

TD01- AJUSTEMENT LINÉAIRE, METHODE DES MOINDRES CARRES (MCO), COEFFICIENT DE DETERMINATION

Rappel de cours :

Soient deux jeux de données $\{y_1, y_2, \dots, y_N\}$, $\{x_1, x_2, \dots, x_N\}$, réalisation de deux variables statistiques X et Y.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^{i=N} x_i \qquad \sigma_X = \sqrt{\frac{1}{N} \sum_{i=1}^{i=N} (x_i - \bar{x})^2} = \sqrt{\frac{1}{N} (\sum_{i=1}^{i=N} x_i^2) - \bar{x}^2}$$

$$\sigma_{xy} = \frac{1}{N} \sum_{i=1}^{i=N} (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{N} (\sum_{i=1}^{i=N} x_i y_i) - \bar{x} \bar{y} \qquad \rho_{x,y} := r_{x,y} := \frac{Cov(X,Y)}{\sigma_X \times \sigma_Y} = \frac{\sigma_{xy}}{\sigma_X \times \sigma_Y}$$

Soit $D_{Y/X} : y = \beta_0 + \beta_1 x$ la droite de régression obtenue par la méthode des moindres carrés, alors

$$\beta_1 = \frac{Cov(X,Y)}{Var(X)} \quad \text{et} \quad \beta_0 = \bar{y} - \beta_1 \bar{x}$$

Le coefficient de détermination $R^2 = \frac{\text{Variation Expliquée}}{\text{Variation Totale}} = \frac{SCE}{SCT} = \rho_{x,y}^2$ avec

$$SCE := \sum_{k=1}^{k=N} (y_k - \bar{y})^2 \quad \text{et} \quad SCR := \sum_{k=1}^{k=N} (y_k - \hat{y}_k)^2 \quad \text{où} \quad \hat{y}_k = \beta_0 + \beta_1 x_k$$

1. Exercice 1.1 (QCM)

1. Lors d'une régression simple, si le R^2 vaut 1, les points sont-ils alignés ?

A. Non ; B. Oui ; C. Pas obligatoirement.

2. La droite des MCO d'une régression simple passe-t-elle par le point (\bar{x}, \bar{y}) ?

A. Toujours ; B. Jamais ; C. Parfois

2. Exercice 1.2 (R^2 et coefficient de corrélation)

Rappeler la formule définissant le coefficient de détermination R^2 et la développer pour montrer qu'il est égal au carré du coefficient de corrélation empirique entre x et y, noté $\rho_{x,y}$, c'est-à-dire qu'on a :

$$R^2 = \rho_{x,y}^2 = \left(\frac{\sum_{i=1}^{i=N} (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{i=N} (x_i - \bar{x})^2 \times \sum_{i=1}^{i=N} (y_i - \bar{y})^2}} \right)^2$$

3. Exercice 1.3 (Poids des pères et des fils)

L'étude statistique ci-dessous porte sur les poids respectifs des pères et de leur fil aîné.

Père : 65 63 67 64 68 62 70 66 68 67 69 71

Fils : 68 66 68 65 69 66 68 65 71 67 68 70

Voici les résultats numériques que nous avons obtenus :

$$\sum_{i=1}^{i=12} p_i = 800 \qquad \sum_{i=1}^{i=12} p_i^2 = 53418 \qquad \sum_{i=1}^{i=12} f_i p_i = 54107 \qquad \sum_{i=1}^{i=12} f_i = 811 \qquad \sum_{i=1}^{i=12} f_i^2 = 54849$$

1. Calculez la droite des moindres carrés du poids des fils en fonction du poids des pères.

2. Calculez la droite des moindres carrés du poids des pères en fonction du poids des fils.

3. Montrer que le produit des pentes des deux droites est égal au carré du coefficient de corrélation empirique entre les p_i et les f_i (ou encore au coefficient de détermination).

4. Exercice 1.4 (Hauteur d'un arbre)

Nous souhaitons exprimer la hauteur y (en pieds) d'un arbre d'une essence donnée en fonction de son diamètre x (en pouces) à 1m30 du sol. Pour ce faire, nous avons mesuré 20 couples (diamètre, hauteur) et effectué les calculs suivants : $\bar{x} = 4.53$, $\bar{y} = 8.65$ et

$$\frac{1}{20} \sum_{i=1}^{i=N} (x_i - \bar{x})^2 = 10.97$$

$$\frac{1}{20} \sum_{i=1}^{i=N} (y_i - \bar{y})^2 = 2.24$$

$$\sum_{i=1}^{i=N} (x_i - \bar{x})(y_i - \bar{y}) = 3.77$$

1. On note $y = \hat{\beta}_0 + \hat{\beta}_1 x$ la droite de régression. Calculer $\hat{\beta}_0$ et $\hat{\beta}_1$.
2. Donner et commenter une mesure de la qualité de l'ajustement des données au modèle. Exprimer cette mesure en fonction des statistiques élémentaires. Commenter le résultat.

5. Exercice 1.5 (Secteur hôtelier)

Un organisme bancaire du secteur hôtelier a besoin de prévoir en fonction du montant des prêts accordés aux professionnels quelles sommes il doit lui-même emprunter sur les marchés financiers. Pour cela il réalise une étude sur les 12 trimestres écoulés. Le montant global des prêts accordés chaque trimestre est donné en millions d'euros. Tous les calculs sont faits à 0,1 près.

Rang du trimestre x_i	1	2	3	4	5	6	7	8	9	10	11	12
Montant y_i	40	42	44	45	48	50	52	55	58	63	68	70

0. Dans un repère orthogonal, représenter le nuage des 12 points. Unités graphiques: 1 cm pour 1 rang sur l'axe des abscisses et 1 cm pour 5 millions d'euros sur l'axe des ordonnées en commençant à la graduation 35.

1. On envisage de résumer quantitativement les valeurs observées à l'aide d'un ajustement affine des 12 points $(x_i ; y_i)$.
 - a. Calculer \bar{x} , \bar{y} , σ_x , σ_y , σ_{XY} et le coefficient de corrélation $\rho_{x,y}$
 - b. Donner une équation de la droite $\Delta 1 : y = \beta_0 + \beta_1 x$ d'ajustement par la méthode des moindres carrés.
 - c. Déterminer une estimation des prêts accordés au quatrième trimestre 2003 sachant que le point (1; 40) est celui du premier trimestre 2000.
2. Cette extrapolation des données repose sur les 12 trimestres précédents l'étude, mais pour tenir compte de l'évolution récente, on se limite aux quatre dernières observations. Reprendre alors la méthode des moindres carrés pour déterminer une équation du nouvel ajustement affine $\Delta 2$ et donner la prévision plus réaliste pour le quatrième trimestre 2003.
3. Dans un repère orthogonal, représenter le nuage des 12 points et les deux droites $\Delta 1$ et $\Delta 2$. Unités graphiques: 1 cm pour 1 rang sur l'axe des abscisses et 1 cm pour 5 millions d'euros sur l'axe des ordonnées en commençant à la graduation 35.

6. Exercice 1.6 (Mortalité infantile)

Remarque : Le but de cette étude est de constater que des résultats statistiques portant sur une certaine période et possédant des propriétés remarquables (comme ici un ajustement linéaire tout à fait justifié) ne peuvent être extrapolés sans précaution.

L'Annuaire statistique de la France donne le tableau suivant indiquant le taux pour mille (‰) de mortalité infantile par période quinquennales de 1886 à 1940 :

période	‰	période	‰
1886-1890	168	1916-1920	119
1891-1895	170	1921-1925	95
1896-1900	161	1926-1930	89
1901-1905	142	1931-1935	73
1906-1910	129	1936-1940	70
1911-1915	126		

1. Représenter graphiquement les données précédentes par un nuage (ensemble de points non reliés) de 11 points. On prendra comme abscisse 1,2, ...11 : 1 sera l'année 1888, 2 l'année 1893, ... , 11 l'année 1938.

2. Vous constatez que les points sont susceptibles d'être ajustés linéairement. Calculer le coefficient de corrélation et procédez à l'ajustement par la méthode des moindres carrés.

Tracer la droite.

3. On admet que l'abscisse n d'une année $An > 1887$ est donnée par : $An - 1888 = 5(n - 1)$.

Quelle est l'abscisse de l'année 1988?

Quel serait le taux en admettant que la droite d'ajustement trouvée est encore valable ?

7. Exercice 1.7 (Consommation de graisse par an et par personne en Norvège)

Le tableau suivant donne la consommation de graisse par an et par personne en Norvège, ainsi que le taux de mortalité par athérosclérose pour 100 000 habitants, pendant une période qui couvre la seconde guerre mondiale.

Année	Consommation de graisse en kg par an et par personne, X	Taux de mortalité par athérosclérose pour 100 000 habitants, Y
1938	14,4	29,1
1939	16	29,7
1940	11,6	29,2
1941	11	26
1942	10	24
1943	9,6	23,1
1944	9,2	23
1945	10,4	23,1
1946	11,4	25,2
1947	12,5	26,1

1. Construire le nuage de points.
2. Calculer les caractéristiques numériques des variables X et Y (moyenne, variance et écart-type).
3. Calculer la covariance entre X et Y.
4. Calculer le coefficient de corrélation linéaire.
5. Utiliser les questions 1. et 4. pour conclure. taux en utilisant la droite de régression obtenue à la question précédente.

6. Calculer les coefficients de régression linéaire de Y sur X. Tracer sur le graphique de la question 1. la droite de régression.

7. En 1948, la consommation de graisse était de 13 kg par personne. Le taux de mortalité par athérosclérose n'a pas été relevé cette année-là. Donner une estimation de ce taux en utilisant la droite de régression obtenue à la question précédente.

8. Exercice 1.8

Le tableau suivant indique les différentes valeurs obtenues pour deux variables quantitatives X et Y dans un échantillon de taille 8.

X	1,3	1,5	2,5	2,5	2,7	3	4	5
Y	2,3	3,5	3,5	4,5	4,7	3	2	1

1. Construire le nuage de points.
2. Calculer le coefficient de corrélation linéaire.
3. Peut-on conclure dans ce cas à l'existence d'un lien linéaire entre X et Y ? Que suggère plutôt le nuage de points ?
4. À l'aide du nuage de points, extraire de l'échantillon initial deux sous-échantillons de taille 4 chacun et calculer le coefficient de corrélation linéaire pour ces deux échantillons. Que constate-t-on ?

TD02- MOYENNES MOBILES

1. Exercice (Vrai-Faux & QCM)

1. QCM

Enoncé

- 1 - Le graphique de la bande permet de connaître de façon simple si le schéma de décomposition est de type additif ou multiplicatif
- 2 - Le filtre des moyennes mobiles utilisé dans le cours est centré.
- 3 - Appliquer une moyenne mobile à une série composée d'une tendance et d'une saison, élimine la composante saisonnière
- 4 - Une moyenne mobile centrée réalisée sur une série, fait perdre autant de points en fin de série que la longueur de la moyenne mobile
- 5 - La moyenne mobile centrée permet d'approcher la composante de long terme

VRAI	FAUX

2. Pour une chronique à 12 termes :

- a) on peut calculer 8 moyennes mobiles centrées de longueur 4
- b) on peut calculer une moyenne mobile centrée de longueur 12
- c) on peut calculer 10 médianes mobiles centrées de longueur 3
- d) on peut calculer 2 moyennes mobiles centrées de longueur 11

3. Si une chronique X a une composante saisonnière de période p, alors :

- a) les moyennes mobiles centrées de longueur 2 p éliminent la saisonnalité
- b) on peut approximer la tendance par la suite des moyennes mobiles centrées de longueur p
- c) la somme de p termes successifs de X donne une approximation de la moyenne de la tendance
- d) on peut toujours calculer (T-p) moyennes mobiles centrées de longueur p si elle a T termes

2. Exercice (air ATMO)

On dispose aussi de la répartition mensuelle du niveau de l'indice de la qualité de l'air ATMO dans l'agglomération parisienne selon trois classes de niveau pour les six années agrégées.

- Légende : Niveau 1 à 4 : très bon à bon.
- Légende : Niveau 5 à 7 : moyen à médiocre.
- Légende : Niveau 8 à 10 : mauvais à très mauvais.
- On s'intéresse à la classe de niveau « 5 à 7 ».

Tableau 1. Fréquences mensuelles d'apparition des indices de 1998 à 2003

Niveau	1 à 4	5 à 7	8 à 10	Nombre total de jours
Janvier	164	22	0	186
Février	136	29	4	169
Mars	151	35	0	186
Avril	152	28	0	180
Mai	132	54	0	186
Juin	115	65	0	180
Juillet	123	59	4	186
Août	93	83	10	186
Septembre	155	25	0	180
Octobre	155	31	0	186
Novembre	172	8	0	180
Décembre	177	9	0	186
Nombre total de jours	1725	448	18	2191

1. Représentez graphiquement son évolution au cours des 12 mois.

2. Calculez la suite des moyennes mobiles de longueur 3 et représentez-la sur le même graphique. Quelle propriété de la moyenne mobile venez-vous d'illustrer ?

3. Exercice (Moyenne mobile)

t	1	2	3	4	5	6	7	8	9	10	11	12
x_t	3	-1	5	1	3	-1	5	1	3	-1	5	1

1. Calculez les suites des moyennes mobiles de longueurs 2, 3, 4 et 5.

Quelles sont les propriétés de la moyenne mobile qui sont illustrées par cet exemple ?

2. Soit la chronique $x_{1t} = 10 - 2t + x_t$, calculez la suite des moyennes mobiles de longueur 4 de la nouvelle série z_t

4. Exercice (Moyennes mobiles)

On considère la série chronologique représentant les ventes d'huitres en tonnes par trimestres

1. Calculez la moyenne mobile centrée d'ordre 4 pour $t = 3$ 63,125 ou 65,525

2. Calculez la moyenne mobile centrée d'ordre 4 pour $t = 4$ 66.775 ou 65,875

3. Calculez la moyenne mobile centrée d'ordre 4 pour $t = 5$ 69,125 ou 68,197

4. Calculez l'ensemble des moyennes mobiles centrées d'ordre 4 et les représenter dans un tableau, par année et par trimestre

Tableau 2. Ventes d'huitres en tonnes par trimestres

Ventes d'huitres	
Période	Tonnes
1er tri 10	52
2e tri 10	36
3e tri 10	69
4e tri 10	89
1er tri 11	65
2e tri 11	45
3e tri 11	86
4e tri 11	111
1er tri 12	81
2e tri 12	56
3e tri 12	108
4e tri 12	139
1er tri 13	102
2e tri 13	70
3e tri 13	135
4e tri 13	174

	Série initiale				Moyenne mobile d'ordre 4			
	Tri-1	Tri-2	Tri-3	Tri-4	Tri-1	Tri-2	Tri-3	Tri-4
2010	52	36						
2011	65							
2012								
2013								

TD03- MODELES MULTIPLICATIF ET ADDITIF

1. Exercice (nombre de mariages, CVS et modèle additif)

On a relevé le nombre de mariages dans une ville du sud-ouest de la France chaque trimestre pendant 3 ans :
On notera Y la variable dont on étudie l'évolution.

Année \ Trimestre	1998	1999	2000
1	10	11	12
2	12	14	15
3	13	15	17
4	11	12	12

1. Représenter graphiquement cette série chronologique (avec périodes superposées puis avec périodes successives). Commenter.
2. Calculer la série des moyennes mobiles, lisser la courbe.

3. Calculer l'équation de la droite de tendance et tracer cette droite sur le graphique précédent.
4. Calculer les quatre coefficients saisonniers (pour le modèle additif).
5. Utiliser le modèle construit pour prévoir le nombre de mariages dans cette ville en 2002.

2. Exercice (nombre de mariages, CVS et modèle additif)

Tableau 3. Source : INSEE- Division indicateurs conjoncturels d'activité.

Le tableau ci-contre donne les indices trimestriels de la production industrielle (base 100 en 1980) en ce qui concerne les produits de la parachimie et de la pharmacie :

Année \ Trimestre	1982	1983	1984
1	106	106,1	109,6
2	108,8	107,1	108,5
3	97,9	98,5	103
4	108,5	111,2	115,5

1. Faire une étude complète de cette série chronologique (reprendre les 4 premières questions de l'exercice 1.1).

2. On note toujours Y la variable dont on étudie l'évolution et afin de réduire les calculs, voici un tableau (à compléter) qui fournit quelques résultats

Quel est l'indice prévisible pour le 3-ième trimestre 1985 ?

t	y(t)	z(t)	t * z(t)	x(t) = 0,49t + 103,04	y(t) - x(t)	s'(t)	s(t)
1	106			103,53	2,47	1,743	
2	108,8			104,02	4,78	2,153	
3	97,9	105,31	315,94	104,51	-6,61		
4	108,5	105,11	420,45	105	3,5		
5	106,1	104,98	524,88	105,49	0,61		
6	107,1	105,39	632,33	105,98	1,12		
7	98,5	106,16	743,14	106,47	-7,97		
8	111,2	106,78	854,20	106,96	4,24		
9	109,6						
10	108,5						
11	103						
12	115,5						

3. Exercice (Moyenne mobile et CVS)

	1974	1975	1976	1977
Janvier	127,4	145,9	159,9	174,3
Février	129,1	147	161	175,5
Mars	130,6	148,2	162,4	177,1
Avril	132,7	149,5	163,8	179,4
Mai	134,3	150,6	164,9	181,1
Juin	135,8	151,7	165,6	182,5
Juillet	137,5	152,8	167,2	184,1
Août	138,6	153,8	168,4	185,1
Septembre	140,1	155,1	170,2	186,7
Octobre	141,8	156,3	171,8	188,2
Novembre	143,1	157,3	173,2	188,9
Décembre	144,3	158,2	173,8	189,4

On se propose d'étudier l'évolution de l'indice mensuel des prix à la consommation de 1974 à 1977. Les observations mensuelles sont consignées dans le tableau ci-contre.

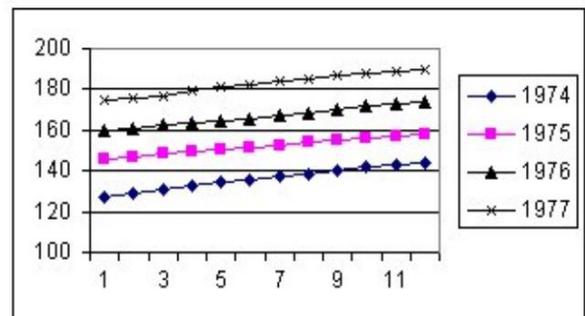
1. Calculer la première et la dernière moyenne mobile.

2. Voici la représentation graphique de cette série chronologique avec périodes superposées :

Est-il intéressant ici de calculer la série des moyennes mobiles ?

3. Qu'apporterait le calcul des variations saisonnières ?

4. Quelle méthode vous paraît la mieux adaptée pour faire des prévisions ?



4. Exercice (Disneyland-Paris & Moyenne mobile et CVS)

Tableau 4. Source : Disneyland-Paris, Marne la Vallée, 1998.

On étudie la fréquentation des hôtels américains de Disneyland-Paris entre 1995 et 1997.

Le nombre de clients (en milliers) est donné dans le tableau ci-contre :

Année	Trimestre 1	Trimestre 2	Trimestre 3	Trimestre 4
1995	8,2	12,3	32,7	8,3
1996	10	14,5	37,3	11,5
1997	11	17,3	41,3	13,3

1. Compléter la série des moyennes mobiles dont les 6 dernières valeurs sont : 16,95 ; 17,925 ; 18,45 ; 18,925 ; 19,775 ; 20,5.

Représenter sur un même graphique la série des données et la série des moyennes mobiles. Commenter.

2. Déterminer l'équation de la droite de tendance et la tracer sur le même graphique.

3. On donne la somme des composantes saisonnières : $S_0 = 0,567$. Calculer les coefficients saisonniers du 1^{er} et du 3^{ème} trimestre.

4. En utilisant le modèle que l'on a construit, quelle fréquentation peut-on prévoir pour le troisième trimestre 2000 ?

5. Exercice 1.5 (billets vendus & moyennes mobiles et modèle additif)

On étudie l'évolution du nombre de billets vendus (en milliers) dans un complexe cinématographique lors des trois premières années :

	Janv-Fév	Mars-Avril	Mai-Juin	Juillet-Août	Sep-Oct	Nov-Déc
1997	100	82	70	40	62	91
1998	105	94	73	43	72	106
1999	111	99	84	52	77	118

1. Représenter graphiquement ces données dans un repère cartésien.
2. Calculer la série des moyennes mobiles.
3. Montrer que l'équation de la droite de tendance est : $x(t) = 1,34t + 68,93$. Tracer cette droite sur le graphique précédent.
4. On donne la somme des composantes saisonnières : $S_0 = 3,04$.

Calculer le coefficient saisonnier pour Juillet-Août. Utiliser ce coefficient pour faire des prévisions pour Juillet-Août 2000.

6. Exercice 1.6 (magasin d'insecticides, moyennes mobiles et modèle additif)

Voici les résultats du chiffre d'affaire d'un magasin d'insecticides d'Egletons (département de la Corrèze) au cours des douze derniers trimestres (en milliers de francs) :

	1998	1999	2000
1 ^{er} trimestre	27	29	30
2 ^{ème} trimestre	10	12	13
3 ^{ème} trimestre	15	16	17
4 ^{ème} trimestre	26	27	28

1. Sur le graphique de la page suivante, faire une représentation cartésienne avec périodes successives de la série chronologique précédente.
Quelles conjectures peut-on tirer de ce graphique ?

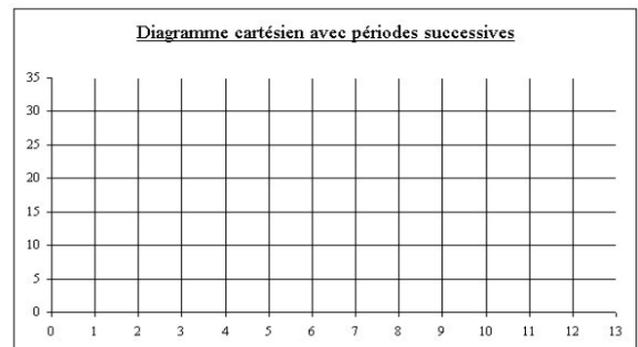


Figure 1. Diagramme cartésien pour les insecticides

2. Afin de dégager la tendance, le propriétaire du magasin décide d'utiliser la méthode des moyennes mobiles ; compléter le tableau avec les moyennes mobiles, $z(t)$, non calculées.
3. Pour avancer les calculs, on donne $\bar{Z} = 20,938$. Montrer que l'équation de la droite de tendance est $x(t) = 0,289t + 19,061$. Tracer sur le graphique précédent cette droite.
4. Compléter sur le tableau les différents calculs relatifs aux coefficients saisonniers ($\delta(t)$, $s'(t)$ et $s(t)$).
5. Tracer sur le graphique les estimations (les valeurs de $\hat{y}(t)$) que donne le modèle pour l'année 2000. Au vu des résultats obtenus, le modèle vous paraît-il pertinent ?
6. Dédire des calculs précédents, la prévision du chiffre d'affaire du magasin pour le troisième trimestre 2001.

t	z(t)	$\delta(t)$	$s'(t)$	s(t)
1		7,650		
2		-9,639		
3	19,750		-5,084	-4,978
4			5,627	5,733
5	20,625	8,494		
6	20,875	-8,795		
7	21,125	-5,084	-5,084	-4,978
8	21,375	5,627	5,627	5,733
9	21,625	8,338		
10		-8,951		
11		-5,240	-5,084	-4,978
12		5,471	5,627	5,733

7. Exercice 1.7 (construction, moyennes mobiles et modèle additif)

Tableau 5. Source INSEE

Le tableau suivant donne l'évolution de l'indice du coût de la construction (base 100 au 4ème trimestre 1953). Cet indice est utilisé par exemple pour la révision annuelle des loyers. On notera Y la variable « indice du coût de la construction » et T le temps.

Trimestres	Années		
	1998	1999	2000
1	1058	1071	1083
2	1058	1074	1089
3	1057	1080	1093
4	1074	1065	1127

On pourra utiliser le tableau et le graphique ci-dessous.
1. Représenter graphiquement cette série chronologique avec périodes successives.
Peut-on parler ici de variations saisonnières ?

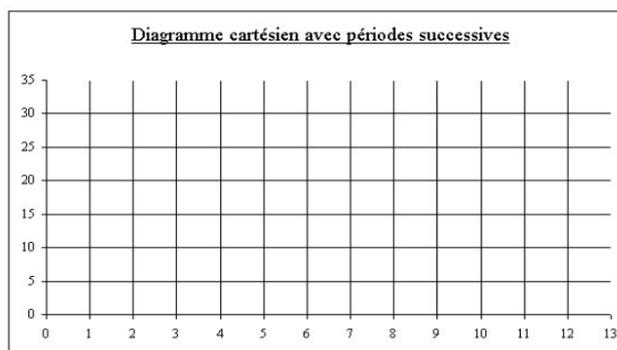


Figure 2. Diagramme cartésien pour la construction

2. Compléter la série des moyennes mobiles (expliquer le calcul des $z(t)$) et représenter cette série sur le graphique ci-dessus.
Quel est l'intérêt des moyennes mobiles ?
Peut-on utiliser le modèle additif pour décrire cette série chronologique ?

t	$y(t)$	$z(t)$
1	1058	
2	1058	
3	1057	1063,375
4	1074	1067
5	1071	1071,875
6	1074	1073,625
7	1080	1074
8	1065	
9	1083	
10	1089	
11	1093	
12	1127	

8. Exercice (TrucNet, Modèle additif + moyenne mobile)

Le tableau ci-contre donne le chiffre d'affaires trimestriel de l'entreprise TrucNet sur la période 2017 à 2017.

- Tracer la série chronologique X .
- Quel modèle peut-on appliquer sur la série chronologique X ? Justifier votre choix.
- Après avoir justifié la longueur de la moyenne mobile à employer, calculer la série Y des moyennes mobiles et représenter les deux courbes sur un même graphique.

	Trimestre 1	Trimestre 2	Trimestre 3	Trimestre 4
2014	120	181	71	119
2015	128	190	73	124
2016	140	196	84	133
2017	145	206	96	142

Figure 3. Chiffre d'affaires trimestriel de TrucNet

TD04- LISSAGE EXPONENTIEL

1. Exercice (QCM)

Une prévision par lissage exponentiel simple :

- a) tient d'autant plus compte des valeurs récentes de la série que la constante α est faible
- b) peut s'envisager pour une chronique possédant une composante saisonnière
- c) ne peut pas s'envisager pour une chronique possédant une tendance à la hausse
- d) s'adapte d'autant plus rapidement à un changement de niveau de la chronique que α est élevée

2. Exercice (Nombre d'immatriculations de voitures avec un moteur diesel)

L'Institut National de la Statistique et des Etudes Economiques (INSEE) vous charge d'un projet comprenant deux objectifs : mener une étude exploratoire sur le nombre d'immatriculations de voitures particulières neuves avec un moteur diesel, puis réaliser une prévision de ce nombre d'immatriculations pour chacun des mois des années 2006 et 2007. Pour mener à bien ce projet, vous disposez des données suivantes exprimées en milliers (source INSEE - site internet)

	Jan.	Feb.	Mar.	Apr.	May	Jun.	Jul.	Aug.	Sep.	Oct.	Nov.	Dec.
1982	17.9	17.8	22.3	18.8	15.4	17.6	16.4	14.0	17.3	20.2	21.0	22.6
1983	17.2	14.6	17.6	13.8	14.1	16.7	15.0	11.8	13.4	17.7	20.2	20.7
1984	17.1	15.7	18.6	17.4	20.9	18.9	19.0	16.9	15.9	27.3	27.4	25.0
1985	23.9	22.2	24.0	21.5	20.4	19.0	23.6	15.7	17.8	26.5	25.0	25.2
1986	24.9	19.3	21.6	23.6	20.5	19.7	26.0	22.5	21.0	31.2	30.7	38.5
1987	27.7	27.4	32.5	32.3	27.0	24.9	37.9	26.6	23.1	41.2	38.2	45.4
1988	37.6	32.4	43.1	40.9	40.8	31.0	53.9	36.9	32.2	45.7	53.1	74.9
1989	66.2	59.9	57.8	56.4	46.5	46.7	72.4	50.9	47.5	68.3	62.7	51.8
1990	82.0	59.7	65.8	58.5	57.2	44.5	75.0	53.5	44.4	77.9	74.9	68.7
1991	76.7	60.8	66.5	68.2	54.4	46.0	91.8	55.0	50.8	76.3	66.2	67.8
1992	74.3	60.7	68.8	68.0	55.9	53.5	93.0	57.2	58.2	81.2	74.6	75.2
1993	58.5	60.0	70.2	61.1	51.3	49.3	88.5	52.7	53.4	78.5	79.5	80.0
1994	64.6	64.0	86.0	80.8	68.8	53.8	102.8	68.9	67.3	87.6	101.0	94.4
1995	84.9	81.2	88.9	71.5	65.4	73.1	97.9	66.4	55.9	72.7	77.3	62.7
1996	81.9	74.6	76.8	74.7	57.7	47.8	97.1	61.8	71.7	70.3	58.5	65.0
1997	53.7	55.4	59.6	67.0	49.1	37.3	94.1	50.2	55.0	68.1	60.8	65.9
1998	60.1	59.2	70.5	67.4	55.6	40.8	101.7	54.7	63.4	66.3	71.1	70.1
1999	64.5	63.7	82.5	80.1	62.8	44.1	136.7	76.5	70.7	86.3	87.3	92.3
2000	82.8	87.4	99.6	86.8	92.5	89.5	94.1	75.4	76.4	91.8	91.9	78.3
2001	99.8	92.8	110.1	108.5	112.3	124.4	121.8	84.5	88.8	116.4	110.4	98.0
2002	117.9	106.7	123.4	128.7	114.7	126.6	127.7	75.7	95.9	122.7	109.5	105.4
2003	118.2	107.8	125.2	121.3	108.1	136.6	125.4	70.1	105.0	125.8	99.9	110.6
2004	108.8	104.8	133.5	118.3	117.4	148.5	116.6	73.5	108.0	119.3	124.3	119.9
2005	117.2	113.0	143.8	134.3	126.6	151.4	108.0	77.0	114.5	109.6	117.8	115.7

A - Phase exploratoire

1. Compléter les tableaux suivants :

Année	Total	Moyenne
1982	.	18.44
1983	192.8	16.07
1984	240.1	20.01
1985	264.8	22.07
1986	299.5	24.96
1987	384.2	32.02
1988	522.5	43.54
1989	.	57.26
1990	762.1	63.51
1991	780.5	.
1992	820.6	68.38
1993	783.0	65.25

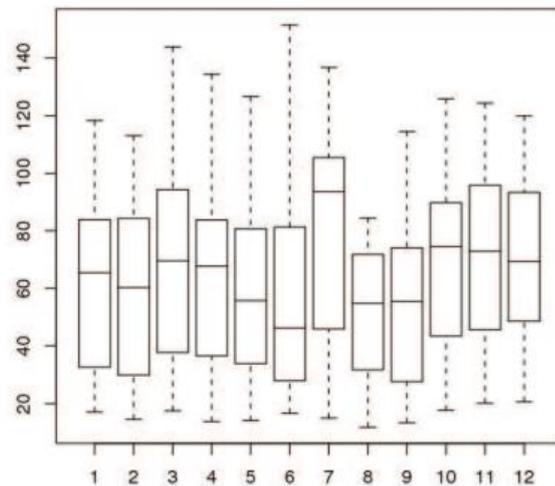
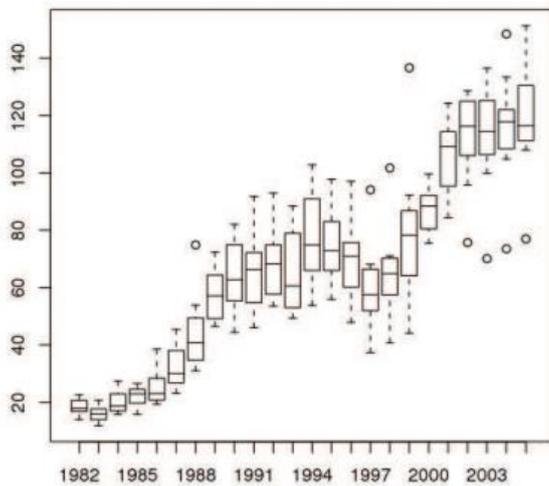
Année	Total	Moyenne
1994	940.0	78.33
1995	897.9	74.83
1996	837.9	69.83
1997	716.2	59.68
1998	780.9	65.08
1999	947.5	78.96
2000	1046.5	87.21
2001	1267.8	.
2002	1354.9	112.91
2003	1354.0	112.83
2004	.	116.08
2005	1428.9	119.08

2. Représenter graphiquement la série correspondant à la moyenne mensuelle d'immatriculations de voitures particulières neuves avec un moteur diesel par an. Interpréter succinctement ce graphique en mettant en évidence les différentes phases.

3. Compléter le tableau suivant, puis commenter :

Mois	Total	Moyenne	Ecart-type
Janvier	.	65.77	33.24
Février	1461.1	60.88	31.29
Mars	1708.7	71.20	37.98
Avril	1619.9	67.50	36.20
Mai	1455.4	60.64	34.64
Juin	1461.7	60.90	43.98
Juillet	1936.4	80.68	38.68
Août	1248.4	52.02	23.01
Septembre	1367.6	56.98	30.74
Octobre	1728.9	.	33.09
Novembre	1683.3	70.14	31.69
Décembre	1674.1	69.75	29.72

4. Identifier chacun des graphiques suivants dans le contexte, puis les commenter (médianes, dispersions, et valeurs atypiques).



5. La représentation graphique de la série est la suivante. Commenter ce graphique :

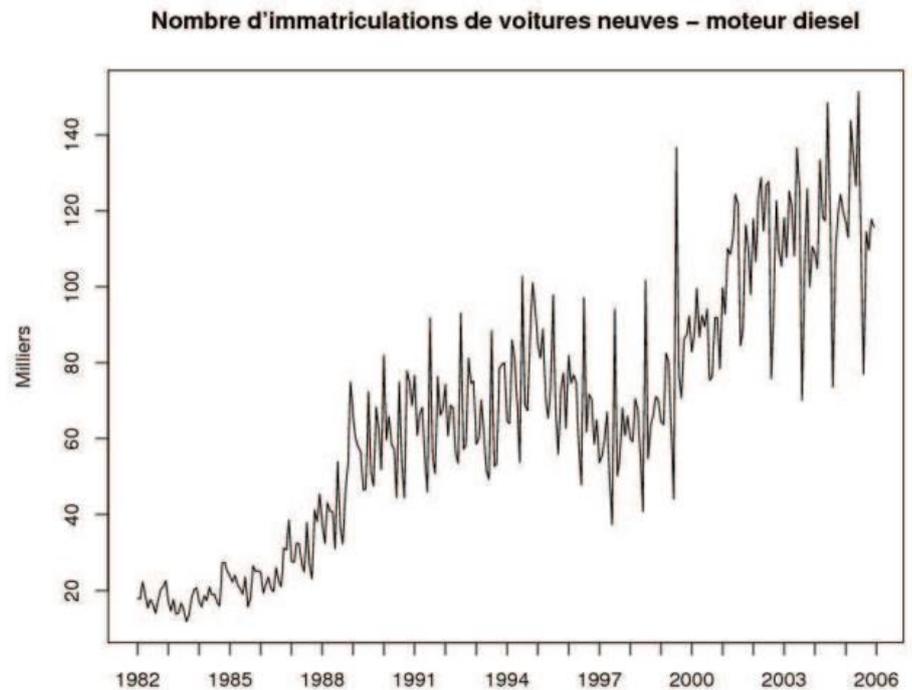
Le phénomène observé est-il croissant, décroissant, ou stationnaire ?

Visualise-t-on une composante tendancielle déterministe ou aléatoire ?

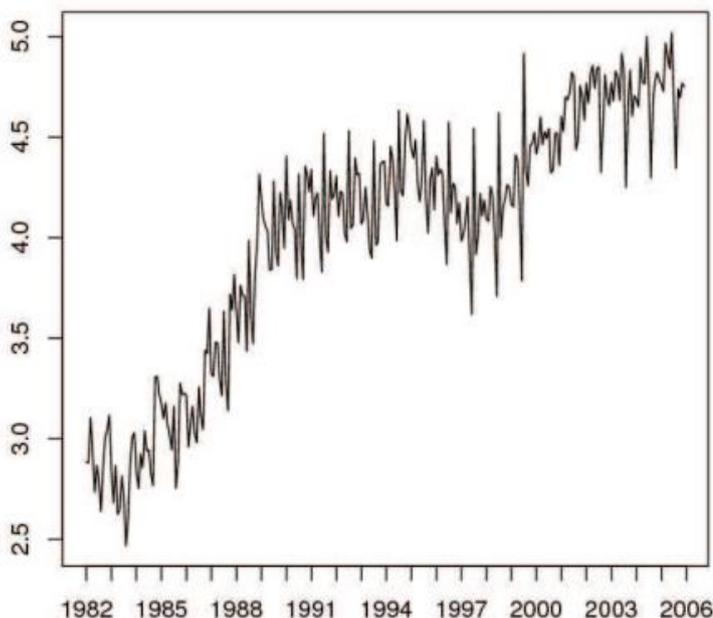
Observe-t-on des ruptures de tendance ?

Détecte-t-on un phénomène saisonnier ?

Existe-t-il des points atypiques ?



6. Déterminer la transformation que l'on devrait mener afin d'homogénéiser la volatilité de la série sur la période d'observation. Via cette transformation on obtient le graphique suivant. Cette transformation a-t-elle été efficace ?



B - Phase de modélisation

La première phase a permis de mettre en évidence l'existence d'une composante tendancielle aléatoire. Dans la phase de modélisation, on propose dans un premier temps de faire usage d'un modèle de type Holt, c'est-à-dire de réaliser un lissage exponentiel double. On rappelle à ce propos que cette méthode consiste à estimer la valeur de la variable à l'instant $t + h$, étant donné que l'on se situe à l'instant t , selon la relation :

$$\hat{y}_t(h) = a_t + h * b_t,$$

où les coefficients a_t et b_t , représentant respectivement l'ordonnée à l'origine et la pente de la droite à l'instant t (selon une notation anglosaxonne), sont calculés par récurrence via le système suivant :

$$\begin{cases} a_t = \alpha y_t + (1 - \alpha)(a_{t-1} + b_{t-1}) \\ b_t = \beta(a_t - a_{t-1}) + (1 - \beta)b_{t-1} \end{cases}$$

où α et β sont deux paramètres appelés constantes de lissage. Cette double relation de récurrence nécessite une initialisation qui, par défaut, consiste en générale à choisir les quantités suivantes : $a_2 = y_2$ et $b_2 = y_2 - y_1$

1. Dans le cas présent, on va travailler avec le logarithme de la série dont les valeurs pour l'année 1982 sont respectivement :

2.885 2.879 3.105 2.934 2.734 2.868 2.797 2.639 2.851 3.006 3.045 3.118

Déduire de ces valeurs les quantités a_2 et b_2 , puis la quantité $\hat{y}_2(1)$

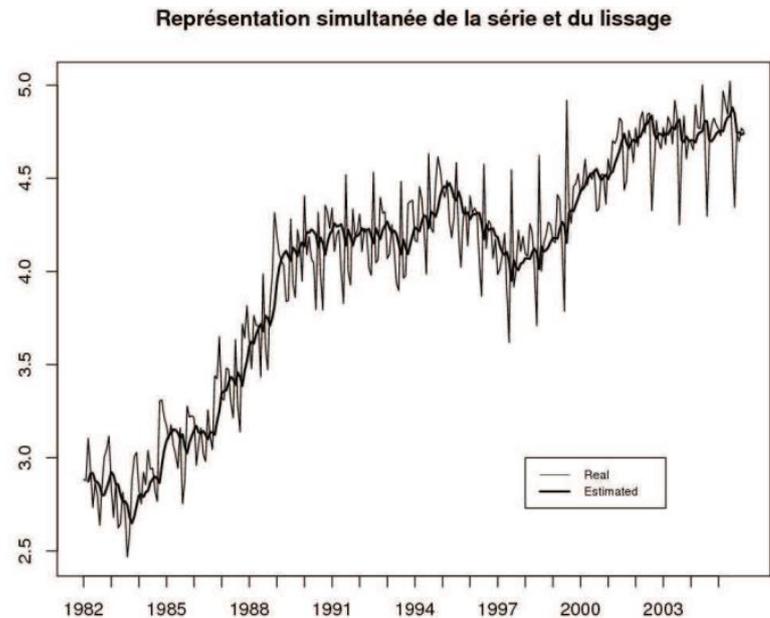
2. En choisissant $\alpha = 0.2$ et $\beta = 0.6$, compléter le tableau suivant :

	Jan.	Feb.	Mar.	Apr.	May	Jun.	Jul.	Aug.	Sep.	Oct.	Nov.	Dec.
1982	-	-	-	-	-	-	-	-	-	-	-	-
1983	2.97	2.99	2.93	2.91	2.82	2.72	2.69	2.65	2.55	2.49	2.55	2.68
1984	2.83	2.91	2.94	3.00	3.01	3.06	3.07	3.06	3.00	2.91	3.00	3.11
1985	3.19	3.24	3.25	3.27	3.23	3.17	3.08	3.06	2.92	2.84	2.90	2.98
1986	3.07	3.16	3.15	3.17	3.19	3.16	3.11	3.14	3.13	3.10	3.20	3.30
1987	3.47	3.52	3.53	3.57	3.59	3.53	3.43	3.46	3.39	3.28	3.36	3.44
1988	3.58	3.67	3.68	3.76	3.81	3.83	3.75	3.82	3.78	3.68	3.69	3.76
1989	3.95	4.11	4.21	4.27	4.28	4.20	4.09	4.12	4.04	3.95	3.98	4.00
1990	3.98	4.10	4.14	4.19	4.19	4.17	4.06	4.11	4.06	3.96	4.03	4.12
1991	4.18	4.28	4.28	4.30	4.30	4.23	4.09	4.16	4.10	4.02	4.07	4.10
1992	4.14	4.21	4.21	4.25	4.26	4.21	4.13	4.23	4.19	4.14	4.20	4.25
1993	4.29	4.25	4.21	4.21	4.17	4.07	3.97	4.06	4.03	3.99	4.08	4.20
1994	4.31	4.34	4.34	4.42	4.46	4.43	4.31	4.38	4.34	4.28	4.32	4.41
1995	4.48	4.52	4.52	4.54	4.48	4.37	4.30	4.34	4.27	4.16	4.13	4.15
1996	4.12	4.18	4.23	4.29	4.33	4.28	4.16	4.24	4.21	4.22	4.23	4.18
1997	4.16	4.09	4.02	4.00	4.02	3.97	3.82	3.98	3.97	3.99	4.07	4.12
1998	4.19	4.21	4.20	4.24	4.26	4.21	4.05	4.17	4.12	4.11	4.13	4.17
1999	4.21	4.22	4.22	4.29	4.36	4.33	4.18	4.37	4.40	4.39	4.44	4.48
2000	4.53	4.53	4.54	4.58	4.57	4.57	4.55	4.55	4.48	4.40	4.39	4.40
2001	4.37	4.43	4.47	4.56	4.65	4.73	4.83	4.91	4.83	4.74	4.73	4.70
2002	4.64	4.65	4.64	4.68	4.74	4.76	4.82	4.86	4.73	4.65	4.66	4.64
2003	4.63	4.65	4.66	4.72	4.76	4.77	4.84	4.88	4.71	4.66	4.67	4.63
2004	4.62	4.62	4.62	4.70	4.75	4.78	4.89	4.91	4.76	4.71	4.69	4.71
2005	4.72	4.73	4.73	4.81	4.87	4.90	4.98	4.93	4.76	4.70	4.64	4.63

3. Dans le cas présent, on a imposé les deux constantes de lissage.
Est-on sûr que ces constantes donnent un lissage optimal ?

Comment faudrait-il procéder pour déterminer les constantes donnant le meilleur ajustement ?

4. Selon une approche consistant à chercher la solution optimale, on obtient le graphique suivant.
Quel est l'intérêt d'obtenir une série lissée ?



5. On propose de recommencer la modélisation en intégrant cette fois-ci une composante saisonnière. Dans ce but, on va faire usage du lissage exponentiel de type Holt-Winters. Dans ce cadre, on estime la valeur de la variable à l'instant $t + h$ par :

$$\hat{y}_t(h) = a_t + h * b_t + s_{t+h/\text{mod } p}$$

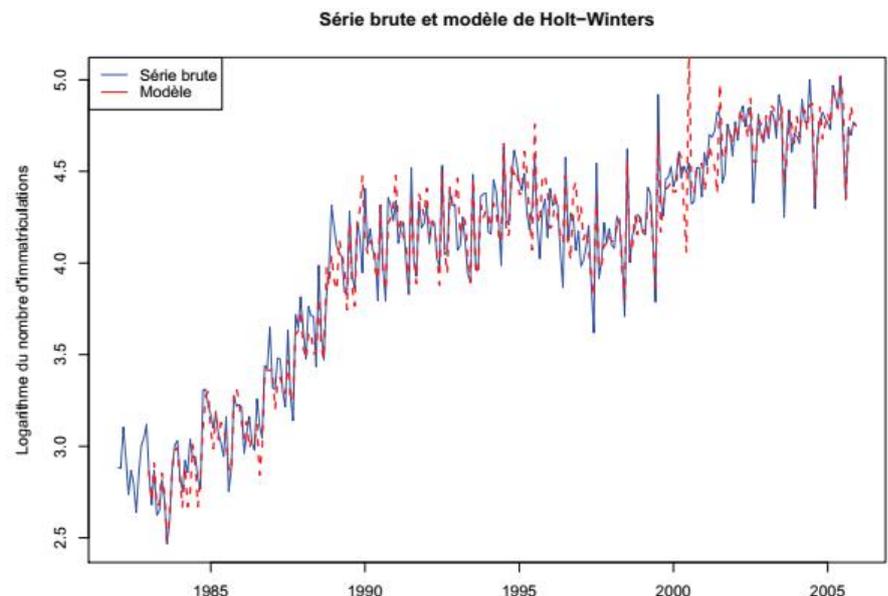
où les coefficients a_t , b_t et s_t sont calculés via le système suivant :

$$\begin{cases} a_t = \alpha(y_t - s_{t-p}) + (1 - \alpha)(a_{t-1} + b_{t-1}) \\ b_t = \beta(a_t - a_{t-1}) + (1 - \beta)b_{t-1} \\ s_t = \gamma(y_t - a_t) + (1 - \gamma)s_{t-p} \end{cases}$$

où α , β et γ sont trois paramètres (les constantes de lissage).

En réalisant cette nouvelle stratégie, on obtient le graphique suivant.

Pensez-vous que cette modélisation est meilleure ? Justifier votre réponse.



a	4.6952
b	0.0049
s1	0.0598
s2	0.0197
s3	0.2395
s4	0.1599
s5	0.1005
s6	0.2724
s7	0.0232
s8	-0.3602
s9	0.0104
s10	0.0517
s11	0.0781
s12	0.0553

C - Phase de prévision

Une modélisation satisfaisante étant obtenue, il convient maintenant de passer à l'étape de prévision. Dans le cadre du lissage de Holt-Winters, les prévisions sont réalisées via la relation

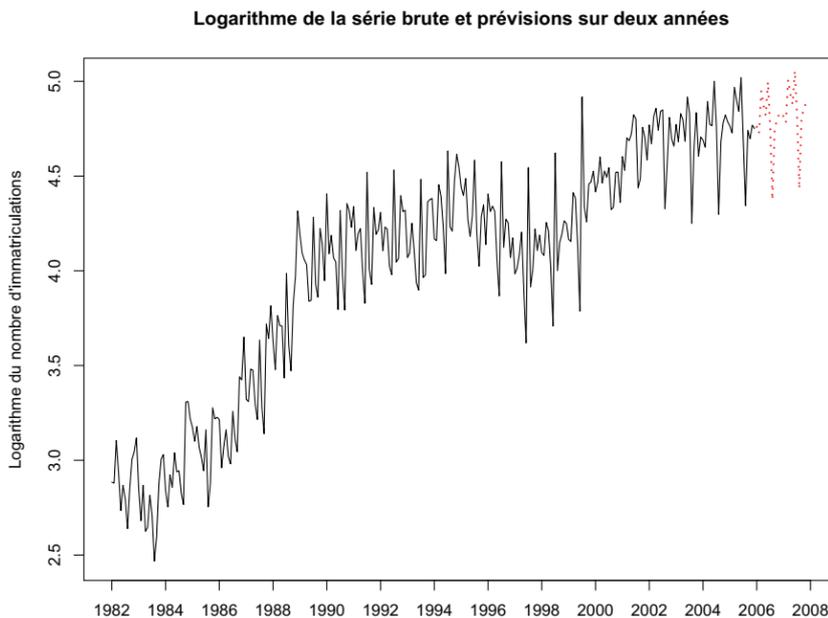
$$\hat{y}_t(h) = a_t + h \times b_t + s_{t+h/\text{mod } p}, \quad \forall h \geq 1$$

A l'issue de la modélisation précédente, on a obtenu les coefficients suivants.

1. Compléter alors le tableau suivant :

$\log \hat{y}_t$	Janv.	Fév.	Mars	Avril	Mai	Juin	Juil.	Août	Sep.	Oct.	Nov.	Déc.
2006
2007

2. Selon cette approche, on obtient la représentation graphique suivante :



Vos résultats sont-ils en accord avec ce graphique ?

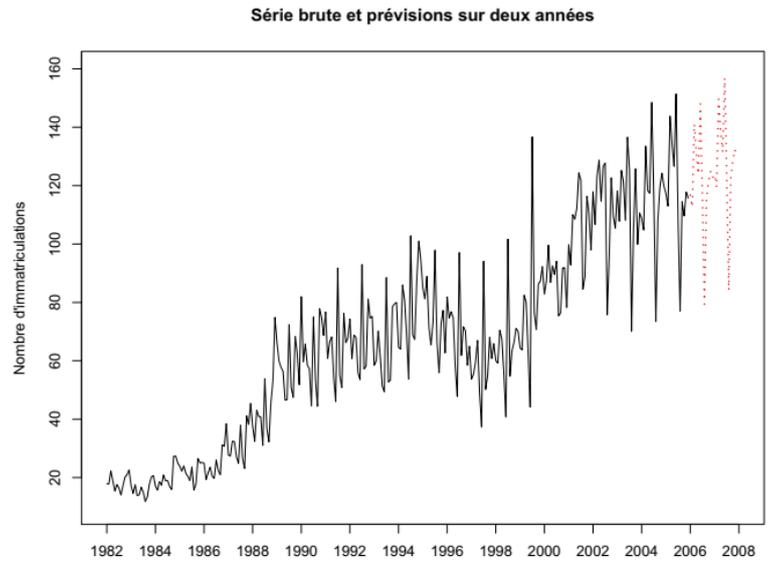
3. Quelle transformation doit-on effectuer sur ces prévisions afin qu'elles soient cohérentes avec la série initiale ? Justifier votre réponse.

4. Compléter alors le tableau suivant :

\hat{y}_t	Janv.	Fév.	Mars	Avril	Mai	Juin	Juil.	Août	Sep.	Oct.	Nov.	Déc.
2006
2007

5. On obtient finalement la représentation graphique suivant.

Ce graphique correspond-il à vos calculs ?
Commenter succinctement ces prévisions.



TD01- AJUSTEMENT LINÉAIRE, METHODE DES MOINDRES CARRES (MCO),
COEFFICIENT DE DETERMINATION-CORRECTION

1. Exercice

B-A

2. Exercice

$$\begin{aligned} R^2 &= \frac{\sum_{i=1}^n (\hat{\beta}_1 + \hat{\beta}_2 x_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{\sum_{i=1}^n (\bar{y} - \hat{\beta}_2 \bar{x} + \hat{\beta}_2 x_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \\ &= \frac{\hat{\beta}_2^2 \sum_{i=1}^n (x_i - \bar{x})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{[\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})]^2 \sum_{i=1}^n (x_i - \bar{x})^2}{[\sum_{i=1}^n (x_i - \bar{x})^2]^2 \sum_{i=1}^n (y_i - \bar{y})^2} \\ &= \frac{[\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})]^2}{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2} = \rho^2(X, Y). \end{aligned}$$

3. Exercice

- Exercice 1.3 (Poids des pères et des fils)**
1. La droite des moindres carrés du poids des fils en fonction du poids des pères s'écrit (cf. figure 1.10 à gauche) : $f = \hat{\alpha}_1 + \hat{\alpha}_2 p = 35.8 + 0.48p$.
 2. La droite des moindres carrés du poids des pères en fonction du poids des fils s'écrit (cf. figure 1.10 à droite) : $p = \hat{\beta}_1 + \hat{\beta}_2 f = -3.38 + 1.03f$.
 3. Le produit des pentes des deux droites est

$$\hat{\alpha}_2 \hat{\beta}_2 = \frac{(\sum (f_i - \bar{f})(p_i - \bar{p}))^2}{(\sum (f_i - \bar{f})^2) (\sum_{i=1}^n (p_i - \bar{p})^2)} = R^2,$$

où R^2 est le coefficient de détermination, carré du coefficient de corrélation linéaire.

4. Exercice 1.4

1. Les estimateurs de la droite des moindres carrés $y = \hat{\beta}_0 + \hat{\beta}_1 x$ sont respectivement :

$$\hat{\beta}_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} \approx 0.344$$

et

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \approx 7.09$$

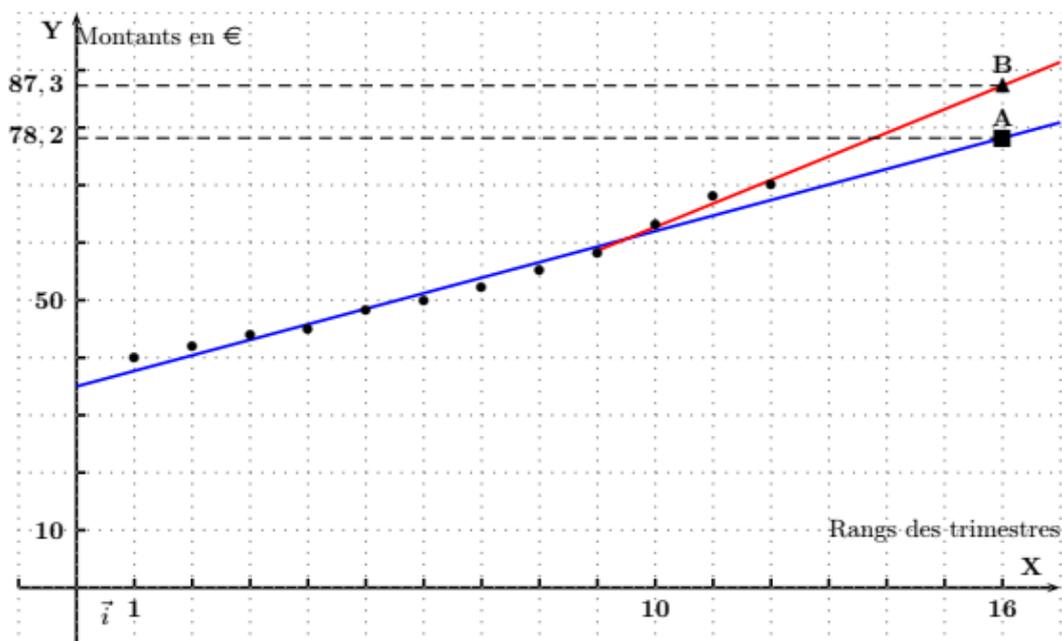
2. Une mesure de la qualité de l'ajustement des données au modèle est donnée par le coefficient de détermination R^2 , dont on a vu qu'il correspond au carré du coefficient de corrélation linéaire empirique :

$$R^2 = \left(\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \right)^2 \approx 0.58.$$

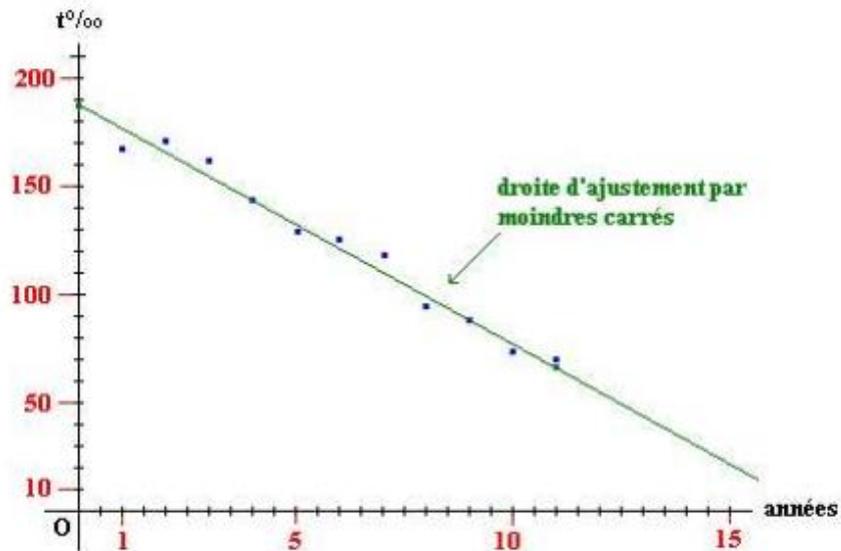
Le modèle de régression linéaire simple explique donc un peu plus de la moitié de la variance présente dans les données.

5. Exercice 1.5 (secteur hôtelier)

- On obtient sur TI 82: $y = 2,7x + 35$ et $r = 0,98$. L'ajustement est justifié.
- $x = 16$ donne la valeur estimée: $\hat{y} = 2,7 \times 16 + 35 = 78,2$ millions d'€. Point A.
- On obtient sur TI 82 en gardant la même numérotation des trimestres: $y = 4,1x + 21,7$ et $r = 0,98$. L'ajustement est de bonne qualité. La prévision est alors: $\hat{y} = 4,1 \times 16 + 21,7 = 87,3$ millions d'€. Point B.



6. Exercice 1.6 (mortalité infantile)



2°/ Le coefficient de corrélation linéaire est donné par la formule :

$$r = \frac{\text{cov}(X, Y)}{\sqrt{V(X) \times V(Y)}} \text{ avec } \text{cov}(X, Y) = \frac{1}{n} \sum x_i y_i - \bar{x} \times \bar{y}$$

Le tableau ci-dessous résume les différents paramètres statistiques (V = variance, σ = écart-type) des séries observées.

$|r| = 0,989$ est proche de 1 : forte présomption d'alignement. La droite de régression de y en x (ajustement linéaire) par la méthode des moindres carrés a sensiblement pour équation : $y = -11x + 187$.

Point moyen : G(6,122)	$\sum x_i = 66$	$\sum y_i = 1342$	$\sum x_i^2 = 506$
$\sum y_i^2 = 177062$	$\sum x_i y_i = 6854$	$V(x_i) = 10$	$\sigma(x_i) = 3,1623$
$V(y_i) = 1212,546$	$\sigma(y_i) = 34,8216$	$\text{cov}(x_i, y_i) = -108,9091$	$r = - 0,989$

→ Rappelons que si (d) : $y = ax + b$ est l'équation de la droite de régression de y en x, le coefficient directeur de cette droite est donné par la formule : $a = \text{cov}(X, Y)/V(X)$; l'ordonnée à l'origine se calcule facilement sachant que (d) passe par le point moyen G($\sum x_i, \sum y_i$).

3°/ Les classes ont une amplitude de 5 ans; si 1888, centre de la classe, correspond à l'abscisse $n = 1$, les années sont en progression arithmétique (A_n) de raison 5, de 1er terme 1888; on a donc : $A_n = 1888 + (n - 1) \times 5$, ou encore :

$$A_n - 1888 = 5(n - 1)$$

! On constate qu'une prédiction à long terme ($x = 21 : 100$ ans entre 1888 et 1988) n'a pas de sens : le taux serait négatif ! Toute extrapolation de résultats statistiques doit bien sûr tenir compte de changements significatifs dans une population donnée.

→ Dans la première moitié du 20e siècle les progrès de la médecine, dus pour beaucoup à Pasteur (1822-1895), ont permis d'éradiquer un grand nombre de maladies du nourrisson.

De plus, en Europe en particulier, les naissances ont lieu désormais dans des maternités avec un suivi de l'enfant, ce qui n'était pas le cas jusque dans les années 1950. La mortalité infantile a beaucoup baissé depuis cette époque mais cette évolution est plus lente. En France, le taux était de 7,8‰ en 1988; 4,2 en 2002; 3,4 en 2008.

7. Exercice 1.7 (Consommation de graisse par an et par personne en Norvège)

1. Voir figure ci-dessous.

2. En notant X la variable consommation de graisse et Y la variable taux de mortalité, on a :

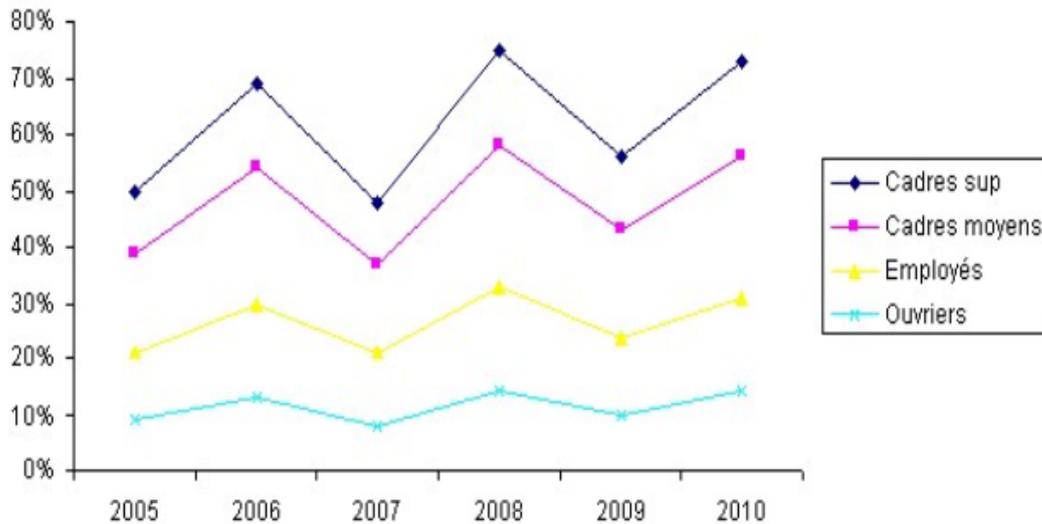


FIGURE 8.2 – Graphique arithmétique des départs en vacances d'hiver.

x_i	y_i	x_i^2	y_i^2	$x_i \times y_i$
14,4	29,1	207,36	846,81	419,04
16	29,7	256	882,09	475,2
11,6	29,2	134,56	852,64	338,72
11	26	121	676	286
10	24	100	576	240
9,6	23,1	92,16	533,61	221,76
9,2	23	84,64	529	211,6
10,4	23,1	108,16	533,61	240,24
11,4	25,2	129,96	635,04	287,28
12,5	26,1	156,25	681,21	326,25
116,1	258,5	1390,09	6746,01	3046,09

On en déduit $\bar{X} = 11,61$, $\sigma_X^2 = 4,22$, $\sigma_X = 2,05$, $\bar{Y} = 25,85$, $\sigma_Y^2 = 6,38$ et $\sigma_Y = 2,53$.

3. Calcul de la covariance :

$$\text{Cov}(X, Y) = \frac{3046,09}{10} - (11,61 \times 25,85) = 4,4905.$$

4. Calcul du coefficient de corrélation linéaire :

$$r(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{4,4905}{2,05 \times 2,53} = 0,87.$$

5. La forme du nuage de points "étirée" (les points sont proches d'une droite) et la valeur du coefficient de corrélation linéaire proche de 1 rendent plausible l'existence d'une liaison linéaire forte entre X et Y .

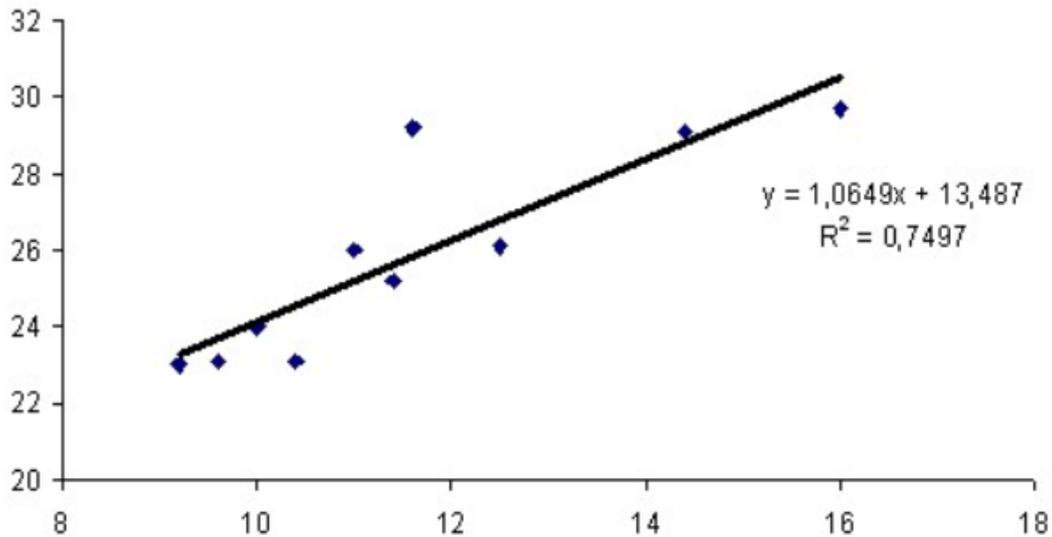


FIGURE 8.3 – Nuage de points et droite de régression pour les variables graisse/taux de mortalité.

6. La pente a de la droite de régression de Y sur X est donnée par :

$$a = \frac{\text{Cov}(X, Y)}{\sigma_X^2} = 1,06,$$

et la valeur à l'origine b est donnée par :

$$b = \bar{Y} - a\bar{X} = 13,49.$$

L'équation de la droite de régression de Y sur X est donc :

$$y = 1,06x + 13,49.$$

7. Une estimation du taux de mortalité par athérosclérose en 1948 est :

$$\hat{y}(1948) = 1,06 \times 13 + 13,49 = 27,27.$$

8. Exercice (moyenne mobile, modele additif)

L'entreprise X communique le montant de son chiffre d'affaires (en milliers d'euro) pour les années de 1989 à 1992

mois/année	1989	1990	1991	1992
janvier	1230	1590	1750	1840
février	1280	1640	1650	1790
mars	1400	1800	1800	2370
avril	1600	1990	1900	2360
mai	1450	1870	1950	2280
juin	1390	1910	1910	2510
juillet	1280	1670	1980	2320
aout	930	1260	1410	1870
septembre	1080	1430	1520	1820
octobre	1400	1780	1920	2210
novembre	1500	1750	1900	2440
décembre	1550	1670	1780	2270

1. Représenter la série chronologique. On considère que janvier 1989 correspond à 1 et que $y_1=1230$
2. Calculer le coefficient de corrélation et pour cette série et l'équation de la droite obtenu par la méthode des moindres carres
3. Choisir un modèle pour l'influence saisonnière (additif ou multiplicatif). Justifier
4. Calculer les coefficients saisonniers sur une période de 1 an.
5. Calculer la moyenne des coefficients saisonniers
6. Calculer la série corrigée des variations saisonnières

7. résumer les résultats précédents dans le tableau suivant et prédire le chiffre d'affaire en 1993.

m=a	1989	1990	1991	1992	α_j	CVS	1989(c)	1990(c)	1991(c)	1992(c)	1993(l)	1993
jan.	1230	1590	1750	1840	1602,5	-147,5	1377,5	1737,5	1897,5	1987,5	2250,5	2103
Dec.	1550	1670	1780	2270								

8. Représenter la Série corrigée des variations saisonnières ainsi que les prévisions effectuées sur un autre graphique

9. Exercice 1.9

2. Après calculs, on obtient : $r(X, Y) = -0,55$.

3. La valeur (moyenne) du coefficient de corrélation linéaire et surtout la forme du nuage de points (en forme de "T") suggère qu'il n'y a pas de liaison linéaire entre X et Y mais qu'il y a éventuellement deux populations pour lesquelles la liaison linéaire entre X et Y est forte.

4. Considérons un premier sous-échantillon constitué par les points 1, 2, 4 et 5. On obtient le tableau :

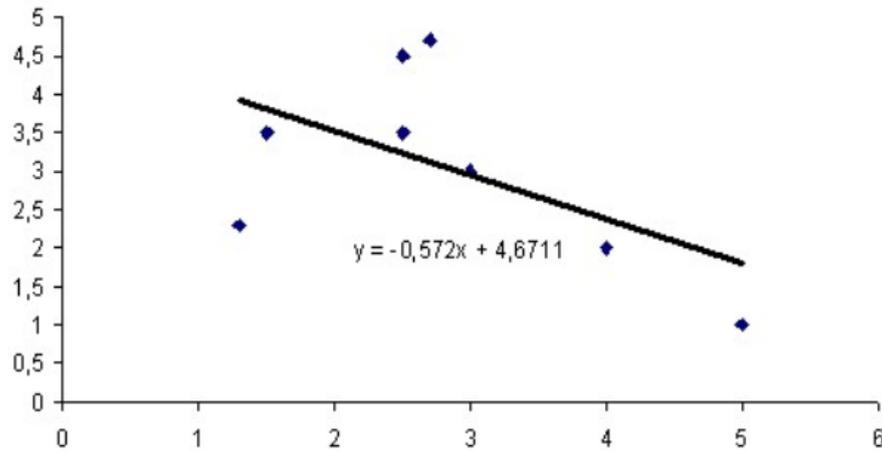


FIGURE 8.4 – Nuage de points et droite de régression pour les variables X et Y .

X	1,3	1,5	2,5	2,7
Y	2,3	3,5	4,5	4,7

Le coefficient de corrélation linéaire pour ce sous-échantillon est :

$$r_1(X, Y) = 0,94.$$

Considérons un second sous-échantillon formé par les points 3, 6, 7 et 8. On obtient le tableau :

X	2,5	3	4	5
Y	3,5	3	2	1

Le coefficient de corrélation linéaire pour ce sous-échantillon est :

$$r_2(X, Y) = -1.$$

On constate donc que les deux coefficients de corrélation linéaire sur chaque sous-échantillon sont proches de 1 en valeur absolue (égal à -1 pour le second), ce qui confirme l'existence d'une liaison linéaire forte sur chaque sous-échantillon.

TD02- MOYENNES MOBILES-CORRECTION

1. Exercice (Vrai-Faux & QCM)

1. 1 - VRAI, 2 - VRAI, 3- VRAI, 4 - FAUX, 5-VRAI.

2. a) c) et d)

Il y a $(T-p + 1)$ moyennes mobiles centrées de longueur impaire p et $(T-p)$ moyennes mobiles centrées de longueur paire p

3. a) et b)

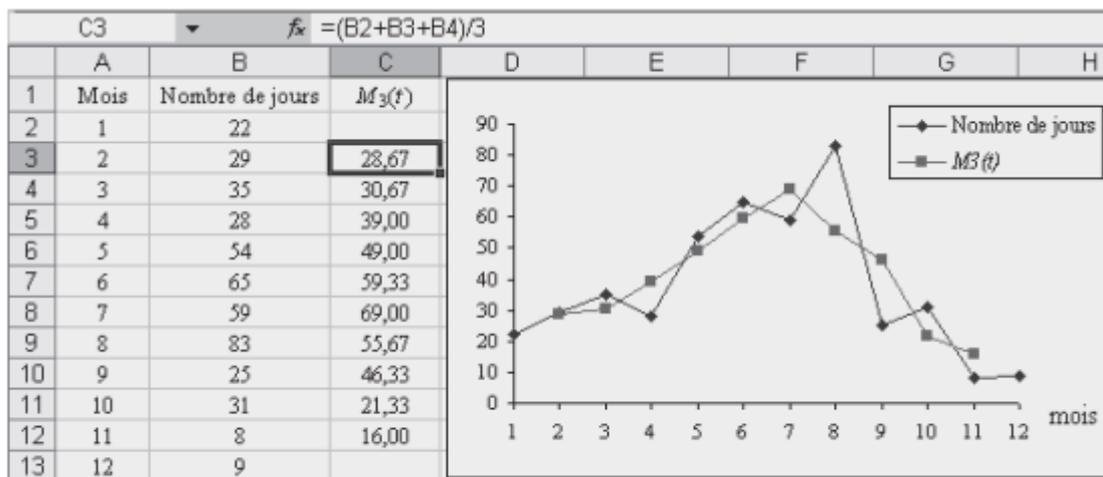
La moyenne mobile centrée de longueur p rend constante les séries périodiques de période p et de période sous-multiple de p .

La moyenne mobile centrée de longueur $2p$ éliminent la composante saisonnière de période p puisque la somme des coefficients saisonniers sur une période est nulle.

La somme de p termes successifs divisée par p donne une évaluation de la tendance pour la date correspondant à celle du terme du milieu des p termes.

On peut calculer $(T-p)$ moyennes mobiles centrées de longueur p si p est pair, et $(T-p + 1)$ moyennes mobiles centrées de longueur p si p est impair, on a donc toujours au moins $(T-p)$ moyennes mobiles centrées.

2. Exercice (Air ATMO)



La moyenne mobile lisse la série chronologique, et permet d'évaluer la tendance.

3. Exercice

G5		fx = 10-2*A5+E5						
	A	B	C	D	E	F	G	H
1	t	x _t	M ₂ (t)	M ₃ (t)	M ₄ (t)	M ₅ (t)	M ₄ (z _t)	
2	1	3						
3	2	-1	1,5	2,33				
4	3	5	2,5	1,67	2	2,2	6	
5	4	1	2,5	3,00	2	1,4	4	
6	5	3	1,5	1,00	2	2,6	2	
7	6	-1	1,5	2,33	2	1,8	0	
8	7	5	2,5	1,67	2	2,2	-2	
9	8	1	2,5	3,00	2	1,4	-4	
10	9	3	1,5	1,00	2	2,6	-6	
11	10	-1	1,5	2,33	2	1,8	-8	
12	11	5	2,5	1,67				
13	12	1						
14								
15								
16								

Annotations de formules Excel :

- Cellule G5: $=SOMME(B3:B7)/5$
- Cellule D13: $=(B9+B10+B11)/3$
- Cellule G5 (encadré) : 4
- Cellule G15: $=(B5/2+B6+B7/2)/2$
- Cellule G16: $=(B2/2+SOMME(B3:B5)+B6/2)/4$

La série x_t est périodique de période 4.

Toutes les suites de moyennes mobiles sont aussi périodiques de période 4.

La suite des moyennes mobiles de longueur 4 est constituée de termes constants égaux à la moyenne des termes sur une période.

- La moyenne mobile transforme une série alignée en elle-même, donc la série $y_t = 10 - 2t$ est transformée en elle-même, et la suite des moyennes mobiles de longueur 4 de la série z_t est égale à : $10 - 2t + 2 = 12 - 2t$ ($t = 3$ à 10).

4. Exercice (Moyennes mobiles)

Question 1 :

Calculez la moyenne mobile centrée d'ordre 4 pour $t = 3$

65,525

63,125

$$mm_{4,3} = 1/4 (52/2 + 36 + 69 + 89 + 65/2) = 63,125$$

Question 2

Calculez la moyenne mobile centrée d'ordre 4 pour $t = 4$

65,875

66,775

$$mm_{4,4} = 1/4 (36/2 + 69 + 89 + 65 + 45/2) = 65,875$$

Question 3

Calculez la moyenne mobile centrée d'ordre 4 pour $t = 5$

68,1975

69,125

$$mm_{4,5} = 1/4 (69/2 + 89 + 65 + 45 + 86/2) = 69,125$$

Question 4

Calculez l'ensemble des moyennes mobiles centrées d'ordre 4

Représentation dans un tableau, par année et par trimestre

Les réponses se trouvent dans le tableau ci-dessous

	Série initiale				Moyenne mobile d'ordre 4			
	tr1	tr2	tr3	tr4	tr1	tr2	tr3	tr4
année 2010	52	36	69	89			63,125	65,875
année 2011	65	45	86	111	69,125	74	78,75	82,125
année 2012	81	56	108	139	86,25	92,5	98,625	103
année 2013	102	70	135	174	108,125	115,875		

TD03- MODELES MULTIPLICATIF ET ADDITIF-CORRECTION

1. Exercice (nombre de mariages, CVS et modèle additif)

1. Les représentations graphiques font apparaître des variations saisonnières.

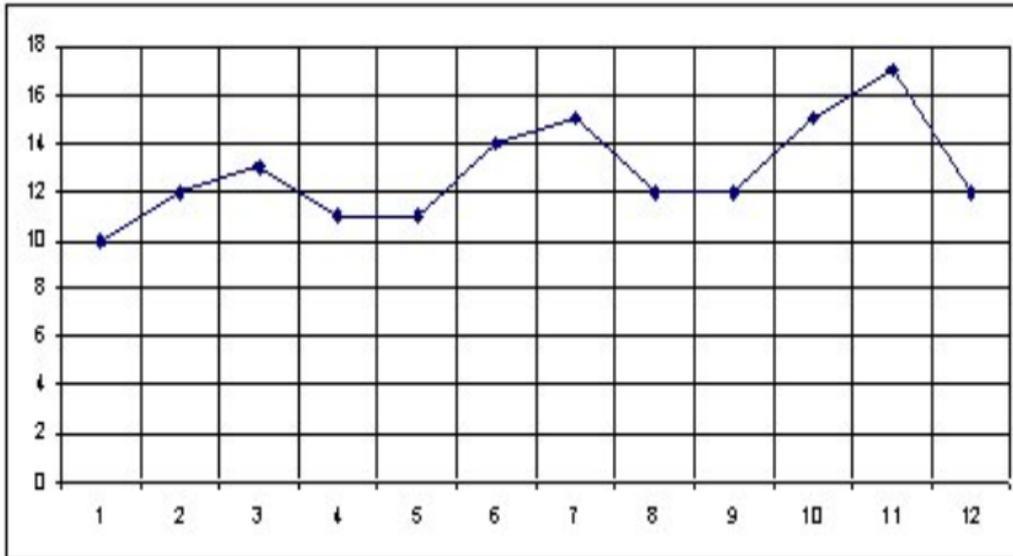


FIGURE 8.19 – Représentation graphique des mariages avec périodes successives

2.3.4. Les relevés étant trimestriels, on considère les moyennes mobiles d'ordre 4 :

$$z(t) = \frac{y(t-2) + y(t-1) + y(t) + y(t+1) + y(t+2)}{4}$$

Ensuite on réalise la régression de z sur t_z . On a d'après le cours

$$\bar{t}_z = \frac{N+1}{2} = 6,5 \quad \text{Var}(t_z) = \frac{N_z^2 - 1}{12} = 5,25$$

où $N = 12$ et $N_z = 8$. On a aussi $\bar{z} = \frac{103,25}{8} \approx 12,91$ puis

$$\text{Cov}(z, t_z) = \frac{685,25}{8} - \frac{103,25}{8} \cdot 6,5 \approx 1,77$$

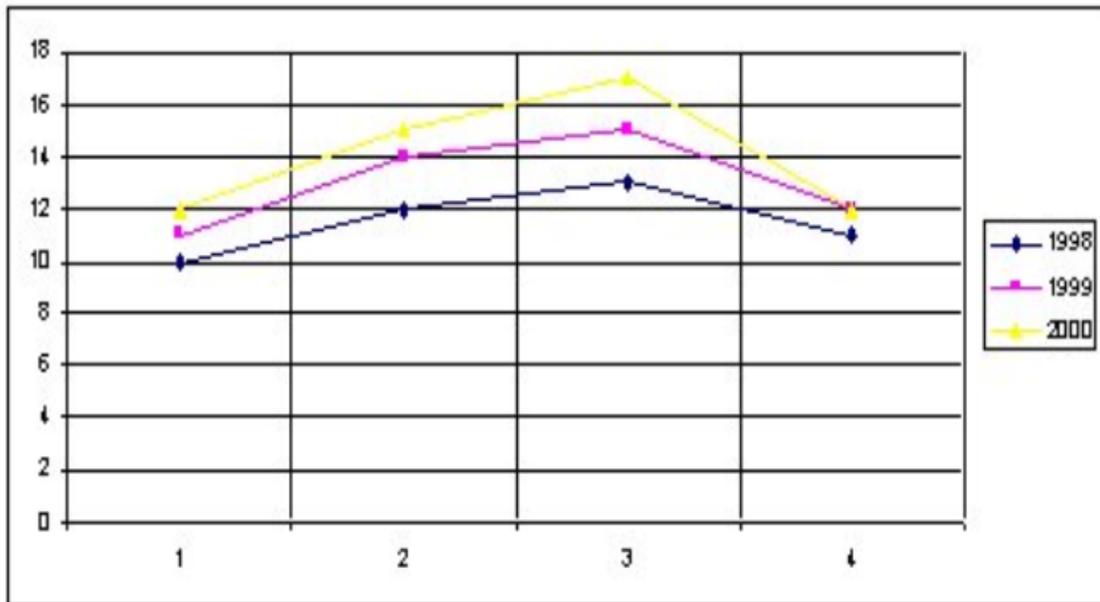


FIGURE 8.20 – Représentation graphique des mariages avec périodes superposées

et $a = \frac{\text{Cov}(z, t_z)}{\text{Var}(t_z)} \approx 0,34$ et $b = \bar{z} - a\bar{t}_z \approx 12,72$.

On peut présenter l'ensemble des calculs dans le tableau suivant :

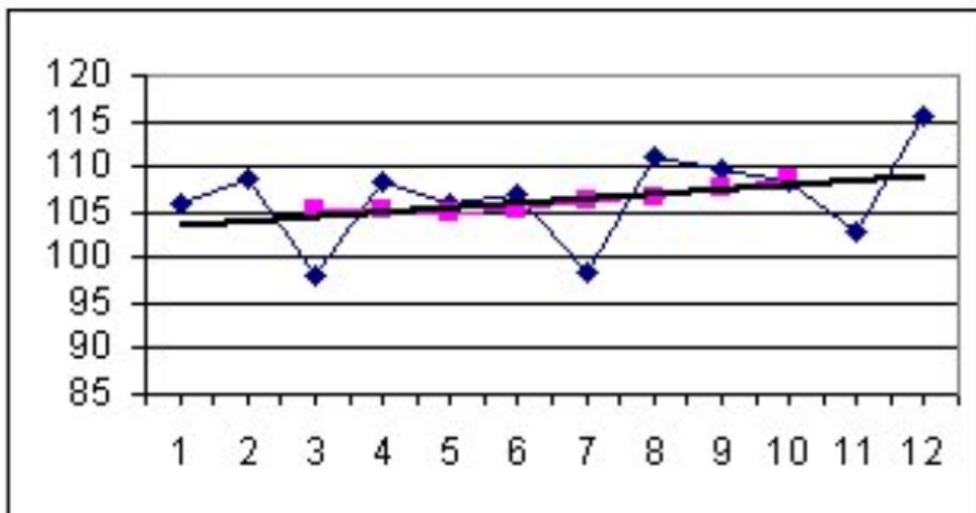
t	$y(t)$	$z(t)$	$t.z(t)$	$x(t) = 0,336t + 10,724$	$y(t) - x(t)$	$s'(t)$	$s(t)$
1	10			11,06	-1,06	-1,404	-1,329
2	12			11,396	0,604	0,927	1,002
3	13	11,63	34,88	11,732	1,268	1,924	1,999
4	11	12,00	48,00	12,068	-1,068	-1,745	-1,670
5	11	12,50	62,50	12,404	-1,404		
6	14	12,88	77,25	12,74	1,26		
7	15	13,13	91,88	13,076	1,924		
8	12	13,38	107,00	13,412	-1,412		
9	12	13,75	123,75	13,748	-1,748		
10	15	14,00	140,00	14,084	0,916		
11	17			14,42	2,58		
12	12			14,756	-2,756		
		103,25	685,25	-	-	$S0 = -0,3$	

5.

t	$x(t) = 0,336t + 10,724$	$s(t)$	$x(t) + s(t)$
17	16,436	-1,329	15,107
18	16,772	1,002	17,774
19	17,108	1,999	19,107
20	17,444	-1,670	15,774

2. Exercice 1.2

t	$y(t)$	$z(t)$	$t \times z(t)$	$x(t) = 0,49t + 103,04$	$y(t) - x(t)$	$s'(t)$	$s(t)$
1	106			103,53	2,47	1,743	1,243
2	108,8			104,02	4,78	2,153	1,653
3	97,9	105,31	315,94	104,51	-6,61	-6,670	-7,170
4	108,5	105,11	420,45	105	3,5	4,773	4,273
5	106,1	104,98	524,88	105,49	0,61		
6	107,1	105,39	632,33	105,98	1,12		
7	98,5	106,16	743,14	106,47	-7,97		
8	111,2	106,78	854,20	106,96	4,24		
9	109,6	107,51	967,61	107,45	2,15		
10	108,5	108,61	1086,13	107,94	0,56		
11	103			108,43	-5,43		
12	115,5			108,92	6,58		
		849,85	5544,66	-	-	$S_0 = 2$	



3ième trimestre 1985 signifie $t = 15$ d'où $\hat{y}(15) = 0,49 \times 15 - 7,170 = 103,22$.

3. Exercice 1.3 (moyennes mobiles)

1. On veut calculer des moyennes mobiles d'ordre 12. La première que l'on peut calculer correspond au mois de juillet 1974 ($t = 7$) :

$$z(7) = \frac{\frac{127,4}{2} + 129,1 + \dots + 144,3 + \frac{145,9}{2}}{12} = 137,046.$$

La dernière que l'on peut calculer correspond au mois de juin 1977 ($t = 42$) :

$$z(42) = \frac{\frac{173,8}{2} + 174,3 + \dots + 188,9 + \frac{189,4}{2}}{12} = 182,042.$$

2. La courbe est déjà lisse, il est inutile de calculer la série des moyennes mobiles : les valeurs seraient très proches des valeurs observées.

3. Il n'y a pas de variations saisonnières.

4. Pour faire des prévisions, on pourrait étudier simplement la corrélation linéaire.

4. Exercice 1.5 ((Disneyland-Paris & Moyenne mobile et CVS)

t	$y(t)$	$z(t)$	$x(t) = 0,26t + 1,15$	$y(t) - x(t)$	$s'(t)$	$s(t) = s'(t) + 0,6$
1	1		1,41	-0,41	-0,36	0,24
2	0		1,67	-1,67	-0,37	0,23
3	5	1,6	1,93	3,07	4,37	4,97
4	2	1,8	2,19	-0,19	-1,39	-0,79
5	0	2,4	2,45	-2,45	-2,65	-2,05
6	2	2,8	2,71	-0,71		
7	3	3,2	2,97	0,03		
8	7	3,4	3,23	3,77		
9	4	3,8	3,49	0,51		
10	1	4	3,75	-2,75		
11	4	4,6	4,01	-0,01		
12	4	4,2	4,27	-0,27		
13	10	4,4	4,53	5,47		
14	2	4,6	4,79	-2,79		
15	2	5	5,05	-3,05		
16	5	5,2	5,31	-0,31		
17	6	5,4	5,57	0,43		
18	11	5,8	5,83	5,17		
19	3		6,09	-3,09		
20	4		6,35	-2,35		
					$S_0 = -3$	

1. On calcule ici des moyennes mobiles d'ordre 4.

2. On est obligé de calculer tous les coefficients $s'(t)$ pour faire la somme puis calculer les coefficients saisonniers $s(t)$.

3.

t	$x(t) = 0,26t + 1,15$	$s(t) = s'(t) + 0,6$	$x(t) + s(t)$
21	6,61	0,24	6,85
22	6,87	0,23	7,1
23	7,13	4,97	12,1

t	$y(t)$	$z(t)$	$t.z(t)$	$x(t) = 0,70t + 13,45$	$y(t) - x(t)$	$s'(t)$	$s(t)$
1	8,2			14,15	-5,95	-7,217	-7,359
2	12,3			14,85	-2,55	-2,950	-3,092
3	32,7	15,6	46,8	15,55	17,15	18,750	18,608
4	8,3	16,1	64,4	16,25	-7,95	-8,017	-8,159
5	10	16,95	84,75	16,95	-6,95		
6	14,5	17,925	107,55	17,65	-3,15		
7	37,3	18,45	129,15	18,35	18,95		
8	11,5	18,925	151,4	19,05	-7,55		
9	11	19,775	177,975	19,75	-8,75		
10	17,3	20,5	205	20,45	-3,15		
11	41,3			21,15	20,15		
12	13,3			21,85	-8,55		
		144,23	6967,03	-	-	$S_0 = 0,57$	

4. Prévisions pour le 3^{ème} trimestre 2000 :

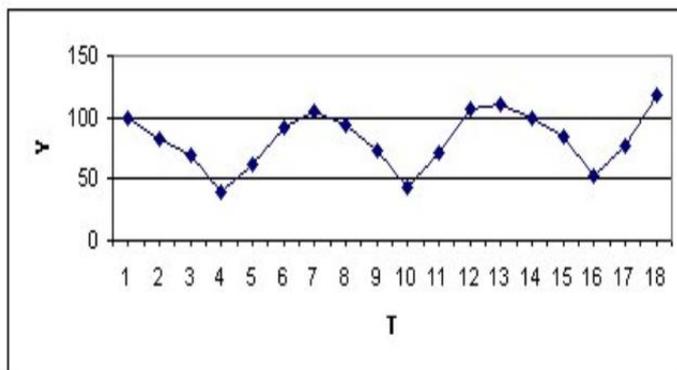
$$\hat{y}(23) = x(23) + s(3) = 0,7 \times 23 + 13,45 + 18,608 = 48,158.$$

On prévoit donc avec ce modèle 48158 visiteurs pour l'été 2000.

5. Exercice 1.6 (billets vendus & moyennes mobiles et modèle additif)

1. Notons T la variable temps numérotée dans l'ordre chronologique.

Notons Y la variable "nombre de billets vendus (en milliers)".



2. Il faut calculer des moyennes mobiles d'ordre 6.

t	$y(t)$	$z(t)$	$t.z(t)$	$x(t) = 1,34t + 68,93$	$y(t) - x(t)$	$s'(t)$	$s(t) = s'(t) - 0,51$
1	100			70,27	29,73	27,02	26,51
2	82			71,61	10,39	12,02	11,51
3	70			72,95	-2,95	-5,32	-5,83
4	40	74,58	298,33	74,29	-34,29	-37,33	-37,84
5	62	76,00	380,00	75,63	-13,63	-13,34	-13,85
6	91	77,25	463,50	76,97	14,03	19,99	19,48
7	105	77,75	544,25	78,31	26,69		
8	94	78,83	630,67	79,65	14,35		
9	73	80,92	728,25	80,99	-7,99		
10	43	82,67	826,67	82,33	-39,33		
11	72	83,58	919,42	83,67	-11,67		
12	106	84,92	1019,00	85,01	20,99		
13	111	86,58	1125,58	86,35	24,65		
14	99	87,75	1228,50	87,69	11,31		
15	84	89,17	1337,50	89,03	-5,03		
16	52			90,37	-38,37		
17	77			91,71	-14,71		
18	118			93,05	24,95		
		980	9501,67	-	-	$S_0 = 3,04$	

3. Pour tracer la droite de tendance, on peut placer le point $B(0; 68, 93)$ et le point moyen :

$$\bar{T} = 9,5 \quad \bar{Z} = \frac{980}{12} = 81,67$$

i.e. le point $M(9,5; 81,67)$ appartient à la droite.

4. Prévisions pour Juillet-Août 2000 :

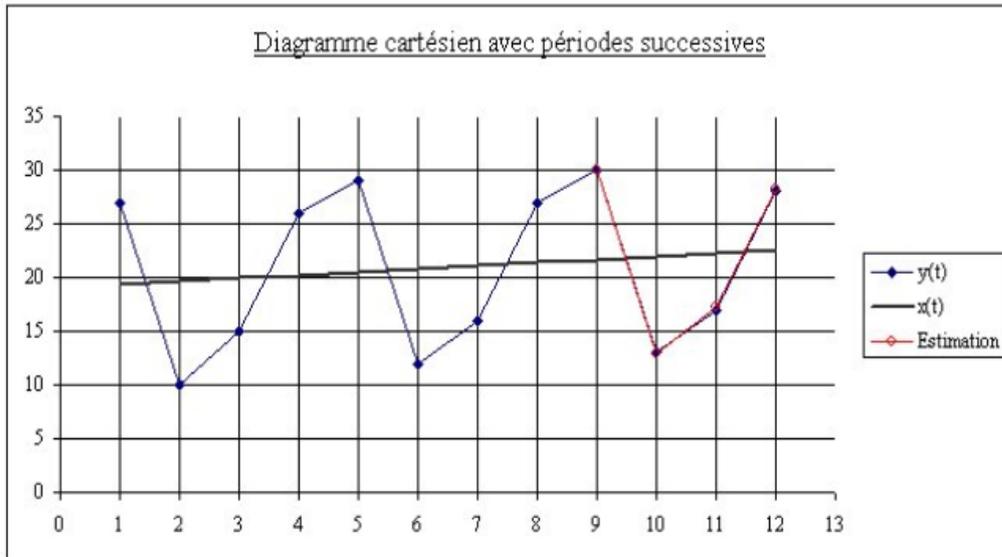
$$\hat{y}(22) = x(22) + s(4) = 1,34 \times 22 + 68,93 - 37,84 = 60,57,$$

soit 60570 billets vendus.

6. Exercice (magasin d'insecticides, moyennes mobiles et modèle additif)

1. On commence par faire le diagramme cartésien :

2. 3. et 4. On fait ensuite le tableau :



t	$y(t)$	$z(t)$	$tz(t)$	$x(t)$	$\delta(t)$	$s'(t)$	$s(t)$	estimation
1	27			19,35	7,65	8,16066667	8,26683333	27,61683
2	10			19,639	-9,639	-9,12833333	-9,02216667	10,61683
3	15	19,75	59,25	19,928	-4,928	-5,084	-4,97783333	14,95017
4	26	20,25	81	20,217	5,783	5,627	5,73316667	25,95017
5	29	20,625	103,125	20,506	8,494		8,26683333	28,77283
6	12	20,875	125,25	20,795	-8,795		-9,02216667	11,77283
7	16	21,125	147,875	21,084	-5,084		-4,97783333	16,10617
8	27	21,375	171	21,373	5,627		5,73316667	27,10617
9	30	21,625	194,625	21,662	8,338		8,26683333	29,92883
10	13	21,875	218,75	21,951	-8,951		-9,02216667	12,92883
11	17			22,24	-5,24		-4,97783333	17,26217
12	28			22,529	5,471		5,73316667	28,26217

D'où l'on déduit :

$$\bar{T}' = 6,5 ; \quad \text{Var}(T') = 0,25 ; \quad \bar{Z} = 20,9375$$

$$\text{Cov}(T', Z) = 1,515625 ; \quad S_0/4 = -0,10616667$$

$$a = 0,28869048 ; \quad b = 19,0610119.$$

6. Prévision pour le 3^{ème} trimestre 2001 : 18,418 milliers de francs (soit 18418 francs).

7. Exercice (construction, moyennes mobiles et modèle additif)

1. Les variations observées ne sont pas des variations saisonnières.

2. $z(8) = 1077,375$, $z(9) = 1080,875$ et $z(10) = 1090,25$. Les moyennes mobiles lissent la courbe et font apparaître une tendance linéaire croissante. Le modèle additif est inadapté.

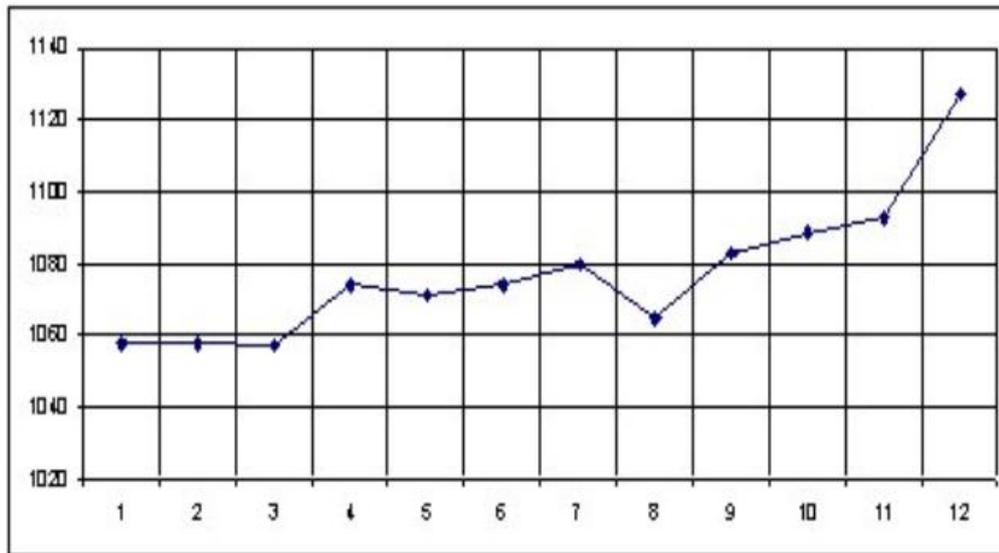


FIGURE 8.21 – Représentation graphique de la construction avec périodes successives

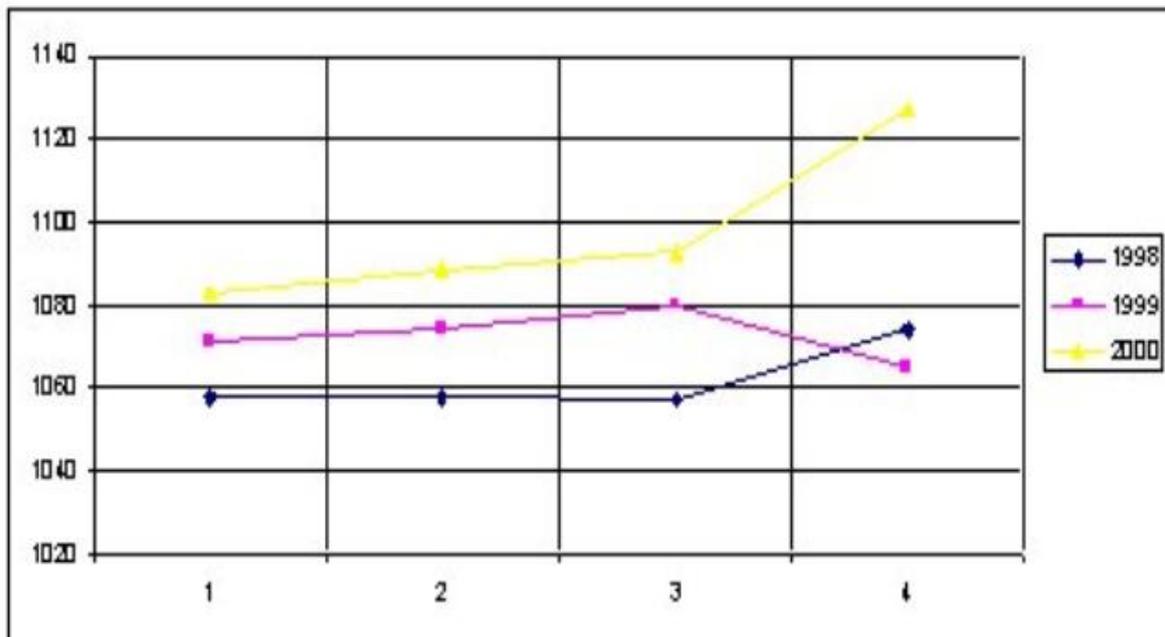


FIGURE 8.22 – Représentation graphique de la construction avec périodes superposées

8. Exercice 8

a) **Représentation** Soit M le caractère donnant le nombre de mois écoulés depuis décembre 1988 et X donnant le chiffre d'affaires pour le mois correspondant. Ayant des données sur 4 ans, on a à disposition une série $(m_i, x_i)_{i=1, \dots, N}$, où $N = 48$, $m_1 = 1, m_2 = 2, \dots, m_{48} = 48$ et $x_1 = 1230, x_2 = 1280, \dots, x_{12} = 1550, x_{13} = 1590, x_{14} = 1640, \dots, x_{48} = 2270$. On représente cette série sur le graphique suivant :

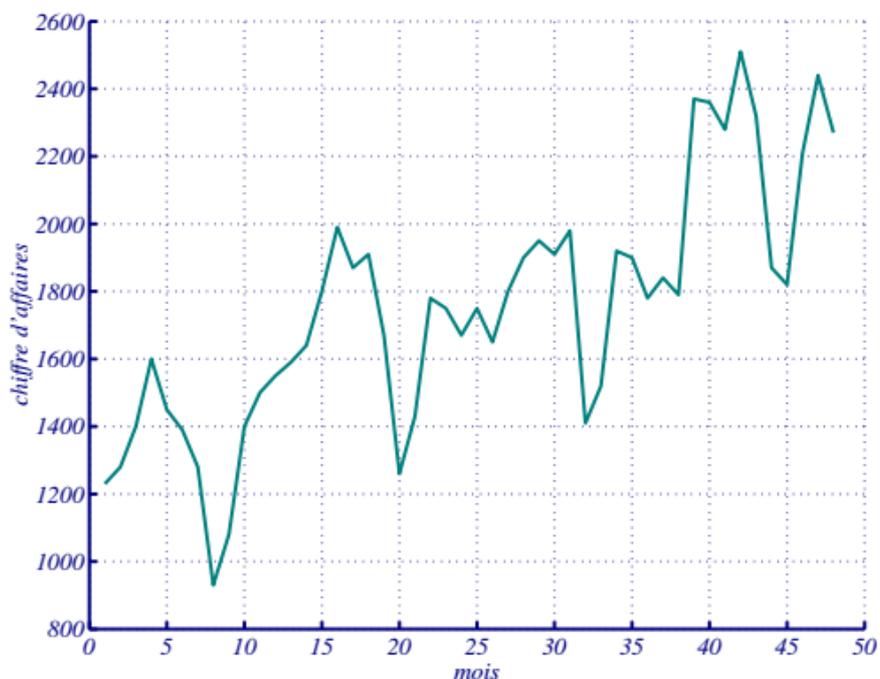


Figure 13. *Évolution du chiffre d'affaires de Janvier 1989 à décembre 1992.*

b) **Ajustement par la méthode des moindres carrés** Le tableau de calcul n'est pas représenté ici. On se contente de donner les résultats, notamment, on indique les différentes sommes suivantes à partir desquelles on calcule toutes les quantités voulues pour l'ajustement : $\sum_{i=1}^N m_i = \frac{N(N+1)}{2} = \frac{48 \times 49}{2} = 1176$, $\sum x_i = 84000$, $\sum m_i^2 = 38024$, $\sum x_i^2 = 153218400$,

$\sum m_i x_i = 2246180$. Commençons par préciser $\bar{M} = 24.5$, $\bar{X} = 1750$, $V(M) = 191.92$, $V(X) = 129550$ et $\text{Cov}(M, X) = 3920.4$. L'ajustement affine de cette série par la méthode des moindres carrés est donné par la droite D d'équation $x = am + b$, où

$$a = \frac{\text{Cov}(M, X)}{V(M)} \text{ et } b = \bar{X} - a\bar{M},$$

ce qui donne numériquement, l'équation $x = 2.4251m + 1690.6$ puisque

$$a = \frac{3920.4}{191.92} = 20.4277 \text{ et } b = 1750 - (20.4277)24.5 = 1249.5.$$

c) Modèle pour l'influence saisonnière On choisit un modèle additif, car l'amplitude des creux (mois d'août) ne varie pas avec les années.

d) Calcul des coefficients saisonniers On va ici calculer les coefficients saisonniers sur une période de 1 an. Autrement dit on doit déterminer 12 coefficient α_j . Plus précisément on écrit, pour $j = 1, \dots, 12$,

$$\alpha_j = \frac{1}{4}(X_j + X_{12+j} + X_{24+j} + X_{36+j})$$

On obtient les résultats suivants: $\alpha_1 = (1230 + 1590 + 1750 + 1840)/4 = 1602.5$, $\alpha_2 = (1280 + 1640 + 1650 + 1790)/4 = 1590$, \dots , $\alpha_{12} = (1550 + 1670 + 1780 + 2270)/4 = 1817.5$ (voir tableau).

e) Moyenne des coefficients saisonniers on a simplement

$$\bar{\alpha} = \frac{1}{12} \sum_{j=1}^{12} \alpha_j = \frac{1}{12}(1602.5 + 1590 + \dots + 1817.5) = \frac{21000}{12} = 1750.$$

On en déduit les CVS, grâce à la formule $\alpha'_j = \alpha_j - \bar{\alpha}$ (modèle additif). Par exemple

$$\begin{aligned} \alpha'_1 &= \alpha_1 - \bar{\alpha} = 1602.5 - 1750 = -147.5, \\ \alpha'_2 &= \alpha_2 - \bar{\alpha} = 1590 - 1750 = -160.0, \dots, \\ \alpha'_{12} &= \alpha_{12} - \bar{\alpha} = 1817.5 - 1750 = 67.5. \end{aligned}$$

f) Série corrigées des variations saisonnières La série corrigée des variations saisonnières est obtenue simplement en écrivant que

$$Y_{12(i-1)+j} = X_{12(i-1)+j} - \alpha'_j$$

où, on a noté (Y_n) la série corrigée des variations saisonnières (voir le tableau). On a par exemple $Y_1 = X_1 - \alpha'_1$, $Y_2 = X_2 - \alpha'_2$, \dots , $Y_{12} = X_{12} - \alpha'_{12}$, $Y_{13} = X_{13} - \alpha'_1$, $Y_{14} = X_{14} - \alpha'_2$, \dots , $Y_{25} = X_{25} - \alpha'_1$, etc., soit numériquement $Y_1 = 1230 - (-147.5) = 1377.5$, $Y_2 = 1280 - (-160) = 1440$, \dots , $Y_{13} = 1590 - (-147.5) = 1737.5$, etc..

g) Chiffre d'affaires en 1993 On commence par résumer les résultats précédents dans le tableau suivant

m/a	1989	1990	1991	1992	α_j	CVS	1989(c)	1990(c)	1991(c)	1992(c)	1993(l)	1993
jan.	1230	1590	1750	1840	1602.5	-147.5	1377.5	1737.5	1897.5	1987.5	2250.5	2103
fév.	1280	1640	1650	1790	1590	-160	1440	1800	1810	1950	2270.9	2110.9
mars	1400	1800	1800	2370	1842.5	92.5	1307.5	1707.5	1707.5	2277.5	2291.3	2383.8
avr.	1600	1990	1900	2360	1962.5	212.5	1387.5	1777.5	1687.5	2147.5	2311.8	2524.3
mai	1450	1870	1950	2280	1887.5	137.5	1312.5	1732.5	1812.5	2142.5	2332.2	2469.7
juin	1390	1910	1910	2510	1930	180	1210	1730	1730	2330	2352.6	2532.6
juil.	1280	1670	1980	2320	1812.5	62.5	1217.5	1607.5	1917.5	2257.5	2373	2435.5
août	930	1260	1410	1870	1367.5	-382.5	1312.5	1642.5	1792.5	2252.5	2393.5	2011
sep.	1080	1430	1520	1820	1462.5	-287.5	1367.5	1717.5	1807.5	2107.5	2413.9	2126.4
oct.	1400	1780	1920	2210	1827.5	77.5	1322.5	1702.5	1842.5	2132.5	2434.3	2511.8
nov.	1500	1750	1900	2440	1897.5	147.5	1352.5	1602.5	1752.5	2292.5	2454.8	2602.3
déc.	1550	1670	1780	2270	1817.5	67.5	1482.5	1602.5	1712.5	2202.5	2475.2	2542.7

Les deux dernières colonnes représentent les valeurs prédites. Plus précisément l'avant dernière colonne représente les prévisions de la série corrigée des variations saisonnières Y_n données par

$$Y_n = a \times n + b, \quad n = 49, \dots, 60.$$

Ces valeurs de n correspondent aux 12 mois de l'année 1993. La dernière colonne est la prévision de la série X_n donnée par

$$X_n = Y_n + \alpha'_{n-48}.$$

En réalité, on devrait écrire $X_{12(i-1)+j} = Y_{12(i-1)+j} + \alpha'_j$ pour $i = 5$ (correspond à l'année 1993) et pour tout $j = 1, 2, \dots, 12$.

On représente la série corrigée des variations saisonnières ainsi que les prévisions effectuées sur le graphique suivant

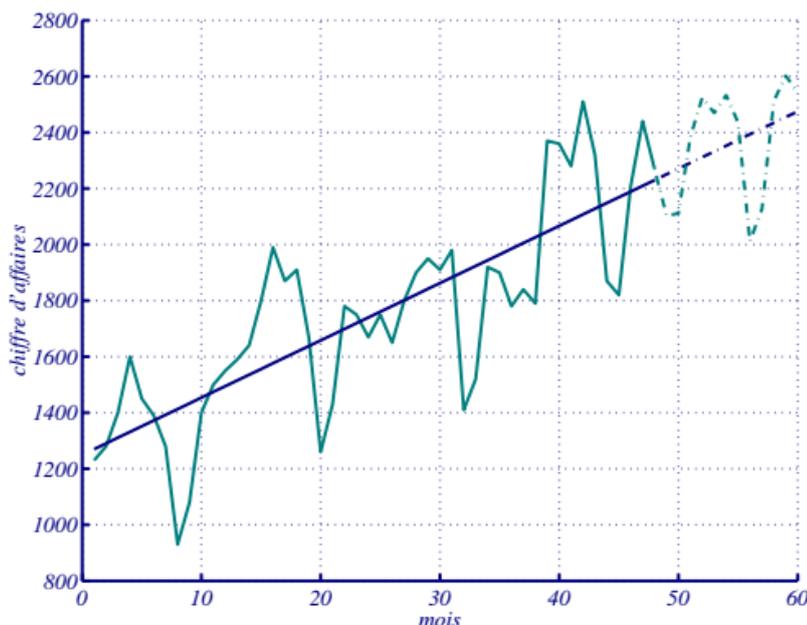


Figure 14. Prévisions pour l'année 1993. La courbe grise représente la série corrigée des variations saisonnières. Les courbes en pointillé représentent les valeurs prédites.

9. Exercice (Truc Net, Modèle additif+ moyenne mobile)

1. La série chronologique de l'entreprise TrucNet sur la période 2014 à 2017 est représentée ci-contre.

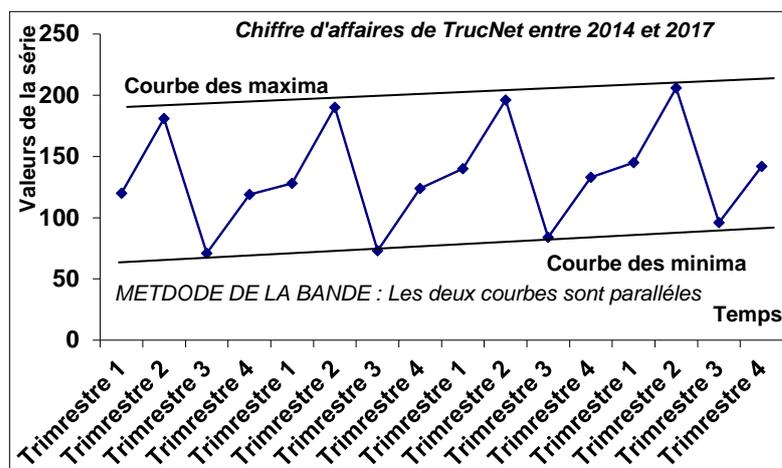


Tableau 6. Tableau des moyennes mobiles du chiffres d'affaires

2. Le modèle de la série des chiffres d'affaires de l'entreprise TrucNet est additif. En effet, si nous employons la méthode de la bande, qui consiste à tracer la droite qui passe par les minima et celle qui passe par les maxima, ces deux droites sont parallèles.

3. La série du chiffre d'affaires de l'entreprise TrucNet est trimestrielle, la période est donc de quatre. Nous devons, pour éliminer la saison, appliquer une moyenne mobile de longueur 4. Nous obtenons les calculs suivants :

	Série X	mm ₄ (X)
Trimestre 1	120	X
Trimestre 2	181	X
Trimestre 3	71	123.75
Trimestre 4	119	125.88
Trimestre 1	128	127.25
Trimestre 2	190	128.13
Trimestre 3	73	130.25
Trimestre 4	124	132.50
Trimestre 1	140	134.63
Trimestre 2	196	137.13
Trimestre 3	84	138.88
Trimestre 4	133	140.75
Trimestre 1	145	143.50
Trimestre 2	206	146.13
Trimestre 3	96	X
Trimestre 4	142	X

Traçons la série des chiffres d'affaires et sa moyenne mobile centrées :

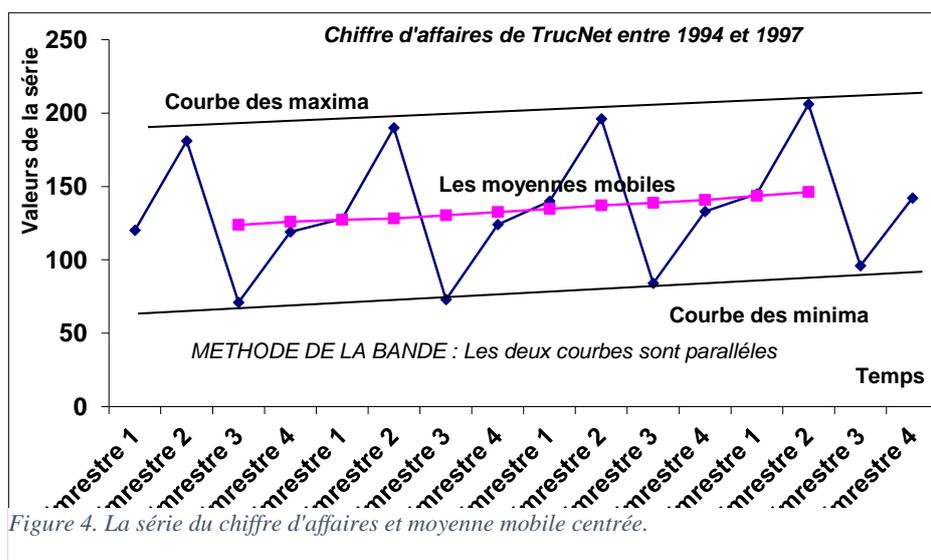


Figure 4. La série du chiffre d'affaires et moyenne mobile centrée.

Commentaires : Le graphique ci-dessus nous permet de voir très nettement que le chiffre d'affaires de l'entreprise TrucNet est en progression constante sur la période étudiée. Nous remarquons également que nous avons perdu deux points au départ et deux en fin de série des moyennes mobiles.ds

TD04- LISSAGE EXPONENTIEL-CORRECTION

1. Exercice (QCM)

c) et d)

Le lissage exponentiel simple ne peut s'envisager que pour une chronique sans saisonnalité et sans évolution tendancielle. La prévision tient d'autant plus compte des valeurs récentes de la série que la constante de lissage α est élevée.

2. Exercice (Nombre d'immatriculations de voitures avec un moteur diesel)

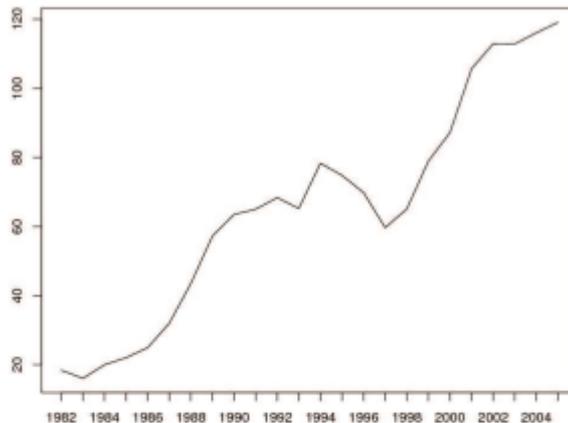
A - Phase exploratoire

1. On obtient :

Année	Total	Moyenne
1982	221.3	18.44
1983	192.8	16.07
1984	240.1	20.01
1985	264.8	22.07
1986	299.5	24.96
1987	384.2	32.02
1988	522.5	43.54
1989	687.1	57.26
1990	762.1	63.51
1991	780.5	65.04
1992	820.6	68.38
1993	783.0	65.25

Année	Total	Moyenne
1994	940.0	78.33
1995	897.9	74.83
1996	837.9	69.83
1997	716.2	59.68
1998	780.9	65.08
1999	947.5	78.96
2000	1046.5	87.21
2001	1267.8	105.65
2002	1354.9	112.91
2003	1354.0	112.83
2004	1392.9	116.08
2005	1428.9	119.08

2. On obtient le graphique suivant :



Sur ce graphique, on peut observer globalement trois périodes : la première de 1982 à 1994, où le nombre d'immatriculation de voitures neuves avec moteur diesel a connu une très forte croissance passant de 20M à 80M, soit une augmentation de 300% ; une seconde période, de 1995 à 1997, où ce nombre d'immatriculations a chuté, passant de 80M à 60M, soit une baisse de 25%. Cette baisse n'est pas facile à expliquer, bien que l'on puisse penser que le marché est peut-être arrivé à saturation. Le mieux serait de poser la question aux constructeurs. Enfin, on note une troisième période, de 1998 à 2005, où ce nombre d'immatriculations connaît de nouveau une très forte progression. Cette progression s'explique vraisemblablement par une problématique de coût d'essence et par le fait que les moteurs diesel sont maintenant comparables aux moteurs essence au niveau des caractéristiques : souples, nerveux, fiables, etc.

3. On obtient :

Mois	Total	Moyenne	Ecart-type
Janvier	1578.4	65.77	33.24
Février	1461.1	60.88	31.29
Mars	1708.7	71.20	37.98
Avril	1619.9	67.50	36.20
Mai	1455.4	60.64	34.64
Juin	1461.7	60.90	43.98
Juillet	1936.4	80.68	38.68
Août	1248.4	52.02	23.01
Septembre	1367.6	56.98	30.74
Octobre	1728.9	72.04	33.09
Novembre	1683.3	70.14	31.69
Décembre	1674.1	69.75	29.72

Tout d'abord, on note que les écarts-types sont assez importants, traduisant ainsi une grande diversité du nombre d'immatriculations pour un mois fixé d'une année à l'autre. Néanmoins, on constate qu'en moyenne, c'est le mois de juillet qui connaît le plus grand nombre d'immatriculations. A contrario, c'est le mois de août qui connaît le nombre moyen d'immatriculations le plus faible. On peut imaginer qu'un grand nombre de personnes achète un véhicule pour partir en vacances, ce qui expliquerait ce pic puis ce creux d'immatriculations. L'analyse du nombre total d'immatriculations confirme évidemment cette observation, avec 80M d'immatriculations en juillet contre 52M en août.

3. On obtient :

Mois	Total	Moyenne	Ecart-type
Janvier	1578.4	65.77	33.24
Février	1461.1	60.88	31.29
Mars	1708.7	71.20	37.98
Avril	1619.9	67.50	36.20
Mai	1455.4	60.64	34.64
Juin	1461.7	60.90	43.98
Juillet	1936.4	80.68	38.68
Août	1248.4	52.02	23.01
Septembre	1367.6	56.98	30.74
Octobre	1728.9	72.04	33.09
Novembre	1683.3	70.14	31.69
Décembre	1674.1	69.75	29.72

Tout d'abord, on note que les écarts-types sont assez importants, traduisant ainsi une grande diversité du nombre d'immatriculations pour un mois fixé d'une année à l'autre. Néanmoins, on constate qu'en moyenne, c'est le mois de juillet qui connaît le plus grand nombre d'immatriculations. A contrario, c'est le mois de août qui connaît le nombre moyen d'immatriculations le plus faible. On peut imaginer qu'un grand nombre de personnes achète un véhicule pour partir en vacances, ce qui expliquerait ce pic puis ce creux d'immatriculations. L'analyse du nombre total d'immatriculations confirme évidemment cette observation, avec 80M d'immatriculations en juillet contre 52M en août.

- Le graphique de gauche représente sous forme de boxplots la distribution du volume mensuel des immatriculations par an sur la période d'étude. Sur ce graphique, on retrouve les trois périodes détectées précédemment via une analyse de l'évolution de la médiane. La nouveauté est que l'on observe une volatilité qui augmente avec le temps. Ainsi, sur la première période, on note une dispersion relativement faible, traduisant un nombre d'immatriculations d'un mois sur l'autre, pour une année fixée, relativement homogène. Par contre, sur les deux autres périodes, on observe une grande dispersion du nombre d'immatriculations, avec la présence de points atypiques. Cela traduit le fait que sur ces deux périodes, le nombre mensuel d'immatriculations peut être très différent d'un mois sur l'autre pour une même année. On note d'ailleurs la présence d'un mois très "creux" pour les années 2002, 2003, 2004, et 2005, avec à peine 80M d'immatriculations pour une médiane aux environs de 120M! Sans surprise, ce mois correspond au mois d'août. Le graphique de droite représente sous forme de boxplots la distribution du volume mensuel des immatriculations par mois sur la période d'étude. On note que sur la période d'étude les dispersions sont très importantes et toutes assez semblables, sauf peut-être pour le mois d'août. Cette double observation s'explique en partie par le fait que le nombre d'immatriculations a connu sur la période 1982-2005 une forte progression. Finalement, on ne peut tirer beaucoup d'informations de ce graphique, si ce n'est que le mois de juillet se démarque des autres mois avec une médiane importante, et donc un nombre élevé d'immatriculations.
- Le graphique de la série brute permet tout d'abord de confirmer l'existence des trois périodes, même si elles apparaissent moins distinctement du fait du "bruit". Néanmoins, le phénomène est globalement croissant avec une augmentation maximale de 600%. La composante tendancielle reste toutefois aléatoire sur l'ensemble de la période, et cela du fait du "trou" observé sur la période 1995-1997. Cette situation fait alors apparaître des ruptures de tendances : en 1995 et en 1997. Sur ce graphique, il est très difficile d'observer un quelconque phénomène saisonnier. Enfin, la variabilité est clairement hétéroscédastique puisqu'elle augmente au cours du temps.
- Dans le cas présent, il importe de transformer la série en prenant le logarithme de la série initiale. Le graphique montre que cette transformation a permis de stabiliser la variabilité de la série.

B - Phase de modélisation

1. Clairement, on obtient : $a_2 = 2.879$ et $b_2 = -0.006$. Ainsi, on obtient : $\hat{y}_2(1) = 2.873$.
2. En prenant $\alpha = 0.2$ et $\beta = 0.6$, on obtient :

	Jan.	Feb.	Mar.	Apr.	May	Jun.	Jul.	Aug.	Sep.	Oct.	Nov.	Dec.
1982	-	-	2.87	2.94	2.96	2.91	2.89	2.85	2.76	2.74	2.79	2.87
1983	2.97	2.99	2.93	2.91	2.82	2.72	2.69	2.65	2.55	2.49	2.55	2.68
1984	2.83	2.91	2.94	3.00	3.01	3.06	3.07	3.06	3.00	2.91	3.00	3.11
1985	3.19	3.24	3.25	3.27	3.23	3.17	3.08	3.06	2.92	2.84	2.90	2.98
1986	3.07	3.16	3.15	3.17	3.19	3.16	3.11	3.14	3.13	3.10	3.20	3.30
1987	3.47	3.52	3.53	3.57	3.59	3.53	3.43	3.46	3.39	3.28	3.36	3.44
1988	3.58	3.67	3.68	3.76	3.81	3.83	3.75	3.82	3.78	3.68	3.69	3.76
1989	3.95	4.11	4.21	4.27	4.28	4.20	4.09	4.12	4.04	3.95	3.98	4.00
1990	3.98	4.10	4.14	4.19	4.19	4.17	4.06	4.11	4.06	3.96	4.03	4.12
1991	4.18	4.28	4.28	4.30	4.30	4.23	4.09	4.16	4.10	4.02	4.07	4.10
1992	4.14	4.21	4.21	4.25	4.26	4.21	4.13	4.23	4.19	4.14	4.20	4.25
1993	4.29	4.25	4.21	4.21	4.17	4.07	3.97	4.06	4.03	3.99	4.08	4.20
1994	4.31	4.34	4.34	4.42	4.46	4.43	4.31	4.38	4.34	4.28	4.32	4.41
1995	4.48	4.52	4.52	4.54	4.48	4.37	4.30	4.34	4.27	4.16	4.13	4.15
1996	4.12	4.18	4.23	4.29	4.33	4.28	4.16	4.24	4.21	4.22	4.23	4.18
1997	4.16	4.09	4.02	4.00	4.02	3.97	3.82	3.98	3.97	3.99	4.07	4.12
1998	4.19	4.21	4.20	4.24	4.26	4.21	4.05	4.17	4.12	4.11	4.13	4.17
1999	4.21	4.22	4.22	4.29	4.36	4.33	4.18	4.37	4.40	4.39	4.44	4.48
2000	4.53	4.53	4.54	4.58	4.57	4.57	4.55	4.55	4.48	4.40	4.39	4.40
2001	4.37	4.43	4.47	4.56	4.65	4.73	4.83	4.91	4.83	4.74	4.73	4.70
2002	4.64	4.65	4.64	4.68	4.74	4.76	4.82	4.86	4.73	4.65	4.66	4.64
2003	4.63	4.65	4.66	4.72	4.76	4.77	4.84	4.88	4.71	4.66	4.67	4.63
2004	4.62	4.62	4.62	4.70	4.75	4.78	4.89	4.91	4.76	4.71	4.69	4.71
2005	4.72	4.73	4.73	4.81	4.87	4.90	4.98	4.93	4.76	4.70	4.64	4.63

3. On ne peut être sûr que ces deux constantes amènent un lissage optimal. Pour obtenir le meilleur ajustement, il faut dans un premier temps déterminer un critère qui permette de quantifier l'ajustement. Souvent, on fait usage de la somme des écarts carrés SSE (Sum of Square Error). Ensuite, il convient de faire tourner un algorithme permettant de tester un ensemble de valeurs possibles pour le couple (α, β) .
4. L'intérêt d'obtenir une série lissée est que l'on visualise plus facilement la tendance, c'est-à-dire en faisant abstraction des irrégularités. Il est alors plus facile d'avoir une approche subjective pour réaliser des prévisions à court terme.

5.

Clairement, cette modélisation semble meilleure car elle s'adapte beaucoup mieux à la série, et donc diminue l'erreur d'ajustement.

C - Phase de prévision

1. On obtient :

$\log \hat{y}_t$	Janv.	Fév.	Mars	Avril	Mai	Juin	Juil.	Aot	Sep.	Oct.	Nov.	Déc.
2006	4.7599	4.7247	4.9494	4.8747	4.8202	4.9969	4.7526	4.3741	4.7496	4.7958	4.8271	4.8091
2007	4.8185	4.7833	5.0080	4.9333	4.8788	5.0555	4.8112	4.4327	4.8082	4.8544	4.8857	4.8678

2. Oui, les résultats numériques sont en accord avec le graphique.
3. On doit réaliser la transformation inverse de celle effectuée précédemment. Ainsi, on doit prendre l'exponentielle de la série.
4. On obtient :

\hat{y}_t	Janv.	Fév.	Mars	Avril	Mai	Juin	Juil.	Aot	Sep.	Oct.	Nov.	Déc.
2006	116.73	112.70	141.09	130.93	123.98	147.86	115.88	79.37	115.51	121.03	124.84	122.61
2007	123.78	119.52	149.61	138.84	131.46	156.79	122.88	84.16	122.48	128.34	132.38	130.01

5. Evident.