf{x}) &= [\mathbf{x}\boldsymbol{\beta} + \sigma \phi(\mathbf{x}\boldsymbol{\beta} / \sigma)] \Phi(\mathbf{x}\boldsymbol{\beta} / \sigma)
 \end{aligned}$$

gdzie $\lambda(c) = \frac{\phi(c)}{\Phi(c)}$ jest nazywane odwrotnością współczynnika Millsa (*inverse Mills ratio*).

- Efekty cząstkowe dla poszczególnych tych wartości są równe:

$$\begin{aligned}\frac{\partial P(y > 0 | \mathbf{x})}{\partial x} &= \phi(x\beta / \sigma) \beta / \sigma \\ \frac{\partial E(y | \mathbf{x}, y > 0)}{\partial x} &= \{1 - \lambda(x\beta / \sigma) [x\beta / \sigma + \lambda(x\beta / \sigma)]\} \beta \\ \frac{\partial E(y | \mathbf{x})}{\partial x} &= \Phi(x\beta / \sigma) \beta\end{aligned}$$

- Znak β_k jest taki sam jak znak wszystkich rodzajów efektów cząstkowych - można pokazać, że $1 - \lambda(x\beta / \sigma) [x\beta / \sigma + \lambda(x\beta / \sigma)] > 0$
- Ostatni wynik ma następującą interpretację: jeśli prawdopodobieństwo uzyskania $y = 0$ jest bliskie zeru $P(y^* > 0 | \mathbf{x}) = \Phi(x\beta / \sigma) \approx 1$, wtedy model praktycznie nie różni się od modelu liniowego. Dla przypadków ciekawych, to jest takich, w których liczba zer jest znacząca relacja między

współczynnikami uzyskanymi z modelu liniowego i tobitowego będzie w przybliżeniu równa $\beta_{MNK} \approx \Phi(\bar{x}\beta/\sigma)\beta \approx \frac{\text{liczba obserwacji } y_i > 0}{\text{liczba obserwacji}} \times \beta$.

- Oszacowania uzyskane z modelu liniowego zastosowanego do danych ocenzonego daje obciążony estymator

prawdziwego parametru β przy czym obciążenie to rośnie wraz ze wzrostem udziału zer w próbie.

- Estymator MNK nie jest zgodnym estymatorem β zarówno dla przypadku, kiedy używamy wszystkich obserwacji jak i dla przypadku, kiedy szacujemy model używając jedynie $y_i > 0$.
- Model tobitowy szacujemy za pomocą MNW . Funkcja gęstości dla

poszczególnych obserwacji ma postać:

$$\begin{aligned} f(y_i | \mathbf{x}_i) &= \begin{cases} 1 - \Phi(\mathbf{x}_i \boldsymbol{\beta} / \sigma) & \text{dla } y_i = 0 \\ \frac{1}{\sigma} \phi\left(\frac{y_i - \mathbf{x}_i \boldsymbol{\beta}}{\sigma}\right) & \text{dla } y_i > 0 \end{cases} \\ &= \{1 - \Phi(\mathbf{x}_i \boldsymbol{\beta} / \sigma)\}^{1_{[y_i=0]}} \left[\frac{1}{\sigma} \phi\left(\frac{y_i - \mathbf{x}_i \boldsymbol{\beta}}{\sigma}\right) \right]^{1_{[y_i>0]}} \end{aligned}$$

Przykład Wydatki na zakup obuwia (zlogarytmowane) w danym miesiącu a logarytm dochodu, liczba osób i miesiąc, dane z budżetów gospodarstw domowych.

- Oszacowania parametrów

```
Tobit estimates
Log likelihood = -53588.396
Number of obs = 35952
LR chi2(13) = 3420.59
Prob > chi2 = 0.0000
Pseudo R2 = 0.0309
```

lobuwie	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ldochg	1.321404	.0439397	30.07	0.000	1.235281	1.407528
los	.4160746	.0165307	25.17	0.000	.383674	.4484753
_Imo_2	.2583854	.1320263	1.96	0.050	-.0003901	.5171609
_Imo_3	1.342601	.1281683	10.48	0.000	1.091387	1.593815
_Imo_4	2.706463	.1253771	21.59	0.000	2.46072	2.952206
_Imo_5	2.609419	.1252601	20.83	0.000	2.363906	2.854933
_Imo_6	1.770684	.1263784	14.01	0.000	1.522978	2.018389
_Imo_7	1.369659	.1275474	10.74	0.000	1.119662	1.619656
_Imo_8	2.043053	.1262433	16.18	0.000	1.795612	2.290494
_Imo_9	2.016629	.1260279	16.00	0.000	1.76961	2.263647
_Imo_10	2.13176	.1257238	16.96	0.000	1.885338	2.378183
_Imo_11	1.816731	.1265315	14.36	0.000	1.568725	2.064736
_Imo_12	1.20642	.1274091	9.47	0.000	.9566939	1.456145

```

      _cons |    -13.2753    .3282685   -40.44    0.000   -13.91872   -12.63189
-----+-----
      _se  |    4.014929    .0276227                (Ancillary parameter)
-----

```

```

Obs. summary:      21467  left-censored observations at lobuwie<=0
                   14485  uncensored observations

```

- W tym przypadku parametry nie mają interpretacji, ponieważ mamy do czynienia z przypadkiem rozwiązań brzegowych a więc zmienna ukryta nie ma, żadnej sensownej interpretacji.
- Na podstawie tego wydruku można jedynie powiedzieć, że wszystkie zmienne w modelu są istotne

- Oszacowania efektów cząstkowych

Marginal Effects: Latent Variable

variable	dF/dx	Std. Err.	z	P> z	X_at	[95% C.I.]
ldochg	1.321404	.0439397	30.07	0.000	7.37311	1.23528	1.40752	
los	.4160746	.0165307	25.17	0.000	3.15553	.383675	.448474	
_Imo_2*	.2583854	.1320263	1.96	0.050	0 --> 1	-.000381	.517152	
_Imo_3*	1.342601	.1281683	10.48	0.000	0 --> 1	1.0914	1.59381	
_Imo_4*	2.706463	.1253771	21.59	0.000	0 --> 1	2.46073	2.9522	
_Imo_5*	2.609419	.1252601	20.83	0.000	0 --> 1	2.36391	2.85492	
_Imo_6*	1.770684	.1263784	14.01	0.000	0 --> 1	1.52299	2.01838	
_Imo_7*	1.369659	.1275474	10.74	0.000	0 --> 1	1.11967	1.61965	
_Imo_8*	2.043053	.1262433	16.18	0.000	0 --> 1	1.79562	2.29049	
_Imo_9*	2.016629	.1260279	16.00	0.000	0 --> 1	1.76962	2.26364	
_Imo_10*	2.13176	.1257238	16.96	0.000	0 --> 1	1.88535	2.37817	
_Imo_11*	1.816731	.1265315	14.36	0.000	0 --> 1	1.56873	2.06473	
_Imo_12*	1.20642	.1274091	9.47	0.000	0 --> 1	.956702	1.45614	
_cons	-13.2753	.3282685	-40.44	0.000	1	-13.9187	-12.6319	

Marginal Effects: Unconditional Expected Value

variable	dF/dx	Std. Err.	z	P> z	X_at	[95% C.I.]
ldochg	.5803899	.0192993	30.07	0.000	7.37311	.542564	.618216	
los	.1827491	.0072606	25.17	0.000	3.15553	.168519	.19698	
_Imo_2*	.1162293	.0579889	2.00	0.045	0 --> 1	.002573	.229885	
_Imo_3*	.6641303	.0562944	11.80	0.000	0 --> 1	.553795	.774465	
_Imo_4*	1.489383	.0550684	27.05	0.000	0 --> 1	1.38145	1.59732	
_Imo_5*	1.425377	.055017	25.91	0.000	0 --> 1	1.31755	1.53321	
_Imo_6*	.9066672	.0555082	16.33	0.000	0 --> 1	.797873	1.01546	
_Imo_7*	.6789829	.0560216	12.12	0.000	0 --> 1	.569182	.788783	
_Imo_8*	1.069416	.0554489	19.29	0.000	0 --> 1	.960738	1.17809	
_Imo_9*	1.052992	.0553542	19.02	0.000	0 --> 1	.9445	1.16148	
_Imo_10*	1.123004	.0552207	20.34	0.000	0 --> 1	1.01477	1.23123	
_Imo_11*	.9338237	.0555754	16.80	0.000	0 --> 1	.824898	1.04275	
_Imo_12*	.5895898	.0559609	10.54	0.000	0 --> 1	.479908	.699271	
_cons	-5.830805	.1441827	-40.44	0.000	1	-6.1134	-5.54821	

Marginal Effects: Conditional on being Uncensored

variable	dF/dx	Std. Err.	z	P> z	X_at	[95% C.I.]
ldochg	.4378849	.0145607	30.07	0.000	7.37311	.409347	.466423	
los	.1378782	.0054779	25.17	0.000	3.15553	.127142	.148615	
_Imo_2*	.0870288	.0437507	1.99	0.047	0 --> 1	.001279	.172779	
_Imo_3*	.4846688	.0424722	11.41	0.000	0 --> 1	.401425	.567913	
_Imo_4*	1.067789	.0415473	25.70	0.000	0 --> 1	.986358	1.14922	
_Imo_5*	1.022704	.0415085	24.64	0.000	0 --> 1	.941349	1.10406	
_Imo_6*	.6569141	.0418791	15.69	0.000	0 --> 1	.574833	.738996	
_Imo_7*	.4952665	.0422665	11.72	0.000	0 --> 1	.412426	.578107	
_Imo_8*	.771793	.0418343	18.45	0.000	0 --> 1	.689799	.853787	
_Imo_9*	.7602637	.0417629	18.20	0.000	0 --> 1	.67841	.842118	
_Imo_10*	.8096546	.0416622	19.43	0.000	0 --> 1	.727998	.891311	
_Imo_11*	.6760974	.0419298	16.12	0.000	0 --> 1	.593917	.758278	
_Imo_12*	.4314933	.0422206	10.22	0.000	0 --> 1	.348742	.514244	
_cons	-4.399149	.1087811	-40.44	0.000	1	-4.61236	-4.18594	

Marginal Effects: Probability Uncensored

variable	dF/dx	Std. Err.	z	P> z	X_at	[95% C.I.]
ldochg	.1297743	.0043153	30.07	0.000	7.37311	.121316	.138232	
los	.0408624	.0016235	25.17	0.000	3.15553	.03768	.044044	
_Imo_2*	.0254667	.0129662	1.96	0.050	0 --> 1	.000053	.05088	
_Imo_3*	.1327763	.0125873	10.55	0.000	0 --> 1	.108106	.157447	
_Imo_4*	.2618206	.0123132	21.26	0.000	0 --> 1	.237687	.285954	
_Imo_5*	.2530791	.0123017	20.57	0.000	0 --> 1	.228968	.27719	
_Imo_6*	.1744484	.0124115	14.06	0.000	0 --> 1	.150122	.198775	
_Imo_7*	.135431	.0125264	10.81	0.000	0 --> 1	.11088	.159982	
_Imo_8*	.2004915	.0123983	16.17	0.000	0 --> 1	.176191	.224792	
_Imo_9*	.1979893	.0123771	16.00	0.000	0 --> 1	.173731	.222248	
_Imo_10*	.2088873	.0123473	16.92	0.000	0 --> 1	.184687	.233087	
_Imo_11*	.1788802	.0124266	14.39	0.000	0 --> 1	.154525	.203236	
_Imo_12*	.1193783	.0125128	9.54	0.000	0 --> 1	.094854	.143903	
_cons	-1.303759	.032239	-40.44	0.000	1	-1.36695	-1.24057	

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

- Tabele:
 1. efekty cząstkowe dla zmiennej ukrytej
 - nieinterpretowalne w tym przypadku
 2. efekty cząstkowe dla bezwarunkowej wartości oczekiwanej $\frac{\partial E(y|\mathbf{x})}{\partial \mathbf{x}}$
 - oczekiwane wydatki gospodarstwa na obuwię wzrosną o 0.58% jeśli dochód wzrośnie o 1%
 3. efekty cząstkowe dla warunkowej wartości oczekiwanej $\frac{\partial E(y|\mathbf{x}, y>0)}{\partial \mathbf{x}}$
 - dla gospodarstw, które poniosły w danym miesiącu jakiegokolwiek wydatki na obuwię, oczekiwane wydatki gospodarstwa na obuwię wzrosną o 0.44% jeśli dochód wzrośnie o 1%
 4. prawdopodobieństwo, że gospodarstwo poniesie jakiegokolwiek wydatki na obuwię wzrośnie o 0.13% jeśli dochód wzrośnie o 1%

- Uwagi: zauważmy że całkowity wpływ wzrostu dochodu na wydatki gospodarstw na obuwię jest w przybliżeniu równy sumie wzrostu wydatków tych gospodarstw, które wydają coś na obuwię i wzrostu proporcji ych

gospodarstw w ogóle populacji.

Selekcja próby

- W wielu przypadkach próba, którą dysponujemy nielosowa.
- Możliwe są trzy przypadki:
 - selekcja próby oparta na zmiennej niezależnej
 - selekcja próby oparta na zmiennej zależnej
 - selekcja próby oparta na osobnym mechanizmie (samoselekcja)

Przykład (selekcja oparta na zmiennej niezależnej) W próbie BAEL obserwujemy jedynie zarobki osób w wieku >16 lat

Przykład (selekcja oparta na zmiennej zależnej) W próbie Z12 obserwujemy płace jedynie osób, których produktywność jest wyższa niż

płaca minimalna - pozostałe nie są przyjmowane do pracy (zakładamy, że wszyscy bezrobotni chcą pracować - nie mogą tego jednak legalnie robić ponieważ są zbyt mało produktywni).

Przykład Oferowana płaca. Oferowana płaca jest to funkcja, która opisuje wysokość płac dla wszystkich osób, łącznie z tymi, które nie pracują. Dane dotyczące płac posiadamy jednak jedynie w odniesieniu do osób o które pracują, przy czym wybór dotyczący tego czy pracować, czy nie związany jest z innym równaniem - równaniem uczestnictwa w rynku pracy. Zakładamy, że osoby, które nie pracują robią to dobrowolnie - ich oczekiwania dotyczące płacy są wyższe niż to co oferują im pracodawcy.

- **Selekcja oparta na zmiennej niezależnej**

- jeśli zmienna niezależna, która determinuje selekcje do próby jest niezależna od błędu losowego, wtedy estymator β uzyskany z regresji liniowej przeprowadzonej dla nielosowej próby *jest zgodny*

Selekcja oparta na zmiennej zależnej

- Różnica w stosunku do tobita: w przypadku tobita cenzurowanie dotyczy jedynie wartości zmiennej zależnej, zmienne niezależne obserwowane są dla wszystkich obserwacji.
- W przypadku selekcji próby obserwujemy *jedynie* obserwacje wyselekcjonowane - takie próby nazywa się niekiedy próbami uciętymi (*truncated samples*)
- Załóżmy, że do próby wybrane mogły być jedynie obserwacje, dla których $a_1 < y < a_2$
- Stosując twierdzenie Bayesa uzyskujemy, że dystrybujanta y jest dana

przez

$$\begin{aligned}\Pr(y \leq Y | \mathbf{x}, a_1 < y < a_2) &= \frac{\Pr(y \leq Y, a_1 < y_i < a_2 | \mathbf{x})}{\Pr(a_1 < y < a_2 | \mathbf{x})} \\ &= \frac{F(Y | \mathbf{x}_i) - F(a_1 | \mathbf{x})}{F(a_2 | \mathbf{x}) - F(a_1 | \mathbf{x})}\end{aligned}$$

ponieważ

$$\Pr(a_1 < y < a_2 | \mathbf{x}) = \Pr(a_1 < y < a_2) = F(a_2 | \mathbf{x}) - F(a_1 | \mathbf{x})$$

oraz

$$\Pr(y \leq Y, a_1 < y < a_2 | \mathbf{x}) = \Pr(a_1 < y \leq Y | \mathbf{x}) = F(Y | \mathbf{x}_i) - F(a_1 | \mathbf{x})$$

- Wynika z tego, że funkcja gęstości y jest równa

$$\frac{\partial \Pr(y \leq Y | \mathbf{x}, a_1 < y < a_2)}{\partial Y} = \frac{f(Y | \mathbf{x})}{F(a_2 | \mathbf{x}) - F(a_1 | \mathbf{x})}$$

- Jeśli założymy, że $\Pr(y \leq Y | \mathbf{x}) = \Phi(\mathbf{x}\beta)$ a więc jest dystrybuntą rozkładu normalnego, to otrzymamy tak zwany regresję uciętą z funkcją gęstości dla poszczególnej obserwacji równą

$$f(y_i | \mathbf{x}_i) = \frac{\frac{1}{\sigma} \phi\left(\frac{y_i - \mathbf{x}_i \beta}{\sigma}\right)}{\Phi(a_2 | \mathbf{x}_i) - \Phi(a_1 | \mathbf{x}_i)}$$

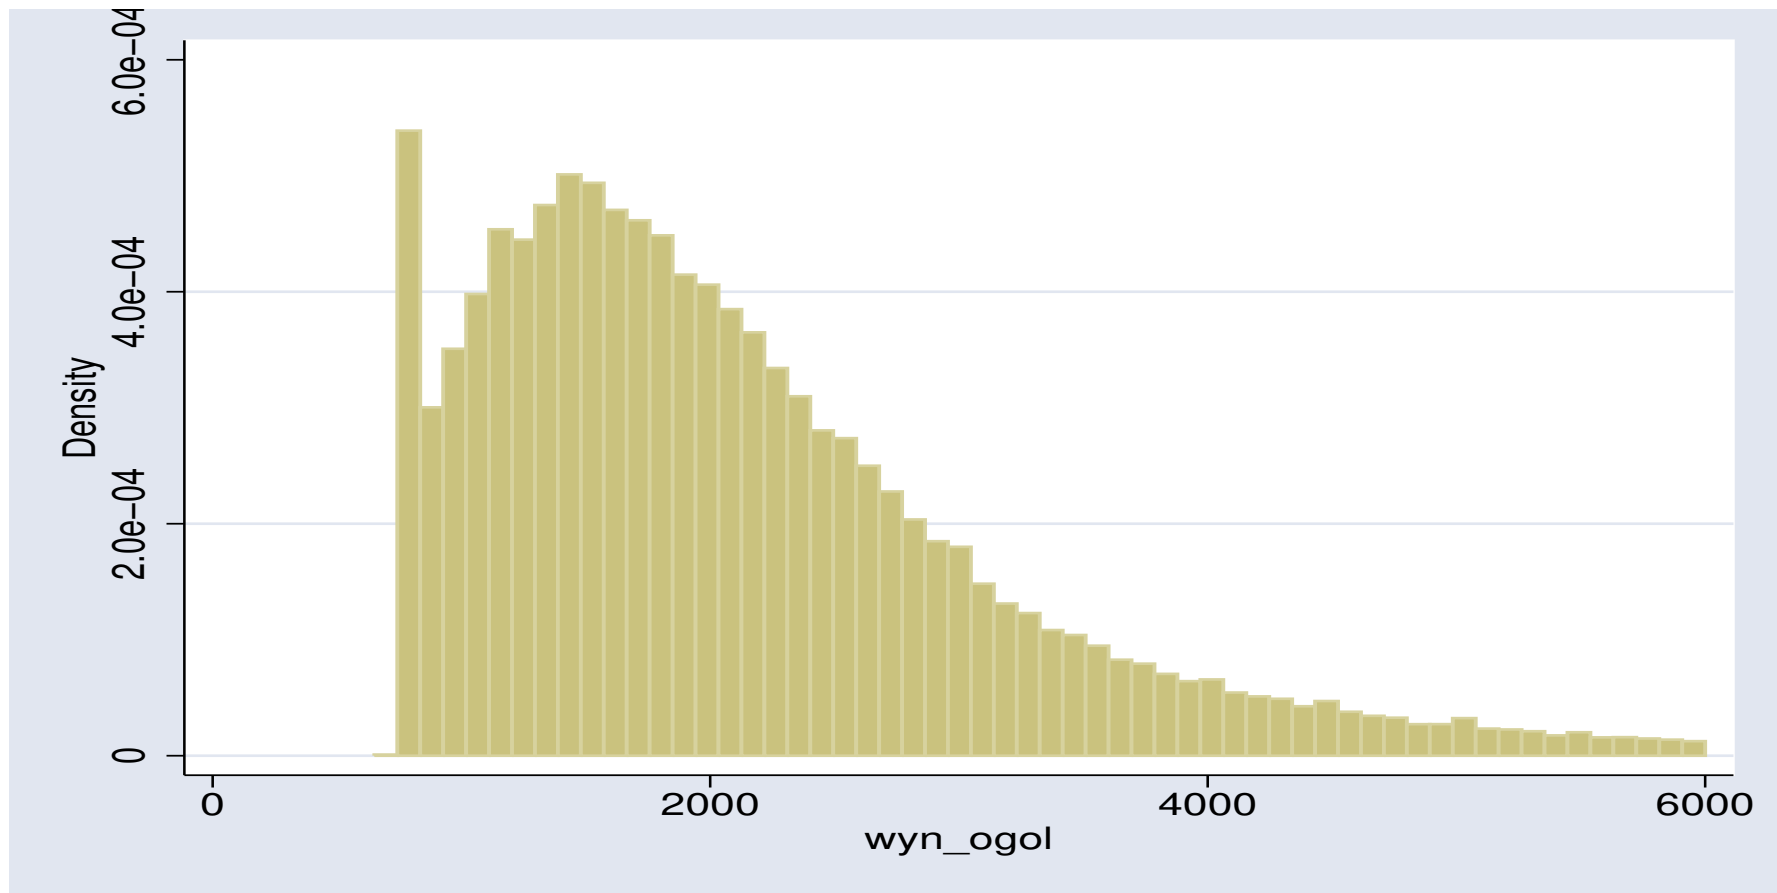
- W zależności od zastosowania będą nas interesować efekty cząstkowe dla wszystkich obserwacji $\frac{\partial E(y | \mathbf{x})}{\partial x} = \beta$, bądź efekty cząstkowe dla populacji

zaobserwowanej

$$\frac{\partial E(y | \mathbf{x}, a_1 < y < a_2)}{\partial \mathbf{x}}$$

Przykład Funkcja oferty płacy (funkcja popytu na pracę) liczona na podstawie danych z poziomu przedsiębiorstw. Dane polskie 2002 roku z badania Z12.

- Płaca brutto na podstawie danych z przedsiębiorstw



- Na poziomie przedsiębiorstw obserwujemy jedynie płace powyżej płacy minimalnej
- Nie jest obserwowalna pełna populacja zatrudnionych a jedynie ci, którzy chcą pracować i ich produktywność jest wyższa od płacy minimalnej

Truncated regression

Limit: lower = 6.6333184
 upper = +inf
 Log likelihood = -35064.9

Number of obs = 63233
 Wald chi2(9) = 20960.00
 Prob > chi2 = 0.0000

lwyn_ogol	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
eq1						
wiek	.0642988	.0016065	40.03	0.000	.0611502	.0674474
wiek2	-.0006349	.0000196	-32.46	0.000	-.0006732	-.0005966
_Iplec_2	-.3271812	.0044484	-73.55	0.000	-.3358998	-.3184626
_Ipoz_wyks_2	-.4024077	.0094504	-42.58	0.000	-.4209302	-.3838852
_Ipoz_wyks_3	-.436441	.0056581	-77.14	0.000	-.4475306	-.4253514
_Ipoz_wyks_4	-.3749871	.0085319	-43.95	0.000	-.3917094	-.3582648

_Ipoz_wyks_5		-.6870413	.0060402	-113.75	0.000	-.6988798	-.6752028
_Ipoz_wyks_6		-.8139249	.0085966	-94.68	0.000	-.8307739	-.7970759
_Ipoz_wyks_7		-.9548006	.0641728	-14.88	0.000	-1.080577	-.8290242
_cons		6.645369	.0314885	211.04	0.000	6.583653	6.707085
-----+-----							
sigma							
_cons		.4766114	.0016778	284.07	0.000	.4733231	.4798998

- Interpretacja parametrów w tym modelu jest identyczna jak w modelu liniowym i dotyczy ofert płacy w całej populacji
- Można także policzyć efekty cząstkowe dla podpopulacji zatrudnionych

Marginal effects after truncreg

$$y = E(\text{lwyn_ogol} | \text{lwyn_ogol} > 6.633318433280377) \quad (\text{predict}, e(6.633318433280377, .)) \\ = 7.5877517$$

variable		dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
wiek		.0562668	.0014	40.23	0.000	.053525 .059008	40.1953

wiek2	-.0005556	.00002	-32.57	0.000	-.000589	-.000522	1713.87
_Iplec_2*	-.284661	.00379	-75.05	0.000	-.292096	-.277227	.489128
Ipoz~2*	-.3164657	.00648	-48.83	0.000	-.329168	-.303763	.059431
Ipoz~3*	-.3587534	.00429	-83.55	0.000	-.36717	-.350337	.258789
Ipoz~4*	-.2984899	.00603	-49.51	0.000	-.310305	-.286675	.073395
Ipoz~5*	-.5410371	.00409	-132.29	0.000	-.549053	-.533021	.265763
Ipoz~6*	-.5650978	.00428	-132.00	0.000	-.573488	-.556707	.092562
Ipoz~7*	-.5855983	.02254	-25.98	0.000	-.629781	-.541415	.001423

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

- Efekty cząstkowe dla podpopulacji są bardzo bliskie oszacowaniom z *MNK*

Source	SS	df	MS	Number of obs = 65110		
Model	5196.35059	9	577.372288	F(9, 65100) = 2829.63		
Residual	13283.3214	65100	.204044875	Prob > F = 0.0000		
-----+-----				R-squared = 0.2812		
Total	18479.672	65109	.28382669	Adj R-squared = 0.2811		
-----+-----				Root MSE = .45171		
lwyn_ogol	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
wiek	.056535	.0013053	43.31	0.000	.0539766	.0590935
wiek2	-.00056	.0000161	-34.73	0.000	-.0005916	-.0005284
_Iplec_2	-.2751897	.0037418	-73.55	0.000	-.2825236	-.2678558
_Ipoz_wyks_2	-.375408	.008194	-45.82	0.000	-.3914682	-.3593478
_Ipoz_wyks_3	-.4123654	.0050178	-82.18	0.000	-.4222003	-.4025305
_Ipoz_wyks_4	-.3625898	.007469	-48.55	0.000	-.377229	-.3479505
_Ipoz_wyks_5	-.6298677	.0050945	-123.64	0.000	-.6398529	-.6198824
_Ipoz_wyks_6	-.7247809	.0068707	-105.49	0.000	-.7382475	-.7113144
_Ipoz_wyks_7	-.808392	.0469905	-17.20	0.000	-.9004933	-.7162907
_cons	6.798214	.0252975	268.73	0.000	6.748631	6.847797

Model selekcji próby Heckmana

- Model Heckmana jest modelem samoselekcji (self-selection) próby - podmioty częściowo same decydują o znalezieniu się w wyselekcjonowanej próbie
- Zmienną zależną obserwujemy tylko dla wyselekcjonowanej części próby, zmienne niezależne obserwujemy dla całej próby
- Problem:
 - obserwacje, którymi dysponujemy są nietypowe na tle całej populacji
 - decyzje o przynależności do próby mogą być oparte są na nieobserwowalnych charakterystykach podmiotów

- jeśli nieobserwowalne charakterystyki wpływające na zmienną, którą modelujemy są skorelowane są z nieobserwowalnymi charakterystykami wpływającymi na selekcje do próby, to otrzymane wyniki estymacji mogą być obciążone

Przykład (klasyczny) Decyzje o podjęciu pracy o oferowana płaca. Chcemy oszacować równanie wyjaśniające zależność oferowanej płacy od charakterystyk respondenta. Niestety obserwujemy oferty płacy jedynie dla pracujących (w postaci płac które otrzymują). Oczywiście jest, że oferowana płaca w_i^o zależy od charakterystyk społeczno ekonomicznych respondanta danych przez zmienne x_{1i} (np. od wykształcenia i płci). Zakładamy, że respondent podejmie pracę jedynie wtedy, gdy oferowana płaca jest wyższa od pewnego minimum w_i^r (reservation wage). Te minimum płacowe jest także zależne od charakterystyk respondenta (np. osoby, które otrzymują rodzinę są silniej motywowane do podjęcia pracy nawet przy niskich stawkach).

1. założmy, że równanie oferowanej płacy ma postać

$$\ln w_i^o = \mathbf{x}_{1i}\boldsymbol{\beta}_1 + u_{1i}$$

2. respondent podejmie pracę jeśli

$$w_i^o > w_i^r$$

założmy, że:

$$\ln w_i^r = \mathbf{x}_{2i}\boldsymbol{\beta}_2 + u_{2i}$$

Podstawiając to równanie do poprzedniej nierówności i logarytmując stronami dochodzimy do wniosku, że respondent podejmie pracę jeśli:

$$\ln w_i^o - \ln w_i^r = \mathbf{x}_{1i}\boldsymbol{\beta}_1 + u_{1i} - \mathbf{x}_{2i}\boldsymbol{\beta}_2 - u_{2i} = \mathbf{x}_i\boldsymbol{\delta}_2 + v_{2i} > 0$$

gdzie $\mathbf{x}_i = (\mathbf{x}_{1i}, \mathbf{x}_{2i})$

Uwagi:

- ponieważ $\mathbf{x}_i = (\mathbf{x}_{1i}, \mathbf{x}_{2i})$, więc wszystkie zmienne wpływające na równanie płac wpływają też równanie selekcji do poby
- skoro $v_{2i} = u_{1i} - u_{2i}$ więc oczekujemy dodatniej korelacji między u_{1i} i v_{2i}
- różnica między przypadkiem analizowanym w przypadku modelu tobitowego: nie znamy dokładnie miejsca cenzurowania $\log w_i^r$
- ponieważ parametry równania $\log w_i^o - \log w_i^r = \mathbf{x}_i \boldsymbol{\delta}_2 + v_{2i}$ są mieszaniną parametrów równania płac i równania selekcji więc nie można ich interpretować jako parametrów równania podaży pracy.

- Podstawowy model:

$$y_1 = \mathbf{x}_1\boldsymbol{\beta} + u_1 \quad (\text{Równanie regresji})$$

$$y^* = \mathbf{x}\boldsymbol{\delta} + u_2 \quad (\text{Równanie selekcji})$$

$$y_2 = \begin{cases} 0 & \text{dla } y^* \leq 0 \\ 1 & \text{dla } y^* > 0 \end{cases}$$

$$(u_1, u_2) \sim N\left(0, \begin{bmatrix} \sigma^2 & \rho \\ \rho & 1 \end{bmatrix}\right)$$

(\mathbf{x}, y_2) są zawsze obserwowalne, y_1 jest obserwowalne tylko dla $y_2 = 1$

- Warunkowa wartość oczekiwana dla obserwacji wyselekcjonowanych

$$E(y_1 | \mathbf{x}, y_2 = 1) = \mathbf{x}_1\boldsymbol{\beta} + \sigma\rho\lambda(\mathbf{x}\boldsymbol{\delta})$$

gdzie $\lambda(\cdot) = \frac{\phi(\cdot)}{\Phi(\cdot)}$ jest nazywany odwrotnością ilorazu Mills'a

- Zwykłą regresją liniową regresję liniową y_1 na x_1 , da niezgodne estymatory parametru β ponieważ pominięty został element $\sigma\rho\lambda(x\delta)$ (problem zmiennej pominiętej: $\sigma\rho\lambda(x\delta)$ jest zazwyczaj skorelowane z x_1)
- Uwaga:
 - w szczególnym przypadku, gdy błędy losowe (charakterystyki nieobserwowalne) w obu równaniach są nieskorelowane ($\rho = 0$) estymator *MNK* jest zgodny
- Zauważmy, że:
 - równanie selekcji opisuje zwykły model probitowy - z modelu probitowego można uzyskać oszacowania δ
 - w równaniu $y_1 = x_1\beta + \sigma\rho\lambda(x\delta) + \varepsilon$ błąd losowy ε jest nieskorelowany z x_1 i $\lambda(x\delta)$ - parametr β można zgodnie oszacować *MNK*

- Dwustopniowa procedura Heckmana:
 1. estymujemy najpierw regresję probitową y_{2i} na x_i , liczymy $\hat{\lambda}_{2i} = \lambda(x_i \hat{\delta})$
 2. przeprowadzamy zwykłą regresję y_{2i} na x_{1i} i $\hat{\lambda}_{2i}$
- Uzyskane w ten sposób estymatory parametru β są zgodne, trudniej uzyskać jest prawidłowe oszacowania jego macierzy wariancji
- Istnienie problemu selekcji próby można przetestować testując istotność parametru $\gamma = \sigma\rho$
- Estymator parametrów w modelu Heckmana można także uzyskać za pomocą *MNW*
- Uwaga:
 - formalnie biorąc model Heckmana można wyestymować nawet wtedy, gdy $x = x_1$ (w równaniu regresji i selekcji występują te same zmienne)

- w literaturze pokazuje się jednak, że dla uzyskania precyzyjnych oszacowań w równaniu selekcji powinny pojawiać się zmienne, które nie pojawiają się w równaniu regresji

Przykład Równanie płac a płac i wykształcenie - dane PGSS. W równaniu selekcji poza charakterystykami respondentów pojawiają się dochody pozostałych członków gospodarstwa. Zakładamy, że wysokie dochody pozostałych członków gospodarstwa wpływają negatywnie na motywację do podjęcia pracy ale nie mają wpływu na poziom płacy. Do obu równań dodano zmienne zerojedynkowe związane z rokiem badania.

- Wyniki regresji metodą dwustopniową

```

Heckman selection model -- two-step estimates      Number of obs      =      7895
(regression model with sample selection)          Censored obs       =      4490
                                                  Uncensored obs     =      3405

                                                  Wald chi2(28)      =      5115.02
                                                  Prob > chi2        =      0.0000
  
```

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
lrincome						
_Isex_2	-.4161068	.0203238	-20.47	0.000	-.4559408	-.3762729
_Idegree_1	-.1686797	.2480776	-0.68	0.497	-.6549029	.3175435
_Idegree_2	.403593	.2313048	1.74	0.081	-.0497561	.8569421
_Idegree_3	.7092761	.2327722	3.05	0.002	.253051	1.165501
_Idegree_4	.7318259	.2381942	3.07	0.002	.2649738	1.198678
_Idegree_5	.9678059	.2342956	4.13	0.000	.508595	1.427017
_Idegree_6	.9905437	.2332893	4.25	0.000	.533305	1.447782
_Idegree_7	1.145547	.2367375	4.84	0.000	.6815499	1.609544
_Idegree_8	.8485571	.2389341	3.55	0.000	.3802549	1.316859
_Idegree_9	1.398745	.2353774	5.94	0.000	.9374135	1.860076

_Ipgssy~1993		.2621812	.0295216	8.88	0.000	.2043199	.3200425
_Ipgssy~1994		.514156	.0297156	17.30	0.000	.4559145	.5723975
_Ipgssy~1995		.7689225	.0298112	25.79	0.000	.7104937	.8273513
_Ipgssy~1997		1.289651	.0275999	46.73	0.000	1.235556	1.343745
_cons		4.306924	.2376954	18.12	0.000	3.841049	4.772798
----- -----							
select							
_Isex_2		-.2238364	.0318749	-7.02	0.000	-.2863101	-.1613627
_Idegree_1		-.1948326	.2648298	-0.74	0.462	-.7138894	.3242242
_Idegree_2		.6486607	.2498993	2.60	0.009	.1588671	1.138454
_Idegree_3		1.49557	.2498923	5.98	0.000	1.00579	1.98535
_Idegree_4		.9601074	.262451	3.66	0.000	.4457129	1.474502
_Idegree_5		1.35211	.2551189	5.30	0.000	.8520858	1.852133
_Idegree_6		1.721247	.2505348	6.87	0.000	1.230208	2.212286
_Idegree_7		2.183448	.2593931	8.42	0.000	1.675047	2.691849
_Idegree_8		1.382837	.2656166	5.21	0.000	.8622379	1.903436
_Idegree_9		2.316108	.2549755	9.08	0.000	1.816366	2.815851
lextrincome		-.5718438	.0248109	-23.05	0.000	-.6204723	-.5232154
_Ipgssy~1993		.1094373	.0512778	2.13	0.033	.0089346	.2099399
_Ipgssy~1994		.2147374	.0525084	4.09	0.000	.1118228	.317652
_Ipgssy~1995		.4566194	.0559933	8.15	0.000	.3468746	.5663643
_Ipgssy~1997		.6723417	.0580917	11.57	0.000	.558484	.7861994
_cons		1.719688	.2771778	6.20	0.000	1.17643	2.262947

mills							
lambda		.2405734	.0387668	6.21	0.000	.1645918	.316555
	rho	0.44030					
	sigma	.54638986					
	lambda	.24057336	.0387668				

- Wyniki regresji *MNW*

```

Heckman selection model          Number of obs      =      7895
(regression model with sample selection)  Censored obs      =      4490
                                          Uncensored obs    =      3405

                                          Wald chi2(14)     =      3803.36
Log likelihood = -6984.195          Prob > chi2       =      0.0000

```

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
lrincome						
_Isex_2	-.4034674	.0195752	-20.61	0.000	-.4418341	-.3651007
_Idegree_1	-.1548126	.2491579	-0.62	0.534	-.6431531	.3335278
_Idegree_2	.3813667	.2321498	1.64	0.100	-.0736385	.8363719
_Idegree_3	.6560963	.2328991	2.82	0.005	.1996224	1.11257
_Idegree_4	.700648	.2388085	2.93	0.003	.232592	1.168704
_Idegree_5	.9247913	.2346873	3.94	0.000	.4648126	1.38477
_Idegree_6	.932306	.2332397	4.00	0.000	.4751646	1.389447
_Idegree_7	1.072007	.2360107	4.54	0.000	.6094347	1.53458
_Idegree_8	.8073619	.2392929	3.37	0.001	.3383564	1.276367
_Idegree_9	1.327589	.2347856	5.65	0.000	.8674171	1.78776

_Ipgssy~1993		.266303	.0291733	9.13	0.000	.2091243	.3234816
_Ipgssy~1994		.5195537	.0293472	17.70	0.000	.4620343	.5770731
_Ipgssy~1995		.7725663	.0294722	26.21	0.000	.7148018	.8303308
_Ipgssy~1997		1.295903	.0272155	47.62	0.000	1.242562	1.349244
_cons		4.394026	.2363644	18.59	0.000	3.93076	4.857292
----- -----							
select							
_Isex_2		-.2284008	.031874	-7.17	0.000	-.2908726	-.165929
_Idegree_1		-.194801	.2648981	-0.74	0.462	-.7139916	.3243897
_Idegree_2		.6475847	.2499664	2.59	0.010	.1576596	1.13751
_Idegree_3		1.493884	.24996	5.98	0.000	1.003972	1.983797
_Idegree_4		.9605035	.2625117	3.66	0.000	.44599	1.475017
_Idegree_5		1.352345	.2551876	5.30	0.000	.8521863	1.852504
_Idegree_6		1.720029	.2506042	6.86	0.000	1.228854	2.211204
_Idegree_7		2.188793	.2594437	8.44	0.000	1.680293	2.697294
_Idegree_8		1.385735	.265691	5.22	0.000	.8649903	1.90648
_Idegree_9		2.313172	.2549965	9.07	0.000	1.813388	2.812956
lextrincome		-.5774507	.0246827	-23.39	0.000	-.6258278	-.5290735
_Ipgssy~1993		.1083887	.0512495	2.11	0.034	.0079415	.2088359
_Ipgssy~1994		.2182079	.0524451	4.16	0.000	.1154174	.3209985
_Ipgssy~1995		.4611189	.055938	8.24	0.000	.3514825	.5707554
_Ipgssy~1997		.6751271	.0579792	11.64	0.000	.56149	.7887642
_cons		1.753689	.2769203	6.33	0.000	1.210936	2.296443

/athrho		.3486491	.0611634	5.70	0.000	.2287711	.4685271
/lnsigma		-.6277223	.0163238	-38.45	0.000	-.6597164	-.5957282
rho		.335177	.054292			.2248619	.4370084
sigma		.5338063	.0087138			.516998	.5511611
lambda		.1789196	.0310179			.1181257	.2397134
LR test of indep. eqns. (rho = 0): chi2(1) = 31.12 Prob > chi2 = 0.0000							

- odrzucamy $H_0 : \rho = 0$, ponieważ
 - dla metody dwustopniowej statystyki z dla oszacowania parametru $\rho\sigma$ (przy zmiennej λ) jest istotnie różna od zera
 - dla MNW na podstawie statystyki LR
- Oszacowany współczynnik korelacji ρ między błędami losowymi z obu równań jest zgodnie z teorią dodatni

- Współczynniki przy zmiennych w równaniu regresji interpretujemy identycznie jak w zwykłym modelu liniowym
- Poza oszacowaniami współczynników w równaniu regresji często interesują nas wielkości efektów cząstkowych.
- Najciekawsza jest
 - wielkość efektów cząstkowych związanych z prawdopodobieństwem selekcji

$$\frac{\partial \Pr(y_2 = 1)}{\partial x} = \phi(x\beta) \beta$$

- wielkość efektów cząstkowych dla y_1^+ gdzie

$$y_1^+ = \begin{cases} y_1 & \text{dla } y_1 \text{ obserwowalnego} \\ 0 & \text{dla } y_1 \text{ nieobserwowalnego} \end{cases}$$

Przykład Kontynuacja

- Efekty czątkowe dla prawdopodobieństw

```
Marginal effects after heckman
      y = Pr(select) (predict, psel)
      = .41197215
```

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
_Isex_2*	-.0890236	.01242	-7.17	0.000	-.113359 -.064688	.572894
_Idegr~1*	-.0740154	.09772	-0.76	0.449	-.26554 .117509	.062571
_Idegr~2*	.2533293	.09542	2.65	0.008	.066313 .440346	.262318
_Idegr~3*	.5392117	.07054	7.64	0.000	.400951 .677473	.244459
_Idegr~4*	.3601846	.08217	4.38	0.000	.199128 .521242	.031032
_Idegr~5*	.4725578	.06144	7.69	0.000	.352141 .592975	.062065
_Idegr~6*	.5866782	.05685	10.32	0.000	.47525 .698106	.185687
_Idegr~7*	.592645	.02194	27.01	0.000	.549638 .635652	.041545
_Idegr~8*	.471792	.05734	8.23	0.000	.359405 .584179	.024446
_Idegr~9*	.6294342	.02332	26.99	0.000	.58373 .675139	.079417
_Ip~1993*	.0424598	.02019	2.10	0.035	.002894 .082025	.186067
_Ip~1994*	.0858635	.02078	4.13	0.000	.045144 .126583	.184927

_Ip~1995*	.1818316	.02191	8.30	0.000	.138881	.224782	.181507
_Ip~1997*	.2638418	.02203	11.98	0.000	.220663	.307021	.260165
lentin~e	-.2247384	.00964	-23.32	0.000	-.243623	-.205854	5.93937

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

- Te efekty cząstkowe interpretujemy tak jak w przypadku probitu i logitu

- Efekty cząstkowe dla y_1^+

Marginal effects after heckman

$$y = E(\text{lrincome}^* | \text{Pr}(\text{select})) \quad (\text{predict}, \text{yexpected})$$

$$= 2.3184213$$

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
_Isex_2*	-.6608731	.0709	-9.32	0.000	-.799843 - .521903	.572894
_Idegr~1*	-.4618541	.54719	-0.84	0.399	-1.53432 .610615	.062571
_Idegr~2*	1.589577	.56954	2.79	0.005	.473302 2.70585	.262318
_Idegr~3*	3.380553	.45301	7.46	0.000	2.49266 4.26844	.244459
_Idegr~4*	2.477582	.54925	4.51	0.000	1.40106 3.5541	.031032
_Idegr~5*	3.313689	.44516	7.44	0.000	2.4412 4.18618	.062065
_Idegr~6*	3.895918	.39973	9.75	0.000	3.11246 4.67937	.185687
_Idegr~7*	4.192403	.27253	15.38	0.000	3.65826 4.72655	.041545
_Idegr~8*	3.237574	.42774	7.57	0.000	2.39922 4.07592	.024446
_Idegr~9*	4.605388	.27225	16.92	0.000	4.07178 5.13899	.079417
_Ip~1993*	.350028	.11715	2.99	0.003	.120413 .579643	.186067
_Ip~1994*	.7133279	.12388	5.76	0.000	.470528 .956128	.184927
_Ip~1995*	1.403312	.13421	10.46	0.000	1.14026 1.66636	.181507
_Ip~1997*	2.143354	.13806	15.52	0.000	1.87276 2.41395	.260165
lextin~e	-1.235701	.05394	-22.91	0.000	-1.34142 -1.12998	5.93937

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

- Zwróćmy uwagę, że całkowity efekt płci i wykształcenia na dochody osiągnane z pracy jest znacznie silniejszy niż by to wynikało z oszacowań uzyskanych z równia płac (np. dla degree9 mamy odpowiednio o 133% lepszą ofertę ale o 461% wyższy oczekiwany dochód z pracy)
- Na oczekiwany dochód osiągnany z pracy (y_1^+) wpływa
 - decyzja o podjęciu pracy: jeśli nie pracujemy do dochód z pracy równy jest zero
 - wielkość płacy jaką oferuje nam rynek