

Contrôle continu 3

Le sujet comporte trois exercices indépendants.

- Les calculatrices sont autorisées.
- Le cours, les exercices de travaux dirigés, leurs corrigés ainsi que les notes de cours sont autorisés. Tout autre document est interdit
- Afin de pouvoir traiter les questions, plusieurs résultats numériques et graphiques ont été intégrés au document.
- Vous prendrez un soin particulier à préciser quelles sont les hypothèses testées.
- Tous les tests seront effectués au seuil de signification $\alpha = 5\%$.

Exercice 1. Prix d'un appartement.

Nous avons relevé quelques annonces d'appartements à vendre dans la presse parisienne journal. Les données sont reproduites dans le tableau suivant :

1. CENSIER, bas de R. Mouffetard, pied-à-terre, 28m ² , tt confort. Visite vendredi, samedi, dim. 650.000 F à discuter. Facilités
2. CONTRESCARPE, imm. Ancien, pierre de taille, beau duplex caractère, 50m ² , poutres, refait neuf, 1.400.000 F
3. RUE ST-SIMON, 4p., 106m ² , en pleine verdure, calme, plein soleil, cuis. aménagée, s. de bains moderne, chff. cent. Parfait état. Px 3.250.000 F à discuter. Agence s'abstenir. Direct propriétaire.
4. RAPP 7P., 196m ² standing, 9 fenêtres plein soleil, 4.000.000 F
5. RUE ST ANDRE DES ARTS, beau liv + chbre, imm. XVIIIe siècle, 55m ² , 1.350.000 F.
6. 5e PRES QUAIS, 7 pièces, 190m ² caractère, standing, 3.950.000 F
7. GOBELINS, Beau 5p., 110m ² , gd cft, soleil, 250.000 F
8. GOBELINS, et. élevé, calme, asc., 2 pièces, 60m ² , 1.600.000 F
9. CENSIER, très grand studio + entrée 48m ² , tt cft, ensoleillé, calme, bel imm., 1.250.000 F
10. PANTHEON, 7e étage, ascenseur, grand studio 35m ² + terrasse. Vue. 1.250.000 F
11. RUE MADAME, 3P. + Serv., 86m ² , 1.750.000 F
12. RUE DE SEINE, 3P., tt cft, 65m ² , calme, soleil, 1.500.000 F
13. PANTHEON, bel imm., verdure, magnifique studio 32m ² , caractère, 775.000 F.
14. SEVRES BAB, 1er ét., 2P., grande cuis., bns 52m ² , état neuf, 1.225.000 F
15. MONTPARNASSE, Part. vend atelier d'artiste 40m ² , duplex, vue imprenable, tout confort, Prix 1.000.000 F
16. RUE D'ASSAS, imm. gd standing, bel appart 260m ² , triple récept. + 5 ch., tt cft (travaux) 2 park., 2 ch. Serv., Prix 7.500.000 F à déb.
17. BD St-GERMAIN, 4P., 70m ² , à amén., 4e ét., 1.625.000 F.
18. ILE St-LOUIS, Lux. appt., 117m ² , en duplex, grande récept., grande chambre, 2 sdb, Terras., parf. et., décor tr. bon goût, 4.750.000 F
19. JUSSIEU, Charme, gd 3pcs, 90m ² , 1.890.000 F
20. QUARTIER LATIN, 30m ² à aménager, prix 390.000 F
21. MONTPARNASSE, Imm. p.d.t., 4-5 P., 105m ² , bon état, 1.875.000 F
22. RUE MAZARINE, 52m ² , 4e ét., sans ascens., à rénover. Prix 1.000.000 F
23. METRO CENSIER, Bel imm., 4P. 80m ² , tt cft, petits travaux, 1.350.000 F
24. ASSAS LUXEMBOURG, 3P. 60m ² s/arbres, imm. caractère, 1.475.000 F
25. SUR JARDINS DE L'OBSERVATOIRE, 140m ² , grand charme, 4.950.000 F
26. RUE DE SAVOIE, studio 20m ² , 4e ét., dche, 425.000 F.
27. PRES LUXEMBOURG, Bel imm., pierre de taille, Appartement 100m ² , salon, salle à manger, 2 chambres, office, cuis., bains, chf. cent., asc., Prix 2.475.000 F
28. METRO LES GOBELINS, studio 28m ² , cuis., s. de bains, calme, 425.000 F
29. METRO NATION, studio 19m ² , 1er ét., cuis., douche, 300.000 F
30. METRO PLACE D'ITALIE, 5P. 190m ² , der. ét., salon, salle à manger, 3 chambres, cuis., s. de bains, PRIX 5.300.000 F

- a) Un économiste souhaite utiliser le modèle linéaire simple pour modéliser le lien entre le prix d'un appartement et sa surface. Spécifier ce modèle (donner les coefficients) et bien identifier chacune des composantes du modèle (la variable explicative et la variable à expliquer) dans le contexte de ce problème.
- b) Tester l'hypothèse nulle suivante avec un test approprié (vous donnerez le nom de ce test) :

$$\mathcal{H}_0 : \beta_1 = 0$$

contre

$$\mathcal{H}_0 : \beta_1 \neq 0.$$

- c) Donner la valeur de la variation qui est expliquée par la droite des MCO et la variation qui est inexpliquée par la même droite. En déduire le pourcentage de variation qui est expliqué par la droite des MCO.
- d) Calculer une estimation du prix d'un appartement pour les superficies suivantes : $X_1 = 50, X_2 = 100, X_3 = 200$. Pour quelle superficie l'estimation du prix d'un appartement serait-elle la plus précise parmi les trois valeurs précédentes ?
- e) Entre quelles valeurs peut se situer la vraie valeur du prix d'un appartement pour les superficies dont le prix a été déterminé à la question précédente ? Utiliser un niveau de confiance de 95%. Quelle est la marge d'erreur dans l'estimation effectuée à la question précédente ?

```
> surface = c(28, 50, 106, 196, 55, 190, 110, 60, 48, 35, 86, 65, 32,
52, 40, 260, 70, 117, 90, 30, 105, 52, 80, 60, 140, 20, 100, 28, 19, 190)
> prix = c(650, 1400, 3250, 4000, 1340, 3950, 2500, 1600, 1250, 1250,
1750, 1500, 775, 1225, 1000, 7500, 1625, 3750, 1890, 390, 1875, 1000,
1350, 1475, 4950, 425, 2475, 425, 300, 5300)
> prix_au_m2 = c(23.21, 28, 30.66, 20.41, 24.36, 20.79, 22.73, 26.67,
26.04, 35.71, 20.35, 23.08, 24.22, 23.56, 25, 28.85, 23.21, 40.6,
21, 13, 17.86, 19.23, 16.88, 24.58, 35.36, 21.25, 24.75, 15.18, 15.79, 27.89)
> appart = data.frame(surface, prix, prix_au_m2)
> appart
  surface prix prix_au_m2
1      28  650      23.21
2      50 1400      28.00
3     106 3250      30.66
4     196 4000      20.41
5      55 1340      24.36
6     190 3950      20.79
7     110 2500      22.73
8      60 1600      26.67
9      48 1250      26.04
10     35 1250      35.71
11     86 1750      20.35
12     65 1500      23.08
13     32  775      24.22
```

14	52	1225	23.56
15	40	1000	25.00
16	260	7500	28.85
17	70	1625	23.21
18	117	3750	40.60
19	90	1890	21.00
20	30	390	13.00
21	105	1875	17.86
22	52	1000	19.23
23	80	1350	16.88
24	60	1475	24.58
25	140	4950	35.36
26	20	425	21.25
27	100	2475	24.75
28	28	425	15.18
29	19	300	15.79
30	190	5300	27.89

```
> appart.lm = lm(appart$prix~appart$surface)
> appart.lm
```

```
Call:
lm(formula = appart$prix ~ appart$surface)
```

```
Coefficients:
(Intercept) appart$surface
   -178.07         26.85
```

```
> plot(appart$surface,appart$prix,xlab = "surface", ylab = "prix",
col.axis = "peru",col.lab = "royalblue",col.main = "royalblue",
main = " étude de 28 appartements")
> abline(appart.lm, col = "green3")
> residus<-residuals(appart.lm)
> shapiro.test(residus)
```

Shapiro-Wilk normality test

```
data: residus
W = 0.9609, p-value = 0.327
> summary(appart.lm)
```

```
Call:
lm(formula = appart$prix ~ appart$surface)
```


```
Residuals:
    Min       1Q   Median       3Q      Max
-1085.40  -232.76   23.86   159.87  1368.45
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-178.069	163.519	-1.089	0.285
appart\$surface	26.854	1.597	16.812	3.65e-16 ***

Residual standard error: 514.4 on 28 degrees of freedom
 Multiple R-squared: 0.9099, Adjusted R-squared: 0.9066
 F-statistic: 282.7 on 1 and 28 DF, p-value: 3.646e-16

étude de 30 appartements



```
> anova(appart.lm)
Analysis of Variance Table
```

```
Response: appart$prix
      Df Sum Sq Mean Sq F value Pr(>F)
appart$surface  1 74805169 74805169  282.66 3.646e-16 ***
Residuals      28  7410168  264649
---
```

```
> predict(appart.lm,interval="confidence")
```

```
      fit      lwr      upr
1  573.8555 308.62334 839.0876
```

2	1164.6532	942.73973	1386.5667
3	2668.5019	2462.85331	2874.1506
4	5085.4017	4670.93337	5499.8700
5	1298.9254	1084.69470	1513.1561
6	4924.2750	4527.09042	5321.4596
7	2775.9197	2565.29224	2986.5472
8	1433.1976	1225.64214	1640.7531
9	1110.9443	885.69827	1336.1904
10	761.8366	511.81740	1011.8558
11	2131.4131	1938.88487	2323.9413
12	1567.4698	1365.48215	1769.4575
13	681.2733	424.87418	937.6723
14	1218.3621	999.63614	1437.0880
15	896.1088	656.20675	1136.0108
16	6804.0859	6196.31943	7411.8524
17	1701.7420	1504.12108	1899.3630
18	2963.9008	2742.95909	3184.8425
19	2238.8309	2045.37074	2432.2910
20	627.5644	366.79347	888.3353
21	2641.6475	2437.13162	2846.1634
22	1218.3621	999.63614	1437.0880
23	1970.2865	1777.49151	2163.0814
24	1433.1976	1225.64214	1640.7531
25	3581.5530	3315.41822	3847.6877
26	359.0200	75.13437	642.9056
27	2507.3753	2307.81369	2706.9369
28	573.8555	308.62334	839.0876
29	332.1655	45.86543	618.4656
30	4924.2750	4527.09042	5321.4596

Exercice 2. Trouvez-vous votre évier trop bas ?

Avez-vous déjà fait la vaisselle dans un évier situé dans une cité U construite dans les années 70 ? Si oui, vous avez remarqué qu'il était très bas. Imaginez que vous soyez un constructeur de cuisines et que vous commenciez à entendre des plaintes sur la hauteur de vos éviers. Vous les construisiez jusqu'à présent pour une taille moyenne de 165 centimètres (vos données vous disaient que la taille moyenne des femmes était justement de 165 centimètres, et vos analyses marketing montrent que ce sont elles les prescriptrices d'achat dans les couples en ce qui concerne la cuisine). Vous conduisez donc une étude et mesurez toutes les femmes qui se présentent à votre magasin (en échange d'un petit cadeau). 64 femmes se prêtent au jeu, cela vous donne les hauteurs x_1, \dots, x_{64} dont la distribution parente suit une loi normale. La hauteur moyenne relevée est égale à $\bar{x}_{64} = 169,5$ centimètres et l'écart-type sur les données est égal à $s_{64,c} = 16,0$ centimètres.

Faut-il faire remonter cette information au syndicat des constructeurs de cuisines afin qu'il diligente une étude plus approfondie ?

Information dont il vous faudra tenir compte : vous voulez vous présenter à la présidence du syndicat l'an prochain.

Pour répondre à la question, vous allez suivre la démarche suivante :

- allez-vous utiliser un test paramétrique ou non ? Justifier votre réponse.
- Donner le nom du test que vous allez utiliser.
- Donner les hypothèses du test. S'agit-il d'un test bilatéral ou d'un test unilatéral ? Justifier votre réponse.
- Donner la statistique du test et calculer-la.
- Conclure. Calculer le risque d'erreur associé à cette décision.


Nous rappelons également quelques valeurs de quantiles qui peuvent vous aider à répondre aux trois exercices :

```
> qnorm(0.975)
[1] 1.959964
> qnorm(0.95)
[1] 1.644854
> qt(0.975,64)
[1] 1.99773
> qt(0.95,64)
[1] 1.669013
> qt(0.975,63)
[1] 1.998341
> qt(0.95,63)
[1] 1.669402
```

Exercice 3. Le classement de logements dans une grande ville française.

Cette étude est réalisée à partir d'un échantillon aléatoire de trente logements situés dans une grande ville française. Pour chaque logement nous disposons de deux variables :

- Prix : prix de vente exprimé en milliers de dollars.
- Situation : variable à trois modalités :
 - 1 : logements situés dans des quartiers du centre ville peu côtés.
 - 2 : logements situés dans les faubourgs.
 - 3 : logements situés dans les banlieues résidentielles.



1. Proposer un modèle statistique qui permet d'étudier une relation (préciser le type de relation) entre le prix de vente et la situation géographique. Préciser la nature de chacune des variables présentes dans le modèle statistique proposé.
2. Les conditions d'application du modèle linéaire sont-elles vérifiées ? Si oui, expliquer votre réponse.
3. Donner le tableau de l'analyse de la variance.
4. D'après les sorties statistiques réalisées avec le logiciel R qui se trouvent ci-dessous, pouvez-vous conclure à une éventuelle significativité de la situation géographique sur le prix de vente ? Pour répondre à cette question, utiliser un test. Vous citerez le nom du test, les hypothèses, la statistique du test et donnerez la conclusion du test (vous préciserez quelle règle vous utilisez).

5. Pouvez-vous séparer les situations géographiques en groupes ne présentant pas de différence significative au seuil de 5% ? Si oui, expliquer comment vous procédez.
6. Dans le cas où vous avez répondu dans l'affirmative à la question précédente, faire cette répartition en groupes homogènes, en indiquant les situations géographiques et les moyennes correspondantes au prix de vente.

```

> situation<-c(3,3,2,2,2,2,2,2,2,2,3,1,1,1,1,1,1,1,3,1,3,1,1,3,3,3,
3,3,2,2)
> prix<-c(198,185,165,170,170,183,158,146,168,162,184,154,170,122,
175,168,181,162,173,178,167,158,151,157,175,181,184,175,181,183)
> exo3<-data.frame(prix,situation)
> str(exo3)
'data.frame': 30 obs. of 2 variables:
 $ prix      : num  198 185 165 170 170 183 158 146 168 162 ...
 $ situation: Factor w/ 3 levels "1","2","3": 3 3 2 2 2 2 2 2 2 2 ...
> exo3
  prix situation
1  198         3
2  185         3
3  165         2
4  170         2
5  170         2
6  183         2
7  158         2
8  146         2
9  168         2
10 162         2
11 184         3
12 154         1
13 170         1
14 122         1
15 175         1
16 168         1
17 181         1
18 162         1
19 173         3
20 178         1
21 167         3
22 158         1
23 151         1
24 157         3
25 175         3
26 181         3
27 184         3
28 175         3
29 181         2

```

```
30 183      2
> modele1<-aov(prix~situation)
> residus<-residuals(modele1)
> shapiro.test(residus)
```

Shapiro-Wilk normality test

```
data: residus
W = 0.9444, p-value = 0.1198
> bartlett.test(residus~situation)
```

Bartlett test of homogeneity of variances

```
data: residus by situation
Bartlett's K-squared = 2.0298, df = 2, p-value = 0.3624
> anova(modele1)
```

Analysis of Variance Table

Response: prix

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
situation	2	1291.3	645.63	3.4354	0.04685 *
Residuals	27	5074.2	187.93		

```
> mean<-tapply(exo3$prix,exo3$situation,mean)
```

```
> mean
```

```
  1      2      3
161.9 168.6 177.9
```

```
> TukeyHSD(modele1)
```

Tukey multiple comparisons of means
95% family-wise confidence level

Fit: aov(formula = prix ~ situation)

\$situation

	diff	lwr	upr	p adj
2-1	6.7	-8.5008055	21.90081	0.5266048
3-1	16.0	0.7991945	31.20081	0.0376200
3-2	9.3	-5.9008055	24.50081	0.2990454