

Vícenásobná lineární regrese – vzorový příklad


V souboru cneck.txt máme k dispozici antropometrická data mladých dospělých lidí (převážně studentů vysokých škol z Brna a Ostravy). Chceme modelovat závislost obvodu krku (proměnná neck.C) na tělesné hmotnosti (proměnná body.W), tělesné výšce (proměnná body.H), obvodu pasu (proměnná waist.C), obvodu boků (proměnná hip.C) a obvodu předloktí (proměnná antb.C). Hmotnost byla měřena v kg, délkové míry v mm.

Načteme data a podíváme se na ně. Soubor neobsahuje žádná chybějící pozorování.

```
> neck <- read.table("cneck.txt", header=T)
> summary(neck)
   id    sex   body.w   body.H   waist.C   hip.C   antb.C   neck.C
Min. : 1.00   f:38   64.5   :4   Min. :1563   Min. :620.0   Min. :840.0   Min. :205.0   Min. :280.0
1st Qu.: 41.00   m:49   68.0   :4   1st Qu.:1660   1st Qu.:663.5   1st Qu.:945.0   1st Qu.:225.0   1st Qu.:306.0
Median : 91.00   :52   72.0   :3   Median :1725   Median :730.0   Median :970.0   Median :240.0   Median :330.0
Mean   : 92.23   :57.5  73.0   :3   Mean   :1729   Mean   :740.1   Mean   :979.9   Mean   :244.5   Mean   :332.9
3rd Qu.:139.50   :58.5  76.0   :3   3rd Qu.:1792   3rd Qu.:800.0   3rd Qu.:1010.0   3rd Qu.:263.5   3rd Qu.:355.0
Max.  :188.00   :59.0  80.0   :3   Max.  :1906   Max.  :1005.0   Max.  :1300.0   Max.  :310.0   Max.  :410.0
```


Vykreslíme si bodové diagramy pro dvojice (obvod krku, hmotnost); (obvod krku, výška); (obvod krku, obvod pasu); (obvod krku, obvod boků) a (obvod krku, obvod předloktí).

```
> par(mfrow=c(2,3))
> plot(neck$body.W, neck$neck.C, xlab='Tělesna hmotnost (kg)', ylab='Obvod krku (mm)')
> plot(neck$body.H, neck$neck.C, xlab='Tělesna vyska (mm)', ylab='Obvod krku (mm)')
> plot(neck$waist.C, neck$neck.C, xlab='Obvod pasu (mm)', ylab='Obvod krku (mm)')
> plot(neck$hip.C, neck$neck.C, xlab='Obvod boku (mm)', ylab='Obvod krku (mm)')
> plot(neck$antb.C, neck$neck.C, xlab='Obvod predlokti (mm)', ylab='Obvod krku (mm)')
```



Bodové diagramy naznačují, že je mezi dvojicemi lineární závislost. Sestavíme regresní model a pomocí analýzy reziduí ověříme předpoklady modelu.

```
> model1 <- lm(neck.C ~ body.W + body.H + waist.C + hip.C + antb.C,
  data=neck)
> par(mfrow=c(2,2))
> plot(model1)
```



Interpretace grafu je stejná jako u jednoduchého regresního modelu. Ověříme předpoklady i pomocí vhodných testů. Pomocí t-testu otestujeme hypotézu, že rezidua mají nulovou střední hodnotu. Normalitu reziduí ověříme pomocí Shapirova-Wilkova testu a nezávislost reziduí ověříme pomocí Durbinova-Watsonova testu (z knihovny car).

```
> t.test(model1$residuals)
One Sample t-test
data: model1$residuals
t = 9.3512e-17, df = 86, p-value = 1
alternative hypothesis: true mean is not equal to 0
95 percent confidence interval:
-2.555173 2.555173
sample estimates:
mean of x
1.201944e-16

> shapiro.test(model1$residuals)
Shapiro-Wilk normality test
data: model1$residuals
W = 0.9902, p-value = 0.7645

> library(car)
> durbinWatsonTest(model1)
  lag Autocorrelation D-W Statistic p-value
1      0.1541587   1.678153   0.12
Alternative hypothesis: rho != 0
```

Hypotézu o nulové střední hodnotě reziduí protože t-test nabývá hodnoty s p-hodnotou, z grafického posouzení také nevidíme problém.

Shapiro-Wilkův test nabývá hodnoty s p-hodnotou, v kvantil-kvantilovém grafu jsou rezidua, předpoklad normality tedy považujeme za

Předpoklad rovnosti rozptylu se na základě grafického posouzení zdá

Durbin-Watsonův test nabývá hodnoty s p-hodnotou, tedy nezávislost reziduí.
Předpoklady modelu jsou tedy

Podívejme se, jestli v našem modelu není problém s multikolinearitou. Vypočítáme si korelační koeficienty mezi nezávislými proměnnými a také hodnoty koeficientu V IF pro proměnné sestaveného modelu.

```
> cor(neck[,c('body.w', 'body.H', 'waist.C', 'hip.C', 'antb.C')])
   body.w   body.H   waist.C    hip.C   antb.C
body.w 1.0000000 0.6086383 0.9047087 0.7604090 0.8810742
body.H  0.6086383 1.0000000 0.4591687 0.2303759 0.5851208
waist.C 0.9047087 0.4591687 1.0000000 0.6539080 0.8520787
hip.C   0.7604090 0.2303759 0.6539080 1.0000000 0.5251877
antb.C 0.8810742 0.5851208 0.8520787 0.5251877 1.0000000

> vif(model1)
   body.w   body.H   waist.C    hip.C   antb.C
18.895276 2.307445 6.812388 3.904779 6.116750
```

Vidíme, že jak korelační koeficienty, tak koeficienty V IF nabývají vysokých hodnot, lze tedy soudit na existenci multikolinearity. Vypíšeme si podrobné informace o modelu:

```
> summary(model1)
Call:
lm(formula = neck.C ~ body.w + body.H + waist.C + hip.C + antb.C,
    data = neck)

Residuals:
   Min     1Q Median     3Q    Max 
-32.266 -8.030  1.169  8.493 33.577 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 165.63910  64.79600  2.556  0.0124 *  
body.w       1.02594  0.46867  2.189  0.0315 *  
body.H        0.04039  0.02314  1.745  0.0847 .  
waist.C      0.18260  0.04025  4.537 1.96e-05 *** 
hip.C        -0.18166  0.04070 -4.463 2.58e-05 *** 
antb.C       0.29120  0.14144  2.059  0.0427 *  
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 12.35 on 81 degrees of freedom
Multiple R-squared: 0.8573, Adjusted R-squared: 0.8485
F-statistic: 97.33 on 5 and 81 DF, p-value: < 2.2e-16

MNČ odhad regresních koeficientů a jejich interpretace:

β_0 =

β_1 =

β_2 =

β_3 =

β_4 =

β_5 =

Odhadnutá regresní funkce má tvar

Index determinace ID2 =

Adjustovaný index determinace ID2adj =

Celkový F-test na hladině významnosti 0:05:

F =

p-hodnota =
závěr

Dílčí t-testy

parametr	hodnota testovací statistiky	p-hodnota	závěr
β_0			
β_1			
β_2			
β_3			
β_4			
β_5			

Intervaly spolehlivosti pro regresní koeficienty:

```
> confint(model1)
              2.5 %      97.5 %
(Intercept) 36.715381614 294.56281096
body.w      0.093443025 1.95844313
body.H      -0.005657005 0.08643304
waist.C     0.102513283 0.26268666
hip.C       -0.262652856 -0.10067593
antb.C      0.009770142 0.57262713
```

Z výsledku dílcích testů vidíme, že proměnná body.H není na hladině 0,05 významná, sestavíme model, který ji neobsahuje.

```
> model2 <- lm(neck.C ~ body.w + waist.C + hip.C + antb.C, data=neck)
> summary(model2)
```

```
Call:
lm(formula = neck.C ~ body.w + waist.C + hip.C + antb.C, data = neck)

Residuals:
   Min     1Q Median     3Q    Max 
-36.799 -7.585 -0.460  8.523 33.903 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 255.80441  39.59226  6.461 6.96e-09 ***
body.w       1.49670  0.38801  3.857 0.000227 ***
waist.C     0.15765  0.03809  4.139 8.42e-05 ***
hip.C        -0.21493  0.03641 -5.903 7.74e-08 ***
antb.C       0.28727  0.14318  2.006 0.048114 * 
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 12.51 on 82 degrees of freedom
Multiple R-squared: 0.8519, Adjusted R-squared: 0.8447
F-statistic: 118 on 4 and 82 DF, p-value: < 2.2e-16

Z podrobných informací o druhém modelu vidíme, že adjustovaný index determinace je o něco nižší, zřejmě tedy i proměnná body.H přispívá k vysvětlení variability obvodu krku.