

MAT7381 Solution # 6.30

6.30 On compare 5 variétés de maïs, chacune plantée dans 4 terrains (des "blocs"). Les blocs sont divisés en 5 parcelles chacun, une parcelle étant consacrée à chaque variété. Une mesure de la quantité récoltée est prise dans chaque parcelle. Voici les données :

Variété	Bloc				Moyenne
	1	2	3	4	
A	21	25	28	35	27,25
B	23	29	33	34	29,75
C	15	21	22	28	21,50
D	16	19	25	25	21,25
E	12	18	21	25	19,00
Moyenne	17,4	22,4	25,8	29,4	23,75

Voici les données (on s'assure que « bloc » soit traité comme facteur)

	récolte	variété	bloc
1	21	A	1
2	25	A	2
3	28	A	3
4	35	A	4
5	23	B	1
6	29	B	2
7	33	B	3
8	34	B	4
9	15	C	1
10	21	C	2
11	22	C	3
12	28	C	4
13	16	D	1
14	19	D	2
15	25	D	3
16	25	D	4
17	12	E	1
18	18	E	2
19	21	E	3
20	25	E	4

On construit les colonne « variété » et « bloc » comme ceci :

```
bloc<-rep(1:4,5)
variété<-gl(5,4,labels=c("A","B","C","D","E"))
```

On développe un modèle additif :

```
> a<-lm(récolte~variété+bloc)
> summary(a)
```

```

              Estimate Std. Error t value Pr(>|t|)
(Intercept)  20.9000    0.8926   23.416 2.20e-11 ***
variétéB      2.5000    0.9979    2.505 0.027649 *
variétéC     -5.7500    0.9979   -5.762 8.99e-05 ***
variétéD     -6.0000    0.9979   -6.013 6.10e-05 ***
variétéE     -8.2500    0.9979   -8.267 2.68e-06 ***
bloc2         5.0000    0.8926    5.602 0.000116 ***
bloc3         8.4000    0.8926    9.411 6.87e-07 ***
bloc4        12.0000    0.8926   13.444 1.35e-08 ***

```

```
Residual standard error: 1.411 on 12 degrees of freedom
Multiple R-squared: 0.9679, Adjusted R-squared: 0.9491
F-statistic: 51.63 on 7 and 12 DF, p-value: 5.119e-08
```

En termes des paramètres μ , v (variété) et b (bloc), les moyennes sont :

	bloc1	bloc2	bloc3	bloc4	
Variété A	μ	$\mu + b_2$	$\mu + b_3$	$\mu + b_4$	$\mu + \sum b/4$
Variété B	$\mu + v_b$	$\mu + v_b + b_2$	$\mu + v_b + b_3$	$\mu + v_b + b_4$	$\mu + v_b + \sum b/4$
Variété C	$\mu + v_c$	$\mu + v_c + b_2$	$\mu + v_c + b_3$	$\mu + v_c + b_4$	$\mu + v_c + \sum b/4$
Variété D	$\mu + v_d$	$\mu + v_d + b_2$	$\mu + v_d + b_3$	$\mu + v_d + b_4$	$\mu + v_d + \sum b/4$
Variété E	$\mu + v_e$	$\mu + v_e + b_2$	$\mu + v_e + b_3$	$\mu + v_e + b_4$	$\mu + v_e + \sum b/4$
	$\mu + \sum v/4$	$\mu + \sum v/4 + b_2$	$\mu + \sum v/4 + b_3$	$\mu + \sum v/4 + b_4$	$\mu + \sum v/4 + \sum b/4$

Elles sont estimées par

```
> M
      [,1] [,2] [,3] [,4]
[1,] 20.90 25.90 29.30 32.90
[2,] 23.40 28.40 31.80 35.40
[3,] 15.15 20.15 23.55 27.15
[4,] 14.90 19.90 23.30 26.90
[5,] 12.65 17.65 21.05 24.65
```

Une façon de les obtenir est celle-ci :

```
> beta<-summary(a)$coefficients[,1]
> beta
(Intercept) variétéB variétéC variétéD variétéE bloc2 bloc3 bloc4
      20.90      2.50     -5.75     -6.00     -8.25      5.00      8.40     12.00
```

On construit la matrice de design :

```
> X<-model.matrix(a)
> X
      (Intercept) variétéB variétéC variétéD variétéE bloc2 bloc3 bloc4
1              1          0          0          0          0          0          0          0
2              1          0          0          0          0          1          0          0
3              1          0          0          0          0          0          1          0
4              1          0          0          0          0          0          0          1
5              1          1          0          0          0          0          0          0
6              1          1          0          0          0          1          0          0
7              1          1          0          0          0          0          1          0
8              1          1          0          0          0          0          0          1
9              1          0          1          0          0          0          0          0
10             1          0          1          0          0          1          0          0
11             1          0          1          0          0          0          1          0
12             1          0          1          0          0          0          0          1
13             1          0          0          1          0          0          0          0
14             1          0          0          1          0          1          0          0
15             1          0          0          1          0          0          1          0
16             1          0          0          1          0          0          0          1
17             1          0          0          0          1          0          0          0
18             1          0          0          0          1          1          0          0
19             1          0          0          0          1          0          1          0
20             1          0          0          0          1          0          0          1
```

```

> muhat<-X%*%beta
> muhat
      [,1]
 [1,] 20.90
 [2,] 25.90
 [3,] 29.30
 [4,] 32.90
 [5,] 23.40
 [6,] 28.40
 [7,] 31.80
 [8,] 35.40
 [9,] 15.15
[10,] 20.15
[11,] 23.55
[12,] 27.15
[13,] 14.90
[14,] 19.90
[15,] 23.30
[16,] 26.90
[17,] 12.65
[18,] 17.65
[19,] 21.05
[20,] 24.65

```

a) Testez à 5% l'hypothèse qu'il n'y a pas de différence entre les variétés, en supposant qu'il n'y a pas d'interaction entre les variétés et les blocs.

La réponse découle immédiatement de l'ANOVA :

```

> anova(a)
Analysis of Variance Table

Response: récolte
      Df Sum Sq Mean Sq F value    Pr(>F)
variété  4 328.50  82.125  41.234 6.416e-07 ***
bloc     3 391.35 130.450  65.498 1.039e-07 ***
Residuals 12  23.90   1.992

```

On voit tout de suite que les différences entre les variétés sont hautement significatives.

b) Testez l'hypothèse qu'en moyenne les variétés A et B produisent autant que les trois autres.

On obtient les moyennes des carrés de façon à estimer la variance

```

> ms<-anova(a)$"Mean Sq"
> ms
[1] 82.125000 130.450000 1.991667

```

La variance σ^2 est estimée par MCR, la 3^e composante de ce vecteur et son écart-type est estimé par

```

> sigma<-sqrt(ms[3])
> sigma
[1] 1.411264

```

La matrice de covariance de $\hat{\beta}$ est $\sigma^2(\mathbf{X}'\mathbf{X})^{-1}$. La matrice $(\mathbf{X}'\mathbf{X})^{-1}$ est donnée par `summary(a)$cov.unscaled`.
Voici donc la variance (estimée) \mathbf{V} de $\hat{\beta}$:

```

> V<-sigma^2*summary(a)$cov.unscaled
> round(V,4)
      (Intercept) variétéB variétéC variétéD variétéE  bloc2  bloc3  bloc4
(Intercept)    0.7967  -0.4979  -0.4979  -0.4979  -0.4979 -0.3983 -0.3983 -0.3983
variétéB       -0.4979  0.9958  0.4979  0.4979  0.4979  0.0000  0.0000  0.0000
variétéC       -0.4979  0.4979  0.9958  0.4979  0.4979  0.0000  0.0000  0.0000
variétéD       -0.4979  0.4979  0.4979  0.9958  0.4979  0.0000  0.0000  0.0000
variétéE       -0.4979  0.4979  0.4979  0.4979  0.9958  0.0000  0.0000  0.0000
bloc2          -0.3983  0.0000  0.0000  0.0000  0.0000  0.7967  0.3983  0.3983
bloc3          -0.3983  0.0000  0.0000  0.0000  0.0000  0.3983  0.7967  0.3983
bloc4          -0.3983  0.0000  0.0000  0.0000  0.0000  0.3983  0.3983  0.7967

```

L'hypothèse à tester est

$$[(\mu+\sum b/4)+(\mu+vb+\sum b/4)]/2=[(\mu+vc+\sum b/4)+(\mu+vd+\sum b/4)+(\mu+ve+\sum b/4)]/3$$

$$\Leftrightarrow vb/2-(vc+vd+ve)/3 = 0. \text{ soit } L'\beta = 0 \text{ où } L \text{ est}$$

```

> L
[1] 0.0000000 0.5000000 -0.3333333 -0.3333333 -0.3333333 0.0000000 0.0000000 0.0000000

```

$L'\hat{\beta} =$

```

> t(L)**%beta
[1,] 7.916667

```

$\text{Var}(L'\hat{\beta})$ est estimée par

```

> t(L)**V**L*sigma^2
[1,] 0.8264034

```

L'écart-type est estimé par

```

> sqrt(t(L)**V**L*sigma^2)
[1,] 0.9090673

```

Sous H_0 , le rapport $\frac{L'\hat{\beta}}{\hat{\sigma}_{L'\hat{\beta}}}$ est de loi de Student à 12 degrés de liberté. Sa valeur est

```

> t(L)**%beta/sqrt(t(L)**V**L*sigma^2)
[1,] 8.70856

```

La valeur p est

```

> 2*(1-pt(abs(t(L)**%beta/sqrt(t(L)**V**L*sigma^2)),12))
[1,] 1.560907e-06

```

On rejette donc l'hypothèse énoncée en b).