

Rastgele Blok Tasarımı Uygulama

Fatih Kızılaslan

24 04 2020

Rastgele Blok Tasarım (Sabit Etkili Model)

Örnek 1:

Bir firmada satış temsilcisi olarak çalışan 4 kişinin (özel olarak seçiliyor) 2019 yılının ilk 6 ayı için yaptığı satış tutarları bin TL olarak aşağıda verilmiştir.

```
##          1. Ay 2. Ay 3. Ay 4. Ay 5. Ay 6. Ay
## 1. Kişi  90.3 89.2 98.2 93.9 87.4 97.9
## 2. Kişi  92.5 89.5 90.6 94.7 87.0 95.8
## 3. Kişi  85.5 90.8 89.6 86.2 88.0 93.4
## 4. Kişi  82.5 89.5 85.6 87.4 78.9 90.7
```

$\alpha = 0.05$ olmak üzere bu veri için

a) Rastgele tam blok tasarımı kullanarak ANOVA tablosunu oluşturunuz.

$H_0 : \mu_1 = \mu_2 = \mu_3 = \mu_4$ ve $H_1 : \text{En az bir } (i, j) \text{ için } \mu_i \neq \mu_j$

hipotezlerini test ederek yorumlayınız.

b) Tek yönlü varyans analizi yaparak faktör düzeyleri arasında fark var mıdır test ediniz.

c) Varyans analizinin varsayımlarını kontrol ediniz.

d) Eğer a ve b'de yapılan analizlerin sonucunda düzeyler arasında farklılık var ise ikili karşılaştırmalar yaparak farklı olan düzeyleri belirleyiniz.

ÇÖZÜM

```
y<-c(90.3,92.5,85.5,82.5,89.2,89.5,90.8,89.5,98.2,90.6,89.6,85.6,93.9,94.7
      ,86.2,87.4,87.4,87,88,78.9,97.9,95.8,93.4,90.7)
```

```
temsilci<-factor(rep(1:4, times = 6)) # Satış temsilcileri
blok<- factor(rep(1:6, each = 4))    # 6 bloğumuz var: Aylar
data<- data.frame(y, temsilci,blok)
print(data)
```

```
##          y temsilci blok
## 1  90.3          1     1
## 2  92.5          2     1
## 3  85.5          3     1
## 4  82.5          4     1
```

```
## 5 89.2      1  2
## 6 89.5      2  2
## 7 90.8      3  2
## 8 89.5      4  2
## 9 98.2      1  3
## 10 90.6     2  3
## 11 89.6     3  3
## 12 85.6     4  3
## 13 93.9     1  4
## 14 94.7     2  4
## 15 86.2     3  4
## 16 87.4     4  4
## 17 87.4     1  5
## 18 87.0     2  5
## 19 88.0     3  5
## 20 78.9     4  5
## 21 97.9     1  6
## 22 95.8     2  6
## 23 93.4     3  6
## 24 90.7     4  6
```

```
tapply(data$y,data$temsilci,mean) #Faktör düzeylerinin (kişilerin satış) ortalamaları
```

```
##      1      2      3      4
## 92.81667 91.68333 88.91667 85.76667
```

```
tapply(data$y,data$blok,mean) #Blokların ortalamaları
```

```
##      1      2      3      4      5      6
## 87.700 89.750 91.000 90.550 85.325 94.450
```

a) Rastgele Tam Blok Tasarım

Bu veri için ilk olarak bloklama yaparak Blok tasarım için varyans analizini yapacağız. “aov” fonksiyonunda hem ana (main) faktör “temsilci” hem de bloklama faktörü “blok” kullanırız.

```
anova1 <- aov(y ~ temsilci + blok, data = data)
summary(anova1)
```

```
##           Df Sum Sq Mean Sq F value Pr(>F)
## temsilci   3  178.2   59.39   8.107 0.00192 **
## blok       5  192.2   38.45   5.249 0.00553 **
## Residuals 15  109.9    7.33
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Bu sonuçlara göre Faktör düzeyleri için $p - value = 0.00192 < 0.05$ olduğundan $H_0 : \mu_1 = \mu_2 = \mu_3 = \mu_4$ veya $H_0 : \tau_1 = \tau_2 = \tau_3 = \tau_4 = 0$ hipotezi red edilir. Böylece, faktör düzeyleri arasında anlamlı bir farklılık vardır.

Ayrıca, bloklar için de $p - value = 0.00553 < 0.05$ olduğundan $H_0 : \beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta_5 = \beta_6 = 0$ hipotezi red edilir. Böylece, bloklar arasında da anlamlı bir farklılık vardır.

b) Tek yönlü ANOVA

Aynı veriyi bloklama yapmadan tek yönlü varyans analizi ile analiz edelim.

```
#Aynı veri bloklama olmadan ANOVA
anova2 <- aov(y ~ temsilci, data = data)
summary(anova2)
```

```
##           Df Sum Sq Mean Sq F value Pr(>F)
## temsilci   3  178.2   59.39   3.931 0.0234 *
## Residuals 20  302.1   15.11
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```


Yukarıdaki sonuçlara göre bu durumda da $p - value = 0.00234 < 0.05$ olduğundan $H_0 : \mu_1 = \mu_2 = \mu_3 = \mu_4$ hipotezi red edilir, yani faktör düzeyleri arasında anlamlı bir farklılık vardır.

Ancak, bu modelde bloklamamın etkisi kaldırıldığı için $MS_E = 15.11$ yükselmiştir. Bloklama yapıldığında $MS_E = 7.33$ olarak bulundu. Görüldüğü gibi bloklama yapmak hata kareler ortalamasının azalmasına sebep olmaktadır. Dolayısıyla, bu veri için bloklama yapmak modelin hassaslığını arttırmıştır.

c) Varsayımların Kontrolü

1. Artıklar üzerinden normallik varsayımı kontrolü yapılır.

```
qqnorm(residuals(anova1))
```



```
shapiro.test(residuals(anova1))
```

```
##  
## Shapiro-Wilk normality test  
##  
## data: residuals(anova1)  
## W = 0.95631, p-value = 0.3689
```

```
ks.test(residuals(anova1), "pnorm", mean(residuals(anova1)), sd(residuals(anova1)))
```

```
##  
## One-sample Kolmogorov-Smirnov test  
##  
## data: residuals(anova1)  
## D = 0.1305, p-value = 0.7609  
## alternative hypothesis: two-sided
```

Sonuçlara göre normallik varsayımı sağlanır.

2. Faktör düzeyleri (temsilciler) için varyansların homojenliğini kontrol edelim.

```
bartlett.test(y ~ temsilci)
```

```
##  
## Bartlett test of homogeneity of variances  
##  
## data: y by temsilci  
## Bartlett's K-squared = 1.2442, df = 3, p-value = 0.7424
```

```
library(car)  
leveneTest(y, temsilci) #medyana göre
```

```
## Levene's Test for Homogeneity of Variance (center = median)  
##      Df F value Pr(>F)  
## group 3  0.7789 0.5195  
##      20
```

```
leveneTest(y, temsilci, mean) #ortalamaya göre
```

```
## Levene's Test for Homogeneity of Variance (center = mean)  
##      Df F value Pr(>F)  
## group 3  0.8542 0.4808  
##      20
```

Sonuçlara göre faktör düzeylerinin varyansları homojendir.

d) İkili Karşılaştırmalar


Rastgele blok tasarımı için Tukey testi ile ikili karşılaştırmaları yapalım.

```
TukeyHSD(anova1)
```

```
## Tukey multiple comparisons of means
## 95% family-wise confidence level
##
## Fit: aov(formula = y ~ temsilci + blok, data = data)
##
## $temsilci
##      diff      lwr      upr    p adj
## 2-1 -1.133333 -5.637161  3.370495 0.8854831
## 3-1 -3.900000 -8.403828  0.603828 0.1013084
## 4-1 -7.050000 -11.553828 -2.546172 0.0020883
## 3-2 -2.766667 -7.270495  1.737161 0.3245644
## 4-2 -5.916667 -10.420495 -1.412839 0.0086667
## 4-3 -3.150000 -7.653828  1.353828 0.2257674
##
## $blok
##      diff      lwr      upr    p adj
## 2-1  2.050  -4.1680828  8.2680828 0.8853016
## 3-1  3.300  -2.9180828  9.5180828 0.5376297
## 4-1  2.850  -3.3680828  9.0680828 0.6757699
## 5-1 -2.375  -8.5930828  3.8430828 0.8105903
## 6-1  6.750   0.5319172 12.9680828 0.0297368
## 3-2  1.250  -4.9680828  7.4680828 0.9845521
## 4-2  0.800  -5.4180828  7.0180828 0.9980198
## 5-2 -4.425 -10.6430828  1.7930828 0.2483499
## 6-2  4.700  -1.5180828 10.9180828 0.1986961
## 4-3 -0.450  -6.6680828  5.7680828 0.9998784
## 5-3 -5.675 -11.8930828  0.5430828 0.0837504
## 6-3  3.450  -2.7680828  9.6680828 0.4925715
## 5-4 -5.225 -11.4430828  0.9930828 0.1263042
## 6-4  3.900  -2.3180828 10.1180828 0.3674672
## 6-5  9.125   2.9069172 15.3430828 0.0027838
```


```
plot(TukeyHSD(anova1))
```

95% family-wise confidence level



Differences in mean levels of temsilci

95% family-wise confidence level



Differences in mean levels of blok

Yukarıdaki sonuçlara göre: **4. ve 1. düzeyler** arasında, **4. ve 2. düzeyler** arasında anlamlı fark vardır.


Eğer bu veri için **Bloklama yapmasaydık** tek yönlü ANOVA ile elde ettiğimiz sonuçlara göre Tukey testi ile ikili karşılaştırmalar aşağıdaki gibi olur.

```
TukeyHSD(anova2)
```

```
## Tukey multiple comparisons of means
## 95% family-wise confidence level
##
## Fit: aov(formula = y ~ temsilci, data = data)
##
## $temsilci
##      diff      lwr      upr    p adj
## 2-1 -1.133333 -7.414210  5.1475436 0.9569358
## 3-1 -3.900000 -10.180877  2.3808769 0.3312583
## 4-1 -7.050000 -13.330877 -0.7691231 0.0243604
## 3-2 -2.766667 -9.047544  3.5142102 0.6140278
## 4-2 -5.916667 -12.197544  0.3642102 0.0693182
## 4-3 -3.150000 -9.430877  3.1308769 0.5116013
```

```
plot(TukeyHSD(anova2))
```

95% family-wise confidence level



Differences in mean levels of temsilci

Bu sonuçlara göre sadece **4. ve 1. düzeyler** arasında anlamlı fark vardır. Bloklama ile hem 4. ve 1. hem de 4. ve 2. düzeyler arasında anlamlı fark olduğu sonucuna ulaştığımız.

Örnek 2: (Birdal Şenoğlu, Şükrü Acıtaş, İstatistiksel Deney Tasarımı, Örnek 5.2)

Y1, Y2, Y3 yemlerinin ineklerin süt verimne olan etkisi araştırılmak isteniyor. Bu amaçla, her biri 9'ar tane inekten oluşan 4 farklı ırktan (yerli kara (YK), boz ırk (BI), siyah alaca (SA), esmer İsviçre (Eİ)) toplam 36 tane inek kullanılıyor. 9'ar inekten oluşan 4 farklı ırkın her biri için Y1, Y2, Y3 yemleri 3'er tane ineğe rastgele uygulanıyor. Bu deneye ilişkin veriler kg cinsinden aşağıda verilmiştir.

##	Y1	Y1	Y1	Y2	Y2	Y2	Y3	Y3	Y3
## YK	257	250	265	232	239	242	281	264	255
## BI	1600	1596	1609	1690	1698	1697	1717	1718	1721
## SA	5492	5497	5499	5589	5609	5588	5692	5688	5710
## Eİ	3993	3982	4008	4214	4206	4201	4291	4292	4312

Bu verileri kullanarak $\alpha = 0.05$ anlam düzeyinde,

- Yemler arasında anlamlı bir farklılık olup olmadığını sınavınız.
- İrklar arasında anlamlı bir farklılık olup olmadığını sınavınız.
- Yem türleri ile ırklar arasındaki etkileşimin anlamlı olup olmadığını sınavınız.

ÇÖZÜM

Bu veride her bir blokta her bir düzey için 3'er tane gözlem yapılmıştır.

Bu analizde yem faktörünün süt üzerindeki etkisini ineklerin farklı özelliklerini göz önünde bulundurarak araştıracağız. Bu nedenle ana faktörümüz yem türleri Y1, Y2, Y3 ve inek ırkları bloklama faktörüdür. Ayrıca, bu iki faktörün kendi aralarında olan etkileşimini de modele ekleyeceğiz.

```
y<-c(257,250,265,232,239,242,281,264,255,1600,1596,1609,1690,1698,1697,1717,  
1718,1721,5492,5497,5499,5589,5609,5588,5692,5688,5710,3993,3982,  
4008,4214,4206,4201,4291,4292,4312)
```

```
blok_irk<- factor(rep(1:4, each = 9)) # Bloklarımız inek ırkları  
yem<-factor(rep(rep(1:3, each = 3))) # Faktör düzeyleri yem türleri
```

```
data<-data.frame(y, blok_irk,yem)  
print(data)
```

```
##      y blok_irk yem  
## 1  257      1  1  
## 2  250      1  1  
## 3  265      1  1  
## 4  232      1  2  
## 5  239      1  2  
## 6  242      1  2  
## 7  281      1  3  
## 8  264      1  3  
## 9  255      1  3  
## 10 1600     2  1  
## 11 1596     2  1  
## 12 1609     2  1  
## 13 1690     2  2  
## 14 1698     2  2  
## 15 1697     2  2  
## 16 1717     2  3  
## 17 1718     2  3  
## 18 1721     2  3  
## 19 5492     3  1  
## 20 5497     3  1  
## 21 5499     3  1  
## 22 5589     3  2  
## 23 5609     3  2  
## 24 5588     3  2  
## 25 5692     3  3  
## 26 5688     3  3  
## 27 5710     3  3  
## 28 3993     4  1  
## 29 3982     4  1  
## 30 4008     4  1  
## 31 4214     4  2  
## 32 4206     4  2  
## 33 4201     4  2  
## 34 4291     4  3  
## 35 4292     4  3  
## 36 4312     4  3
```

```
tapply(data$y,data$yem,mean)
```

```
##      1      2      3  
## 2837.333 2933.750 2995.083
```



```
tapply(data$y, data$blok_irk, mean)
```

```
##           1           2           3           4  
## 253.8889 1671.7778 5596.0000 4166.5556
```

Rastgele blok tasarımı kullanarak varyans analizi yapacağız. Etkileşimi modele “yem:blok_irk” biçiminde dahil ederiz. Bu modeli

$$y_{ijk} = \mu + \tau_i + \beta_j + (\tau\beta)_{ij} + \epsilon_{ijk}, \quad i = 1, \dots, a, \quad j = 1, \dots, b, \quad k = 1, \dots, n$$

biçiminde ifade ederiz. Burada, $(\tau\beta)_{ij}$: i. faktör düzeyi ile j. blok arasındaki etkileşimi gösterir.

```
anova<-aov(y~ yem + blok_irk+yem:blok_irk, data = data)  
summary(anova)
```

```
##           Df      Sum Sq  Mean Sq  F value Pr(>F)  
## yem          2      151772    75886     939.8 <2e-16 ***  
## blok_irk     3 156429603 52143201 645736.2 <2e-16 ***  
## yem:blok_irk 6       78891    13148     162.8 <2e-16 ***  
## Residuals   24        1938         81  
## ---  
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

a) Bu sonuçlara göre Faktör düzeyleri yem türleri için $p - value < 0.05$ olduğundan $H_0 : \mu_1 = \mu_2 = \mu_3$ veya $H_0 : \tau_1 = \tau_2 = \tau_3 = 0$ hipotezi red edilir. Böylece, yem türleri arasında anlamlı bir farklılık vardır.

b) Bloklar için yani inek ırkları için $p - value < 0.05$ olduğundan $H_0 : \beta_1 = \beta_2 = \beta_3 = \beta_4 = 0$ hipotezi red edilir. Böylece, inek ırkları arasında anlamlı bir farklılık vardır.

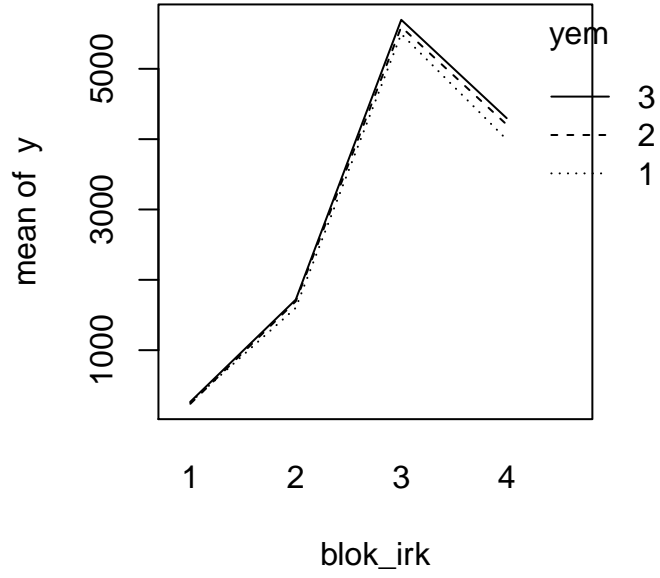
c) Yem türleri ile inek ırkları arasındaki etkileşim için sıfır hipotezi

$$H_0 : (\tau\beta)_{11} = (\tau\beta)_{12} = \dots = (\tau\beta)_{34} = 0$$

biçiminde olur. Etkileşim için $p - value < 0.05$ olduğundan yem türleri ile ırklar arasındaki etkileşim anlamlıdır.

Ayrıca, yem türleri ile ırklar arasında etkileşim grafiği aşağıdaki gibidir. Eğer bu etkileşim grafiğinde birbirlerine paralel doğrular gözlenirse, bu faktörlerin etkilerinin birbirine bağlı olmadığı veya birbirleri ile etkileşimsiz olduğu yorumu yapılabilir. Ancak, etkileşim grafiği bu yorumları kesin olarak ifade etmez. Etkileşimin olup olmadığı hipotez testi ile kontrol edilmelidir.


```
with(data, interaction.plot(x.factor = blok_irk , trace.factor = yem, response = y))
```



Ayrıca, aşağıdaki sonuçlardan varyans analizinin varsayımları hataların normalliği ve faktör düzeylerinin eş varyanslılığın sağlandığı görülmektedir.

```
qqnorm(residuals(anova))
```

Normal Q-Q Plot



```
shapiro.test(residuals(anova))
```

```
##  
## Shapiro-Wilk normality test  
##  
## data: residuals(anova)  
## W = 0.93539, p-value = 0.03656
```

```
ks.test(residuals(anova), "pnorm", mean(residuals(anova)), sd(residuals(anova)))
```

```
##  
## One-sample Kolmogorov-Smirnov test  
##  
## data: residuals(anova)  
## D = 0.10231, p-value = 0.8088  
## alternative hypothesis: two-sided
```

```
library(goftest)
```

```
ad.test(residuals(anova), "pnorm", mean=mean(residuals(anova)), sd=sd(residuals(anova)), estimated=TRUE)
```

```
##  
## Anderson-Darling test of goodness-of-fit  
## Braun's adjustment using 6 groups  
## Null hypothesis: Normal distribution  
## with parameters mean = 8.02309607639273e-17, sd = 7.44119806022037  
## Parameters assumed to have been estimated from data  
##  
## data: residuals(anova)  
## Anmax = 2.0867, p-value = 0.4111
```

```
cvm.test(residuals(anova), "pnorm", mean=mean(residuals(anova)), sd=sd(residuals(anova)), estimated=TRUE)
```

```
##  
## Cramer-von Mises test of goodness-of-fit  
## Braun's adjustment using 6 groups  
## Null hypothesis: Normal distribution  
## with parameters mean = 8.02309607639273e-17, sd = 7.44119806022037  
## Parameters assumed to have been estimated from data  
##  
## data: residuals(anova)  
## omega2max = 0.51932, p-value = 0.1774
```

```
bartlett.test(y ~ data$yem)
```

```
##  
## Bartlett test of homogeneity of variances  
##  
## data: y by data$yem  
## Bartlett's K-squared = 0.019667, df = 2, p-value = 0.9902
```

```
library(car)
leveneTest(y, data$yem) #medyana göre
```

```
## Levene's Test for Homogeneity of Variance (center = median)
##      Df F value Pr(>F)
## group 2  0.0495 0.9518
##      33
```

```
leveneTest(y, data$yem,mean) #ortalamaya göre
```

```
## Levene's Test for Homogeneity of Variance (center = mean)
##      Df F value Pr(>F)
## group 2  0.0496 0.9517
##      33
```