


Άσκηση 1

Θέλουμε να δούμε εάν επηρέασε η επίλυση των ασκήσεων, που ανατέθηκαν στους φοιτητές κατά τη διάρκεια της εκπαιδευτικής διαδικασίας, την επίδοσή τους στην πρόοδο. Οι βαθμοί στις ασκήσεις x , και ο βαθμός στην πρόοδο y (με άριστα το 100) δίδονται για 18 φοιτητές.

y	x	y	x	y	x
95	96	72	89	35	0
80	77	66	47	50	30
0	0	98	90	72	59
0	0	90	93	55	77
79	78	0	18	75	74
77	64	95	86	66	67



```
> x<-scan()
1: 96 77 0 0 78 64 89 47 90 93 18 86 0 30 59 77 74 67
19:
Read 18 items
> y<-scan()
1: 95 80 0 0 79 77 72 66 98 90 0 95 35 50 72 55 75 66
19:
Read 18 items
> cbind(y,x,y*x,x*x)
      y  x
[1,] 95 96 9120 9216
[2,] 80 77 6160 5929
[3,]  0  0    0    0
[4,]  0  0    0    0
[5,] 79 78 6162 6084
[6,] 77 64 4928 4096
[7,] 72 89 6408 7921
[8,] 66 47 3102 2209
[9,] 98 90 8820 8100
[10,] 90 93 8370 8649
[11,]  0 18    0  324
[12,] 95 86 8170 7396
[13,] 35  0    0    0
[14,] 50 30 1500  900
[15,] 72 59 4248 3481
[16,] 55 77 4235 5929
[17,] 75 74 5550 5476
[18,] 66 67 4422 4489
>
> cbind(sum(y),sum(x),sum(y*x),sum(x*x))
      [,1] [,2] [,3] [,4]
[1,] 1105 1045 81195 80199
```



```
> predict(yx.lm, list(x=c(45)))  
      1  
49.996
```

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$$

```
> cbind(x, y, yx.lm$fitted.values, yx.lm$residuals)  
      x  y  
1  96 95 94.50098  0.4990229  
2  77 80 77.92069  2.0793072  
3   0  0 10.72691 -10.7269091  
4   0  0 10.72691 -10.7269091  
5  78 79 78.79334  0.2066607  
6  64 77 66.57629 10.4237122  
7  89 72 88.39245 -16.3924513  
8  47 66 51.74130 14.2587034  
9  90 98 89.26510  8.7349022  
10 93 90 91.88304 -1.8830375  
11 18  0 26.43455 -26.4345469  
12 86 95 85.77451  9.2254883  
13  0 35 10.72691 24.2730909  
14 30 50 36.90631 13.0936946  
15 59 72 62.21306  9.7869449  
16 77 55 77.92069 -22.9206928  
17 74 75 75.30275 -0.3027532  
18 67 66 69.19423 -3.1942274  
> sum(yx.lm$residuals)  
[1] 1.160183e-14
```

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$$

$$\hat{\varepsilon}_i = y_i - \hat{y}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i),$$

εκτιμώμενα σφάλματα κατάλοιπα

Sum of Squares of Errors

$$SSE = \sum_{i=1}^n \hat{\varepsilon}_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Total Sum of Squares

$$SSTO = \sum_{i=1}^n (y_i - \bar{y})^2$$

Regression Sum of Squares

$$SSR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

Το συνολικό άθροισμα τετραγώνων $\sum_{i=1}^n (y_i - \bar{y})^2$ γράφεται στη μορφή

$$SSTO = SSR + SSE$$

$$(y_i - \bar{y})^2 = [(y_i - \hat{y}_i) + (\hat{y}_i - \bar{y})]^2 = (y_i - \hat{y}_i)^2 + (\hat{y}_i - \bar{y})^2 + 2(y_i - \hat{y}_i)(\hat{y}_i - \bar{y})$$

μπορούμε να αναλύσουμε το άθροισμα $SSTO$ σε τρία επιμέρους αθροίσματα, ως εξής

$$SSTO = \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + 2 \sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}).$$

Σύμφωνα με τον τύπο έχουμε

$$y_i - \hat{y}_i = y_i - [\bar{y} + \hat{\beta}_1(x_i - \bar{x})] = (y_i - \bar{y}) - \hat{\beta}_1(x_i - \bar{x}),$$

$$\hat{y}_i - \bar{y} = [\bar{y} + \hat{\beta}_1(x_i - \bar{x})] - \bar{y} = \hat{\beta}_1(x_i - \bar{x})$$

όποτε το 3^ο άθροισμα του δεξιού μέλους της θα είναι ίσο με

$$\begin{aligned} \sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) &= \sum_{i=1}^n [(y_i - \bar{y}) - \hat{\beta}_1(x_i - \bar{x})] \hat{\beta}_1(x_i - \bar{x}) = \\ &= \hat{\beta}_1 \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) - \hat{\beta}_1^2 \sum_{i=1}^n (x_i - \bar{x})^2 = \\ &= \hat{\beta}_1 \left(\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) - \hat{\beta}_1 \sum_{i=1}^n (x_i - \bar{x})^2 \right) = 0 \end{aligned}$$

$$SSR = \sum_{i=1}^v (\hat{y}_i - \bar{y})^2$$

$$SSE = \sum_{i=1}^v \hat{\varepsilon}_i^2 = \sum_{i=1}^v (y_i - \hat{y}_i)^2$$

```
> anova(yx.lm)
```

```
Analysis of Variance Table
```

```
Response: y
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
x	1	14873.0	14873	77.483	1.571e-07 ***
Residuals	16	3071.2	192		

```
---
```

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

$$R^2 = \frac{SSR}{SSTO} = 1 - \frac{SSE}{SSTO}$$

λέγεται συντελεστής προσδιορισμού

```
> summary(yx.lm)
```

```
Call:  
lm(formula = y ~ x)
```

```
Residuals:
```

Min	1Q	Median	3Q	Max
-26.4345	-8.8437	0.3528	9.6466	24.2731

```
Coefficients:
```

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	10.72691	6.61733	1.621	0.125
x	0.87265	0.09914	8.802	1.57e-07 ***

```
---  
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 13.85 on 16 degrees of freedom  
Multiple R-squared:  0.8288,    Adjusted R-squared:  0.8181  
F-statistic: 77.48 on 1 and 16 DF,  p-value: 1.571e-07
```

Ιδιότητες των εκτιμητών

Πρόταση

Για το απλό γραμμικό μοντέλο οι εκτιμητές ελαχίστων τετραγώνων είναι γραμμικοί συνδυασμοί των παρατηρήσεων Y_i . Δηλαδή,

$$\widehat{\beta}_1 = \sum_{i=1}^n \kappa_i Y_i \quad \text{και} \quad \widehat{\beta}_0 = \sum_{i=1}^n \lambda_i Y_i,$$

όπου $\kappa_i = \frac{X_i - \bar{X}}{\sum_{j=1}^n (X_j - \bar{X})^2} \equiv \frac{X_i - \bar{X}}{S_{XX}}$ και $\lambda_i = \frac{1}{n} - \kappa_i \bar{X} \quad i = 1, \dots, n.$

Για τα κ_i και λ_i ισχύουν τα εξής:

$$\begin{aligned} \sum_{i=1}^n \kappa_i &= 0, & \sum_{i=1}^n \kappa_i^2 &= \frac{1}{S_{XX}}, & \sum_{i=1}^n \kappa_i X_i &= 1, \\ \sum_{i=1}^n \lambda_i &= 1, & \sum_{i=1}^n \lambda_i^2 &= \frac{1}{n} + \frac{\bar{X}^2}{S_{XX}}, & \sum_{i=1}^n \lambda_i X_i &= 0. \end{aligned}$$