

Ekonometrija 1

Osme vaje:

Vpliv linearnih transformacij spremenljivk na ocene parametrov regresijske funkcije. Napovedovanje povprečne in posamične vrednosti odvisne spremenljivke.

Na osmih vajah bomo nadaljevali s proučevanjem vplivov linearnih transformacij na ocene parametrov regresijske funkcije. Pogledali si bomo tudi standardizacijo kot poseben primer linearne transformacije ter spoznali beta regresijske koeficiente. Nato pa se bomo posvetili napovedovanju (povprečne in posamične) vrednosti odvisne spremenljivke na podlagi ocenjenega regresijskega modela. Prikazali bomo postopek napovedovanja s pomočjo matričnih obrazcev in z uporabo nepravih spremenljivk.



Primer 1: Na podlagi podatkov za Slovenijo (razdobje 1965–1989), ocenite naslednjo funkcijo porabe: $OP_t = \beta_1 + \beta_2 OD_t + \beta_3 SOC_t + u_t$, kjer je OP osebna poraba, OD so osebni dohodki, SOC pa socialni prejemki (datoteka potrosnja1.dta). Vse spremenljivke so izražene v mio DIN po cenah iz leta 1972.

Transformirajte podatke v indekse s stalno osnovo v letu 1965 in izračunajte ocene parametrov transformirane funkcije. Kaj bi se zgodilo, če bi osnovne podatke spremenili v stopnje rasti?

Izpis rezultatov obdelav v programskem paketu Stata:

```
. list year op od soc
```

| | year | op | od | soc |
|-----|------|---------|---------|---------|
| 1. | 1965 | 1.24064 | 1.22162 | .217641 |
| 2. | 1966 | 1.20039 | 1.30085 | .234338 |
| 3. | 1967 | 1.35596 | 1.3316 | .216654 |
| 4. | 1968 | 1.51461 | 1.38599 | .230007 |
| 5. | 1969 | 1.42015 | 1.47827 | .241759 |
| 6. | 1970 | 1.6326 | 1.63529 | .274318 |
| 7. | 1971 | 1.77324 | 1.76129 | .305323 |
| 8. | 1972 | 1.9179 | 1.8373 | .3542 |
| 9. | 1973 | 1.93033 | 1.88083 | .355417 |
| 10. | 1974 | 1.96894 | 1.95176 | .355336 |
| 11. | 1975 | 2.03957 | 2.02637 | .385763 |
| 12. | 1976 | 2.12242 | 2.15717 | .413712 |
| 13. | 1977 | 2.2178 | 2.33236 | .442065 |
| 14. | 1978 | 2.30118 | 2.51628 | .471227 |
| 15. | 1979 | 2.36374 | 2.57485 | .492795 |
| 16. | 1980 | 2.46614 | 2.55371 | .499732 |
| 17. | 1981 | 2.16908 | 2.34876 | .456095 |
| 18. | 1982 | 2.17416 | 2.27551 | .450201 |

| | | | | |
|-------|------|---------|---------|---------|
| 19. | 1983 | 2.07052 | 2.08096 | .413724 |
| 20. | 1984 | 1.98772 | 2.04743 | .393934 |
| ----- | | | | |
| 21. | 1985 | 2.09171 | 2.21289 | .455336 |
| 22. | 1986 | 2.55057 | 2.49932 | .607234 |
| 23. | 1987 | 2.66605 | 2.43745 | .640811 |
| 24. | 1988 | 2.30521 | 2.20272 | .578541 |
| 25. | 1989 | 2.15802 | 2.19513 | .634889 |

. regress op od soc

| Source | SS | df | MS | Number of obs = | 25 |
|----------|------------|----|------------|-----------------|--------|
| Model | 3.67855587 | 2 | 1.83927794 | F(2, 22) = | 253.82 |
| Residual | .1594234 | 22 | .007246518 | Prob > F = | 0.0000 |
| ----- | | | | R-squared = | 0.9585 |
| ----- | | | | Adj R-squared = | 0.9547 |
| Total | 3.83797927 | 24 | .159915803 | Root MSE = | .08513 |

| op | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] |
|-------|----------|-----------|------|-------|----------------------|
| od | .6648524 | .0872809 | 7.62 | 0.000 | .4838429 .8458619 |
| soc | .9483866 | .283467 | 3.35 | 0.003 | .360512 1.536261 |
| _cons | .2653599 | .0937114 | 2.83 | 0.010 | .0710144 .4597054 |

. scalar op65=op in 1
. scalar od65=od in 1
. scalar soc65=soc in 1

. gen iop=100*op/op65
. gen iod=100*od/od65
. gen isoc=100*soc/soc65

. regress iop iod isoc

| Source | SS | df | MS | Number of obs = | 25 |
|----------|------------|----|------------|-----------------|--------|
| Model | 23899.3329 | 2 | 11949.6665 | F(2, 22) = | 253.82 |
| Residual | 1035.76295 | 22 | 47.0801339 | Prob > F = | 0.0000 |
| ----- | | | | R-squared = | 0.9585 |
| ----- | | | | Adj R-squared = | 0.9547 |
| Total | 24935.0959 | 24 | 1038.96233 | Root MSE = | 6.8615 |

| iop | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] |
|-------|----------|-----------|------|-------|----------------------|
| iod | .6546597 | .0859428 | 7.62 | 0.000 | .4764253 .8328942 |
| isoc | .166372 | .0497276 | 3.35 | 0.003 | .0632433 .2695007 |
| _cons | 21.38895 | 7.55347 | 2.83 | 0.010 | 5.724008 37.05388 |

. gen sop=100*op/op[_n-1]-100
(1 missing value generated)

. gen sod=100*od/od[_n-1]-100
(1 missing value generated)

. gen ssoc=100*soc/soc[_n-1]-100
(1 missing value generated)

. regress sop sod ssoc

| Source | SS | df | MS | Number of obs = | 24 |
|----------|------------|----|------------|-----------------|--------|
| Model | 854.289289 | 2 | 427.144645 | F(2, 21) = | 12.35 |
| Residual | 726.605459 | 21 | 34.6002599 | Prob > F = | 0.0003 |
| ----- | | | | R-squared = | 0.5404 |
| ----- | | | | Adj R-squared = | 0.4966 |
| Total | 1580.89475 | 23 | 68.7345543 | Root MSE = | 5.8822 |

| sop | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] |
|-------|-----------|-----------|-------|-------|----------------------|
| sod | .6821941 | .3399349 | 2.01 | 0.058 | -.0247392 1.389128 |
| ssoc | .2406695 | .2112369 | 1.14 | 0.267 | -.1986217 .6799607 |
| _cons | -.3450666 | 1.358774 | -0.25 | 0.802 | -3.170792 2.480658 |



Primer 2: Na podlagi podatkov v datoteki `investicije.dta` smo za razdobje 1970–1989 ocenili naslednjo investicijsko funkcijo slovenskega gospodarstva:

$$\widehat{INV} = -0,32131 - 0,15188OS + 0,67872DP \quad R^2 = 0,6578$$

$$t: \quad (-1,19) \quad (-5,10) \quad (5,65) \quad s_e = 0,16297$$

Pri tem so INV investicije, OS so osnovna sredstva, DP pa je domači proizvod (vse spremenljivke so v mio DIN po cenah iz leta 1972). Izpeljite in razložite standardizirane regresijske koeficiente ter izračunajte ocene vseh parametrov transformiranega modela.

Beta koeficienti so standardizirani regresijski koeficienti, ki jih dobimo na podlagi standardiziranih vrednosti odvisne in pojasnjevalnih spremenljivk. Ker gre pri standardizaciji spremenljivk za linearne transformacije, si lahko pri izračunu beta koeficientov pomagamo z obrazci, ki smo jih uporabljali v predhodnih nalogah:

$$y_i^{Tr} = \frac{y_i - \bar{y}}{s_y} = \frac{1}{s_y} y_i - \frac{\bar{y}}{s_y} \quad \Rightarrow \quad a = \frac{1}{s_y} \quad c = -\frac{\bar{y}}{s_y}$$

$$x_{ji}^{Tr} = \frac{x_{ji} - \bar{x}_j}{s_{x_j}} = \frac{1}{s_{x_j}} x_{ij} - \frac{\bar{x}_j}{s_{x_j}} \quad \Rightarrow \quad d_j = \frac{1}{s_{x_j}} \quad f_j = -\frac{\bar{x}_j}{s_{x_j}}$$

$$b_j^{Tr} = \frac{a}{d_j} b_j = \frac{1/s_y}{1/s_{x_j}} b_j = \frac{s_{x_j}}{s_y} b_j; \quad j = 2, 3, \dots, k.$$

Beta koeficient nam pove, za koliko standardnih odklonov se v povprečju spremeni vrednost odvisne spremenljivke, če se, *ceteris paribus*, vrednost pojasnjevalne spremenljivke poveča za en standardni odklon. Uporabljamo jih predvsem pri presojanju pomembnosti posamezne pojasnjevalne spremenljivke. K pojasnitvi variance odvisne spremenljivke največ prispeva tista spremenljivka (in je s tem seveda najpomembnejša), ki ima po absolutni vrednosti največji beta koeficient.

Izpis rezultatov obdelav v programskem paketu Stata:

. sum

| Variable | Obs | Mean | Std. Dev. | Min | Max |
|----------|-----|----------|-----------|--------|--------|
| year | 20 | 1979.5 | 5.91608 | 1970 | 1989 |
| dp | 20 | 5.121725 | 1.015669 | 3.1468 | 6.1611 |

```

      inv |          20    1.140806    .2635112    .73843    1.62434
      os  |          20    13.26153    4.101662    6.6331   19.0711

```

. regress inv os dp

```

-----+-----
Source |          SS      df      MS                Number of obs =      20
-----+-----
Model  |    .867795456      2    .433897728            F( 2, 17) =      16.34
Residual|    .451529117     17    .026560536            Prob > F      =      0.0001
-----+-----
Total  |    1.31932457     19    .069438135            R-squared     =      0.6578
                                           Adj R-squared =      0.6175
                                           Root MSE     =      .16297

```

```

-----+-----
      inv |          Coef.    Std. Err.      t    P>|t|    [95% Conf. Interval]
-----+-----
      os  |   -0.1518757    .0297665     -5.10  0.000    -0.2146775   -0.0890738
      dp  |    0.6787201    .1202086      5.65  0.000     0.4251022    0.932338
      _cons|   -0.3213069    .2710886     -1.19  0.252    -0.8932539    0.2506402
-----+-----

```

. egen invs=std(inv)
. egen oss=std(os)
. egen dps=std(dp)

. regress invs oss dps

```

-----+-----
Source |          SS      df      MS                Number of obs =      20
-----+-----
Model  |   12.4973899      2   6.24869496            F( 2, 17) =      16.34
Residual|    6.50261026     17    .382506486            Prob > F      =      0.0001
-----+-----
Total  |   19.0000002     19    1.00000001            R-squared     =      0.6578
                                           Adj R-squared =      0.6175
                                           Root MSE     =      .61847

```

```

-----+-----
      invs |          Coef.    Std. Err.      t    P>|t|    [95% Conf. Interval]
-----+-----
      oss  |   -2.364008    .4633282     -5.10  0.000    -3.341545   -1.386471
      dps  |    2.616038    .4633282      5.65  0.000     1.638501    3.593575
      _cons|    7.65e-09    .1382943      0.00  1.000    -0.2917755    0.2917755
-----+-----

```

. regress invs oss dps, noconst

```

-----+-----
Source |          SS      df      MS                Number of obs =      20
-----+-----
Model  |   12.4973899      2   6.24869496            F( 2, 18) =      17.30
Residual|    6.50261026     18    .361256125            Prob > F      =      0.0001
-----+-----
Total  |   19.0000002     20    .950000009            R-squared     =      0.6578
                                           Adj R-squared =      0.6197
                                           Root MSE     =      .60105

```

```

-----+-----
      invs |          Coef.    Std. Err.      t    P>|t|    [95% Conf. Interval]
-----+-----
      oss  |   -2.364008    .4502741     -5.25  0.000    -3.309999   -1.418018
      dps  |    2.616038    .4502741      5.81  0.000     1.670047    3.562029
-----+-----

```

. regress inv os dp, beta

```

-----+-----
Source |          SS      df      MS                Number of obs =      20
-----+-----
Model  |    .867795456      2    .433897728            F( 2, 17) =      16.34
Residual|    .451529117     17    .026560536            Prob > F      =      0.0001
-----+-----
Total  |    1.31932457     19    .069438135            R-squared     =      0.6578
                                           Adj R-squared =      0.6175
                                           Root MSE     =      .16297

```

| inv | Coef. | Std. Err. | t | P> t | Beta |
|-------|-----------|-----------|-------|-------|-----------|
| os | -.1518757 | .0297665 | -5.10 | 0.000 | -2.364008 |
| dp | .6787201 | .1202086 | 5.65 | 0.000 | 2.616038 |
| _cons | -.3213069 | .2710886 | -1.19 | 0.252 | . |



Primer 3: Sodelavci avtorevije so proučevali razmere na trgu rabljenih avtomobilov določenega tipa. Želeli so ugotoviti, kakšen vpliv imata starost (*STAR*; v mesecih) in število prevoženih kilometrov (*KM*; v 1.000 km) na ceno rabljenih avtomobilov (*CENA*; v evrih). Podatki so v datoteki *avtomobili.dta*. Ocenite regresijsko funkcijo:

$$CENA_i = \beta_1 + \beta_2 STAR_i + \beta_3 KM_i + u_i$$

ter izračunajte točkovno in intervalno napoved za ceno avtomobila, ki je star 5 let in ima 75.000 prevoženih kilometrov.

a) Napoved posamezne vrednosti v matrični obliki

1. Izračunamo točkovno napoved posamezne vrednosti odvisne spremenljivke:

$$\hat{y}_0 = \mathbf{x}_0^T \mathbf{b} =$$

2. Izračunamo standardno napako napovedi posamezne vrednosti odvisne spremenljivke:

$$\text{var}(\hat{y}_0 - y_0) = s_e^2 (\mathbf{x}_0^T (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0 + 1) = \mathbf{x}_0^T [\text{var-cov}(\mathbf{b})] \mathbf{x}_0 + s_e^2 =$$

$$\text{se}(\hat{y}_0 - y_0) = \sqrt{\text{var}(\hat{y}_0 - y_0)} =$$

3. Izračunamo intervalno napoved posamezne vrednosti odvisne spremenljivke:

$$\hat{y}_0 - t_{\alpha/2} \text{se}(\hat{y}_0 - y_0) \leq y_0 \leq \hat{y}_0 + t_{\alpha/2} \text{se}(\hat{y}_0 - y_0); \quad \alpha =$$

Izpis rezultatov obdelav v programskem paketu Stata:

```
. regress cena star km
```

| Source | SS | df | MS | Number of obs = | 22 |
|----------|------------|----|------------|-----------------|--------|
| Model | 241090396 | 2 | 120545198 | F(2, 19) = | 69.22 |
| Residual | 33087786.3 | 19 | 1741462.43 | Prob > F = | 0.0000 |
| | | | | R-squared = | 0.8793 |
| | | | | Adj R-squared = | 0.8666 |
| Total | 274178182 | 21 | 13056103.9 | Root MSE = | 1319.6 |

| cena | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] |
|-------|-----------|-----------|-------|-------|----------------------|
| star | -61.62429 | 20.6776 | -2.98 | 0.008 | -104.903 -18.34559 |
| km | -35.24952 | 15.37506 | -2.29 | 0.033 | -67.42989 -3.06915 |
| _cons | 14284.76 | 509.8481 | 28.02 | 0.000 | 13217.64 15351.89 |

```
. matrix b=(e(b))'  
. matrix list b
```

```
b[3,1]  
          y1  
star -61.624291  
km -35.249522  
_cons 14284.762
```

```
. matrix x0=(60\75\1)  
. matrix list x0
```

```
x0[3,1]  
      c1  
r1 60  
r2 75  
r3 1
```

```
. matrix y0=x0'*b  
. matrix list y0
```

```
symmetric y0[1,1]  
          y1  
c1 7943.5907
```

```
. matrix vce=e(V)  
. matrix list vce
```

```
symmetric vce[3,3]  
          star          km          _cons  
star 427.56298  
km -285.96651 236.39249  
_cons -3100.1392 -599.45182 259945.07
```

```
. scalar se=e(rmse)  
. display se  
1319.6448
```

```
. matrix var0 = x0'*vce*x0 + se^2  
. matrix list var0
```

```
symmetric var0[1,1]  
      c1  
r1 1834708.9
```

```

. matrix se0=cholesky(var0)
. matrix list se0

symmetric se0[1,1]
      c1
r1 1354.5143

```



b) Napoved posamezne vrednosti s pomočjo nepravih spremenljivk

1. Proučevanim spremenljivkam dodamo še nepravo spremenljivko, ki ima pri vseh n opazovanih enotah vrednost nič.
2. Opazovanim enotam dodamo še eno enoto, pri kateri ima nepravna spremenljivka vrednost 1, odvisna 0, pojasnjevalne spremenljivke pa imajo enake vrednosti kot pri enoti, pri kateri izračunavamo napoved.
3. Ocenimo naslednji razširjeni regresijski model:

$$\hat{y}_i = b_1 + b_2 x_{2i} + \dots + b_k x_{ki} + b_{k+1} D_i,$$

pri čemer velja:

- a) ocene regresijskih koeficientov b_1, b_2, \dots, b_k ostanejo nespremenjene v primerjavi z osnovnim regresijskim modelom, prav tako pa tudi njihove standardne napake in t -statistike;
- b) točkovna napoved posamezne vrednosti odvisne spremenljivke je enaka z minus ena pomnoženi oceni regresijskega koeficienta b_{k+1} ;
- c) standardna napaka napovedi posamezne vrednosti je enaka standardni napaki regresijskega koeficienta b_{k+1} .

$$\widehat{CENA}_i = b_1 + b_2 STAR_i + b_3 KM_i + b_4 D_i$$

Izpis rezultatov obdelav v programskem paketu Stata:

```

. gen d=0

. set obs `=_N+1'
obs was 22, now 23

. replace d=1 if _n==23
(1 real change made)

. replace cena=0 if _n==23
(1 real change made)

. replace star=60 if _n==23
(1 real change made)

```

```
. replace km=75 if _n==23
(1 real change made)
```

```
. regress cena star km d
```

| Source | SS | df | MS | | | |
|----------|------------|----|------------|-----------------|--------|--|
| Model | 323981779 | 3 | 107993926 | Number of obs = | 23 | |
| Residual | 33087786.3 | 19 | 1741462.43 | F(3, 19) = | 62.01 | |
| Total | 357069565 | 22 | 16230434.8 | Prob > F = | 0.0000 | |
| | | | | R-squared = | 0.9073 | |
| | | | | Adj R-squared = | 0.8927 | |
| | | | | Root MSE = | 1319.6 | |

| | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] | |
|-------|-----------|-----------|-------|-------|----------------------|-----------|
| star | -61.62429 | 20.6776 | -2.98 | 0.008 | -104.903 | -18.34559 |
| km | -35.24952 | 15.37506 | -2.29 | 0.033 | -67.42989 | -3.06915 |
| d | -7943.591 | 1354.514 | -5.86 | 0.000 | -10778.62 | -5108.56 |
| _cons | 14284.76 | 509.8481 | 28.02 | 0.000 | 13217.64 | 15351.89 |

Sedaj izračunajte še točkovno in intervalno napoved za povprečno ceno avtomobila, ki je star 5 let in ima 75.000 prevoženih kilometrov.

c) Napoved povprečne vrednosti v matrični obliki

1. Izračunamo točkovno napoved povprečne vrednosti odvisne spremenljivke:

$$\hat{y}_0 = \mathbf{x}_0^T \mathbf{b} =$$

2. Izračunamo standardno napako napovedi povprečne vrednosti odvisne spremenljivke:

$$\text{var}(\hat{y}_0) = s_e^2 \left(\mathbf{x}_0^T (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0 \right) = \mathbf{x}_0^T [\text{var-cov}(\mathbf{b})] \mathbf{x}_0 =$$

$$\text{se}(\hat{y}_0) = \sqrt{\text{var}(\hat{y}_0)} =$$

3. Izračunamo intervalno napoved povprečne vrednosti odvisne spremenljivke:

$$\hat{y}_0 - t_{\alpha/2} \text{se}(\hat{y}_0) \leq E(y_0 | \mathbf{x}_0) \leq \hat{y}_0 + t_{\alpha/2} \text{se}(\hat{y}_0); \quad \alpha =$$

Izpis rezultatov obdelav v programskem paketu Stata:

```
. qui regress cena star km // prej ponovno odpreti datoteko //

. matrix b=(e(b))'
. matrix list b

b[3,1]
      y1
star  -61.624291
km    -35.249522
_cons 14284.762

. matrix x0=(60\75\1)
. matrix list x0

x0[3,1]
      c1
r1    60
r2    75
r3     1

. matrix y0=x0'*b
. matrix list y0

symmetric y0[1,1]
      y1
c1    7943.5907

. matrix vce=e(V)
. matrix list vce

symmetric vce[3,3]
      star      km      _cons
star  427.56298
km    -285.96651  236.39249
_cons -3100.1392 -599.45182  259945.07

. matrix var0 = x0'*vce*x0
. matrix list var0

symmetric var0[1,1]
      c1
c1    93246.456

. matrix se0=cholesky(var0)
. matrix list se0

symmetric se0[1,1]
      c1
c1    305.36283
```

