

Szacowanie modeli dla nielosowej selekcji w pakiecie STATA

Paweł Strawiński

Uniwersytet Warszawski
Wydział Nauk Ekonomicznych

17 kwietnia 2005

1 Dane

Przedmiotem badania jest oszacowanie funkcji płacy dla mieszkańców mazowsza, oraz stwierdzenie czy z ekonomicznego punktu widzenia opłacalne jest uzyskanie wyższego wykształcenia.

Zostanie oszacowany następujący model płacy

$$\ln(\text{zarobki}) = f(\text{plec}, \text{wiek}, \text{wiek2}, \text{wwiek}, \text{wwiek2}, \text{rodzina})$$

Jest to równanie płacy bazujące na teorii kapitału ludzkiego. Jeśli współczynniki przy zmiennych `wwiek` oraz `wwiek2` okażą się większe od zera będzie oznaczało to, że wyższe wykształcenie ma pozytywny wpływ na wysokość płac oraz, że ludzie z wyższym wykształceniem szybciej zdobywają doświadczenie zawodowe.

Źródłem danych dla analizowanego przykładu jest część Badanie Budżetów Gospodarstw Domowych przeprowadzonego przez GUS w roku 2000. Z tego badania zostały wybrane pełne obserwacje dla województwa mazowieckiego.

Contains data from C:\stata8\DATA\hecklab.dta

```
obs:          42,312          Badanie budzetow gospodarstw
                               domowych 2000
vars:          14          13 Apr 2005 20:17
size:    1,100,112 (96.7% of memory free)
```

variable name	storage type	display format	value label	variable label
wiek	byte	%9.0g		wiek w latach
ldonp	float	%9.0g		logarytm dochodu osob niepracujacych
ld14	byte	%9.0g		Liczba dzieci do 14 lat
samo	byte	%9.0g		samo zatrudnienie

wiek2	int	%9.0g		kwadrat wieku
wyzsze	byte	%9.0g		wyzsze wykształcenie
srednie	byte	%9.0g		srednie wykształcenie
wwiek	byte	%9.0g		wiek*wyzsze wykształcenie
wwiek2	int	%9.0g		wiek*kwadrat wyzsze- go wykształcenia
lzarobki	float	%9.0g		logarytm zarobkow
plec	byte	%9.0g	plec_ety	plec respondenta
rodzina	byte	%9.0g		posiadanie rodziny
miastodu	byte	%9.0g		duze miasto
select	byte	%9.0g		

Rozpatrywana jest próba z badania przekrojowego zawierająca informacje o 42312 osobach. Zmienna `select` jest zmienną pomocniczą, która wyróżnia obserwacje wybrane do modelu.

Dokonamy oszacowania modelu selekcji za pomocą kilku alternatywnych sposobów. Sprawdzimy jak wygląda rozkład zmiennej zależnej. Ponieważ nie wszystkie badane osoby pracują i osiągają z tego tytułu dochody, to zmienna `logarytm zarobków` posiada braki. By się o tym przekonać wykonajmy

```
. count if lzarobki==.
31230
```

Wobec tego utworzymy zmienną pomocniczą `lz`, która posłuży do zrobienia słupkowego wykresu rozkładu wartości logarytmu dochodu

```
gen lz=lzarobki
recode lz .=0
histogram lz
```


Nieobserwowane wartości zastępujemy zerami dla prostoty. Należy jednak pamiętać, że jeżeli osoba zarabia 0, to logarytm jej zarobków wynosi $-\infty$, i z tego powodu pakiet Stata traktuje te obserwacje jako brakujące.

Jak widzimy rozkład zarobków byłby logarytmo-normalny gdyby nie występowała duża liczba obserwacji zerowych.

2 Model tobitowy

Model tobitowy jest modelem regresji dla próby uciętej. Wybór tego modelu jest ekonomicznie uzasadniony, gdy uznamy że osoby nie pracujące nie podejmują pracy wskutek tego, że została zaoferowana im płaca niższa od płacy minimalnej. Jeśli tak rzeczywiście jest to powinniśmy obserwować dla każdej osoby płacę równą zero lub nie niższą niż minimalna.

W dostępnym zbiorze danych występują jednak zarobki niższe od minimalnych. Są one wynikiem pracy w niepełnym wymiarze godzinowym, lub pracy która jest dodatkiem do świadczeń socjalnych. Z uwagi na ich charakter nie biorą one udziału przy szacowaniu modelu, zmienna `tobit` przyjmuje dla nich wartość zero.



Opcja `ll(·)` ustawia punkt lewostronnego obcięcia próby zadeklarowaną wartość. Wszystkie wartości zmiennej `lz` o wartościach mniejszych bądź równych tej wartości nie są uwzględniane przy obliczaniu oszacowań parametrów modelu.

Ponieważ płaca minimalna według danych GUS w roku 2000 wynosiła przeciętnie 687,50 zł, rozsądne będzie obcięcie w modelu obserwacji o płacach niższych. Aby tego dokonać musimy najpierw obliczyć logarytm tej kwoty

```
. di ln(687.50)
6.5330618
```

Wobec tego używamy obliczonej wartości w opcji `ll(·)`

```
. tobit lz plec wiek wiek2 wwiek wwiek2 rodzina if tobit==1,ll(6.53)
```

```
Tobit estimates                    Number of obs   =    38679
                                   LR chi2(6)       =   14597.80
                                   Prob > chi2        =    0.0000
Log likelihood = -14021.496        Pseudo R2      =    0.3423
```

lz	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
plec	.3577091	.0114236	31.31	0.000	.3353186 .3800996
wiek	.1734932	.0037761	45.95	0.000	.166092 .1808944
wiek2	-.0023535	.0000464	-50.69	0.000	-.0024445 -.0022625
wwiek	.0210963	.0017792	11.86	0.000	.017609 .0245836
wwiek2	-.0000759	.0000346	-2.20	0.028	-.0001436 -8.14e-06
rodzina	.2167354	.0147393	14.70	0.000	.187846 .2456248
_cons	2.966095	.0752042	39.44	0.000	2.818693 3.113497

```

-----+-----
      _se | .6583414 .0060776 (Ancillary parameter)
-----+-----

Obs. summary:      31230 left-censored observations at lz<=6.53
                   7449 uncensored observations

```

Jak widzimy aż 31230 obserwacji zostało ocenzurowanych. W rezultacie otrzymujemy dużo wyższe oszacowania nieznanymi parametrów niż z modelu regresji liniowej. Wyniki interpretujemy identycznie jak w przypadku regresji liniowej. Uzyskane rezultaty są zgodne z teorią ekonomiczną. Dodatni efekt dla mężczyzn, kwadratowa zależność płacy od wieku, i premia do zarobków jeśli się posiada rodzinę są szeroko uzasadnione w literaturze ekonomicznej.

Nawet gdy ograniczymy regresję do niezerowych obserwacji to otrzymane estymatory nie będą zgodne.

```
. reg lz plec wiek wiek2 wwiek wwiek2 rodzina if lz>0 & tobit==1
```

Source	SS	df	MS	Number of obs =	7449
Model	139.235784	6	23.205964	F(6, 7442) =	159.66
Residual	1081.64353	7442	.145343124	Prob > F =	0.0000
Total	1220.87931	7448	.163920423	R-squared =	0.1140
				Adj R-squared =	0.1133
				Root MSE =	.38124

lz	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
plec	.1562638	.0097118	16.09	0.000	.137226 .1753016
wiek	.0201409	.0034538	5.83	0.000	.0133706 .0269113
wiek2	-.0002226	.0000429	-5.20	0.000	-.0003066 -.0001386
wwiek	.0142162	.0013639	10.42	0.000	.0115427 .0168898
wwiek2	-.0001428	.0000288	-4.96	0.000	-.0001992 -.0000864
rodzina	.0017956	.0136775	0.13	0.896	-.025016 .0286073
_cons	6.475064	.0685771	94.42	0.000	6.340634 6.609495

Jak widać uzyskane oszacowania są zdecydowanie niższe niż w modelu tobitowym.

2.1 Efekty krańcowe

Czasem głównym punktem zainteresowania badacza nie są same oszacowania nieznanymi parametry modelu, a np. wartość oczekiwana zarobków. W tym celu obliczymy wartości krańcowe funkcji prawdopodobieństwa (pochodną).

Po oszacowaniu modelu Tobitowego mogą zostać obliczone cztery rodzaje efektów krańcowych.

Po pierwsze efekt krańcowy obliczony w sposób tradycyjny

```
.mfx compute
```

```
Marginal effects after tobit
  y = Fitted values (predict)
    = 5.2004885
```

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
plec*	.3577091	.01142	31.31	0.000	.335319	.380099	.43437	
wiek	.1734932	.00378	45.95	0.000	.166092	.180894	53.677	
wiek2	-.0023535	.00005	-50.69	0.000	-.002445	-.002263	3161.98	
wwiek	.0210963	.00178	11.86	0.000	.017609	.024583	3.56594	
wwiek2	-.0000759	.00003	-2.20	0.028	-.000144	-8.1e-06	203.92	
rodzina*	.2167354	.01474	14.70	0.000	.187847	.245624	.684868	

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

Jest to efekt krańcowy dla nieobserwowanej zmiennej y^* . Są to efekty cząstkowe dla zmiennej ukrytej. Nie posiadają one interpretacji ekonomicznej.

Po drugie efekt krańcowy prawdopodobieństwa nieocenzurowania, czyli:

$$\frac{\partial E(y > y_c | X)}{\partial x}$$

gdzie y_c jest punktem ocenzurowania. Do komendy `mfx compute` dodajemy opcję `predict(p(·,·))`. Jeśli `·` pojawia się po lewej stronie przecinka oznacza, że zmienna nie jest ograniczona z lewej strony, jeśli pojawia się po prawej stronie oznacza, że zmienna jest nieograniczona z góry. Jeśli zamiast kropki są wstawione liczby oznaczają one ocenzurowanie zmiennej zależnej odpowiednio z dołu lub z góry.

```
. mfx compute, predict(p(6.53,.))
```

```
Marginal effects after tobit
  y = Pr(lz>6.53) (predict, p(6.53,.))
    = .02171834
```

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
plec*	.0313834	.00179	17.56	0.000	.02788	.034886	.43437	
wiek	.0136818	.00051	26.98	0.000	.012688	.014676	53.677	
wiek2	-.0001856	.00001	-27.52	0.000	-.000199	-.000172	3161.98	
wwiek	.0016637	.00018	9.05	0.000	.001303	.002024	3.56594	
wwiek2	-5.98e-06	.00000	-2.10	0.036	-.000012	-4.0e-07	203.92	
rodzina*	.0153136	.00121	12.61	0.000	.012933	.017694	.684868	

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

Jeśli zwrócimy uwagę na lewą kolumnę zobaczymy, że przy nazwach wybranych zmiennych pojawiają się gwiazdki. Oznaczają one, że dana zmienna jest dyskretna, bądź jakościowa. W takim przypadku obliczenie pochodnej nie jest możliwe, i liczone są zmiany dyskretne.

$$\frac{E(y > y_c | X = 1) - E(y > y_c | X = 0)}{\Delta x}$$

Druga miara którą możemy obliczyć jest efekt krańcowy dla warunkowej wartości oczekiwanej pod warunkiem nieocenzurowania.

$$\frac{\partial E(y > y_c | X)}{\partial x}$$

```
. mfx compute, predict(e(6.53,.))
```

Marginal effects after tobit

```
y = E(lz|lz>6.53) (predict, e(6.53,.))
= 6.7742446
```

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
plec*	.0413998	.0014	29.52	0.000	.038651 .044149	.43437
wiek	.0196273	.0003	65.56	0.000	.01904 .020214	53.677
wiek2	-.0002663	.00000	-79.96	0.000	-.000273 -.00026	3161.98
wwiek	.0023866	.00021	11.24	0.000	.00197 .002803	3.56594
wwiek2	-8.58e-06	.00000	-2.17	0.030	-.000016 -8.4e-07	203.92
rodzina*	.0237981	.0016	14.89	0.000	.020667 .02693	.684868

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

W takim wypadku współczynniki mają interpretację zmian wysokości logarytmu zarobków pod wpływem zmiany danego czynnika o 1 % pod warunkiem, że osoba ma pracę (zarobki > płacy minimalnej).

Ostatnią miarą są efekty krańcowe dla zmiennej ukrytej

$$\frac{\partial E(y^* | X)}{\partial x}$$

```
. mfx compute, predict (ys(6.53,.))
```

Marginal effects after tobit

```
y = E(lz*|lz>6.53) (predict, ys(6.53,.))
= 6.5353046
```

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
plec*	.0089438	.00058	15.33	0.000	.0078 .010087	.43437
wiek	.003768	.00017	21.63	0.000	.003427 .004109	53.677
wiek2	-.0000511	.00000	-21.87	0.000	-.000056 -.000047	3161.98
wwiek	.0004582	.00005	8.57	0.000	.000353 .000563	3.56594
wwiek2	-1.65e-06	.00000	-2.08	0.037	-3.2e-06 -9.7e-08	203.92
rodzina*	.0041566	.00035	11.73	0.000	.003462 .004851	.684868

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

Wielkości oszacowań nie mają interpretacji.

Gdy mamy zainstalowany pakiet dodatkowy `dtobit`, to wywołując jego nazwę możemy uzyskać wszystkie powyższe oszacowania za pomocą jednej komendy.

Marginal Effects: Latent Variable

variable	dF/dx	Std. Err.	z	P> z	X_at	[95% C.I.]
plec*	.3577091	.0114236	31.31	0.000	0 --> 1	.335319	.380099	
wiek	.1734932	.0037761	45.95	0.000	53.677	.166092	.180894	
wiek2	-.0023535	.0000464	-50.69	0.000	3161.98	-.002445	-.002263	
wwiek	.0210963	.0017792	11.86	0.000	3.56594	.017609	.024583	
wwiek2	-.0000759	.0000346	-2.20	0.028	203.92	-.000144	-8.1e-06	
rodzina*	.2167354	.0147393	14.70	0.000	0 --> 1	.187847	.245624	
_cons	2.966095	.0752042	39.44	0.000	1	2.8187	3.11349	

Pierwsza tabela jest równoważna wywołaniu komendy `mfxf compute`. Są to efekty cząstkowe dla zmiennej ukrytej. Nie posiadają one interpretacji ekonomicznej.

Marginal Effects: Unconditional Expected Value

variable	dF/dx	Std. Err.	z	P> z	X_at	[95% C.I.]
plec*	.0089438	.0002481	36.05	0.000	0 --> 1	.008457	.00943	
wiek	.003768	.000082	45.95	0.000	53.677	.003607	.003929	
wiek2	-.0000511	1.01e-06	-50.69	0.000	3161.98	-.000053	-.000049	
wwiek	.0004582	.0000386	11.86	0.000	3.56594	.000382	.000534	
wwiek2	-1.65e-06	7.51e-07	-2.20	0.028	203.92	-3.1e-06	-1.8e-07	
rodzina*	.0041566	.0003201	12.98	0.000	0 --> 1	.003529	.004784	
_cons	.0644187	.0016333	39.44	0.000	1	.061217	.06762	

Kolejnym wydrukiem są bezwarunkowe wartości oczekiwane. Możemy je również uzyskać komendą `. mfx compute, predict (ys(6.53,.))`. Współczynniki możemy interpretować jako oczekiwaną zmianę wartości zmiennej zależnej pod wpływem zmiany wartości przez zmienną niezależną o 1 %.

Marginal Effects: Conditional on being Uncensored

variable	dF/dx	Std. Err.	z	P> z	X_at	[95% C.I.]
plec*	.0413998	.0012924	32.03	0.000	0 --> 1	.038867	.043933	
wiek	.0196273	.0004272	45.95	0.000	53.677	.01879	.020465	
wiek2	-.0002663	5.25e-06	-50.69	0.000	3161.98	-.000277	-.000256	
wwiek	.0023866	.0002013	11.86	0.000	3.56594	.001992	.002781	
wwiek2	-8.58e-06	3.91e-06	-2.20	0.028	203.92	-.000016	-9.2e-07	
rodzina*	.0237981	.0016675	14.27	0.000	0 --> 1	.02053	.027066	
_cons	.3355541	.0085078	39.44	0.000	1	.318879	.352229	

W trzeciej tabeli są krańcowe efekty obliczone pod warunkiem nieocenzurowania zmiennej. Obliczone efekty są identyczne jak dla komendy `.mfx compute, predict(e(6.53,.))`. Współczynniki interpretujemy jako zmianę zmiennej zależnej pod wpływem zmiany wartości zmiennej zależnej, o ile wartość tej ostatniej była obserwowana.

Marginal Effects: Probability Uncensored

variable	dF/dx	Std. Err.	z	P> z	X_at	[95% C.I.]
plec*	.0313834	.0009009	34.84	0.000	0 --> 1	.029618 .033149
wiek	.0136818	.0002978	45.95	0.000	53.677	.013098 .014265
wiek2	-.0001856	3.66e-06	-50.69	0.000	3161.98	-.000193 -.000178
wwiek	.0016637	.0001403	11.86	0.000	3.56594	.001389 .001939
wwiek2	-5.98e-06	2.73e-06	-2.20	0.028	203.92	-.000011 -6.4e-07
rodzina*	.0153136	.0011624	13.17	0.000	0 --> 1	.013035 .017592
_cons	.2339089	.0059307	39.44	0.000	1	.222285 .245533

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

Ostatnia tabela jest to efekt komendy `mfx compute, predict(p(6.53,.))`, czyli prawdopodobieństwo, że zmienna nie jest ocenzurowana.

3 Model Heckmana

3.1 Regresja liniowa

Na początku zostanie oszacowane równanie regresji liniowej. Jego zaletą jest prostota estymacji i łatwość interpretacji jego wyników.

```
. reg lz plec wiek wiek2 wwiek wwiek2 rodzina
```

Source	SS	df	MS	Number of obs =	42312
Model	88951.1878	6	14825.198	F(6, 42305) =	2209.59
Residual	283844.128	42305	6.70946999	Prob > F =	0.0000
				R-squared =	0.2386
				Adj R-squared =	0.2385
Total	372795.316	42311	8.81083679	Root MSE =	2.5903

lz	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
plec	.5765174	.0264844	21.77	0.000	.5246074 .6284274
wiek	.0226098	.004519	5.00	0.000	.0137524 .0314671
wiek2	-.0008826	.0000437	-20.20	0.000	-.0009683 -.000797
wwiek	.1524604	.0043079	35.39	0.000	.1440167 .160904
wwiek2	-.0021082	.0000695	-30.35	0.000	-.0022443 -.001972
rodzina	.4921381	.0302997	16.24	0.000	.4327501 .5515261
_cons	2.561404	.1063367	24.09	0.000	2.352982 2.769826

Jak widzimy mężczyźni zarabiają przeciętnie więcej, oraz rzeczywiście występuje premia za wyższe studia, ponieważ współczynnik przy zmiennej `wwiek` jest większy od zera i statystycznie istotny. Wpływ kwadratu wieku jest na tyle mały, że możemy go pominąć.

Jeśli przeprowadzimy diagnostykę modelu okaże się że występuje problem zmiennej pominiętej.

```
. ovtest, rhs
(note:  wiek2 dropped due to collinearity)
(note:  wiek2^2 dropped due to collinearity)
(note:  wwiek^2 dropped due to collinearity)
(note:  wwiek^4 dropped due to collinearity)

Ramsey RESET test using powers of the independent variables
Ho:  model has no omitted variables
      F(9, 42297) =      819.10
      Prob > F =      0.0000
```

Jednak gdyby problem ten nie występował, oraz składniki losowe równania doboru i równania zjawiska byłyby nieskorelowane, wówczas estymatory uzyskane metodą najmniejszych kwadratów byłyby zgodne i efektywne.

3.2 Estymacja oparta na MNK

3.2.1 Procedura dwustopniowa

Rozwiązanie problemu obciążenia estymatorów metody najmniejszych kwadratów zaproponował James Heckman. Zaproponował by potraktować obciążenie estymatora tak samo jak traktuje się model o błędnej specyfikacji.

Model szacowany jest za pomocą procedury dwustopniowej. W pierwszym kroku jest równanie uczestnictwa określające prawdopodobieństwo z jakim dana obserwacja trafia do modelu. Następnie prawdopodobieństwa są przekształcane w tzw. odwrócone ilorazy Millsa i są używane jako dodatkowa zmienna objaśniająca w równaniu zjawiska.

```
. heckman lzarobki plec wiek wiek2 wwiek wwiek2 rodzina,
select(plec wiek wiek2 wwiek wwiek2 rodzina ld14 ldonp) twostep

Heckman selection model -- two-step estimates   Number of obs   =   42312
(regression model with sample selection)       Censored obs   =   31230
                                                Uncensored obs =   11082

                                                Wald chi2(12)  =   6296.60
                                                Prob > chi2    =   0.0000

-----+-----
            |      Coef.  Std. Err.      z    P>|z|      [95% Conf. Interval]
-----+-----
lzarobki   |
      plec |   .2853284   .0139103   20.51  0.000   .2580648   .3125921
```

```

      wiek | .0960455   .005161   18.61   0.000   .0859301   .106161
      wiek2 | -.0012665  .0000655  -19.33   0.000  -.0013949  -.0011381
      wwiek | .0198695   .0018766   10.59   0.000   .0161915   .0235475
      wwiek2 | -.0001396  .0000374   -3.73   0.000  -.0002129  -.0000662
      rodzina | .1331675   .0177234    7.51   0.000   .0984302   .1679048
      _cons | 4.607437   .1132801   40.67   0.000   4.385412   4.829462
-----+-----
select
      plec | .4187567   .0165401   25.32   0.000   .3863387   .4511747
      wiek | .1920273   .0042093   45.62   0.000   .1837772   .2002775
      wiek2 | -.0024844  .0000485  -51.23   0.000  -.0025794  -.0023893
      wwiek | .0439469   .0030818   14.26   0.000   .0379066   .0499871
      wwiek2 | -.0004023  .0000543   -7.41   0.000  -.0005088  -.0002959
      rodzina | .1421164   .0204784    6.94   0.000   .1019794   .1822533
      ld14 | .0743513   .0082463    9.02   0.000   .0581888   .0905138
      ldonp | -.3849657  .0087019  -44.24   0.000  -.4020211  -.3679103
      _cons | -1.765745  .0971778  -18.17   0.000  -1.95621  -1.57528
-----+-----
mills
      lambda | .1043912   .0215924    4.83   0.000   .062071   .1467115
-----+-----
      rho | 0.16139
      sigma | .64684178
      lambda | .10439121  .0215924
-----+-----

```

Na początku zwróćmy uwagę na górną część wydruku.

```

. heckman lzarobki plec wiek wiek2 wwiek wwiek2 rodzina,
select(plec wiek wiek2 wwiek wwiek2 rodzina ld14 ldonp) twostep

```

Po poleceniu `heckman` zapisane jest główne równanie modelu, następnie opcja `select` definiuje równanie doboru obserwacji do próby. To równanie ma domyślną zmienną objaśniającą `lzarobki`. W celu zapewnienia identyfikacji równania selekcji i zjawiska powinny różnić się conajmniej jedną zmienną objaśniającą. Eliminując zmienne z równań należy kierować się teorią ekonomiczną i zdrowym rozsądkiem. Należy również pamiętać jakie konsekwencje niesie nałożenie ograniczenia zerowego na daną zmienną. W równaniu zarobków nie uwzględniona została zmienna oznaczająca liczbę dzieci do lat 14 w gospodarstwie domowym `ld14`, bowiem trudno przypuszczać by wpływała ona na zarobki. Inną zmienną nie posiadającą wpływu na wysokość zarobków, a decydującą o podjęciu bądź niepodjęciu pracy jest logarytm dochodu pozapłacowego `ldonp`.

Następnie analizujemy własności statystyczne modelu

```

Heckman selection model -- two-step estimates   Number of obs   =   42312
(regression model with sample selection)       Censored obs    =   31230
                                                Uncensored obs  =   11082

                                                Wald chi2(12)   =   6296.60
                                                Prob > chi2     =   0.0000

```

Informuje nas ona, że estymacja została wykonana za pomocą procedury dwustopniowej regresji z selekcją próby. Zbiór liczył 42312 obserwacji, z czego 31230 zostało ocenzurowanych, a na podstawie pozostałych 11082 zbudowano równanie płacy. Statystyka Walda informuje nas o tym, że zmienne w równaniu płacy są łącznie istotne.

Następnie zajmijmy się dolną częścią

mills						
lambda		.1043912	.0215924	4.83	0.000	.062071 .1467115

rho		0.16139				
sigma		.64684178				
lambda		.10439121	.0215924			

Parametr lambda jest estymatorem "zmiennej pominiętej". Jest on na poziomie istotności 7.4 % różny od zera, co świadczy o tym, że chociaż zjawisko nielosowej selekcji jest słabe jednak występuje. rho jest oszacowaniem współczynnika korelacji między składnikami losowymi obu równań, a sigma jest oszacowaniem odchylenia standardowego składnika losowego w równaniu selekcji.

Wartości oszacowań parametrów probitowego równania selekcji nie mają interpretacji. Ważne jest by były łącznie istotne. Natomiast równanie zjawiska interpretujemy standardowo.

		Coef.	Std. Err.	z	P> z	[95% Conf. Interval]

lzarobki						
plec		.2853284	.0139103	20.51	0.000	.2580648 .3125921
wiek		.0960455	.005161	18.61	0.000	.0859301 .106161
wiek2		-.0012665	.0000655	-19.33	0.000	-.0013949 -.0011381
wwiek		.0198695	.0018766	10.59	0.000	.0161915 .0235475
wwiek2		-.0001396	.0000374	-3.73	0.000	-.0002129 -.0000662
rodzina		.1331675	.0177234	7.51	0.000	.0984302 .1679048
_cons		4.607437	.1132801	40.67	0.000	4.385412 4.829462

Pracujący mężczyźni zarabiają przeciętnie 30 % więcej niż kobiety ($\exp(0.28) \approx 0.3$), pracownicy posiadający rodzinę zarabiają przeciętnie o 14 % ($\exp(0.13) \approx 0.14$) więcej niż osoby samotne. Interpretacja współczynników przy zmiennych odnoszących się do wieku jest bardziej skomplikowana. Można jedynie powiedzieć, że płaca rośnie wraz z wiekiem pracownika do pewnego momentu potem zaczyna spadać, oraz że ludzie z wyższym wykształceniem cieszą się szybszym wzrostem płac od pozostałych pracowników.

3.2.2 Odtworzenie procedury Heckmana

Identyczne wyniki można osiągnąć posługując się instrukcją zawartą w artykule Heckmana. Na początku szacujemy probitowe równanie uczestnictwa. Tłumaczymy zmienną pomocniczą `select` za pomocą czynników, które uznaliśmy za determinujące dobór do próby.

```
. probit select plec wiek wiek2 wwiek wwiek2 rodzina ld14 ldonp
```

```
Iteration 0: log likelihood = -24331.381
Iteration 1: log likelihood = -17267.802
Iteration 2: log likelihood = -16106.018
Iteration 3: log likelihood = -15810.048
Iteration 4: log likelihood = -15786.086
Iteration 5: log likelihood = -15785.916
Iteration 6: log likelihood = -15785.916
```

```
Probit estimates                               Number of obs   =    42312
                                                LR chi2(8)      =   17090.93
                                                Prob > chi2     =    0.0000
Log likelihood = -15785.916                  Pseudo R2      =    0.3512
```

select	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
plec	.4187567	.0165401	25.32	0.000	.3863387 .4511747
wiek	.1920273	.0042093	45.62	0.000	.1837772 .2002775
wiek2	-.0024844	.0000485	-51.23	0.000	-.0025794 -.0023893
wwiek	.0439469	.0030818	14.26	0.000	.0379066 .0499871
wwiek2	-.0004023	.0000543	-7.41	0.000	-.0005088 -.0002959
rodzina	.1421164	.0204784	6.94	0.000	.1019794 .1822533
ld14	.0743513	.0082463	9.02	0.000	.0581888 .0905138
ldonp	-.3849657	.0087019	-44.24	0.000	-.4020211 -.3679103
_cons	-1.765745	.0971778	-18.17	0.000	-1.95621 -1.57528

note: 496 failures and 0 successes completely determined.

Uzyskawszy oszacowania modelu probitowego generujemy wartości dopasowane

```
predict selecthat, xb
```

a następnie ilorazy Millsa

```
gen lambda = normden(selecthat) / norm(selecthat)
```

ostatnim krokiem jest dołączenie zmiennej lambda do równania płacy i wykonanie regresji na podstawie tej części próby dla której znamy wartość logarytmu zarobków.

```
. reg lzarobki plec wiek wiek2 wwiek wwiek2 rodzina lambda
```

Source	SS	df	MS	Number of obs	=	11082
Model	812.074557	7	116.010651	F(7, 11074)	=	281.34
Residual	4566.40334	11074	.412353562	Prob > F	=	0.0000
				R-squared	=	0.1510
				Adj R-squared	=	0.1504
Total	5378.4779	11081	.485378386	Root MSE	=	.64215

lzarobki	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
----------	-------	-----------	---	------	----------------------

```

      plec | .2853284 .0138707 20.57 0.000 .2581394 .3125174
      wiek | .0960455 .00515 18.65 0.000 .0859506 .1061405
      wiek2 | -.0012665 .0000654 -19.37 0.000 -.0013947 -.0011384
      wwiek | .0198695 .0018699 10.63 0.000 .0162043 .0235348
      wwiek2 | -.0001396 .0000373 -3.74 0.000 -.0002127 -.0000664
      rodzina | .1331675 .0176904 7.53 0.000 .0984911 .1678438
      lambda | .1043912 .021504 4.85 0.000 .0622396 .1465428
      _cons | 4.607437 .1129889 40.78 0.000 4.385958 4.828915
-----

```

Jak widać uzyskano dokładnie takie same oszacowania nieznanymi parametrów modelu. Ewentualne niewielkie odchylenia wartości parametrów oraz ich błędów standardowych są wynikiem stosowania różnych metod szacowania macierzy wariancji-kowariancji składnika losowego. W przypadku polecenia `heckman` są one obliczone dużo bardziej skomplikowaną metodą, niż w procedurze dwukrokowej. Mimo wszystko rozbieżności są małe.

Oszacowania parametrów uzyskane metodą najmniejszych kwadratów są zgodne, ale nie są efektywne.

3.3 MNW

3.3.1 MNW odtwarzające wyniki MNK

Za pomocą metody największej wiarygodności można w prosty sposób odtworzyć wyniki otrzymane metodą największych kwadratów. Aby uzyskać ten efekt należy ograniczyć liczbę iteracji do zera dodając do polecenia `heckman` opcję `iterate(0)`

```

. heckman lzarobki plec wiek wiek2 wwiek wwiek2 rodzina,
select(plec wiek wiek2 wwiek wwiek2 rodzina ld14 ldonp) iterate(0)
Iteration 0: log likelihood = -26606.877
convergence not achieved

```

```

Heckman selection model                Number of obs    =    42312
(regression model with sample selection) Censored obs     =    31230
                                         Uncensored obs   =    11082

```

```

Log likelihood = -26606.88              Wald chi2(6)     =    1415.55
                                         Prob > chi2      =    0.0000

```

```

-----
      |          Coef.   Std. Err.   z   P>|z|   [95% Conf. Interval]
-----+-----
lzarobki |
      plec | .2853284 .0134532 21.21 0.000 .2589607 .3116962
      wiek | .0960455 .0045514 21.10 0.000 .0871249 .1049661
      wiek2 | -.0012665 .0000564 -22.45 0.000 -.0013771 -.001156
      wwiek | .0198695 .0018721 10.61 0.000 .0162002 .0235388
      wwiek2 | -.0001396 .0000374 -3.73 0.000 -.0002129 -.0000662
      rodzina | .1331675 .0175083 7.61 0.000 .0988519 .167483
      _cons | 4.607437 .0975805 47.22 0.000 4.416182 4.798691
-----

```

```

select |
      plec | .4187567 .0165362 25.32 0.000 .3863464 .451167
      wiek | .1920273 .0042082 45.63 0.000 .1837794 .2002752
      wiek2 | -.0024844 .0000485 -51.25 0.000 -.0025794 -.0023893
      wwiek | .0439469 .0030805 14.27 0.000 .0379092 .0499846
      wwiek2 | -.0004023 .0000543 -7.41 0.000 -.0005088 -.0002959
      rodzina | .1421164 .020474 6.94 0.000 .101988 .1822447
      ld14 | .0743513 .0082102 9.06 0.000 .0582595 .090443
      ldonp | -.3849657 .0087291 -44.10 0.000 -.4020745 -.367857
      _cons | -1.765745 .0972018 -18.17 0.000 -1.956257 -1.575233
-----+-----
      /athrho | .1628094 .0237722 6.85 0.000 .1162167 .2094021
      /lnsigma | -.4356536 .0071045 -61.32 0.000 -.4495782 -.4217289
-----+-----
      rho | .161386 .0231531 .1156963 .2063942
      sigma | .6468418 .0045955 .6378972 .6559118
      lambda | .1043912 .015237 .0745271 .1342553
-----+-----
LR test of indep. eqns. (rho = 0):   chi2(1) =      5.73   Prob > chi2 = 0.0167
-----+-----

```

W rezultacie otrzymaliśmy identyczne oszacowania jak w pierwszym analizowanym modelu selekcji próby. Metoda największej wiarygodności ma tę zaletę, że jednocześnie szukane są estymatory dla parametrów obu równań. Pozwala to na przeprowadzenie metodą ilorazu wiarygodności test niezależności równań. Jak widać w ostatniej linii wydruku odrzucamy hipotezę, o tym że parametr `rho` jest równy zero, na każdym poziomie istotności. W analizowanym modelu występuje niezerowa korelacja między składnikami losowymi równania doboru i równania zjawiska. Wobec tego zastosowanie modelu Heckmana jest uzasadnione.

3.3.2 MNW

Komendę szacującą model Heckmana pełną metodą największej wiarygodności można zapisać używając dwóch równoważnych sposobów

```
.heckman lzarobki plec wiek wiek2 wwiek wwiek2 rodzina,
select(plec wiek wiek2 wwiek wwiek2 rodzinald14 ldonp)
```

albo alternatywnie

```
.heckman lzarobki plec wiek wiek2 wwiek wwiek2 rodzina,
select(select=plec wiek wiek2 wwiek wwiek2 rodzina ld14 ldonp)
```

W pierwszym zapisie zmienną zależną równania selekcji jest zmienna `lzarobki`. Gdy posiada ona wartość to obserwacja trafia do próby na podstawie której szacowany jest model. Czasami jednak braki w obserwacjach zapisane są jako 0 lub bardzo duża liczba dodatnia. Z tego powodu istnieje drugi sposób wywołania komendy `heckman`. Istnieje możliwość samodzielnego wygenerowania zmiennej zero-jedynkowej która decyduje czy na podstawie danej obserwacji ma być szacowane równanie zjawiska czy też nie. W takim przypadku używamy alternatywnego sposobu wywołania polecenia

heckman. Ten sposób jest przydatny gdy np. chcemy sprawdzić czy jedna z obserwacji w naszym zbiorze nie jest nietypowa bez usuwania jej.

Zbiór danych do ćwiczeń został utworzony w taki sposób, że oba wywołania dają taki sam rezultat.

```
Iteration 0: log likelihood = -26606.877
Iteration 1: log likelihood = -26602.837
Iteration 2: log likelihood = -26602.804
Iteration 3: log likelihood = -26602.804
```

```
Heckman selection model                Number of obs    =    42312
(regression model with sample selection) Censored obs     =    31230
                                         Uncensored obs   =    11082

                                         Wald chi2(6)     =    1254.52
Log likelihood = -26602.8              Prob > chi2      =    0.0000
```

```
-----+-----
          |      Coef.  Std. Err.      z    P>|z|      [95% Conf. Interval]
-----+-----
lzarobki |
   plec  |   .2751912   .0134784    20.42  0.000    .2487741    .3016084
   wiek  |   .0890127   .0046028    19.34  0.000    .0799914    .0980339
  wiek2  |  -.0011702   .0000572   -20.46  0.000   -.0012823   -.0010581
  wwiek  |   .019494    .0018688    10.43  0.000    .0158311    .0231568
  wwiek2 |  -.000142    .0000374    -3.80  0.000   -.0002153   -.0000688
  rodzina |  .125106    .0175096     7.14  0.000    .0907878    .1594242
   _cons |  4.773756    .0988922    48.27  0.000    4.579931    4.967581
-----+-----
select   |
   plec  |   .4196785   .0165414    25.37  0.000    .3872581    .452099
   wiek  |   .192081    .0042088    45.64  0.000    .1838319    .2003301
  wiek2  |  -.0024843   .0000485   -51.24  0.000   -.0025793   -.0023893
  wwiek  |   .0439072   .003081     14.25  0.000    .0378686    .0499458
  wwiek2 |  -.0004016   .0000543    -7.40  0.000   -.0005081   -.0002952
  rodzina |  .1411091   .0204774     6.89  0.000    .1009742    .181244
   ld14  |   .075616    .0082343     9.18  0.000    .0594772    .0917549
   ldonp |  -.385874    .0087099   -44.30  0.000   -.402945    -.368803
   _cons | -1.763376    .097171    -18.15  0.000   -1.953828   -1.572925
-----+-----
   /athrho |   .0936672   .0246531     3.80  0.000    .0453481    .1419863
   /lnsigma | -.4400404    .006844   -64.30  0.000   -.4534544   -.4266264
-----+-----
   rho    |   .0933942   .024438            .045317    .1410398
   sigma  |   .6440104   .0044076            .6354294    .6527074
   lambda |   .0601469   .0158231            .0291342    .0911596
-----+-----
LR test of indep. eqns. (rho = 0):   chi2(1) =    13.87   Prob > chi2 = 0.0002
-----+-----
```

3.4 Efekty Krańcowe

Tak jak w przypadku modelu dla zmiennej ocenzurowanej, możemy obliczyć różne efekty krańcowe dla zmiennej zależnej.

Możemy obliczyć krańcowy efekt pod warunkiem, że zmienna zależna jest obserwowana

$$\frac{\partial E(y \mid y_{\text{obserwowane}})}{\partial x}$$

```
. mfx compute, predict(ycond)
```

```
Marginal effects after heckman
```

```
  y = E(lzarobki|Zg>0) (predict, ycond)
    = 6.2348473
```

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
plec*	.254484	.01311	19.41	0.000	.228788	.28018	.431556	
wiek	.0794953	.00385	20.63	0.000	.071944	.087046	52.7701	
wiek2	-.0010471	.00005	-22.92	0.000	-.001137	-.000958	3062.33	
wwiek	.0173184	.00191	9.05	0.000	.013568	.021069	3.52186	
wwiek2	-.0001221	.00004	-3.23	0.001	-.000196	-.000048	200.282	
rodzina*	.1180917	.01728	6.83	0.000	.084215	.151968	.691293	
ld14	-.0037467	.00108	-3.47	0.001	-.005863	-.001631	.624551	
ldonp	.0191195	.00504	3.79	0.000	.009245	.028994	6.15523	

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

Współczynniki interpretujemy jako zmianą wartości oczekiwanej zmiennej zależnej pod wpływem zmiany zmiennej niezależnej o 1 % pod warunkiem, że zmienna zależna jest obserwowana.

Efekt krańcowy prawdopodobieństwa selekcji

$$\frac{\partial Pr(y_{\text{obserwowane}})}{\partial x}$$

uzyskujemy następująco:

```
. mfx compute, predict(psel)
```

```
Marginal effects after heckman
```

```
  y = Pr(select) (predict, psel)
    = .11312427
```

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
plec*	.0835625	.00358	23.36	0.000	.076552	.090573	.431556	
wiek	.0368492	.00065	56.56	0.000	.035572	.038126	52.7701	
wiek2	-.0004766	.00001	-69.61	0.000	-.00049	-.000463	3062.33	
wwiek	.0084232	.00063	13.31	0.000	.007183	.009664	3.52186	
wwiek2	-.0000771	.00001	-7.15	0.000	-.000098	-.000056	200.282	

rodzina*	.0262026	.00369	7.10	0.000	.018974	.033431	.691293
ld14	.0145063	.00164	8.86	0.000	.011298	.017714	.624551
ldonp	-.0740268	.00217	-34.13	0.000	-.078277	-.069776	6.15523

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

Współczynniki interpretujemy jako zmianę prawdopodobieństwa doboru zmiennej do próby do wpływem zmiany wartości zmiennej niezależnej o 1 %.

Ostatnim efektem jest wartość krańcowa dla prawdopodobieństwa wartości oczekiwanej zmiennej zależnej.

$$\frac{\partial E(y^* | z = 1)}{\partial x}$$

. mfx compute, predict(yexpected)

Marginal effects after heckman

y = E(lzarobki*|Pr(select)) (predict, yexpected)
= .70531254

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
plec*	.5539878	.0228	24.29	0.000	.509292	.598684		.431556
wiek	.2387417	.00413	57.79	0.000	.230644	.246839		52.7701
wiek2	-.0030899	.00004	-70.70	0.000	-.003176	-.003004		3062.33
wwiek	.0544767	.00397	13.73	0.000	.0467	.062253		3.52186
wwiek2	-.0004942	.00007	-7.33	0.000	-.000626	-.000362		200.282
rodzina*	.1756028	.02292	7.66	0.000	.130675	.220531		.691293
ld14	.0900208	.01015	8.87	0.000	.070121	.10992		.624551
ldonp	-.4593827	.01353	-33.96	0.000	-.485895	-.43287		6.15523

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

Współczynniki są efektami krańcowymi dla oczekiwanego dochodu z pracy. Więc jest to sumaryczny efekt wzrost prawdopodobieństwa zatrudnienia i wzrostu oczekiwanej płacy pod wpływem zmiany zmiennej niezależnej.

4 Model efektów oddziaływania (wyłącznie dla IiE)

Model Heckmana ma zastosowanie gdy zmienna zależna jest oceniana. Jednak czasem zachodzi konieczność zbadania oddziaływania jednego czynnika na inny, np. wpływu szkolenia na płace pracowników. Jeżeli jeden z tych czynników jest endogeniczny względem drugiego, np. jeżeli badamy wysokość zarobków w zależności od faktu czy pracownik należy do związku zawodowego to musimy rozpatrzyć dwa przypadki. Jeżeli wierzymy, że przynależność do związku jest sprawą czysto losową wówczas możemy zastosować zwykły model regresji, jednak gdy ufamy że pracownik sam decyduje o przynależności do związku, wówczas bycie w związku jest czynnikiem endogenicznym względem płacy. W takim przypadku używa się modelu efektów oddziaływania. Jest on matematycznie równoważny modelowi selekcji próby, ale

nie wymaga by zmienna zależna była ocenzurowana. Oczywiście istnieje możliwość sztucznego ocenzurowania zmiennej, jednak prowadzi to do utraty informacji.

Zbadamy czy zarobki pracowników z wykształceniem wyższym znacząco różnią się od pensji pozostałych pracowników. Oszacujemy następujący model płacy

$$\ln(\text{zarobki}) = f(\text{plec}, \text{wiek}, \text{wiek2}, \text{rodzina})$$

Model został oszacowany na podstawie całej próby, ale równanie płacy wyłącznie dla osób o wykształceniu wyższym. Pierwszy model oszacowany metodą dwustopniową.

```
Treatment effects model -- two-step estimates   Number of obs   =   11082
                                                Wald chi2(9)    =   1119.09
                                                Prob > chi2     =   0.0000
```

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	

lzarobki						
plec	.3223371	.0166584	19.35	0.000	.2896872	.3549871
wiek	.0941707	.0046847	20.10	0.000	.0849889	.1033525
wiek2	-.0012375	.0000564	-21.93	0.000	-.0013481	-.001127
rodzina	.1134364	.0199527	5.69	0.000	.0743297	.1525431
wyzsze	1.660543	.1414317	11.74	0.000	1.383342	1.937744
_cons	4.576325	.1026646	44.58	0.000	4.375106	4.777544

wyzsze						
plec	-.2617793	.0329088	-7.95	0.000	-.3262792	-.1972793
wiek	-.0404883	.0090814	-4.46	0.000	-.0582875	-.0226891
wiek2	.0005921	.0001032	5.74	0.000	.0003899	.0007942
miastodu	.5173512	.0418904	12.35	0.000	.4352476	.5994548
rodzina	.041806	.0421377	0.99	0.321	-.0407824	.1243944
_cons	-.5390671	.1939149	-2.78	0.005	-.9191333	-.1590008

hazard						
lambda	-.6154013	.0756754	-8.13	0.000	-.7637222	-.4670803

rho	-0.82834					
sigma	.74293573					
lambda	-.61540126	.0756754				

Współczynnik lambda jest statystycznie istotny. Ponadto rho jest równe -1, co jest dowodem na występowanie dokładnej linowej zależności między składnikami resztowymi obu równań.

```
. reg lzarobki plec wiek wiek2 rodzina if wyzsze==1
```

Source	SS	df	MS	Number of obs =	1396

Model	102.373682	4	25.5934206	F(4, 1391) =	55.85
Residual	637.46997	1391	.45828179	Prob > F =	0.0000
				R-squared =	0.1384

-----+-----				Adj R-squared = 0.1359		
Total		739.843653	1395	.530353873	Root MSE	= .67697
-----+-----						
lzarobki		Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
-----+-----						
plec		.341363	.0391103	8.73	0.000	.2646415 .4180844
wiek		.1004311	.010552	9.52	0.000	.0797314 .1211307
wiek2		-.0012122	.0001155	-10.49	0.000	-.0014388 -.0009855
rodzina		.126696	.0467979	2.71	0.007	.0348939 .2184981
_cons		4.924052	.2339208	21.05	0.000	4.465177 5.382928
-----+-----						

Jeżeli porównamy wyniki z modelem regresji dla osób o wykształceniu wyższym, to łatwo zauważymy że zignorowanie problemu endogeniczności spowoduje niedoszacowanie lub przeszacowanie efektów wyższego wykształcenia. Różnice w uzyskanych oszacowaniach są mimo wszystko nieznaczne.

Tak jak poprzednio estymatory metody dwustopniowej nie są efektywne. Lepsze rezultaty daje użycie metody największej wiarygodności.

```
. treatreg lzarobki plec wiek wiek2 rodzina,treat(wyzsze=plec wiek
wiek2 miastodu rodzina)
```

```
Iteration 0: log likelihood = -15765.752
Iteration 1: log likelihood = -14963.736
Iteration 2: log likelihood = -14858.743
Iteration 3: log likelihood = -14852.415
Iteration 4: log likelihood = -14852.309
Iteration 5: log likelihood = -14852.309
```

```
Treatment effects model -- MLE                               Number of obs   =    11082
                                                            Wald chi2(5)     =    1354.83
Log likelihood = -14852.309                               Prob > chi2      =    0.0000
```

-----+-----						
		Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
-----+-----						
lzarobki						
plec		.273855	.0132242	20.71	0.000	.2479359 .299774
wiek		.082542	.0038194	21.61	0.000	.075056 .0900279
wiek2		-.001071	.0000447	-23.98	0.000	-.0011585 -.0009834
rodzina		.1133073	.0173585	6.53	0.000	.0792853 .1473292
wyzsze		.7275764	.0460687	15.79	0.000	.6372833 .8178694
_cons		4.898903	.0801325	61.14	0.000	4.741846 5.05596
-----+-----						
wyzsze						
plec		-.2585516	.0328213	-7.88	0.000	-.3228801 -.194223
wiek		-.0393215	.0090747	-4.33	0.000	-.0571077 -.0215353
wiek2		.00058	.0001031	5.63	0.000	.0003779 .0007821
miastodu		.5575744	.0421984	13.21	0.000	.4748671 .6402817
rodzina		.0471117	.0421107	1.12	0.263	-.0354237 .1296472
-----+-----						

_cons		-.5765116	.1936897	-2.98	0.003	-.9561365	-.1968867

/athrho		-.1693054	.0361993	-4.68	0.000	-.2402547	-.0983561
/lnsigma		-.4364315	.0071235	-61.27	0.000	-.4503933	-.4224697

rho		-.1677061	.0351812			-.2357363	-.0980402
sigma		.6463388	.0046042			.6373774	.6554261
lambda		-.1083949	.0230085			-.1534907	-.0632992

LR test of indep. eqns. (rho = 0):				chi2(1) =	16.65	Prob > chi2 = 0.0000	

Jak widać z testu ilorazu wiarygodności odrzucamy hipotezę o niezależności równań. Zmienne w równaniu płacy są łącznie istotne. Jak widać zmiana metody oszacowania modelu dość znacząco zmieniła wielkości oszacowań.