

# Examen du 23/01/2018

MAP-STA2 : Séries chronologiques

Yannig Goude - [yannig.goude@edf.fr](mailto:yannig.goude@edf.fr); M. Zaouche - [mounia.zaouche@gmail.com](mailto:mounia.zaouche@gmail.com);

## Barem

**exercice1** sur 6 points répartis en 1.5 pour les questions 2) et 3), 1 point pour les autres.

**exercice2** sur 2 points répartis en 0.5 point par question

**exercice3** sur 4 points répartis en 1 point par question

**exercice4** sur 8 points répartis en 3 points pour la question 1) et 1 point pour les autres

## Exercice 1

1. Soit  $X_t$  un processus stationnaire du second ordre,  $\varepsilon_t$  suite de v.a. iid centrée de variance  $\sigma^2$ . On fait l'hypothèse  $H_a$  que ce processus est un AR(1):

$$X_t = aX_{t-1} + \varepsilon_t$$

avec  $|a| < 1$ .

1. calculer l'autocorrélation d'ordre 1 :  $\rho(1)$ .

on a:  $\gamma(0) = \sigma^2/(1 - a^2)$  et  $\gamma(k) = a^k\gamma(0)$

2. supposons qu'on observe une trajectoire de taille  $n$  de ce processus. Définir l'estimateur empirique  $a_n$  de  $a$ . Quelle est la limite de  $a_n$  quand  $n$  tend vers l'infini?

$\hat{a}_n(1) = \rho_n$  l'autocorrélation empirique. On sait qu'il est consistant:  $\lim_{n \rightarrow \infty} \rho_n = \rho(1) = a$  presque sûrement.

3. suggérer un test pour valider l'hypothèse  $H_a$ .

Si le modèle est correct,  $X_n - aX_{n-1} = \varepsilon_n$  est un bruit blanc. On peut ainsi tester la validité du modèle en calculant les autocorrélations empiriques  $\rho_n^\varepsilon(k)$  des résidus  $\varepsilon_i = X_i - a_n X_{i-1}$ . Pour une valeur raisonnable et fixée de  $q$ , on pose  $T_n = \rho_n^\varepsilon(1) + \dots + \rho_n^\varepsilon(q)$ . Sous  $H_a$ ,  $T_n$  suit approximativement une  $\chi^2$  à  $q$  degrés de liberté. La région de rejet du test est  $T_n > t$  ou  $t$  est un quantile approprié (selon le niveau du test) de la loi du  $\chi^2$ .

4. le processus est en fait un processus AR(2):

$$X_t = \alpha X_{t-1} + \beta X_{t-2} + \varepsilon_t$$

montrer que pour que ce processus puisse se décomposer en une somme de valeur passées de  $\varepsilon_t$  il est nécessaire d'avoir  $|\beta| < 1$ .

Pour cela le polynôme caractéristique  $P(z) = 1 - \alpha z - \beta z^2$  doit avoir ses racines en dehors du cercle unité. Le produit des racines vaut  $-1/\beta$  on doit donc avoir  $|1/\beta| < 1$ .

5. écrire les équations de Yule-Walker reliant  $\rho(1)$ ,  $\rho(2)$ ,  $\alpha$  et  $\beta$ . Exprimer  $\rho(1)$  et  $\rho(2)$  en fonction de  $\alpha$  et  $\beta$ .

$$\rho(1) = \alpha + \beta\rho(1)$$

$$\rho(2) = \alpha\rho(1) + \beta$$

et donc:

$$\rho(1) = \alpha/(1 - \beta)$$

$$\rho(2) = \alpha^2/(1 - \beta) + \beta$$

## Exercice 2

Etudiez la stationnarité des processus suivants ( $\varepsilon_t$  est un bruit blanc de variance  $\sigma^2$ ):

1.  $y_t = at + \varepsilon_t$

*non-stationnaire, en effet  $E(y_t) = at$  dépend du temps*

2.  $x_t = \Delta y_t$

*$\Delta y_t = a + \varepsilon_t - \varepsilon_{t-1}$  processus MA(1) stationnaire*

3.  $z_t = at^2 + bt + \varepsilon_t$

*non-stationnaire, en effet  $E(y_t) = at^2 + bt$  dépend du temps*

4.  $z_t = \Delta^2 y_t$

*stationnaire, en effet  $z_t = \varepsilon_t - 2\varepsilon_{t-1} + \varepsilon_{t-2}$  processus MA(2) stationnaire*

## Exercice 3

Soit  $Z_t$  une suite de variables aléatoires iid de loi normale de moyenne 0 et de variance  $\sigma^2$ .  $a$ ,  $b$  et  $c$  des constantes. Déterminer lequel ou lesquels des processus ci-dessous sont stationnaires. Pour chaque processus stationnaire, calculer la moyenne et la fonction d'autocovariance.

1.  $X_t = a + Z_t + cZ_{t-2}$

*stationnaire,  $E(X_t) = a$ ,  $V(X_t) = \sigma^2 + c^2\sigma^2$ ,  $\gamma(1) = 0$ ,  $\gamma(2) = c\sigma^2$ ,  $\gamma(k) = 0$  pour  $k > 2$*

2.  $X_t = Z_1 \cos(ct) + Z_2 \sin(ct)$

*stationnaire,  $E(X_t) = 0$ ,  $V(X_t) = \sigma^2$ , comme  $\cos(u+v) = \cos u \cos v - \sin u \sin v$  on a  $\gamma(k) = \sigma^2 \cos(kc)$*

3.  $X_t = Z_t \cos(ct) + Z_{t-1} \sin(ct)$

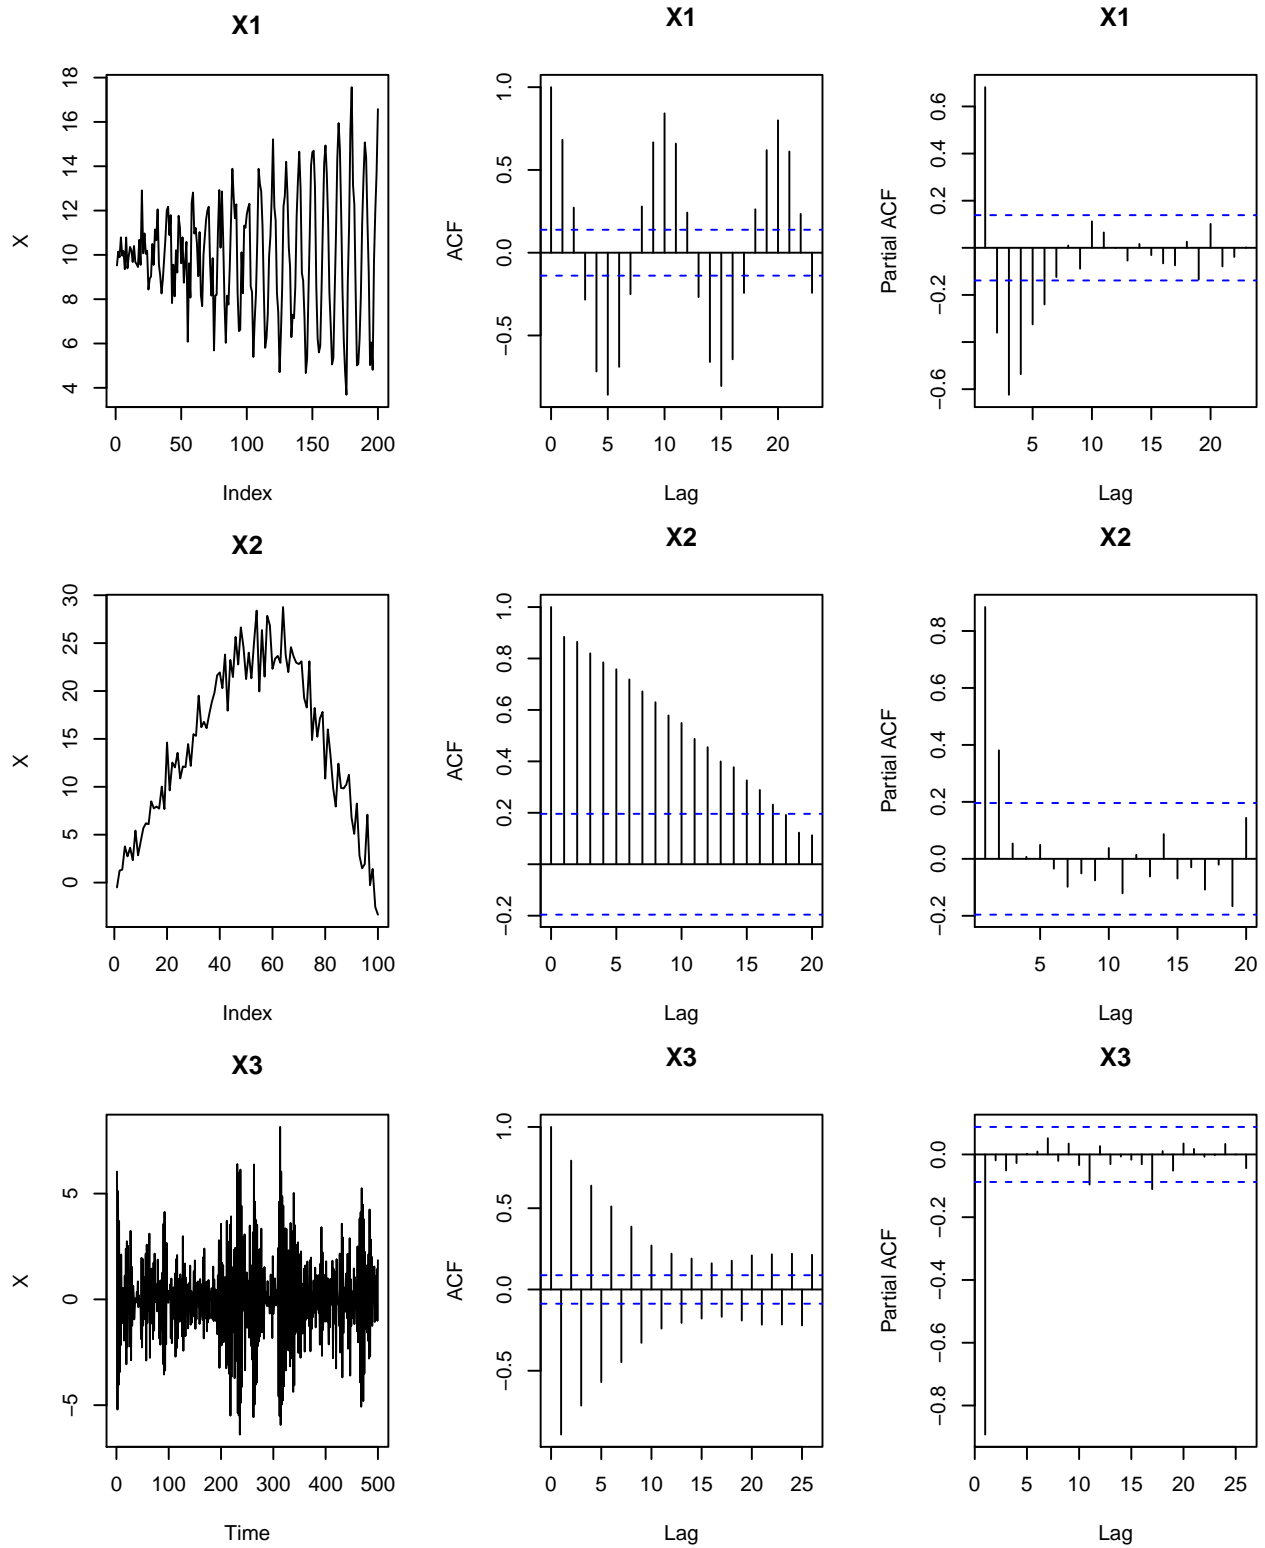
*non stationnaire,  $E(X_t) = 0$ ,  $V(X_t) = \sigma^2$  mais  $\gamma(k) = \sigma^2 \sin(ct) \cos(c(t-k))$  dépend de  $t$*


4.  $X_t = Z_t Z_{t-1}$

*stationnaire,  $E(X_t) = 0$ ,  $V(X_t) = \sigma^4$ ,  $\gamma(k) = 0$  pour  $k$  différent de 0.*

## Exercice 4

Un statisticien étudie un jeu de données composé de 4 séries temporelles pour lesquelles il a représenté/calculé les statistiques suivantes:





1. Proposer une démarche de modélisation pour chacune de ces séries, justifier.

- $X_1$  la trajectoire du processus fait apparaître une saisonnalité, confirmée par l'ACF, de période 10. D'autre part, on constate que l'amplitude de ces oscillations périodiques croît avec le temps ce qui plaide en faveur d'une tendance multiplicative. On peut donc proposer le modèle de régression suivant:  $X_{1t} = at\cos(2\pi/10) + \text{eps}$
- $X_2$  la trajectoire du processus fait apparaître une tendance polynomiale par morceaux, cette non-stationnarité est confirmée par l'ACF qui ne décroît pas exponentiellement vers 0. Une démarche possible est d'estimer cette tendance par régression spline ou estimateur à noyau. Ensuite il faudra étudier les résidus: ACF, PACF...
- $X_3$  l'acf décroît exponentiellement vers 0 et la pacf montre qu'il s'agit d'un AR(1)
- $X_4$  l'acf décroît brutalement après  $q = 3$  ce qui est caractéristique d'un MA(3)

Notre statisticien s'intéresse ensuite à une autre série  $X_t^5$ . Il propose de la modéliser par un ARMA et cherche ensuite à valider son modèle. Il obtient les sorties suivantes:

```
##
## Call:
## arima(x = X5, order = c(3, 0, 4), include.mean = T, method = c("ML"))
##
## Coefficients:
##      ar1      ar2      ar3      ma1      ma2      ma3      ma4  intercept
##    -0.2995  0.4580  0.2501  0.9064 -0.0054  0.0914  0.2061   0.2204
## s.e.   0.2213  0.1404  0.1866  0.2183  0.1672  0.1907  0.1047   0.4837
##
## sigma^2 estimated as 5.183:  log likelihood = -673.01,  aic = 1364.02
## pvalue student-test:
##      ar1      ar2      ar3      ma1      ma2      ma3      ma4
##      0.18      0.00      0.18      0.00      0.97      0.63      0.05
## intercept
##      0.65
```

2. Expliquer comment sont estimés les coefficients du modèle ARMA?  
par les équations de yule-walker ou moindres carrés conditionnels, cf cours.

3. Expliquer ce que signifie la sortie "aic=1364.02".

l'aic est calculé ainsi:  $AIC(\phi, \theta, \sigma^2) = -2\log(L(\theta, \phi, \sigma^2)) + 2k$  ou  $L$  est la vraisemblance du modèle. Ce critère permet d'effectuer un choix de modèle parmi une famille de modèles ARMA, c'est un compromis entre un bon ajustement aux données et la dimension du modèle.

4. A quoi correspond la ligne "s.e"? Comment est calculée la p-value du test de student de nullité de chacun des coefficients?

s.e. correspond à l'écart type estimé des coefficients du modèle, diminuer d'une unité l'ordre de l'AR(p) ou du MA(q) revient à tester la significativité du coefficient  $\phi_p$  (resp.  $\theta_q$ ) ce qui peut être fait par un test de student, les estimateurs  $\hat{\phi}_p$  et  $\hat{\theta}_q$  obtenus par maximum de vraisemblance ayant les mêmes propriétés qu'en régression linéaire.

5. Au vu de ces résultats que doit faire notre statisticien?

la constante et la coefficient de l'AR(3) ne sont pas significativement non nuls. Il faut réduire l'ordre de l'AR de 1 et ne pas inclure la constante dans le modèle.

6. Il s'intéresse ensuite à une série  $X_t^6$  et effectue un test de Box-Pierce sur  $X_{6t}$ . Il obtient le résultat suivant:

```
## Lags Statistic df      pvalue
##    20  29.13311 20 0.08517126
```

à quoi correspond "Lags"? "df"? Quelle est la conclusion de ce test?

ce test permet de tester l'hypothèse que les résidus d'une série  $X_t$  suivant une modélisation ARMA(p,q) sont un bruit blanc ie, pour une série  $X_t$  et ses résidus associés  $\hat{\varepsilon}_t = \hat{\Theta}(L)^{-1}\hat{\Phi}(L)(1-B)^d X_t$  de fonction d'autocorrélation  $\rho_\varepsilon(h)$  et son estimateur empirique associé:

$$H_0(h) : \rho_\varepsilon(1) = \rho_\varepsilon(2) = \dots = \rho_\varepsilon(h) = 0$$

$$H_1(h) : \exists k \in (1, \dots, h) \text{ t.q } \rho_\varepsilon(k) \neq 0$$

Il se base sur la statistique de Box-Pierce:

$$Q_{BP}(h) = n \sum_{j=1}^h \hat{\rho}_\varepsilon(j)^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \chi^2(h-k)$$

lags correspond donc à h l'ordre du test, et df le nombre de degrés de libertés de la  $\chi^2$  associée