

Lors d'un mémoire de DEA (promotion 2000-2001), Frédéric Rey et Alexandre Turpin ont étudié le taux de chômage. Ils ont recueilli un jeu de données (présenté à la fin du devoir) constitué de $n = 34$ observations annuelles (de 1960 à 1993). Voici une description des variables fournie par les auteurs du mémoire :

- **an** : année
- **chom** : taux de chômage.
- **txpib** : taux de variation du produit intérieur brut (pib) représentant le taux de croissance de l'économie.
- **deppub** : part des dépenses publiques par rapport au pib, qui peut ainsi représenter le degré d'intervention de l'état dans l'économie.
- **pfisc** : pressions fiscales, pour voir si une imposition trop importante des entreprises nuit à leur embauche et donc au niveau du chômage.
- **salva** : la part des salaires par rapport à la valeur ajoutée permettant de connaître l'influence du coût sur l'embauche.
- **infl** : taux d'inflation afin de vérifier la relation inverse entre le chômage et l'inflation définie par la courbe de Philips.

Partie I : modèle à un seul régresseur

On envisage un modèle linéaire expliquant la variable **chom** en fonction de la seule variable **txpib**. On tente une modélisation linéaire du type :

$$(chom)_i = \beta_0 + \beta_1(txpib)_i + \varepsilon_i, \quad i = 1, \dots, 34$$

Question : Pourquoi les paramètres β_0 et β_1 ne sont pas calculables ?

Question : On s'intéresse tout naturellement à l'estimation des paramètres β_0 et β_1 . Déterminez les estimations obtenues par la méthode des moindres carrés.

On rappelle à titre indicatif que

- $var(\mathbf{x}) = \overline{x^2} - \bar{x}^2$
- $cov(\mathbf{x}, \mathbf{y}) = \overline{x \times y} - \bar{x} \times \bar{y}$.

```

1 > mean(txpib)
2 [1] 3.488235
3 > mean(txpib^2)
4 [1] 16.06412
5 > mean(chom)
6 [1] 5.458824
7 > mean(chom^2)
8 [1] 42.03294
9 > mean(txpib*chom)
10 [1] 13.85794

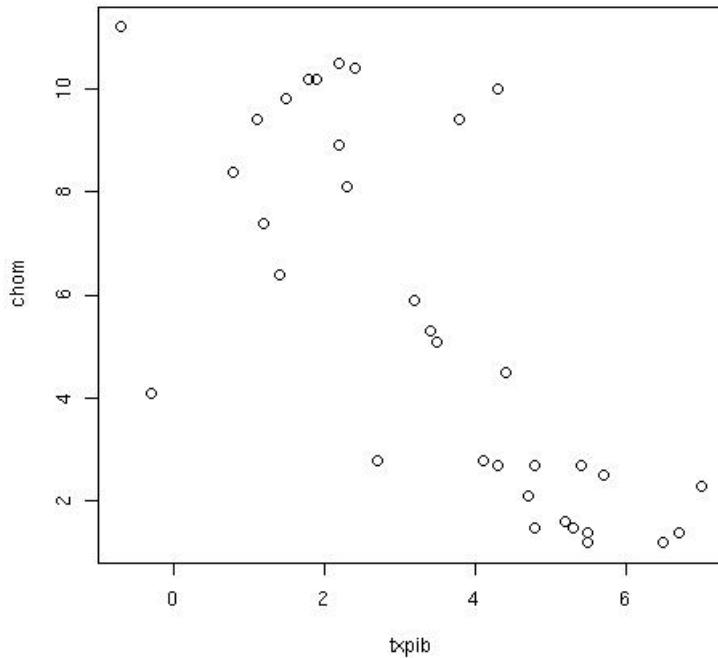
```

Question : Déterminez le coefficient de détermination linéaire (R^2) (puis le coefficient de corrélation linéaire (R)) entre `txpib` et `chom`, et donnez-en une interprétation.

Question : Rappelez brièvement à quoi correspondent chacune des quatre colonnes de la matrice "Coefficients" de la sortie ci-dessous. Retrouvez les résultats des deux questions précédentes.

```
1 > summary(lm(chom~txpib))
2
3 Call:
4 lm(formula = chom ~ txpib)
5
6 Residuals:
7   Min     1Q Median     3Q    Max
8 -6.3987 -1.5732 -0.2337  1.4000  5.6212
9
10 Coefficients:
11             Estimate Std. Error t value Pr(>|t|)
12 (Intercept) 10.0996    0.8293   12.18 1.48e-13 ***
13 txpib       -1.3304    0.2069   -6.43 3.14e-07 ***
14 ---
15 Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
16
17 Residual standard error: 2.381 on 32 degrees of freedom
18 Multiple R-squared:  0.5637,    Adjusted R-squared:  0.5501
19 F-statistic: 41.34 on 1 and 32 DF,  p-value: 3.144e-07
20
21 > sqrt(0.5637051)
22 [1] 0.750803
```

Question : Sur le graphique ci-dessous reportez la droite ajustée (même approximativement) et illustrez la notion de valeur ajustée et de résidu.



Question : Peut-on penser au vu des données que la variable *txpib* apporte de l'information pour expliquer la variable *chom* (indication : fournir la *p*-valeur associée puis conclure.)

Partie II : modèle linéaire multiple

On envisage un modèle linéaire multiple expliquant la variable *chom* en fonction de tous les régresseurs du jeu de données (exceptée la variable *an*).

Question : A la vue de la matrice de corrélation ci-après, quels sont les régresseurs qui vous semblent être les plus explicatifs ?

```

1 > cor(chomage[-1])
2      chom      txpib      deppub      pfisc      salva      infl
3 chom  1.00000000 -0.7508029  0.978885951  0.97923991 -0.167503533 -0.04814577
4 txpib -0.75080295  1.0000000 -0.780822861 -0.75374536 -0.105374429 -0.30407625
5 deppub  0.97888595 -0.7808229  1.000000000  0.99212248 -0.007785484  0.06750973
6 pfisc   0.97923991 -0.7537454  0.992122482  1.00000000 -0.035551565  0.06640145
7 salva  -0.16750353 -0.1053744 -0.007785484 -0.03555157  1.000000000  0.70322004
8 infl    -0.04814577 -0.3040763  0.067509734  0.06640145  0.703220044  1.000000000

```

Question : Interprétez la sortie ci-dessous, en particulier les *p*-valeurs des tests de significativité locale, le R^2 .

```

1 > summary(lm(chom~txpib+deppub+pfisc+salva+infl))
2
3 Call:

```

```

4 lm(formula = chom ~ txpib + deppub + pfisc + salva + infl)
5
6 Residuals:
7   Min     1Q Median     3Q    Max
8 -0.84262 -0.26630  0.05442  0.27937  1.33259
9
10 Coefficients:
11             Estimate Std. Error t value Pr(>|t|)
12 (Intercept) -5.80283   3.86147 -1.503 0.144098
13 txpib       -0.07188   0.07753 -0.927 0.361820
14 deppub       0.35855   0.12702  2.823 0.008665 **
15 pfisc        0.22751   0.14324  1.588 0.123432
16 salva        -0.19195   0.05079 -3.779 0.000757 ***
17 infl         -0.03131   0.03961 -0.791 0.435873
18 ---
19 Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
20
21 Residual standard error: 0.469 on 28 degrees of freedom
22 Multiple R-squared: 0.9852,      Adjusted R-squared: 0.9826
23 F-statistic: 372.7 on 5 and 28 DF,  p-value: < 2.2e-16

```

Question : Rappelez les effets indésirables sur les tests de significativité locale s'il y a colinéarité entre les régresseurs.

Question : A la lumière de la matrice de corrélation associée au jeu de données, peut-on suspecter de la colinéarité entre les régresseurs ?

Question : Rappelez la définition du VIF, et son interprétation générale. Ensuite, interprétez-les quant au jeu de données étudié.

```

1 > vif(lm(chom~txpib+deppub+pfisc+salva+infl))
2      txpib     deppub     pfisc     salva      infl
3  3.620834 91.775821 81.135288  2.384586  2.712915

```

Question : (Relation avec la matrice de corrélation) Justifier l'ordre de grandeur des VIFs des covariables *deppub* et *pfisc* en utilisant l'instruction suivante.

```

1 > 1/(1-(0.992122482)^2)
2 [1] 63.72276

```

Question : Quelle est la stratégie qui a été adoptée dans la série d'instructions ci-dessous ? A la dernière étape, précisez l'équation du modèle sélectionné et analysez brièvement les sorties.

```

1 > ## Etape 1
2 > summary(lm(chom~txpib+deppub+pfisc+salva))
3
4 Call:
5 lm(formula = chom ~ txpib + deppub + pfisc + salva)
6
7 Residuals:
8   Min     1Q Median     3Q    Max
9 -0.809610 -0.313125 -0.002559  0.265016  1.411467
10

```

```

11 Coefficients:
12             Estimate Std. Error t value Pr(>|t|)
13 (Intercept) -3.93872   3.03798 -1.296  0.20503
14 txpib       -0.04277   0.06779 -0.631  0.53302
15 deppub      0.39774   0.11619  3.423  0.00186 ***
16 pfisc        0.18756   0.13315  1.409  0.16959
17 salva       -0.22177   0.03379 -6.563 3.44e-07 ***
18 ---
19 Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
20
21 Residual standard error: 0.4659 on 29 degrees of freedom
22 Multiple R-squared: 0.9849,          Adjusted R-squared: 0.9828
23 F-statistic: 471.8 on 4 and 29 DF, p-value: < 2.2e-16
24
25 > vif(lm(chom~txpib+deppub+pfisc+salva))
26     txpib    deppub    pfisc    salva
27 2.804297 77.798129 71.033914 1.069126
28 > ## Etape 2
29 > summary(lm(chom~deppub+pfisc+salva))
30
31 Call:
32 lm(formula = chom ~ deppub + pfisc + salva)
33
34 Residuals:
35      Min      1Q      Median      3Q      Max
36 -0.79521 -0.27194 -0.02836  0.26418  1.42664
37
38 Coefficients:
39             Estimate Std. Error t value Pr(>|t|)
40 (Intercept) -4.63681   2.80081 -1.656  0.108244
41 deppub      0.42511   0.10670  3.984  0.000399 ***
42 pfisc        0.16761   0.12804  1.309  0.200456
43 salva       -0.21907   0.03318 -6.603 2.62e-07 ***
44 ---
45 Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
46
47 Residual standard error: 0.4612 on 30 degrees of freedom
48 Multiple R-squared: 0.9847,          Adjusted R-squared: 0.9831
49 F-statistic: 641.8 on 3 and 30 DF, p-value: < 2.2e-16
50
51 > vif(lm(chom~deppub+pfisc+salva))
52     deppub    pfisc    salva
53 66.949894 67.030557 1.051973
54 > ## Etape 3
55 > summary(lm(chom~deppub+salva))
56
57 Call:
58 lm(formula = chom ~ deppub + salva)
59

```

```

60 Residuals:
61   Min      1Q Median      3Q     Max
62 -0.73827 -0.36129 -0.03607  0.29649  1.37843
63
64 Coefficients:
65             Estimate Std. Error t value Pr(>|t|)
66 (Intercept) -2.83284   2.46623 -1.149   0.259
67 deppub       0.56373   0.01319 42.741 < 2e-16 ***
68 salva        -0.22872   0.03272 -6.990  7.6e-08 ***
69 ---
70 Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
71
72 Residual standard error: 0.4665 on 31 degrees of freedom
73 Multiple R-squared:  0.9838,    Adjusted R-squared:  0.9827
74 F-statistic: 940.2 on 2 and 31 DF,  p-value: < 2.2e-16
75
76 > vif(lm(chom~deppub+salva))
77   deppub     salva
78 1.000061 1.000061
79

```

Question : A partir de cette question, nous ne considérerons que le modèle final. Peut-on montrer au vu des données que le paramètre $\beta_1 < 1$ au seuil de 5% ?

```

1 > (0.56373-(1))/0.01319
2 [1] -33.07582

```

Question : A partir de l'instruction R suivante, que peut-on avancer au vu des données comme assertion(s) d'intérêt au seuil 5% ?

```

1 > pnorm((-0.22872-(-.3))/0.03272)
2 [1] 0.985315

```

Question : En vous aidant de l'instruction R ci-dessous, proposez un intervalle de confiance à 95% pour le paramètre β_2 et interprétez-le (via l'approche expérimentale). Quelle relation y-a-t-il entre cet intervalle et le test de significativité locale du paramètre β_2 ?

```

1 > -0.22872+c(-1,1)*qnorm(0.975)*0.03272
2 [1] -0.2928500 -0.1645900

```

Question : Supposons que l'on ne connaisse pas la valeur de *chom* en 1993. Pourriez-vous prévoir sa valeur, calculer un intervalle de prévision au niveau 95% ? Quelle était la valeur observée de *chom* en 1993 et est-ce surprenant ?

```

1 > xTau <- data.frame(chom=11.2,deppub=52.2,salva=68.6)
2 > predict(lm(chom~deppub+salva),xTau,interval="prediction")
3   fit      lwr      upr
4 1 10.9039 9.872652 11.93515

```

Jeu de données :

```

1 > chomage
2   an chom txpib deppub pfisc salva infl
3   1 1960  1.4  5.5  34.6  34.9  72.8  3.4
4   2 1961  1.2  5.5  35.7  36.2  72.8  3.4
5   3 1962  1.4  6.7  37.0  36.3  72.8  4.7
6   4 1963  1.5  5.3  37.8  37.1  72.8  6.4
7   5 1964  1.2  6.5  38.0  38.0  72.8  4.1
8   6 1965  1.5  4.8  38.4  38.4  73.3  2.7
9   7 1966  1.6  5.2  38.5  38.4  73.3  2.9
10  8 1967  2.1  4.7  39.0  38.2  73.3  3.2
11  9 1968  2.7  4.3  40.3  38.8  73.3  4.2
12 ...
13 25 1984  9.8  1.5  52.5  49.8  75.6  7.3
14 26 1985 10.2  1.8  52.7  49.9  74.6  5.8
15 27 1986 10.4  2.4  52.2  49.4  72.1  5.3
16 28 1987 10.5  2.2  51.7  49.8  71.3  3.0
17 29 1988 10.0  4.3  50.8  49.2  70.2  3.1
18 30 1989  9.4  3.8  49.8  48.7  69.1  3.5
19 31 1990  8.9  2.2  50.3  48.9  69.6  3.1
20 32 1991  9.4  1.1  50.6  48.7  69.6  3.1
21 33 1992 10.2  1.9  51.3  48.5  68.8  2.9
22 34 1993 11.2 -0.7  52.2  49.0  68.6  2.9

```