

1 Metoda Największej Wiarogodności

1.0.1 Wprowadzenie

Dotychczas omawiane modele szacowane były za pomocą metody najmniejszych kwadratów. Jednak takie modele nie wyczerpują wszystkich możliwości. Istnieje duża rodzina modeli których nie da się oszacować za pomocą tej metody. W takich przypadkach stosuje się metodą największej wiarogodności.

1.1 MNW

Metoda największej wiarogodności polega takim wyborze wartości dla szacowanych parametrów, że maksymalizują one funkcję wiarogodności.

Lemat 1 *Wiarogodność jest to funkcja $L : \Theta \rightarrow \mathbb{R}$ dana wzorem:*

$$L(\theta) = f(\theta, x_1, \dots, x_n)$$

Funkcja wiarogodności jest to funkcja gęstości prawdopodobieństwa, ale rozważana jako funkcja parametru lub zbioru parametrów θ przy ustalonych wartościach z próby x_1, \dots, x_n .

Lemat 2 *$\hat{\theta}$ jest estymatorem największej wiarogodności nieznanego parametru θ jeżeli:*

$$f(\hat{\theta}(x_1, \dots, x_n); x_1, \dots, x_n) = \sup_{\theta \in \Theta} f(\theta, x_1, \dots, x_n)$$

1.2 Modele Wyborów Dyskretnych

Wiele zjawisk będących obiektem badania w naukach społecznych ma charakter dyskretny. Dyskretne zmienne zależne powstają w wyniku wyboru jednej z wielu możliwych alternatyw. Liczba potencjalnych wyborów jest skończona. Modele oparte na zasadzie regresji liniowej nie opisują ich z dużą dokładnością, bowiem zmienna zależna w takim przypadku nie jest ciągła. Przykładami zjawisk ekonomicznych o charakterze dyskretnym są np. podjęcie decyzji o zakupie dobra trwałego przez gospodarstwo domowe, czy jego posiadanie, status aktywności zawodowej, czyli to czy osoba pracuje czy jest bezrobotna, czy fakt, że osoba się uczy bądź nie. Te zjawiska łączy wspólna cecha: dla każdego z nich możliwe są dwa stany zmiennej, będącej przedmiotem zainteresowania. Jednak nie wyczerpuje to wszystkich możliwości zastosowania modeli wyborów dyskretnych. Jeżeli te same zjawiska będziemy badali od innej strony, np. nie fakt czy osoba pracuje czy nie, ale jaki

ma zawód, nie fakt czy osoba się uczy czy nie, ale jakie osiągnęła najwyższe wykształcenie, to w takim przypadku każde zjawisko ma więcej niż dwa stany. Takie zjawiska również można analizować za pomocą modeli wyborów dyskretnych.

1.2.1 Model losowej użyteczności

Podstawą teoretyczną dla modeli wyborów dyskretnych jest model losowej użyteczności (*Random Utility Model*). W tym modelu jednostka i dokonująca wyboru może go dokonać spośród J dostępnych alternatyw. Z każdą z nich związany jest pewien poziom osiągniętej użyteczności. Uzyskiwana użyteczność z wyboru możliwości j wynosi:

$$U_{i,j} = X_{i,j} + \varepsilon_{i,j} \quad (1)$$

Można ją rozłożyć na dwie części. Zależną od ujawnionych parametrów związanych ze zmiennymi $X_{i,j}$, oraz nieujawnionych $\varepsilon_{i,j}$. O części ujawnionej zakładamy, że jest wszystkim znana. W jej skład zazwyczaj wchodzi różne charakterystyki społeczno-demograficzne oraz czynniki związane z przedmiotem wyboru. Część nieujawniona jest znana jedynie podejmującemu decyzję, natomiast badacz tworząc model nie zna jej i traktuje ją jako zmienną losową o pewnym rozkładzie prawdopodobieństwa. Zakładamy, że decydent postępuje racjonalnie i dokonuje wyboru maksymalizując swoją użyteczność. Budujemy model, w którym prawdopodobieństwo takiego wyboru wynosi:

$$Pr(y_j = j) = Pr(U_j > U_k \quad \forall j \neq k)$$

Analityczna postać modelu zależy od wyboru rozkładu zaburzeń losowych.

1.2.2 Logit i probit

Rozpocniemy od najprostszego przypadku, w którym zmienna zależna ma charakter dyskretny i przyjmuje tylko dwie wartości. Celem jest oszacowanie parametrów modelu, w którym możliwe są dwa stany: zjawisko nie wystąpiło, zazwyczaj oznaczane przez 0, oraz stan w którym zjawisko wystąpiło, oznaczane przez 1, to model (1) możemy zapisać jako:

$$Pr(y_i = 1) = F(\theta, X_i) \quad (2)$$

czyli prawdopodobieństwo wyboru konkretnej alternatywy jest funkcją od obserwowanych charakterystyk X_i i zbioru parametrów θ . Do lat siedemdziesiątych ubiegłego wieku powszechnie przyjmowano za $F(\theta, X_i)$ funkcję

liniową, a w konsekwencji liniowy model prawdopodobieństwa. Posiada on następujące właściwości:

$$Pr(y_i = 1) = X'_i\beta$$

$$Pr(y_i = 0) = 1 - X'_i\beta$$

wektor parametrów β odzwierciedla wpływ poszczególnych zmiennych na prawdopodobieństwo wystąpienia jednej z dwóch możliwych sytuacji. Jego zaletą jest to, że może być szacowany metodą MNK.

$$y_i = X'_i\beta + \varepsilon \quad (3)$$

Ale ma też poważne wady. Po pierwsze postać (3) nie gwarantuje, że wartość dopasowana modelu $x'\beta$, która jest interpretowana jako prawdopodobieństwo wystąpienia stanu zakodowanego jako 1, leży pomiędzy zerem a jedynką. Po drugie, ponieważ zmienna objaśniana przyjmuje tylko dwie wartości 0 i 1, to składnik losowy ma rozkład dwumianowy i jest równy $\varepsilon = -X'\beta$ lub $\varepsilon = 1 - X'\beta$. Wobec tego można pokazać, że warunkowa wariancja wynosi:

$$var(\varepsilon | X) = X'\beta(1 - X'\beta)$$

Ponieważ $X'\beta$ może przyjmować różne wartości, nie możemy mieć pewności że wariancja w modelu liniowym prawdopodobieństwa będzie nieujemna. Ponadto, składnik losowy jest heteroscedastyczny.

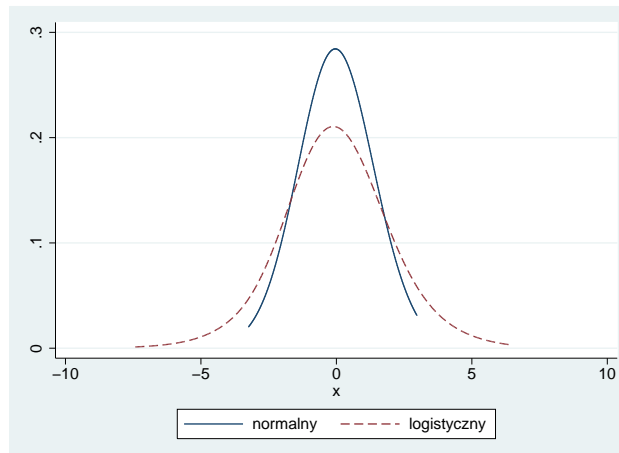
Wobec tych niepożądanych cech modelu liniowego w praktyce ekonometrycznej używa się dwóch innych funkcji prawdopodobieństwa. Przyjęcie rozkładu normalnego prowadzi nas do modelu probitowego:

$$Pr(y_i = 1) = \int_{-\infty}^{X'_i\beta} \phi(t)dt = \Phi(X'_i\beta) \quad (4)$$

A przyjęcie rozkładu logistycznego do modelu logitowego.

$$Pr(y_i = 1) = \frac{e^{X'_i\beta}}{1 + e^{X'_i\beta}} = \Lambda(X'_i\beta) \quad (5)$$

Ponieważ obie funkcje są funkcjami prawdopodobieństwa ich wartości są ograniczone przez 0 i 1. Oba rozkłady są symetryczne względem zera. Tym co je różni jest wariancja. Dla rozkładu normalnego wynosi ona 1, dla logistycznego $\frac{\pi^2}{3}$. Oba rozkłady są do siebie bardzo podobne, z tą różnicą że logistyczny ma grubsze ogony. Jeżeli nie dysponujemy dużą próbą niemożliwością jest rozróżnić z którego z nich została ona wylosowana. Wobec tego, w modelach jednorównaniowych nie ma znaczenia, którą funkcję wybierzemy, z wyjątkiem sytuacji gdy prawdopodobieństwo skupia się w ogonach rozkładu.



1.2.3 Estymacja

Z wyjątkiem modelu prawdopodobieństwa liniowego modele wyborów dyskretnych szacowane są metodą największej wiarygodności. W przypadku modeli dwumianowych każda obserwacja jest traktowana jako realizacja zmiennej losowej z rozkładu Bernoulliego o nieznanym parametrze z prawdopodobieństwem sukcesu $F(x'\beta)$. Łączną funkcję prawdopodobieństwa zapisujemy jako:

$$Pr(Y_1 = y_1, Y_2 = y_2, \dots, Y_n = y_n | X) = \prod_{y_i=0} [1 - F(x'_i\beta)] \prod_{y_i=1} [F(x'_i\beta)]$$

Funkcja wiarygodności dla n obserwacji może być zapisana jako:

$$L(\beta | X) = \prod_{i=1}^n [1 - F(x'_i\beta)]^{1-y_i} [F(x'_i\beta)]^{y_i} \quad (6)$$

logarytmując (6) otrzymujemy:

$$\ln L = \sum_{i=1}^n \left((1 - y_i) [1 - F(x'_i\beta)] + y_i [F(x'_i\beta)] \right) \quad (7)$$

obliczając pochodną funkcji wiarygodności otrzymujemy układ równań normalnych

$$\frac{\partial \ln L}{\partial \beta} = \sum_{i=1}^n \left[y_i \frac{f_i}{F_i} + (1 - y_i) \frac{-f_i}{1 - F_i} \right] x_i = 0 \quad (8)$$

gdzie F_i to dystrybuanta, a f_i funkcja gęstości prawdopodobieństwa. Rozwiązaniem tego układu równań jest wektor parametrów, który nazywamy estymatorem największej wiarygodności i oznaczamy $ENW(\beta)$.

1.2.4 Przykład 1.

Przykład ten pochodzi artykułu Thomasa Mroz'a (1987) dotyczącego aktywności kobiet na rynku pracy. Dane do artykułu pochodzą z roku 1976.¹ Zmienna zależna, przynależność do siły roboczej, przyjmuje wartość 1 gdy kobieta jest zatrudniona, 0 w przeciwnym przypadku.

```
. use "binlfp2.dta", clear
(Data from 1976 PSID-TMroz)
. des lfp k5 k618 age wc hc lwg inc
```

variable name	storage type	display format	value label	variable label
lfp	byte	%9.0g	lfp1bl	Paid Labor Force: 1=yes 0=no
k5	byte	%9.0g		# kids < 6
k618	byte	%9.0g		# kids 6-18
age	byte	%9.0g		Wife's age in years
wc	byte	%9.0g	collbl	Wife College: 1=yes 0=no
hc	byte	%9.0g	collbl	Husband College: 1=yes 0=no
lwg	float	%9.0g		Log of wife's estimated wages
inc	float	%9.0g		Family income excluding wife's

```
. probit lfp k5 k618 age wc hc lwg inc
```

```
Iteration 0:  log likelihood = -514.8732
Iteration 1:  log likelihood = -453.92167
Iteration 2:  log likelihood = -452.69643
Iteration 3:  log likelihood = -452.69496
```

```
Probit estimates
```

Number of obs	=	753
LR chi2(7)	=	124.36
Prob > chi2	=	0.0000
Pseudo R2	=	0.1208

```
Log likelihood = -452.69496
```

	lfp	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
k5		-.8747112	.1135583	-7.70	0.000	-1.097281 - .6521411
k618		-.0385945	.0404893	-0.95	0.340	-.117952 .0407631
age		-.0378235	.0076093	-4.97	0.000	-.0527375 -.0229095
wc		.4883144	.1354873	3.60	0.000	.2227642 .7538645
hc		.0571704	.1240052	0.46	0.645	-.1858754 .3002161
lwg		.3656287	.0877792	4.17	0.000	.1935847 .5376727
inc		-.020525	.0047769	-4.30	0.000	-.0298875 -.0111626
_cons		1.918422	.3806536	5.04	0.000	1.172355 2.66449

¹Dane mogą być ściągnięte do Staty poleceniem `net from http://www.stata-press.com/data/lfr/`, a następnie `net install rmc dvs`, oraz `net get rmc dvs`

Interpretacja parametrów modelu probitowego (logitowego także) jest trudna. W zasadzie możemy zinterpretować jedynie znaki przy zmiennych. Znak dodatni oznacza, że większa wartość zmiennej niezależnej zwiększa prawdopodobieństwo przyjęcia przez zmienną zależną wartości 1, a ujemny oznacza, że zwiększenie wartości danej zmiennej objaśniającej zwiększa prawdopodobieństwo otrzymania zera.

W celu interpretacji ekonomicznej zjawiska często oblicza się przyrosty krańcowe (efekty krańcowe). Otrzymuje je się ze wzoru:

$$\frac{\partial Pr(Y = 1 | X)}{\partial x_k}$$

Pakiet Stata standardowo oblicza krańcowe efekty przyjmując przeciętne wartości pozostałych zmiennych. Nie zawsze są one interesujące i w zastosowaniach warto kontrolować punkt w którym obliczana jest pochodna. Należy pamiętać, że wartość krańcowego efektu zależy od przyjętego poziomu pozostałych zmiennych objaśniających. Dodatkowo, w ogólnym przypadku są one funkcjami nieliniowymi zmiennych objaśniających. Obie cechy wartości krańcowych należy uwzględnić przy interpretacji.

W przypadku objaśniających zmiennych dyskretnych przyrosty krańcowe nie mają sensu. Oblicza się zmianę prawdopodobieństwa, że zmienna Y przyjmie wartość 1, pod wpływem zmiany wartości zmiennej objaśniającej x_k z 0 na 1, według wzoru:

$$\frac{\Delta Pr(Y = 1 | X)}{\Delta x_k}$$

Wartość zmian dyskretnych prawdopodobieństwa zależy od poziomu startowego zmiennej objaśniającej, jej poziomu końcowego (w przypadku zmiennych zero-jedynkowych to nie ma znaczenia), oraz poziomu pozostałych zmiennych.

Obliczmy efekt krańcowy dla kobiety która ukończyła college i obecnie ma 40 lat.

```
. mfx compute, at(wc=1 age=40)
```

```
warning: no value assigned in at() for variables k5 k618 hc lwg inc;
         means used for k5 k618 hc lwg inc
```

```
Marginal effects after probit
      y = Pr(lfp) (predict)
      = .74021954
```

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
k5	-.2836023	.03937	-7.20	0.000	-.360774 -.20643	.237716
k618	-.0125133	.01312	-0.95	0.340	-.038238 .013211	1.35325
age	-.0122633	.00244	-5.03	0.000	-.01704 -.007486	40
wc*	.1783511	.04656	3.83	0.000	.087101 .269601	1
hc*	.0184605	.04045	0.46	0.648	-.060819 .09774	.391766
lwg	.1185456	.03077	3.85	0.000	.058239 .178852	1.09711
inc	-.0066547	.00158	-4.21	0.000	-.009749 -.00356	20.129

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

Dla zmiennych, które zadeklarowaliśmy w opcji `at` pochodna została policzona w zadanym punkcie. Dla pozostałych zmiennych Stata automatycznie przyjęła wartości przeciętne. Jak widzimy, dla dwóch zmiennych obliczone zostały zmiany dyskretne, z powodu ich dyskretnego charakteru (oznaczono je na wydruku gwiazdkami przy nazwie zmiennej).

W tym miejscu należy się zastanowić czy efekt dla zmiennej oznaczającej ukończenie przez męża collegu ma sensowną interpretację ekonomiczną. Uzyskany wynik można zinterpretować następująco: *Dla przeciętnej kobiety fakt, że mąż ukończył college zwiększa prawdopodobieństwo uczestnictwa w rynku pracy o 2 %, zakładając że ma ona męża o przeciętnym wykształceniu.* Oczywiście taka interpretacja nie ma sensu ekonomicznego, bowiem nie istnieje "mąż o przeciętnym wykształceniu", ponieważ jest to osoba która w 39 % ukończyła college i w 61 % go nie ukończyła.

Jest to obserwacja, którą można rozszerzyć na wszystkie zmienne o charakterze nominalnym. Dla takich zmiennych efekty krańcowe powinny być liczone dla ich ustalonych wartości, co więcej takich które posiadają sensowną interpretację ekonomiczną.

Sprawdźmy efekty krańcowe dla `hc=0` oraz `hc==1`

```
. mfx compute, at(wc=1 age=40 hc=0)
```

```
warning: no value assigned in at() for variables k5 k618 lwg inc;
means used for k5 k618 lwg inc
```

```
Marginal effects after probit
```

```
y = Pr(lfp) (predict)
= .73290575
```

variable	dy/dx	Std. Err.	z	P> z	[95% C.I.]	X
k5	-.2876506	.04272	-6.73	0.000	-.371388 -.203913	.237716
k618	-.0126919	.01333	-0.95	0.341	-.03882 .013436	1.35325
age	-.0124383	.00251	-4.96	0.000	-.017349 -.007527	40

```

      wc* | .1798796   .04573   3.93  0.000   .090258   .269502       1
      hc* | .0184605   .04045   0.46  0.648  -.060819   .09774       0
      lwg | .1202378   .03165   3.80  0.000   .058203   .182273   1.09711
      inc | -.0067497   .00169  -3.99  0.000  -.010063  -.003436   20.129

```

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

```
. mfx compute, at(wc=1 age=40 hc=1)
```

```
warning: no value assigned in at() for variables k5 k618 lwg inc;
means used for k5 k618 lwg inc
```

Marginal effects after probit

```

y = Pr(lfp) (predict)
= .75136622

```

```

-----
variable |      dy/dx  Std. Err.      z    P>|z|    [   95% C.I.   ]      X
-----+-----
      k5 | -.2771541   .03763   -7.36  0.000   -.350915  -.203393   .237716
     k618 | -.0122287   .01282   -0.95  0.340   -.037353   .012895   1.35325
      age | -.0119845   .00244   -4.91  0.000   -.016773  -.007196       40
      wc* | .1758324   .0485    3.63  0.000   .08078    .270885       1
      hc* | .0184605   .04045   0.46  0.648  -.060819   .09774       1
      lwg | .1158502   .0302    3.84  0.000   .05666    .175041   1.09711
      inc | -.0065034   .00144  -4.51  0.000  -.009333  -.003674   20.129
-----

```

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

Jak widać dla wielkości efektu krańcowego zmiennej oznaczającej wykształcenie męża hc punkt w którym jest liczona pochodna nie ma znaczenia. Natomiast wartości oszacowań przy pozostałych zmiennych różnią się, co świadczy o nieliniowym wpływie pozostałych czynników na prawdopodobieństwo posiadania pracy przez kobietę.

1.2.5 Miary dopasowania modelu

Zarówno model probit, jak również model logit nie są liniowe względem swoich parametrów. Z tego powodu tradycyjne miary dopasowania modelu do danych empirycznych nie mają zastosowania. Standardową statystyką podawaną w tych modelach jest logarytm ilorazu wiarygodności. Na jego podstawie są tworzona jest większość miar.

Miarą dopasowania zastępującą R^2 jest statystyka oparta na ilorazie funkcji wiarygodności. W literaturze ekonometrycznej występuje pod kilkoma nazwami, najbardziej popularną jest iloraz wiarygodności (*Likelihood Ratio Index (LRI)*). Inne nazwy tej statystyki to *pseudo* – R^2 , lub *McFadden* – R^2 . Mierzy ona łączną istotność oszacowanych parametrów modelu, w stosunku

do hipotezy zerowej, że wszystkie parametry modelu są równe zero. Wartość statystyki jest obliczona na podstawie wartości funkcji logarytmu wiarygodności. LRI jest zdefiniowany następująco:

$$\rho = 1 - \frac{L(\beta)}{L_0}$$

gdzie: $L(\beta)$ jest wartością funkcji logarytmu wiarygodności dla wyestymowanych parametrów, a L_0 jest wartością tej funkcji, gdy wszystkie parametry są równe zero, czyli gdy jedynym regresorem jest stała. Pomimo tego że statystyka LRI przyjmuje wartości z przedziału $(0,1)$, nie ma ona takiej interpretacji jak statystyka R^2 dla modelu regresji liniowej. Nawet gdy model jest idealnie dopasowany do danych, statystyka LRI przyjmuje wartości znacznie mniejsze od 1. Wobec tego nie jest ona dobrą miarą dopasowania modelu. Na jej podstawie możemy jedynie stwierdzić który z wyestymowanych modeli na tej samej próbie danych, z tymi samymi zmiennymi objaśniającymi, jest lepiej do nich dopasowany. Natomiast test nic nie mówi o stopniu dopasowania.

Podobną miarą jest Maximum Likelihood R^2 . Wyraża się ona wzorem:

$$MLR^2 = 1 - \frac{1}{1 + 2 \frac{L(\beta) - L_0}{n}}$$

powiela ona zalety oraz wady statystyki LRI.

```
. fitstat
```

```
Measures of Fit for probit of lfp
```

Log-Lik Intercept Only:	-514.873	Log-Lik Full Model:	-452.695
D(745):	905.390	LR(7):	124.356
		Prob > LR:	0.000
McFadden's R2:	0.121	McFadden's Adj R2:	0.105
Maximum Likelihood R2:	0.152	Cragg & Uhler's R2:	0.204
McKelvey and Zavoina's R2:	0.247	Efron's R2:	0.154
Variance of y*:	1.328	Variance of error:	1.000
Count R2:	0.687	Adj Count R2:	0.274
AIC:	1.224	AIC*n:	921.390
BIC:	4029.539	BIC':	-77.988

Polecenie `fitstat` z dodatku `SPost` do pakietu `Stata` podaje również kilka kolejnych modyfikacji współczynnika R^2 , oraz dodatkowo standardowe kryteria informacyjne Akaike (AIC), oraz Schwarza (BIC).

Rozpatrywany przez nas model możemy również przedstawić w formie logitowej.

```

. logit lfp k5 k618 age wc hc lwg inc

Iteration 0:   log likelihood =  -514.8732
Iteration 4:   log likelihood = -452.63296

Logit estimates                               Number of obs   =       753
                                                LR chi2(7)      =       124.48
                                                Prob > chi2     =       0.0000
Log likelihood = -452.63296                    Pseudo R2      =       0.1209

-----+-----
      lfp |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-----+-----
      k5 | -1.462913   .1970006    -7.43  0.000    -1.849027   -1.076799
     k618 | -.0645707   .0680008    -0.95  0.342    -.1978499    .0687085
     age | -.0628706   .0127831    -4.92  0.000    -.0879249   -.0378162
      wc |  .8072738   .2299799     3.51  0.000    .3565215    1.258026
      hc |  .1117336   .2060397     0.54  0.588    -.2920969    .515564
     lwg |  .6046931   .1508176     4.01  0.000    .3090961    .9002901
     inc | -.0344464   .0082084    -4.20  0.000    -.0505346   -.0183583
    _cons |  3.18214    .6443751     4.94  0.000    1.919188    4.445092
-----+-----

```

Współczynniki tego modelu nie mają bezpośredniej interpretacji ale możemy je przedstawić w postaci ilorazów względnych szans.

1.2.6 Ilorazy względnych szans

Współczynniki modelu zawierają informacje o wpływie zmiennej na poziom prawdopodobieństwa wystąpienia danej kategorii zmiennej objaśnianej. Ich interpretacja jest trudna. Dlatego zazwyczaj nie dokonuje się jej bezpośrednio. Wylicza się ilorazy szans, których interpretacja jest łatwiejsza. Jest to miara podobna do prawdopodobieństwa. Prawdopodobieństwo mierzy szansę zaistnienia jakiegoś stanu, np. szansa wyrzucenia 6 prawidłową sześcienną kostką do gry wynosi $\frac{1}{6}$. Natomiast rzucając kostką mamy szansę 1 do 5, że otrzymanym wynikiem rzutu będzie 6. Iloraz szans jest to stosunek prawdopodobieństw wystąpienia dwóch zdarzeń przy danym wektorze x_i zmiennych objaśniających.

$$\Omega = \frac{Pr(Y = 1)}{Pr(Y = 0)} = \frac{Pr(Y = 1)}{1 - Pr(Y = 1)}$$

W modelu logitowym logarytm ilorazu szans jest funkcją liniową parametrów.

$$\ln \left\{ \frac{Pr(Y = 1)}{1 - Pr(Y = 1)} \right\} = \ln \Omega(x) = X' \beta$$

Dodatkowym czynnikiem ułatwiającym interpretację tego współczynnika jest jego konstrukcja. Jest on obliczony bez konieczności odwoływania się do innych kategorii zmiennej objaśnianej. Ilorazy szans interpretujemy następująco: jednostkowa zmiana zmiennej x_k powoduje zmianę szans o βx_k .

Wyniki estymacji przedstawione za pomocą ilorazów szans wyglądają następująco:

```
. logit lfp k5 k618 age wc hc lwg inc, or
```

```
Iteration 0:   log likelihood =  -514.8732
```

```
Iteration 4:   log likelihood = -452.63296
```

```
Logit estimates                               Number of obs   =       753
                                                LR chi2(7)      =      124.48
                                                Prob > chi2     =       0.0000
Log likelihood = -452.63296                    Pseudo R2      =       0.1209
```

	lfp	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
k5		.2315607	.0456176	-7.43	0.000	.1573902 .3406843
k618		.9374698	.0637487	-0.95	0.342	.820493 1.071124
age		.939065	.0120042	-4.92	0.000	.9158296 .9628899
wc		2.241788	.5155662	3.51	0.000	1.428352 3.518469
hc		1.118215	.2303967	0.54	0.588	.7466962 1.674583
lwg		1.83069	.2761003	4.01	0.000	1.362193 2.460317
inc		.9661401	.0079304	-4.20	0.000	.9507211 .9818092

Można zauważyć, że przy zmiennych ze znakiem ujemnym pojawiły się współczynniki szans mniejsze od 1, a przy zmiennych ze znakiem dodatnim większe od 1. Ich interpretacja jest następująca. Każde kolejne dziecko (k5) zmniejsza szansę zatrudnienia o 0,23 przy innych czynnikach stałych. Jeśli kobieta ukończyła college (wc=1), to szansa że pracuje wynosi 2,24 czyli prawdopodobieństwo, że pracuje wynosi 69%. ($Pr(\text{pracuje}) = \frac{2,24}{3,24} = 0,69$) przy innych czynnikach stałych.

Mając oszacowane dwa modele możemy porównać ich współczynniki.

```
. qui probit lfp k5 k618 age wc hc lwg inc
. estimates store probit
. qui logit lfp k5 k618 age wc hc lwg inc
. estimates store logit
. estimates table probit logit
```

Variable	probit	logit
k5	.2315607	.2315607
k618	.9374698	.9374698
age	.939065	.939065
wc	2.241788	2.241788
hc	1.118215	1.118215
lwg	1.83069	1.83069
inc	.9661401	.9661401

k5		-.87471118	-1.462913
k618		-.03859449	-.06457068
age		-.0378235	-.06287055
wc		.48831439	.80727378
hc		.05717035	.11173357
lwg		.36562871	.60469312
inc		-.02052503	-.03444643
_cons		1.9184223	3.1821405

Wyraźnie widać, że przeciętnie współczynniki modelu logitowego są o 1,6 razy większe od odpowiadających im współczynników modelu probitowego. Nie jest to przypadek, tylko reguła, która obowiązuje dla prawdopodobieństw spoza ogonów rozkładu.

1.2.7 Test ilorazu wiarygodności

Do porównywania różnych form funkcyjnych modeli możemy posłużyć się testem ilorazu wiarygodności. Jest on zbudowany na podobnej zasadzie do testu LRI. Jest on również oparty na różnicy logarytmów wartości funkcji wiarygodności dla dwóch modeli. Ponieważ logarytm funkcji wiarygodności jest zawsze ujemny, statystyka testowa jest zawsze dodatnia.

$$LR = -2(L_1 - L_0) \sim \chi^2(p(c - 1)) \quad (9)$$

gdzie: L_1 jest logarytm funkcji wiarygodności modelu z narzuconymi ograniczeniami, L_0 - logarytm funkcji wiarygodności modelu bez ograniczeń, p - ilością zmiennych niezależnych w modelu, c - ilością kategorii zmiennej objaśnianej, co ma znaczenie przy modelach wielomianowych.

Test ten może służyć zarówno do porównywania dwóch modeli, jak i do testowania narzuconych ograniczeń na parametry modelu. Jego zaletą jest to, że pozwala bezpośrednio porównać dwa wyestymowane na tej samej próbie modele.

Spojrzymy na wyniki testu dla naszego modelu.

```
. qui probit lfp k5 k618 age wc hc lwg inc
. qui fitstat, save
. qui logit lfp k5 k618 age wc hc lwg inc
. fitstat, dif force
```

```
Measures of Fit for logit of lfp
```

```
Warning: Current model estimated by logit, but saved model
estimated by probit
```

	Current	Saved	Difference
Model:	logit	probit	
N:	753	753	0
Log-Lik Intercept Only:	-514.873	-514.873	0.000
Log-Lik Full Model:	-452.633	-452.695	0.062
D:	905.266(745)	905.390(745)	0.124(0)
LR:	124.480(7)	124.356(7)	0.124(0)
Prob > LR:	0.000	0.000	.
McFadden's R2:	0.121	0.121	0.000
McFadden's Adj R2:	0.105	0.105	0.000
Maximum Likelihood R2:	0.152	0.152	0.000
Cragg & Uhler's R2:	0.204	0.204	0.000
McKelvey and Zavoina's R2:	0.217	0.247	-0.030
Efron's R2:	0.155	0.154	0.001
Variance of y*:	4.203	1.328	2.875
Variance of error:	3.290	1.000	2.290
Count R2:	0.693	0.687	0.007
Adj Count R2:	0.289	0.274	0.015
AIC:	1.223	1.224	-0.000
AIC*n:	921.266	921.390	-0.124
BIC:	-4029.663	-4029.539	-0.124
BIC':	-78.112	-77.988	-0.124

Difference of 0.124 in BIC' provides weak support for current model.

Note: p-value for difference in LR is only valid if models are nested.

Jak widać zarówno na podstawie wartości logarytmu funkcji wiarygodności (bliższy zera), jak i BIC preferowany jest model logitowy.

Test ilorazu wiarygodności jest standardową procedurą od wersji 9.0. Sprawdźmy teraz za jej pomocą czy posiadanie dzieci wpływa na prawdopodobieństwo podjęcia pracy przez kobiety. W tym celu przebadamy:

$$H_0 : \beta_{k5} = \beta_{k618} = 0$$

przeciw alteratywie

$$H_1 : \beta_{k5} \neq 0 \vee \beta_{k618} \neq 0$$

Aby to zrobić musimy oszacować pełen model

```
. qui probit lfp k5 k618 age wc hc lwg inc
. estimates store probit
```

oraz model z ograniczeniami

```
. qui probit lfp age wc hc lwg inc
. estimates store probit_r
```

a następnie należy porównać oba modele wykorzystując polecenie `lrtest`

```
. lrtest probit probit_r, stats
```

```
Likelihood-ratio test          LR chi2(2) =    65.97
(Assumption: probit_r nested in probit)  Prob > chi2 =    0.0000
```

Model	Obs	ll(null)	ll(model)	df	AIC	BIC
probit_r	753	-514.8732	-485.6786	6	983.3572	1011.102
probit	753	-514.8732	-452.695	8	921.3899	958.3824

Wynik testu jednoznacznie wskazuje, że odrzucana jest hipoteza o tym że model o mniejszej ilości zmiennych zawiera się w modelu o większej ilości zmiennych. Oznacza to, iż ograniczenia nałożone na model są nieprawidłowe.

1.2.8 Test prawidłowości formy funkcyjnej

Odpowiednikiem testu RESET dla model szacowanych metodą największej wiarygodności, który również działa dla modelu regresji, jest test sprawdzający poprawność funkcji łączącej obserwację. Jego działanie jest analogiczne do testu RESET w którym jako dodatkowy regresor używany jest kwadrat wartości dopasowanej.

```
. estimates restore probit (results probit are active now)
```

```
. linktest
```

```
Iteration 0:  log likelihood = -514.8732
Iteration 1:  log likelihood = -451.38098
Iteration 2:  log likelihood = -449.36073
Iteration 3:  log likelihood = -449.34652
Iteration 4:  log likelihood = -449.34652
```

```
Probit regression          Number of obs =    753
                          LR chi2(2) =    131.05
                          Prob > chi2 =    0.0000
Log likelihood = -449.34652  Pseudo R2 =    0.1273
```

lfp	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_hat	.9697123	.0957237	10.13	0.000	.7820974 1.157327
_hatsq	.2924195	.1085821	2.69	0.007	.0796026 .5052364
_cons	-.0762115	.0586236	-1.30	0.194	-.1911117 .0386887

Pierwsze polecenie przywraca wyniki estymacji zachowane pod nazwą probit, polecenie linktest sprawdza poprawność formy funkcyjnej. Ponieważ


kwadrat wartości dopasowanej jest zmienną istotną w regresji pomocniczej wnioskujemy, że forma funkcyjna modelu nie jest poprawna.

1.2.9 Klasyfikacja

Po oszacowaniu modelu wyborów dyskretnych warto jest sprawdzić jak radzi on sobie z klasyfikowaniem kolejnych obserwacji jako *sukcesy* albo *porażki*. W tym celu bada się jego własności dyskryminacyjne, oraz zdolność do prawidłowego przewidywania sukcesów i porażek.

Krzywa ROC. Dokładność klasyfikacji danych zależy od stopnia w jakim zbudowany model rozróżnia sukcesy od porażek. Miarą dokładności jest pole zawarte pod krzywą ROC. Pole równe 1 oznacza, że model doskonale dyskryminuje między sukcesem a porażką, wartość równa 0,5 oznacza brak możliwości dyskryminacji.

. lroc



Logistic model for lfp


```
number of observations =      753
area under ROC curve   =      0.7364
```

W analizowany przez nas model charakteryzuje się przeciętną zdolnością do rozróżniania kobiet pracujących i niepracujących.

Analiza wrażliwości. Krzywa wrażliwości (ang. *sensitivity*) przedstawia prawdopodobieństwo sklasyfikowania obserwacji jako sukces pod warunkiem, że wystąpił on w rzeczywistości $Pr(+ | D)$, przy różnych poziomach podziału wartości dopasowanych na sukcesy i porażki. Krzywa specyficzności (ang.

emphspecifity) reprezentuje prawdopodobieństwo klasyfikacji obserwacji jako porażka, pod warunkiem że ona wystąpi w rzeczywistości $Pr(-|\sim D)$, przy różnych poziomach podziału wartości dopasowanych na sukcesy i porażki.

. lsens



Analiza trafności Tablica trafności dopasowania porównuje wartości zaobserwowane w rzeczywistości z przewidywaniami modelu. W kolumnach są wartości rzeczywiste. Sukcesy oznaczone są przez D, porażki przez $\sim D$. Wiersze przedstawiają sposób klasyfikacji obserwacji wynikający z dopasowań modelu.

. estat clas (lstat w Stata8)

Probit model for lfp

Classified	True		Total
	D	$\sim D$	
+	342	150	492
-	86	175	261
Total	428	325	753

Classified + if predicted $Pr(D) \geq .5$ True D defined as lfp != 0

Sensitivity	$Pr(+ D)$	79.91%
Specificity	$Pr(- \sim D)$	53.85%
Positive predictive value	$Pr(D +)$	69.51%
Negative predictive value	$Pr(\sim D -)$	67.05%
False + rate for true $\sim D$	$Pr(+ \sim D)$	46.15%

False - rate for true D	Pr(- D)	20.09%
False + rate for classified +	Pr(~D +)	30.49%
False - rate for classified -	Pr(D -)	32.95%

Correctly classified		68.66%

Trafność dopasowania zależy od przyjętego poziomu, który ogranicza wartości dopasowane w modelu na sukcesy i porażki. Standardowo przyjęta wartością jest (0,5). Jeżeli zostanie ustalony poziom wyznaczony przez punkt przecięcia krzywej wrażliwości i specyficzności to zostanie zmaksymalizowana liczba poprawnie sklasyfikowanych obserwacji.

```
. lstat, cutoff(0.52)
```

```
Probit model for lfp
```

Classified	----- True -----		Total
	D	~D	
+	330	129	459
-	98	196	294

Total	428	325	753

```
Classified + if predicted Pr(D) >= .52 True D defined as lfp != 0
```

Sensitivity	Pr(+ D)	77.10%
Specificity	Pr(- ~D)	60.31%
Positive predictive value	Pr(D +)	71.90%
Negative predictive value	Pr(~D -)	66.67%

False + rate for true ~D	Pr(+ ~D)	39.69%
False - rate for true D	Pr(- D)	22.90%
False + rate for classified +	Pr(~D +)	28.10%
False - rate for classified -	Pr(D -)	33.33%

Correctly classified		69.85%

Wybór miar na które należy zwrócić szczególną uwagę zależy od konkretnego celu badania. Jeżeli model jest używany do kontroli jakości leków to chcemy minimalizować przypadki w których pacjent poddany kuracji umrze, czyli będziemy minimalizować „False - rate for true D”. Jeżeli chcemy uniknąć fałszywej klasyfikacji, np przy identyfikacji przestępców szczególną uwagę powinniśmy zwrócić na minimalizowanie „False + rate for true D”.

1.3 Modele wielowartościowe

W badaniach ekonomicznych i społecznych często odpowiedzi na pytania są kodowane za pomocą skali Likerta zgodności z zaproponowanym stwierdzeniem. Wartości tej skali są przyjmowane arbitralne, zazwyczaj od 1 do 5, lub od 1 do 7. Z uwagi na arbitralne ustalenie wartości jakie przyjmuje zmienna nie posiada ona interpretacji ilościowej, ponadto z reguły wartości pośrednie nie posiadają interpretacji. Z tego powodu nie powinno się traktować takich zmiennych identycznie jak traktowane są zmienne kardynalne.

Gdy chcemy zmienną o wielu wartościach użyć jako zmienną zależną modelu to wygodnym narzędziem ekonometrycznym są uogólnione modele wyborów dyskretnych.

1.3.1 Modele wielomianowe

Założmy, że jednostka dokonuje wyboru spośród K dostępnych alternatyw ($K > 2$), dla $K = 2$ problem redukuje się do modelu z binarną zmienną zależną. Jeżeli założymy, że jednostki są racjonalne, to osoba i wybierze alternatywę j , gdy powiązana z nią użyteczność będzie wyższa niż użyteczność uzyskana z wyboru każdej z pozostałych alternatyw.

$$Pr(y_j = j) = Pr(U_j > U_k \quad \forall j \neq k)$$

Inne podejście do modelowania wyborów dyskretnych zakłada, że za wybór odpowiada nieobserwowana zmienna ciągła y^* , o której zakłada się, że ma znany rozkład, zazwyczaj normalny lub logistyczny. Obserwowane jest zmienna dyskretna y przyjmująca wartości $1 \dots K$. Wartości tej zmiennej są związane z wartościami zmiennej y^* .

Niezależność niezwiązanych alternatyw (IIA) Ważnym założeniem modeli wielomianowych jest niezależność wykluczających się alternatyw. W przypadku pojawienia się nowej alternatywy, wszystkie prawdopodobieństwa dotychczas uwzględnionych alternatyw powinny się tak dostosować, aby ilorazy szans wystąpienia danej wartości pomiędzy wszystkimi możliwymi parami kategorii zmiennej objaśnianej pozostały bez zmian. By lepiej zobrazować to założenie przedstawię przykład, który opisał McFadden.

Przypuśćmy, że w pewnym mieście ludzie dojeżdżający do pracy mają do wyboru jazdę samochodem, albo autobusem. Dwie trzecie z nich wybierają samochód. Przypuśćmy, że powstaje nowy "rodzaj" autobusu. Intuicyjnie rzecz ujmując dwie trzecie populacji dalej powinno wybierać samochód jako środek transportu, a pozostali powinni podzielić się pomiędzy dwa rodzaje autobusu. Ale by zachować założenie o niezależności wykluczających się

alternatyw, tylko połowa ludzi powinna używać własnych samochodów od momentu wprowadzenia drugiego rodzaju autobusu. Ponieważ, do momentu uruchomienia nowego autobusu było:

$$\frac{Pr(samochod)}{Pr(autobus)} = \frac{2}{1}$$

to po wprowadzeniu drugiego rodzaju autobusu, ta proporcja powinna być zachowana. Ale jej zachowanie powoduje że prawdopodobieństwo wyboru samochodu jako środka transportu spadnie z 2/3 do 1/2, bowiem

$$\frac{Pr(samochod)}{Pr(autobus_1)} = \frac{2}{1} \quad \frac{Pr(samochod)}{Pr(autobus_2)} = \frac{2}{1}$$

wobec tego $P(samochod) = \frac{1}{2}$, $P(autobus_1) = P(autobus_2) = \frac{1}{4}$.

Modele wielomianowe zakładają niezależność wykluczających się alternatyw. Z tego powodu powinny być używane jedynie w przypadku, gdy kategorie zmiennej objaśnianej są niezależne, oraz rozróżnialne dla jednostki podejmującej decyzję lub dokonującej wyboru. Dodatkowym warunkiem poprawności modelu jest, że różnica pomiędzy kategoriami zmiennej objaśnianej powinna mieć istotny wpływ na decyzję o wyborze. Założenie o niezależności składników losowych powoduje, że modele wielomianowe są poprawne tylko w przypadku braku podobieństw pomiędzy dostępnymi alternatywami.

1.3.2 Przykład 2.

Dane do przykładu pochodzą z amerykańskiego rynku obligacji komercyjnych. Zbiór liczy 98 obserwacji i zawiera informacje firmach. Zmienną zależną jest rating obligacji `rating83` od AAA do C, który zakodowany jest jako wartość całkowita, im wyższa tym wyższy rating. Jego poziom jest tłumaczony za pomocą wskaźnika dochód do wartości `ia83` (ang. *income-to-asset ratio*), oraz zmianą poziomu tego wskaźnika między rokiem 1982 a 1983, zmienna `dia`.

Dane są dostępne w internecie. Wystarczy w Stacie wpisać

```
. use http://www.stata-press.com/data/imeus/panel84extract, clear
```

Zmienna oryginalna `rating` dla pewnych kategorii zawiera małą liczbę obserwacji.

```
. tab rating83
```

rating83	Freq.	Percent	Cum.
AAA	29	29.59	29.59

AA	2	2.04	31.63
A	13	13.27	44.90
BAA	28	28.57	73.47
BA	16	16.33	89.80
B	7	7.14	96.94
C	3	3.06	100.00

Total	98	100.00	

Gdybyśmy chcieli użyć zmiennej `rating83` jako objaśnianej to dla wyboru między ratingiem C a ratingiem B dysponowalibyśmy tylko 10 obserwacjami. W modelu są 2 zmienne, stała, należy oszacować wariancję, czyli zostaje tylko 6 stopni swobody. Powodowało by to niską precyzję oszacowań.

Z tego powodu przed przystąpieniem do szacowania parametrów modelu należy ją przekształcić w taki sposób, aby w każdej kategorii przekształconej zmiennej zawierała podobną ilość obserwacji. Taka operacja ułatwia, a czasami wręcz umożliwia oszacowanie parametrów modelu.

```
. tab rating83c
```

Bond rating, 1983	Freq.	Percent	Cum.
BA_B_C	26	26.53	26.53
BAA	28	28.57	55.10
AA_A	15	15.31	70.41
AAA	29	29.59	100.00

Total	98	100.00	

Na początku potraktujemy `rating` jako zmienną bez ustalonej hierarchii². Wobec tego aby zbudować model użyjemy modelu wielomianowego.

```
. mlogit rating83c ia83 dia
```

```
Iteration 0: log likelihood = -133.04224
Iteration 1: log likelihood = -119.74382
Iteration 2: log likelihood = -118.09549
Iteration 3: log likelihood = -118.00312
Iteration 4: log likelihood = -118.00239
```

```
Multinomial logistic regression      Number of obs =      98
                                      LR chi2(6)      =     30.08
                                      Prob > chi2     =     0.0000
```

²Przyjmujemy takie założenie wyłącznie w celach szkoleniowych.

```

Log likelihood = -118.00239                Pseudo R2      =      0.1130
-----+-----
      rating83c |      Coef.   Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----
BA_B_C         |
   ia83 | -.1303426   .0489834   -2.66   0.008   -.2263484   -.0343369
     dia |  .1542639   .0735878    2.10   0.036    .0100345    .2984934
   _cons |  .9820093   .4966503    1.98   0.048    .0085926    1.955426
-----+-----
BAA            |
   ia83 | -.0454026   .0441004   -1.03   0.303   -.1318378    .0410326
     dia |  .1240656   .0709813    1.75   0.080   -.0150552    .2631865
   _cons |  .4024031   .5154444    0.78   0.435   -.6078494    1.412656
-----+-----
AA_A          |
   ia83 |  .1464149   .0593538    2.47   0.014    .0300836    .2627462
     dia |  .1748879   .0910389    1.92   0.055   -.0035451    .3533209
   _cons | -2.909247   .9744167   -2.99   0.003   -4.819069   -.9994255
-----+-----
(rating83c==AAA is the base outcome)

```

Wyniki dla każdej kategorii są liczone w odniesieniu do poziomu bazowego. Stata jako poziom odniesienia ustaliła rating AAA, ponieważ dla tej kategorii dostępna jest największa liczba obserwacji. Za pomocą opcji `baseoutcome(#)`, gdzie `#` oznacza numer alternatywy, można kontrolować poziom odniesienia. W wierszu pierwszym są współczynniki porównujące rating BA_B_C z AAA, w drugim porównany jest rating BAA z AAA, a w trzecim AA_A. Zbliżone wyniki można uzyskać szacując osobno modele logitowe dla każdej kategorii. Wyniki nie będą takie same, bowiem w przypadku logitu funkcja wiarygodności zależy od 4 parametrów, a w przypadku wielomianowego logitu od 10.

Analogiczne wyniki można uzyskać szacując wielomianowy model probitowy

```

. mprobit rating83c ia83 dia

Iteration 0:   log likelihood = -117.80861
Iteration 1:   log likelihood = -117.62741
Iteration 2:   log likelihood = -117.6271
Iteration 3:   log likelihood = -117.6271

Multinomial probit regression                Number of obs   =      98
                                             Wald chi2(6)    =      21.56
Log likelihood = -117.6271                  Prob > chi2     =      0.0015

```

```

-----+-----
      rating83c |      Coef.   Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----
BA_B_C         |

```

	ia83		-.0911987	.0331999	-2.75	0.006	-.1562694	-.026128
	dia		.0995189	.050054	1.99	0.047	.0014149	.197623
	_cons		.6635147	.3480602	1.91	0.057	-.0186707	1.3457

BAA								
	ia83		-.0284042	.0307741	-0.92	0.356	-.0887203	.0319118
	dia		.0834583	.0505054	1.65	0.098	-.0155304	.1824471
	_cons		.2136007	.3606114	0.59	0.554	-.4931847	.9203861

AA_A								
	ia83		.1113513	.0418002	2.66	0.008	.0294244	.1932782
	dia		.1167499	.0636459	1.83	0.067	-.0079937	.2414935
	_cons		-2.143089	.6606959	-3.24	0.001	-3.438029	.8481486

Porównując wartość logarytmu funkcji wiarygodności i wartość statystyki LR łatwo zauważyć, że wielomianowy model logitowy jest lepiej dopasowany do danych empirycznych.

Tak jak w modelu logitowym wartości współczynników nie mają interpretacji ekonomicznej. Aby im ją nadać należy przedstawić wyniki w postaci ilorazów szans (ryzyk) (ang. *relative risk ratio*)

mlogit, rrr

```

Multinomial logistic regression           Number of obs   =           98
                                           LR chi2(6)      =           30.08
                                           Prob > chi2     =           0.0000
Log likelihood = -118.00239              Pseudo R2       =           0.1130

```

	rating83c		RRR	Std. Err.	z	P> z	[95% Conf. Interval]

BA_B_C							
	ia83		.8777946	.0429974	-2.66	0.008	.7974402 .9662459
	dia		1.166799	.0858622	2.10	0.036	1.010085 1.347827

BAA							
	ia83		.9556127	.0421429	-1.03	0.303	.8764831 1.041886
	dia		1.13209	.0803573	1.75	0.080	.9850576 1.301069

AA_A							
	ia83		1.157676	.0687125	2.47	0.014	1.030541 1.300497
	dia		1.191113	.1084376	1.92	0.055	.9964612 1.423788

(rating83c==AAA is the base outcome)

Im wyższa była wartość wskaźnika dochód do wartości, tym większa szansa na wyższy rating, natomiast wpływ zmiany tego wskaźnika jest ujemny.

Testowanie istotności Na wydruku ze Staty widzimy, że zmienne są łącznie istotne (statystyka LR). Natomiast warto jest przetestować istotność poszczególnych zmiennych. Można zrobić to dwoma metodami. Testem Walda

```
. test ia83

( 1)  [BA_B_C]ia83 = 0
( 2)  [BAA]ia83 = 0
( 3)  [AA_A]ia83 = 0

      chi2( 3) =    17.07
      Prob > chi2 =    0.0007
```

```
. test dia

( 1)  [BA_B_C]dia = 0
( 2)  [BAA]dia = 0
( 3)  [AA_A]dia = 0

      chi2( 3) =     5.82
      Prob > chi2 =    0.1208
```

Na podstawie tego testu odrzucamy hipotezę o łącznej nieistotności zmiennej `ia83`, natomiast zmienna `dia` jest statystycznie nieistotna.

Alternatywnym testem jest test ilorazu wiarygodności. W uzyskaniu jego wyników, jak również innych testów, bardzo przydatny jest dodatkowy pakiet `mlogtest`.

```
. mlogtest, l w

**** Likelihood-ratio tests for independent variables

Ho: All coefficients associated with given variable(s) are 0.
```

rati~83c	chi2	df	P>chi2
ia83	23.935	3	0.000
dia	6.741	3	0.081

```
**** Wald tests for independent variables

Ho: All coefficients associated with given variable(s) are 0.
```

rati~83c	chi2	df	P>chi2
ia83	17.068	3	0.001

```
dia |      5.819    3    0.121
```

Wartości statystyk nieznacznie różnią się w obu testach, jednak dają one takie same konkluzję.

Testowanie niezależności niezwiązanych alternatyw W pakiecie Stata za zaimplementowane dwa testy sprawdzające założenie o niezależności niezwiązanych alternatyw. W obu hipotezą zerową jest niezależność niezwiązanych alternatyw. Oba mają podobną konstrukcję i porównują oszacowania przy pełnym zestawie alternatyw i pominięciu jednej z nich.

Test Hausmana opiera się o statystykę Walda.

```
. mlogtest, h sm
**** Hausman tests of IIA assumption

Ho: Odds(Outcome-J vs Outcome-K) are independent of other alternatives.
```

Omitted	chi2	df	P>chi2	evidence
BA_B_C	-1.834	6	1.000	for Ho
BAA	-5.012	6	1.000	for Ho
AA_A	-1.956	6	1.000	for Ho

Test Small'a i Hsiao bazuje na statystyce ilorazu wiarygodności.

```
**** Small-Hsiao tests of IIA assumption

Ho: Odds(Outcome-J vs Outcome-K) are independent of other alternatives.
```

Omitted	lnL(full)	lnL(omit)	chi2	df	P>chi2	evidence
BA_B_C	-35.112	-33.256	3.713	3	0.294	for Ho
BAA	-29.480	-26.636	5.688	3	0.128	for Ho
AA_A	-36.001	-34.593	2.816	3	0.421	for Ho

Oba testy wskazują, że założenie o niezależności alternatyw jest spełnione. Jest to rzadko spotykany przypadek. Szczególnie w dużych próbach testy mogą dawać przeczące sobie wyniki.

Warto również sprawdzić czy pewnych kategorii zmiennej zależnej nie da się połączyć w jedną.

```
. mlogtest, c lrc
**** Wald tests for combining outcome categories
```


Ho: All coefficients except intercepts associated with given pair of outcomes are 0 (i.e., categories can be collapsed).

Categories tested		chi2	df	P>chi2
BA_B_C-	BAA	3.287	2	0.193
BA_B_C-	AA_A	17.198	2	0.000
BA_B_C-	AAA	8.067	2	0.018
BAA-	AA_A	10.214	2	0.006
BAA-	AAA	3.212	2	0.201
AA_A-	AAA	10.273	2	0.006

**** LR tests for combining outcome categories

Ho: All coefficients except intercepts associated with given pair of outcomes are 0 (i.e., categories can be collapsed).

Categories tested		chi2	df	P>chi2
BA_B_C-	BAA	3.534	2	0.171
BA_B_C-	AA_A	24.973	2	0.000
BA_B_C-	AAA	9.476	2	0.009
BAA-	AA_A	13.573	2	0.001
BAA-	AAA	3.392	2	0.183
AA_A-	AAA	14.280	2	0.001

Oba testy dają podobne wyniki wskazując, że kategorię BAA można połączyć z kategorią BA_B_C, oraz można ją połączyć z kategorią AAA.

Wszystkie testy można wywołać poleceniem

```
. mlogtest, all
```

Na koniec zapamiętajmy wyniki oszacowań

```
. qui mlogit rating83c ia83 dia
. est store mlogit
```

1.3.3 Modele uporządkowane

Czasami zmienna zależna o charakterze nominalnym posiada naturalną hierarchię. Wobec tego modelując zjawisko można i wskazane jest taką informację wykorzystać.

Przystępując do analizy danych o ratingu w poprzednim punkcie pominieliśmy fakt uszeregowania zmiennej zależnej.

```
. ologit rating83c ia83 dia

Iteration 0:  log likelihood = -133.04224
Iteration 1:  log likelihood = -127.30126
Iteration 2:  log likelihood = -127.27148
Iteration 3:  log likelihood = -127.27146

Ordered logistic regression                Number of obs   =          98
                                           LR chi2(2)      =          11.54
                                           Prob > chi2     =          0.0031
Log likelihood = -127.27146              Pseudo R2      =          0.0434
```

rating83c	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
ia83	.0939166	.0296196	3.17	0.002	.0358633 .1519699
dia	-.0866925	.0449789	-1.93	0.054	-.1748496 .0014646
/cut1	-.1853053	.3571432			-.8852931 .5146825
/cut2	1.185726	.3882098			.4248489 1.946603
/cut3	1.908412	.4164895			1.092108 2.724717

Podobne wyniki uzyskamy szacując uszeregowany model probitowy

```
. oprobit rating83c ia83 dia

Iteration 0:  log likelihood = -133.04224
Iteration 1:  log likelihood = -127.87966
Iteration 2:  log likelihood = -127.87756

Ordered probit regression                Number of obs   =          98
                                           LR chi2(2)      =          10.33
                                           Prob > chi2     =          0.0057
Log likelihood = -127.87756              Pseudo R2      =          0.0388
```

rating83c	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
ia83	.0512509	.0167257	3.06	0.002	.0184691 .0840327
dia	-.0496082	.0254406	-1.95	0.051	-.0994709 .0002545
/cut1	-.1877442	.2048421			-.5892274 .213739
/cut2	.6344613	.2156936			.2117095 1.057213
/cut3	1.064523	.2231879			.6270823 1.501963

Tak jak w przypadku modelu wielomianowego model logitowy wydaje się być lepiej dopasowany do danych ze względu na wyższą wartość logarytmu funkcji wiarygodności oraz statystyki LR.

Uporządkowany model logitowy może być traktowany w pewnym przybliżeniu jako model wielomianowy z narzuconymi ograniczeniami. Wobec tego można porównać oba modele.

```
. lrtest ologit mlogit, force
```

Likelihood-ratio test	LR chi2(4)=	18.54
(Assumption: ologit nested in mlogit)	Prob > chi2 =	0.0010

Test wskazuje, że model uporządkowany nie jest zagnieżdżony w modelu wielomianowym, wobec tego wnosi dodatkową informację.

1.4 Modele nielosowej próby

W badaniach ekonometrycznych próba, którą dysponujemy nie zawsze powstaje w sposób czysto losowy. Przeanalizujemy dwa przypadki odejścia od założenia o jej losowym charakterze. Pierwszy z nich będzie analizował obcięcie, bądź ocenzurowanie rozkładu zmiennej zależnej, drugi nie w pełni losowy mechanizm doboru obserwacji do próby i jego konsekwencje.

1.4.1 Tobit

Model próby uciętej powstaje w efekcie obciążenia rozkładu z którego próba jest losowana, lub ocenzurowania wartości zmiennej zależnej. W przypadku ucięcia niedostępne są informacje dotyczące zarówno zmiennej zależnej, jak również zmiennych objaśniających. Ocenzurowanie jest innym, często spotykanym w praktyce badawczej mechanizmem. Ogranicza on zakres zmienności zmiennej zależnej. Ocenzurowanie występuje, gdy zmiennej zależnej jest arbitralnie przypisywana pewna wartość, gdy prawdziwa wartość przekroczy pewien ustalony poziom.

Rozkład obcięty jest to rozkład zmiennej losowej w przypadku, gdy przekracza ona pewną wartość. Wpływ ucięcia na momenty zmiennej losowej wydaje się oczywisty. Wartość oczekiwana (średnia) oddala się od punktu odcięcia, a wariancja zmiennej zmniejsza się.

Rozkład zmiennej uciętej w punkcie a dany jest przez:

$$f(x | x > a) = \frac{f(x)}{Pr(X > a)}$$

gdzie X jest ciągłą zmienną losową, a $f(x)$ jej funkcją gęstości. W zastosowaniach najczęściej używa się obciętego rozkładu normalnego. W takim przypadku:

$$Pr(X > a) = 1 - \Phi\left(\frac{a - \mu}{\sigma}\right) = 1 - \Phi(\alpha)$$

gdzie μ, σ to średnia i odchylenie standardowe rozkładu normalnego, $\Phi(\cdot)$ jego dystrybuanta, a $\alpha = \frac{a-\mu}{\sigma}$.

Lemat 3 *Jeśli zmienna losowa $X \sim N(\mu, \sigma^2)$ oraz a jest stałą, wtedy:*

$$E(X \mid \text{obcięcie}) = \mu + \sigma\lambda(\alpha)$$

$$\text{Var}(X \mid \text{obcięcie}) = \sigma^2[1 - \delta(\alpha)]$$

gdzie:

$$\lambda(\alpha) = \frac{\phi(\alpha)}{1 - \Phi(\alpha)}$$

$$\lambda(\alpha) = \frac{-\phi(\alpha)}{\Phi(\alpha)} \quad x > a$$

$$\delta(\alpha) = \lambda(\alpha)[\lambda(\alpha) - \alpha] \quad x < a$$

Funkcja $\lambda(\alpha)$ nazywana jest odwróconym ilorazem Millsa (*inverse Mills ratio*)

Problem ocenzurowania polega na tym, że pewna część wartości zmiennej zależnej od pewnego jej poziomu jest niedostępna. W takim przypadku, jeżeli zmienna zależna przekracza pewną wartość, to jako wynik zawsze dostajemy tą samą liczbę. Zmienna może być ocenzurowana z dołu lub z góry, bądź z obu stron jednocześnie. Ekonomicznymi przykładami ocenzurowania zmiennej zależnej są: zakup przez gospodarstwa domowe dóbr trwałych, liczba przepracowanych godzin przez kobiety, czy wydatki na urlopy wypoczynkowe. W każdym z wymienionych przykładów wiele obserwacji przyjmuje wartość zero.

Dane mogą być traktowane jako realizacja nieobserwowanego procesu y_i^* , dla którego jedynie obserwujemy:

$$y_i = \begin{cases} y_i^* & \text{dla } y_i \geq 0 \\ 0 & \text{dla } y_i < 0 \end{cases} \quad (10)$$

Stosowanie modeli zmiennej ocenzurowanej jest zalecane, gdy znacząca część obserwacji, powiedzmy więcej niż 5 %, leży na granicy przedziału w którym obserwujemy wartość zmiennej.

Forma modelu ekonometrycznego dla zmiennej ocenzurowanej została zaproponowana przez Tobina w 1958 roku. Zaproponował on model

$$y_i^* = X_i' \beta + \varepsilon \quad (11)$$

$$\varepsilon \sim_{IID} N(0, \sigma^2)$$

w którym obserwowana zmienna y_i jest generowana przez równanie (10).

Proste oszacowanie (11) przez MNK prowadzi do uzyskania obciążonych estymatorów dla populacji bez wprowadzenia poprawki, ze względu na nielosowość cenzurowania. Dzieje się tak, ponieważ $E(Y_i | X) = X'\beta$, zamiast $E(Y_i^* | X) = X'\beta$. Oszacowanie równania regresji na dostępnej podpróbie nie rozwiązuje problemu, bowiem uzyskane oszacowania współczynników będą obciążone w kierunku zera lub niedokładne. Również wariancja będzie niedoszacowana.

Składnik losowy równania modelu ma rozkład $\varepsilon \sim N(0, \sigma^2)$. Wobec tego zmienna objaśniana ma rozkład:

$$(Y_i | X_i) \sim N(X_i'\beta, \sigma^2)$$

dla wartości zmiennej objaśnianej większych od punktu obciążenia, Y_i ma rozkład:

$$E[Y_i | Y_i > a] = X_i'\beta + \sigma \frac{\phi\left(\frac{a - X_i'\beta}{\sigma}\right)}{1 - \Phi\left(\frac{a - X_i'\beta}{\sigma}\right)}$$

Jeżeli punkt obciążenia a znormalizujemy do zera, to rozkład upraszcza się do:

$$Pr(y_i > y | X_i) = \Phi\left(\frac{X_i'\beta - y}{\sigma}\right) = \int_0^y \frac{1}{\sigma} \phi\left(\frac{z - X_i'\beta}{\sigma}\right) dz \quad (12)$$

Zgodne estymatory otrzymywane są metodą największej wiarygodności. Prawdopodobieństwo ocenzurowania wynosi:

$$Pr(y_i = 0 | X_i) = Pr(y_i^* < 0 | X_i) = Pr(X_i'\beta + \varepsilon_i < 0 | X_i) \quad (13)$$

$$Pr(y_i = 0 | X_i) = Pr\left(\frac{\varepsilon_i}{\sigma} < -\frac{X_i'\beta}{\sigma} | X_i\right) = \Phi\left(-\frac{X_i'\beta}{\sigma}\right)$$

Jeżeli zestawimy (12) oraz (13) to możemy zapisać funkcję wiarygodności dla modelu tobitowego.

$$L(\beta) = \Phi\left(-\frac{X_i'\beta}{\sigma}\right)^{\sum \mathbb{I}(y=0)} \left[\frac{1}{\sigma} \phi\left(\frac{z - X_i'\beta}{\sigma}\right)\right]^{\sum \mathbb{I}(y>0)} \quad (14)$$

Gdzie \mathbb{I} oznacza funkcję indykatorową. Estymator wektora β otrzymujemy przez maksymalizację logarytmu funkcji wiarygodności.

1.4.2 Przykład 3.

Rozważmy próbę pracujących kobiet. Z naturalnych powodów liczba godzin pracy jest z dołu ograniczona przez 0.

```
. use http://www.stata-press.com/data/imeus/laborsub, clear

. des

Contains data from
http://www.stata-press.com/data/imeus/laborsub.dta
  obs:          250
  vars:          6                25 Sep 2004 18:36
  size:          2,750 (99.9% of memory free)
```

```
-----
      storage  display  value
variable name  type    format  label    variable label
-----
lfp            byte    %9.0g    1 if woman worked in 1975
whrs           int     %9.0g    Wife's hours of work
kl6            byte    %9.0g    # of children younger than 6
k618           byte    %9.0g    # of children between 6 and 18
wa            byte    %9.0g    Wife's age
we            byte    %9.0g    Wife's educational attainment
-----
```

Co się stanie jeżeli pominiemy problem ucięcia zmiennej i oszacujemy model regresji na nieuciętych obserwacjach .

```
. reg whrs kl6 k618 wa we if whrs>0
```

```
-----+-----
Source |      SS      df      MS              Number of obs =      150
-----+-----
Model | 7326995.15      4 1831748.79          F( 4, 145) =      2.80
Residual | 94793104.2    145 653745.546          Prob > F      = 0.0281
-----+-----
Total | 102120099    149 685369.794          R-squared     = 0.0717
                          Adj R-squared  = 0.0461
                          Root MSE     = 808.55
```

```
-----+-----
whrs |      Coef.   Std. Err.      t    P>|t|     [95% Conf. Interval]
-----+-----
kl6  | -421.4822   167.9734     -2.51  0.013   -753.4748   -89.48953
k618 | -104.4571   54.18616     -1.93  0.056   -211.5538    2.639668
wa   | -4.784917   9.690502     -0.49  0.622    -23.9378    14.36797
we   |  9.353195   31.23793      0.30  0.765    -52.38731    71.0937
_cons | 1629.817    615.1301      2.65  0.009    414.0371   2845.597
-----+-----
```

Jeżeli możemy przyjąć założenie, że składnik losowy w populacji ma rozkład normalny, to możemy uzyskać poprawne oszacowania dla uciętej próby wykorzystując polecenie `truncreg` z odpowiednią opcją `ll(·)` dla ucięcia z dołu, oraz `ul(·)` dla ucięcia z góry. Przyjmując założenie o normalności rozkładu na podstawie oszacowań możemy wnioskować o całej populacji.

```
. truncreg whrs k16 k618 wa we, ll(0)
(note: 100 obs. truncated)
```

Fitting full model:

```
Iteration 0: log likelihood = -1205.6992
Iteration 1: log likelihood = -1200.9873
Iteration 2: log likelihood = -1200.9159
Iteration 3: log likelihood = -1200.9157
Iteration 4: log likelihood = -1200.9157
```

Truncated regression

```
Limit: lower = 0 Number of obs = 150
       upper = +inf Wald chi2(4) = 10.05
Log likelihood = -1200.9157 Prob > chi2 = 0.0395
```

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

eq1						
	k16	-803.0042	321.3614	-2.50	0.012	-1432.861 -173.1474
	k618	-172.875	88.72898	-1.95	0.051	-346.7806 1.030578
	wa	-8.821122	14.36848	-0.61	0.539	-36.98283 19.34059
	we	16.52873	46.50375	0.36	0.722	-74.61695 107.6744
	_cons	1586.26	912.355	1.74	0.082	-201.9233 3374.442

sigma						
	_cons	983.7262	94.44303	10.42	0.000	798.6213 1168.831

Jak widać z porównania wyników obu oszacowań, w modelu regresji zgodnie z przewidywaniami oszacowane wartości parametrów i wariacji są znacznie niższe. Estymatory parametrów są prawie dwukrotnie niższe, a odchylenia standardowego $\sigma=984$, podczas gdy $RMSE=809$. Natomiast wpływ na istotność zmiennych jest niewielki.

Jeżeli przyjmiemy, że każda kobieta, która chce pracować robi to, to problem z którym mamy do czynienia to nie ucięcie rozkładu a ocenzurowanie. Dla tych kobiet czas pracy nie jest dostępny, ale w skutek arbitralnej decyzji badacza został ustalony na zero. Prowadzi to do modelu tobitowego. W tym modelu zakłada się, że te same zmienne determinują fakt nieocenzurowania i wartość nieocenzurowanej obserwacji.

```
. tobit whrs k16 k618 wa we, ll(0)
```

```
Tobit regression Number of obs = 250
LR chi2(4) = 23.03
Prob > chi2 = 0.0001
```

Log likelihood = -1367.0903 Pseudo R2 = 0.0084

whrs	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
k16	-827.7657	214.7407	-3.85	0.000	-1250.731	-404.8008
k618	-140.0192	74.22303	-1.89	0.060	-286.2129	6.174547
wa	-24.97919	13.25639	-1.88	0.061	-51.08969	1.131317
we	103.6896	41.82393	2.48	0.014	21.31093	186.0683
_cons	589.0001	841.5467	0.70	0.485	-1068.556	2246.556
/sigma	1309.909	82.73335			1146.953	1472.865
Obs. summary:						
		100	left-censored observations at whrs<=0			
		150	uncensored observations			
		0	right-censored observations			

Model Tobitowy jest połączeniem modelu liniowego i probitowego. Wobec tego poważny problem dla uzyskania poprawnych oszacowań stanowi heteroscedastyczność. Dlatego częściej stosuje się model Heckamana, który jest bardziej elastyczny i dodatkowo pozwala na to by różne czynniki determinowały ocenzenie i poziom zjawiska.

1.4.3 Heckit

Zjawisko samoselekcji, nielosowej selekcji lub obciążenia próby zostało szeroko opisane we współczesnej literaturze ekonomicznej, zarówno teoretycznej jak i empirycznej. Znaczna część prac w tej dziedzinie dotyczy ekonomii rynku pracy. Pomimo tego, takie same techniki mogą być z powodzeniem stosowane na innych polach, np. długie szeregi zwrotów z papierów wartościowych są samoselekcjonującą się próbą ze względu na obciążenie związane z przetrwaniem (*survivorship bias*), w medycynie przy badaniach nad nowymi lekami występuje obciążenie związane z wycieraniem się próby (*attrition bias*).

Próba którą dysponuje badacz jest reprezentatywna dla całej populacji ale obserwacje dla zmiennej zależnej są ucięte zgodnie z regułą, które błędy są skorelowane z błędami równania analizowanego zjawiska.

Przypadkowe obcięcie W przypadku występowania przypadkowego ucięcia próba jest podzbiorem populacji. Zmienna zależna jest obserwowana, wyłącznie wtedy gdy wartość innej zmiennej wskaże, że obserwacja zostanie wyselekcjonowana.

1.4.4 Przykład 4.

W badaniu „bardziej zamożnych amerykańców” okazało się, że ich przeciętny dochód to 142.000 \$ rocznie. Ludzie podlegający badaniu mieli albo co najmniej 100.000 \$ rocznego dochodu, albo dysponowali majątkiem powyżej 500.000 \$ (nie wliczając wartości domu). Przypuśćmy, że badanie dochodów bazowało tylko na jednostkach, których dochód przekraczał 500.000 \$. Taka selekcja jest formą obciążenia próby, ale sposób selekcji nie koniecznie obcina wszystkie obserwacje o niskich dochodach. Jednak nadal możemy przypuszczać, że przeciętnie jednostki posiadające duży majątek równocześnie będą miały wysokie dochody. Z tego powodu przeciętny dochód w tej subpopulacji nie będzie dobrym przybliżeniem dochodu przeciętnego Amerykanina. Dane w takim badaniu są wybrane nielosowo lub są przypadkowo obciążone.

Studia nad nielosowością próby analizują szkodliwe efekty doboru próby na właściwości tradycyjnych estymatorów, np. otrzymanych metodą najmniejszych kwadratów. Dzięki nim powstały alternatywne metody estymacji i wiele modeli empirycznych. W wielu przypadkach analiza doprowadziła do nowej interpretacji wcześniej uzyskanych wyników.

1.4.5 Model selekcji

Proces budowy podstawowej wersji modelu nielosowego doboru rozpoczyna się od równania badanego zjawiska, które zazwyczaj jest tradycyjnym równaniem regresji

$$y_i^* = X_i' \beta + \varepsilon_i \quad (15)$$

Obserwujemy wartości zmiennej wynikowej y_i tylko dla wyselekcjonowanej części próby. Drugim elementem jest równanie opisujące mechanizm wyboru obserwacji do próby. Dobór zależy od obserwowanych charakterystyk jednostek

$$d_i^* = Z_i' \gamma + \nu_i \quad (16)$$

Zmienna zależna d_i^* jest wskaźnikiem podjętej decyzji o zaliczeniu obserwacji do próby.

W celu uproszczenia postaci funkcyjnej i interpretacji parametrów równania (16) definiuje się wartość progową zmiennej decyzyjnej \bar{d}_i . Wykorzystuje się ją do zastąpienia nieobserwowanej wartości zmiennej decyzyjnej indykatorową zmienną zero-jedynkową

$$d_i = \begin{cases} 1 & \text{gdy } d_i^* \geq \bar{d}_i \\ 0 & \text{gdy } d_i^* < \bar{d}_i \end{cases} \quad (17)$$

Czasem przyjmuje się normalizację $\bar{d}_i = 0$, ale nie jest to konieczne. Celem normalizacji jest uproszczenie wyprowadzenia postaci analitycznej formy funkcyjnej.

Zmienna, której wartości obserwujemy w próbie y_i powstaje jako

$$y_i = y_i^* * d_i \quad (18)$$

Zestawiając powyższe równania możemy przedstawić model nielosowego doboru w postaci strukturalnej

$$\begin{cases} y_i^* = X_i' \beta + \varepsilon_i \\ d_i^* = Z_i' \gamma + \nu_i \\ d_i = \begin{cases} 1 & \text{gdy } d_i^* \geq \bar{d}_i \\ 0 & \text{gdy } d_i^* < \bar{d}_i \end{cases} \\ y_i = y_i^* * d_i \end{cases} \quad (19)$$

Dodatkowo przyjmuje się, że ε_i oraz ν_i są składnikami losowymi o średniej zero, wariancjach odpowiednio σ_ε^2 i σ_ν^2 oraz kowariancji $cov(\varepsilon_i, \nu_i) = \sigma_{\varepsilon\nu}$. W przypadku, gdy kowariancja jest równa zero, a składniki losowe mają rozkłady normalne, równania (15) i (16) są niezależne i nie występuje problem selekcji w modelu.

Z reguły przedstawiając model prezentuje się dwa pierwsze równania. Równanie zmiennej d_i^* nazywane jest równaniem selekcji, a równanie opisujące y_i^* równaniem zjawiska.

Przypuśćmy, że zmienne losowe Y i Z mają dwuwymiarowy rozkład z korelacją ρ . Interesuje nas rozkład zmiennej Y pod warunkiem, że zmienna Z jest większa od pewnej ustalonej wartości. Intuicja nam podpowiada, że jeżeli zmienne Y i Z są dodatnio skorelowane to obcięcie zmiennej Z powinno przesunąć dystrybuantę rozkładu zmiennej Y w prawo. Jesteśmy zainteresowani zarówno rozkładem obciętej zmiennej losowej, jak również jego wartością średnią i wariancją.

Na początku dla uproszczenia analizy zajmijmy się dwuwymiarowym rozkładem normalnym. Obcięty łączny rozkład zmiennych Y i Z jest dany następująco:

$$f(y, z | Z > a) = \frac{f(y, z)}{Pr(Z > a)} \quad (20)$$

By uzyskać rozkład brzegowy przypadkowo obciętej zmiennej Y wystarczy dokonać całkowania powyższego wyrażenia po zmiennej Z . Momenty przypadkowo obciętego rozkładu normalnego wynoszą odpowiednio:

$$E[Y | Z > a] = \int y \frac{f(y, z)}{Pr(Z > a)} dz = \mu_y + \rho \sigma_y \lambda(\alpha_z) \quad (21)$$

$$\text{Var}[Y | Z > a] = \int (Y - EY)^2 \frac{f(y, z)}{\text{Pr}(Z > a)} dz = \sigma_y^2 [1 - \rho^2 \delta(\alpha_z)]$$

gdzie: $\alpha_z = (a - \mu_z) / \sigma_z$, $\lambda(\alpha_z) = \phi(\alpha_z) / [1 - \Phi(\alpha_z)]$, $\delta(\alpha_z) = \lambda(\alpha_z) [\lambda(\alpha_z) - \alpha_z]$, $\Phi(\alpha_z)$ jest dystrybuantą rozkładu normalnego, a $\phi(\alpha_z)$ jego gęstością.

Odpowiednie wyrażenia opisujące momenty zmiennej Z wyglądają następująco:

$$E[z | \text{obcięcie}] = \mu_z + \sigma_y \lambda(\alpha_z) \quad (22)$$

$$\text{Var}[z | \text{obcięcie}] = \sigma_z^2 [1 - \delta(\alpha_z)]$$

Jeżeli obcięcie rozkładu następuje z góry. tzn. $z < a$, należy dokonać podstawienia $\lambda(\alpha_z) = -\phi(\alpha_z) / \Phi(\alpha_z)$

Tak jak można oczekiwać, średnia rozkładu obciętego jest przesunięta w kierunku wyznaczonym przez znak korelacji pomiędzy zmiennymi jeżeli obcięcie następuje z dołu, a w przeciwnym kierunku do znaku korelacji przy obcięciu rozkładu z góry. Dodatkowo obcięcie rozkładu zmniejsza wariancję, ponieważ zarówno $\delta(\alpha_z)$ jak i ρ^2 są pomiędzy zerem a jedynką.

1.4.6 Przykład 5. Regresja w modelu z selekcją

W celu uzasadnienia celowości użycia modelu powstałego w wyniku obcięcia rozkładów rozważymy przykład.

1. *Równanie płac.* Różnica między rynkową pensją jednostki, której może domagać się na rynku pracy, i jej minimalną akceptowaną płacą, powyżej której osoba zdecyduje się uczestniczyć w rynku pracy jest funkcją takich charakterystyk jak wiek i wykształcenie, oraz, np. liczba dzieci i gdzie dana osoba mieszka.
2. *Równanie godzin pracy.* Pożądana liczba godzin pracy dostarczana na rynek zależy od płacy, charakterystyk gospodarstwa domowego np.: czy występują w nim małe dzieci, stanu cywilnego osoby.

Problem obcięcia występuje ponieważ równanie opisuje pożądaną liczbę godzin pracy, ale wartość ta jest obserwowana tylko w przypadku gdy badana osoba pracuje. Wnioskujemy z tego, że płaca rynkowa przekracza płacę minimalną przy której dana osoba skłonna jest podjąć pracę. Z tego powodu zmienna opisująca ilość godzin w drugim równaniu jest przypadkowo obcięta.

Występuje systematyczna różnica pomiędzy wylosowaną próbą a populacją z której ona pochodzi. By opisać powyższe przykłady za pomocą ogólnej

struktury równań, możemy posłużyć się nieobserwowaną zmienną. Równanie selekcji będzie dane następująco:

$$d_i^* = Z_i' \gamma_i + \nu_i$$

równanie zjawiska przyjmuje następującą formę:

$$y_i = X_i' \beta + \varepsilon_i$$

Zmienna y_i jest obserwowana, tylko w przypadku gdy obserwacja znajdzie się w próbie, czyli gdy $d_i^* > 0$.

Przyjmijmy dodatkowo, że ν_i i ε_i mają dwuwymiarowy rozkład normalny ze średnimi zero i korelacją ρ . Przyjmując założenie o normalności rozkładu mamy:

$$\varepsilon_i = \rho u_i + \xi_i \quad (23)$$

gdzie ξ jest niezależne od u_i . Do wyprowadzenia postaci funkcyjnej modelu przydaje się użyteczny fakt o rozkładzie normalnym:

$$E(\nu_i | \nu_i > -x) = \lambda(x) = \frac{\phi(x)}{\Phi(x)} \quad (24)$$

Funkcja $\lambda(x)$ nazywana jest odwróconym ilorazem Millsa. Jest ona iloczynem korelacji między składnikami losowymi i wariancji składnika losowego równania selekcji.

Przyjmując te założenia możemy uzyskać model, który jest dostosowany do obserwacji w naszej próbie:

$$\begin{aligned} E[y_i | y_i \text{ jest obserwowane}] &= E[y_i | d_i^* > 0] \\ &= E[y_i | \nu_i > -Z_i' \gamma_i] \\ &= X_i' \beta + E[\varepsilon_i | \nu_i > -Z_i' \gamma_i] \\ &= X_i' \beta + \rho \sigma_\varepsilon \lambda_i(\alpha_\nu) \\ &= X_i' \beta + \beta_\lambda \lambda_i(\alpha_\nu) \end{aligned}$$

gdzie: $\alpha_u = -Z_i' \gamma / \sigma_u$ oraz $\lambda_i(\alpha_u) = \phi(Z_i' \gamma / \sigma_u) / \Phi(Z_i' \gamma / \sigma_u)$

$$E[Y_i | d_i^* > 0] + \nu_i = X_i \beta + \beta_\lambda + \lambda_i(\alpha_\nu) + \nu_i$$

Regresja przeprowadzona metodą najmniejszych kwadratów z użyciem dostępnych obserwacji, np. regresja przepracowanych godzin na ich determinanty z użyciem wyłącznie obserwacji dla pracujących kobiet daje niezgodne estymatory wektora parametrów β . Możemy potraktować ten problem jako problem zmiennych pominiętych. Regresja metodą MNK y na X i λ daje zgodne estymatory, lecz jeśli λ jest pominięta w regresji, wtedy powstaje błąd na skutek błędnej specyfikacji modelu w wyniku pominięcia zmiennej.

$$y_i = X_i' \beta + \rho \lambda(Z_i \gamma) + \nu_i \quad (25)$$

Ta regresja oszacowana MNK daje zgodne estymatory dla obserwowanej próby. Z drugiej części równania (22) wynika, że jeśli nawet λ_i są obserwowane, metoda najmniejszych kwadratów będzie dawała nieefektywne estymatory, ponieważ zaburzenie losowe ν_i jest heteroscedastyczne.

Krańcowy efekt wpływu regresora na zmienną objaśnianą y_i w obserwowanej próbie zawiera dwa składniki. β jest bezpośrednim efektem mierzonym na poziomie średniej wartości Y_i . Dodatkowo, dla niektórych zmiennych niezależnych, jeśli $Z_i^* > 0$ wtedy oddziałuje na zmienną y_i poprzez parametr λ_i . Całkowity efekt regresora, który występuje zarówno w X_i jak i w Z_i na zmienną y wynosi:

$$\frac{\partial E[Y_i | d_i^* > 0]}{\partial X_{i,k}} = \beta_k - \gamma_k \left(\frac{\rho \sigma_\epsilon}{\sigma_u} \right) \delta_i(\alpha_u) \quad (26)$$

gdzie:

$$\delta_i = \lambda_i^2 - \alpha_i \lambda_i$$

Przypuśćmy, że ρ jest większe od zera oraz $E[Y_i]$ jest większe przy dodatnim d_i^* niż przy ujemnym. Ponieważ δ_i należy do przedziału $(0,1)$, dodatkowy składnik w równaniu (26) redukuje efekt krańcowy. Zmiana prawdopodobieństwa wpływa na średnią wartość Y_i - w grupie z dodatnim d_i^* średnia wartość jest wyższa. Drugi składnik równania kompensuje ten efekt. W rezultacie otrzymujemy warunkową średnią zmianę.

1.4.7 Przykład 6.

Przypuśćmy, że wykształcenie wpływa na prawdopodobieństwo migracji i dochód. Jeżeli założymy, że dochody migrantów są wyższe niż osób o takich samych charakterystykach ale nie migrujących, wtedy krańcowy efekt wykształcenia składa się z dwóch części: pierwsza powstaje w wyniku zwiększenia prawdopodobieństwa awansu do grupy o wyższych dochodach, druga w wyniku wpływu na dochód wewnątrz danej grupy dochodowej. Współczynnik przy zmiennej wykształcenie przeszacowuje krańcowy efekt wykształcenia ludzi migrujących i niedoszacowuje ten efekt dla pozostałych. Oszacowane kierunki i rozmiary efektów mogą różnić się od otrzymanych z wektora β .

W większości przypadków, zmienna decydująca o wyborze do próby d^* nie jest obserwowana. Często znamy jedynie jej znak. Np. z reguły wiemy czy kobieta pracuje czy nie, lub czy osoba migrowała czy nie. Z takiej informacji możemy uzyskać znak zmiennej d^* , ale nic nie wiemy o jej wartości. Ponieważ skala zmiennej d^* nie jest znana, nie może być oszacowana wariancja składnika losowego. Dlatego przy szacowaniu modelu za pomocą procedury dwustopniowej jej wartość arbitralnie jest ustalana na 1.

1.4.8 Estymacja

Parametry modelu z selekcjonującą się próbą mogą być estymowane metodą największej wiarygodności. Ta procedura w literaturze anglojęzycznej jest określana jako *Full Maximum Likelihood*. Wymaga przyjęcia trudnego do spełnienia założenia o dwuwymiarowej normalności rozkładu ν_i i ε_i . Wówczas łącznie są znajdowane oszacowania parametrów β, γ, ρ .

Ale, zazwyczaj używana jest dwustopniowa procedura Heckmana. Polega ona na tym, że:

1. Estymowany jest model probitowy metodą największej wiarygodności. Z tego modelu uzyskuje się estymator γ . Następnie dla każdej obserwacji wylicza się $\hat{\lambda}_i = \phi(X_i' \hat{\gamma}) / \Phi(X_i' \hat{\gamma})$, oraz $\hat{\delta}_i = \hat{\lambda}_i(\hat{\lambda}_i - w_i' \hat{\gamma})$.
2. Przeprowadzana jest regresja metodą MNK y na X i $\hat{\lambda}$ i z niej otrzymujemy β oraz $\beta_\lambda = \rho \sigma_\varepsilon$.

Możliwe jest również uzyskanie zgodnych estymatorów dla indywidualnych parametrów ρ i σ_ε . Dla każdej obserwacji, prawdziwa warunkowa wariancja wynosi:

$$\sigma_i^2 = \sigma_\varepsilon^2(1 - \rho^2 \delta_i)$$

Średnia warunkowa wariancja w próbie dąży do

$$p \lim \frac{1}{n} \sum_{i=1}^n \sigma_i^2 = \sigma_\varepsilon^2(1 - \rho^2 \bar{\delta})$$

czyli do wariancji otrzymywanej metodą najmniejszych kwadratów $\frac{e'e}{n}$. Dla kwadrat współczynnika λ mamy

$$p \lim b_\lambda^2 = \rho^2 \sigma_\varepsilon^2$$

Z modelu probitowego otrzymujemy:

$$p \lim \sum_{i=1}^n \hat{\delta}_i = \bar{\delta}.$$

Możemy uzyskać zgodny estymator parametru σ_ε^2 używając:

$$\sigma_\varepsilon^2 = \frac{1}{n} e'e + \hat{\delta} b_\lambda^2$$

ostatnim estymatorem jest oszacowanie korelacji składników losowych:

$$\hat{\rho}^2 = \frac{b_\lambda^2}{\hat{\sigma}_\varepsilon^2}$$

który uzupełnia zbiór estymatorów modelu.

Ten sposób estymacji jest często używany przy występowaniu problemu samoselekcji, bądź braku losowości próby. Jednak stosowanie procedury Heckmana wymaga ostrożności bowiem jest ona wrażliwa na niespełnienie założenia o normalności rozkładu reszt. często dodatkowym utrudnieniem jest mała wariancja parametru $\lambda(w_i\gamma)$ w próbie. Jest ona konsekwencją słabego dopasowania modelu probitowego do danych empirycznych.

1.4.9 Przykład 7.

Dane do przykładu są wycinkiem amerykańskiego badania rynku pracy. Próba zawiera informacje o 2000 kobiet, wśród których 657 nie pracuje. Zmienna `lw` to logarytm płacy, `age` to wiek w latach, `children` oznacza ilość posiadanych dzieci, a `education` ilość ukończonych lat nauki.

W celu identyfikacji parametrów przyjmujemy że stan cywilny wpływa na partycypację w rynku pracy, ale nie wpływa na wysokość płacy.

```
. use http://www.stata-press.com/data/imeus/womenwk, clear

. heckman lw education age children, select(age married children education)

Iteration 0:   log likelihood = -1065.7948
Iteration 1:   log likelihood = -1053.6855
Iteration 2:   log likelihood = -1052.867
Iteration 3:   log likelihood = -1052.8574
Iteration 4:   log likelihood = -1052.8574

Heckman selection model               Number of obs   =       2000
(regression model with sample selection)  Censored obs   =        657
                                           Uncensored obs =       1343

                                           Wald chi2(3)   =       454.78
Log likelihood = -1052.857             Prob > chi2    =        0.0000

-----+-----
          |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-----+-----
lw       |
  education |   .0397189   .0024525   16.20   0.000   .0349121   .0445256
    age     |   .0075872   .0009748    7.78   0.000   .0056767   .0094977
  children |  -.0180477   .0064544   -2.80   0.005  -.0306981  -.0053973
    _cons  |   2.305499   .0653024   35.30   0.000   2.177509   2.43349
-----+-----
select   |
    age   |   .0350233   .0042344    8.27   0.000   .0267241   .0433225
  married |   .4547724   .0735876    6.18   0.000   .3105434   .5990014
```

children		.4538372	.0288398	15.74	0.000	.3973122	.5103621
education		.0565136	.0110025	5.14	0.000	.0349492	.0780781
_cons		-2.478055	.1927823	-12.85	0.000	-2.855901	-2.100208

/athrho		.3377674	.1152251	2.93	0.003	.1119304	.5636045
/lnsigma		-1.375543	.0246873	-55.72	0.000	-1.423929	-1.327156

rho		.3254828	.1030183			.1114653	.5106469
sigma		.2527024	.0062385			.2407662	.2652304
lambda		.0822503	.0273475			.0286501	.1358505

LR test of indep. eqns. (rho = 0):				chi2(1) =	5.53	Prob > chi2 =	0.0187

Test ilorazu wiarygodności odrzuca hipotezę o niezależności równania selekcji i równania zjawiska. Oznacza to, że pominięcie mechanizmu selekcji i oszacowanie modelu regresji prowadziłyby do uzyskania obciążonych estymatorów.

Oszacowania uzyskane metodą największej wiarygodności są czułe na niespełnienie założenia o dwuwymiarowej normalności. Dlatego często używa się procedury dwustopniowej, która jest bardziej odporna.

```
. heckman lw education age children,select(age married children education) twostep
```

```
Heckman selection model -- two-step estimates   Number of obs   =   2000
(regression model with sample selection)       Censored obs    =    657
                                                Uncensored obs  =   1343

                                                Wald chi2(6)    =   737.21
                                                Prob > chi2     =    0.0000
```

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

lw							
education		.0427067	.003106	13.75	0.000	.0366191 .0487944	
age		.009322	.0014343	6.50	0.000	.0065108 .0121333	
children		-.0019549	.0115202	-0.17	0.865	-.0245341 .0206242	
_cons		2.124787	.1249789	17.00	0.000	1.879833 2.369741	

select							
age		.0347211	.0042293	8.21	0.000	.0264318 .0430105	
married		.4308575	.074208	5.81	0.000	.2854125 .5763025	
children		.4473249	.0287417	15.56	0.000	.3909922 .5036576	
education		.0583645	.0109742	5.32	0.000	.0368555 .0798735	
_cons		-2.467365	.1925635	-12.81	0.000	-2.844782 -2.089948	

mills							

lambda		.1822815	.0638285	2.86	0.004	.05718	.307383

rho		0.66698					
sigma		.27329216					
lambda		.18228151	.0638285				

Dzieci zwiększają prawdopodobieństwo posiadania pracy, ale zmniejszają płacę.

Jak widać wielkości oszacowań parametrów wektorów β oraz γ nieznacznie różnią się. Natomiast występuje znaczna różnica w oszacowanej wielkości parametru ρ . Może to wskazywać na brak dwuwymiarowej normalności rozkładu składnika losowego, bowiem metoda dwustopniowa daje oszacowania zgodne i bardziej odporne.

Literatura

- [1] Takeshi Amemya (1981) „Qualitative Resopnse Models:A Survey” *Journal of Economic Literature*, vol 19 pp. 1483-1536.
- [2] Kit Baum (2006) *An Introduction to Econometrics Using Stata*, Stata Press.
- [3] William H. Greene (2003) *Econometric Analysis*, 5th edition.
- [4] J. Scott Long, Jeremy Freese (2003) *Regression Models for Categorical Dependent Variables Using Stata. Revised Edition*, Stata Press.
- [5] Thomas A. Mroz (1987) „The Sensivity of an Empirical Model of Marired Women’s Hours of Worked to Economic and statistical Assumptions” *Econometrica*, vol. 55/4 pp. 765-799.
- [6] Wojciech Niemirow (1999) *Rachunek Prawdopodobieństwa i Statystyka Matematyczna*, Szkoła Nauk Ścisłych.
- [7] Robert Willis, Shervin Rosen (1979) „Education and Self Selection” *Journal of Political Economy*, vol. 87/5 pp. S7-S36.