

Estymacja modeli ARDL przy użyciu Staty

Michał Kurcewicz

21 lutego 2005

Celem zadania jest oszacowanie długookresowego modelu popytu na szeroki pieniądz w Niemczech. Załączony zbiór danych `beyer.csv` pochodzi z pracy Beyer (1998) i zawiera następujące szeregi (wyrównane sezonowo dane kwartalne 1975:1 - 1994:4):

- y – logarytm *realnego* GDP,
- m – logarytm *nominalnej* podaży szerokiego pieniądza,
- p – logarytm poziomu cen,
- rl, rs – odpowiednio długo i krótkookresowa stopa procentowa.

Dodatkowo zbiór ten zawiera dwie zmienne zerojedynkowe przyjmujące odpowiednio wartość 1 dla pierwszego kwartału 1990 (zmienna $D1990(1)$) i 1991 (zmienna $D1991(1)$), oraz 0 dla wszystkich pozostałych obserwacji. Zmienna $D1990(1)$ modeluje bardzo wysoki wzrost stóp procentowych, jaki nastąpił po upadku muru berlińskiego w listopadzie 1989. Zmienną $D1991(1)$ wprowadzono ze względu na zmianę definicyjną szeregów m i y - od tej daty obejmują one cały obszar zjednoczonych Niemiec, a nie jedynie ich część zachodnią. Omawiany zbiór danych zawiera też zmienną znakową obs określającą datę danej obserwacji w formacie `<rok>q<kwartał>` (np. 1974q1).

Zbiór danych należy zaimportować do Staty w standardowy sposób (poleceniem `insheet using <ścieżka do beyer.csv>` lub poprzez odpowiedni punkt w menu).

1 Wstępna obróbka danych

Przed przystąpieniem do dalszych czynności konieczne jest określenie, że wczytany zbiór danych zawiera szeregi czasowe. W tym celu zostanie wykorzystana funkcja `quarterly` (gdyż dane są kwartalne) przekształcająca ciągi znakowe na zmienną kodującą datę:

```
gen date = quarterly(obs, "yq")
```

Funkcja `quarterly` wymaga podania dwóch argumentów. Pierwszym argumentem jest nazwa zmiennej znakowej zawierającej datę (w naszym przypadku `obs`), drugim argumentem jest ciąg znaków definiujący kolejność pól określających rok i kwartał w zmiennej będącej pierwszym argumentem ("yq" dla formatu `<rok>q<kwartał>`). W Stacie dostępne są też odpowiedniki funkcji `quarterly` dla danych o innych częstotliwościach (`yearly`, `monthly` itp.). Po zdefiniowaniu zmiennej `date` określenie zakresu próby należy wykonać za pomocą polecenia `tsset`:

```
tsset date
```

Bez wykonania polecenia `tsset` funkcje dostępne jedynie dla szeregów czasowych nie będą dostępne.

W kolejnym kroku zdefiniowana zostanie zmienna mr będąca logarytem *realnej* podaży szerokiego pieniądza. Jako deflator zostanie wykorzystana zmienna p (tj. $mr = m - p$, gdyż zmienne m i p są w logarytmach):

```
gen mr = m - p
```

1.1 Operatory opóźnienia i różnicowania

W Stacie są dostępne standardowe operatory opóźnienia

$$Lx_t = x_{t-1}$$

oraz różnicowania

$$Dx_t = x_t - x_{t-1}$$

W celu opóźnienia danej zmiennej należy ją poprzedzić operatorem “1.”. Na przykład zmienną y_1 będącą opóźnioną o jeden zmienną y można utworzyć poprzez wydanie polecenia:

```
gen y_1 = 1.y
```

Operator 1. można składać. Na przykład wydanie polecenia

```
gen y_2 = 1.1.y
```

utworzy zmienną y_2 równą zmiennej y opóźnionej o dwa okresy. Korzystając ze skrótovej notacji `l<liczba złożeń>`. zmienną y_2 można też zdefiniować jako

```
gen y_2 = l2.y
```

W podobny sposób korzysta się z operatora różnicowania “d.” – aby zdefiniować szereg pierwszych różnic zmiennej y należy wykonać polecenie

```
gen dy = d.y
```

zaś szereg czwartych różnic zmiennej p ($p_t - p_{t-4}$ czyli roczną inflację) można uzyskać wykonując

```
gen infl = d4.p
```

2 Estymacja modelu ARDL

2.1 Postać modelu ogólnego

Bieżąca realna podaż pieniądza będzie modelowana przy pomocy opóźnionej podaży pieniądza (część *AR*) oraz bieżących i opóźnionych wartościach zmiennych y , rl , rs oraz $infl$ (część *DL*)

$$\begin{aligned} mr_t = & \gamma + \sum_{i=1}^k \alpha_i mr_{t-i} + \sum_{i=0}^k \beta_{1i} y_{t-i} + \sum_{i=0}^k \beta_{2i} rl_{t-i} \\ & + \sum_{i=0}^k \beta_{3i} rs_{t-i} + \sum_{i=0}^k \beta_{4i} infl_{t-i} + \varepsilon_t \end{aligned} \quad (1)$$

Początkowa liczba opóźnień k w modelu ogólnym 1 została ustalona na 5. Estymacja w Stacie modelu 1 za pomocą polecenia

```
reg mr l(1/5).mr l(0/5).y l(0/5).rl l(0/5).rs l(0/5).infl
```

dała następujące wyniki (zauważmy, że zastosowano skrótową notację l(od/do).zmienna do wyspecyfikowania listy zmiennych objaśniających)

Source	SS	df	MS	Number of obs =	71
Model	2.90632962	29	.100218263	F(29, 41) =	660.67
Residual	.006219335	41	.000151691	Prob > F =	0.0000
Total	2.91254896	70	.041607842	R-squared =	0.9979
				Adj R-squared =	0.9964
				Root MSE =	.01232

	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
mr						
L1	.580608	.1523782	3.81	0.000	.272874	.8883421
L2	.1013025	.1761214	0.58	0.568	-.2543819	.4569869
L3	.0070535	.1752333	0.04	0.968	-.3468374	.3609444
L4	.2017544	.1720825	1.17	0.248	-.1457731	.549282
L5	.0059789	.1435266	0.04	0.967	-.283879	.2958368
y						
--	.8157333	.1339717	6.09	0.000	.5451719	1.086295
L1	-.3797597	.1986511	-1.91	0.063	-.7809438	.0214244
L2	.1040901	.1906346	0.55	0.588	-.2809042	.4890844
L3	-.2189562	.1852762	-1.18	0.244	-.593129	.1552166
L4	-.376016	.191971	-1.96	0.057	-.7637093	.0116772
L5	.1453949	.1899431	0.77	0.448	-.2382029	.5289927
rl						
--	-1.413011	.5390444	-2.62	0.012	-2.501633	-.3243889
L1	-.559029	.6727754	-0.83	0.411	-1.917726	.7996684
L2	.3704283	.6731584	0.55	0.585	-.9890427	1.729899
L3	-.0083337	.6685498	-0.01	0.990	-1.358497	1.34183
L4	1.232711	.6938101	1.78	0.083	-.1684667	2.633889
L5	-1.702538	.5587959	-3.05	0.004	-2.831049	-.574027
rs						
--	.2701893	.3944419	0.68	0.497	-.5264023	1.066781
L1	.240676	.5995517	0.40	0.690	-.9701431	1.451495
L2	-.0091683	.6050045	-0.02	0.988	-1.231	1.212663
L3	-.355061	.6060457	-0.59	0.561	-1.578995	.868873
L4	.051324	.5584163	0.09	0.927	-1.07642	1.179069
L5	.8386374	.3945392	2.13	0.040	.0418494	1.635425
infl						
--	-.2367176	.2924638	-0.81	0.423	-.8273602	.3539251

L1		-.6843034	.6765461	-1.01	0.318	-2.050616	.6820092
L2		-.8707841	.9219914	-0.94	0.350	-2.732784	.9912154
L3		-.7866773	.9152193	-0.86	0.395	-2.635	1.061646
L4		-.6217233	.6306125	-0.99	0.330	-1.895271	.6518244
L5		-.2175916	.2595862	-0.84	0.407	-.7418365	.3066534
_cons		.244463	.2003123	1.22	0.229	-.1600759	.649002

2.2 Testowanie własności składnika losowego modelu ogólnego

W przypadku modeli dynamicznych najważniejszym testem diagnostycznym jest test na autokorelację składnika losowego gdyż w przypadku występowania autokorelacji w takim modelu, uzyskiwane oszacowania parametrów są *niezgodne*. Wyniki testu Brauscha-Godfrey'a dla modelu ogólnego wskazują, że nie ma podstaw do odrzucenia hipotezy zerowej o braku autokorelacji składnika losowego:

```
. bgodfrey, lags(1/4)
```

Breusch-Godfrey LM test for autocorrelation

lags(p)		chi2	df	Prob > chi2
1		0.029	1	0.8649
2		0.385	2	0.8249
3		3.059	3	0.3826
4		4.810	4	0.3073

H0: no serial correlation

Zauważmy, że ponieważ w modelu występuje opóźniona zmienna zależna, do badania autokorelacji składnika losowego *nie można* wykorzystywać testu Durбина-Watsona. Oprócz testu na autokorelację reszt na tym etapie należy przeprowadzić także pozostałe testy diagnostyczne (np. testy normalności i homoskedastyczności składnika losowego). W przypadku odrzucenia hipotezy zerowej należy zmienić specyfikację modelu (np. rozszerzyć model o dodatkowe zmienne, zwiększyć liczbę opóźnień).

2.3 Ustalanie liczby opóźnień

Liczba opóźnień w modelu ogólnym zostanie ustalona na podstawie kryterium od ogólnego do szczególnego. W pierwszej kolejności testujemy łączną nieistotność ostatniego opóźnienia zmiennych objaśniających:

```
. test l5.mr l5.y l5.r1 l5.rs l5.infl
```

```
( 1) L5.mr = 0
( 2) L5.y = 0
( 3) L5.r1 = 0
```

```
( 4) L5.rs = 0
( 5) L5.infl = 0
```

```
F( 5, 41) = 2.45
Prob > F = 0.0494
```

Przyjmując poziom istotności 0.01 nie ma podstaw do odrzucenia hipotezy zerowej - zatem model ogólny możemy zredukować usuwając z modelu ostatnie opóźnienie zmiennych objaśniających. Zredukowany model szacujemy za pomocą polecenia:

```
reg mr l(1/4).mr l(0/4).y l(0/4).rl l(0/4).rs l(0/4).infl
```

Przeprowadzając test na autokorelację reszt w zredukowanym modelu nie mamy podstaw do odrzucenia hipotezy zerowej - zatem nałożenie restrykcji zerowych na ostatnie opóźnienie w modelu ogólnym nie zaburzyło własności składnika losowego.

```
. bgodfrey, lags(1/4)
```

Breusch-Godfrey LM test for autocorrelation

lags(p)	chi2	df	Prob > chi2
1	1.158	1	0.2820
2	1.560	2	0.4583
3	4.205	3	0.2402
4	4.862	4	0.3017

H0: no serial correlation

W kolejnych krokach rekurencyjnie redukujemy model, za każdym razem badając własności składnika losowego zredukowanego modelu. W ten sposób uzyskujemy model *ARDL*(1, 1)

```
. reg mr l.mr l(0/1).y l(0/1).rl l(0/1).rs l(0/1).infl
```

Source	SS	df	MS	Number of obs =	75
Model	3.352526	9	.372502889	F(9, 65) =	2011.03
Residual	.012039927	65	.00018523	Prob > F =	0.0000
				R-squared =	0.9964
				Adj R-squared =	0.9959
Total	3.36456592	74	.045467107	Root MSE =	.01361

	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
mr					
L1	.8807592	.0507273	17.36	0.000	.7794497 .9820687
y					
--	.7487373	.1135013	6.60	0.000	.5220595 .9754151

rl	L1		-.6021427	.1297239	-4.64	0.000	-.8612192	-.3430663
	--		-.5205242	.4614789	-1.13	0.263	-1.442161	.4011128
rs	L1		-.0836479	.4580373	-0.18	0.856	-.9984116	.8311157
	--		-.1669498	.3213477	-0.52	0.605	-.8087255	.4748259
infl	L1		.3729614	.3108881	1.20	0.235	-.247925	.9938477
	--		.061933	.1105664	0.56	0.577	-.1588834	.2827494
_cons	L1		.0057136	.1091126	0.05	0.958	-.2121993	.2236264
	--		-.0539844	.10943	-0.49	0.623	-.2725311	.1645623

Modelu tego już nie można dalej zredukować:

```
. test l1.mr l1.y l1.rl l1.rs l1.infl
```

```
( 1) L.mr = 0
( 2) L.y = 0
( 3) L.rl = 0
( 4) L.rs = 0
( 5) L.infl = 0
```

```
F( 5, 65) = 71.50
Prob > F = 0.0000
```

Test Brauscha-Godfrey dla tego modelu nie daje podstaw do odrzucenia hipotezy zerowej o braku autokorelacji składnika losowego:

```
. test l1.mr l1.y l1.rl l1.rs l1.infl
```

```
( 1) L.mr = 0
( 2) L.y = 0
( 3) L.rl = 0
( 4) L.rs = 0
( 5) L.infl = 0
```

```
F( 5, 65) = 71.50
Prob > F = 0.0000
```

Na podstawie kryterium od ogólnego do szczególnego przyjęto, że liczba opóźnień k jest równa jeden.

2.4 Wyznaczanie rozwiązania długookresowego

Mnożniki długookresowe dla modelu $ARDL(1,1)$ wyznaczono jako

$$\hat{\beta}_i^* = \frac{\hat{\beta}_{i0} + \hat{\beta}_{i1}}{1 - \hat{\alpha}_1}$$

uzyskując $\hat{\beta}_1^* = \frac{0.75-0.6}{1-0.88} = 1.23$, $\hat{\beta}_2^* = -5.07$, $\hat{\beta}_3^* = 1.73$, $\hat{\beta}_4^* = 0.63$. Zauważmy, że wszystkie mnożniki długookresowe, poza mnożnikiem związanym z inflacją, mają znaki zgodne z teorią ekonomii (popyt na pieniądz rośnie wraz ze wzrostem dochodu i gdy rośnie oprocentownie depozytów krótkookresowych, maleje zaś w przypadku wzrostu oprocentowania aktywów nie ujętych w M3).

2.5 Testowanie przyczynowości w sensie Grangera

```
. reg infl l.mr l.y l.rl l.rs l.infl
```

Source	SS	df	MS	Number of obs =	75
Model	.020618651	5	.00412373	F(5, 69) =	18.72
Residual	.015200555	69	.000220298	Prob > F =	0.0000
				R-squared =	0.5756
				Adj R-squared =	0.5449
Total	.035819207	74	.000484043	Root MSE =	.01484

		Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
infl						
mr	L1	-.0057479	.0522252	-0.11	0.913	-.1099343 .0984385
y	L1	.0098845	.0711375	0.14	0.890	-.132031 .1518
rl	L1	.0972729	.2807613	0.35	0.730	-.4628307 .6573764
rs	L1	-.0748774	.1577653	-0.47	0.637	-.3896105 .2398557
infl	L1	-.7396271	.0765765	-9.66	0.000	-.8923931 -.5868611
_cons		-.0240587	.1140845	-0.21	0.834	-.2516511 .2035337

```
. test l.mr
```

```
( 1) L.mr = 0
```

```
F( 1, 69) = 0.01
Prob > F = 0.9127
```

Zatem zmiany podaży pieniądza nie są przyczyną inflacji.

Literatura

Beyer, A. (1998). Modelling Money Demand in Germany. *Journal of Applied Econometrics*, **13**(1):57–76.