# Modèles de prévision <br> Partie 2 - séries temporelles \# 1 

Arthur Charpentier

charpentier.arthur@uqam.ca
http ://freakonometrics.hypotheses.org/

Été 2014

## Plan du cours

- Motivation et introduction aux séries temporelles
- Méthodes de lissage
- Modèles de régression (Buys-Ballot)
- Lissage(s) exponentiel(s) (Holt-Winters)
- Notions générales sur les processus stationnaires
- Les processus SARIMA
- Les modèles autorégressifs, $A R(p), \Phi(L) X_{t}=\varepsilon_{t}$
- Les modèles moyennes mobiles, $M A(q)$ (moving average), $X_{t}=\Theta(L) \varepsilon_{t}$
- Les modèles autorégtressifs et moyenne mobiles, $A R M A(p, q)$, $\Phi(L) X_{t}=\Theta(L) \varepsilon_{t}$
- Les modèles autorégtressifs, $A R I M A(p, d, q),(1-L)^{d} \Phi(L) X_{t}=\Theta(L) \varepsilon_{t}$
- Les modèles autorégtressifs, $\operatorname{SARIMA}(p, d, q)$, $(1-L)^{d}\left(1-L^{s}\right) \Phi(L) X_{t}=\Theta(L) \varepsilon_{t}$
- Prévision avec un SARIMA, ${ }_{T} \widehat{X}_{T+h}$


## Méthode de Buys Balot - la tendance

Notons $\left(X_{t}\right)$ une série temporelle, observée jusqu'à la date $T$.
Si on a une tendance linéaire, on cherche à résoudre

$$
\widehat{\boldsymbol{\beta}}=\left(\widehat{\beta}_{0}, \widehat{\beta}_{1}\right) \in \operatorname{argmin}\left\{\sum_{t=1}^{T}\left(X_{t}-\left(\beta_{0}+\beta_{1} \cdot t\right)\right)^{2}\right\}
$$

> autoroute=read.table(

+ "http://freakonometrics.blog.free.fr/public/data/autoroute.csv",
+ header=TRUE,sep=";")
> a7=autoroute\$a007
$>X=t s(a 7$, start $=c(1989,9)$, frequency $=12)$
$>\mathrm{T}=\mathrm{time}(\mathrm{X})$
$>$ S=cycle (X)
$>B=$ data.frame ( $\mathrm{x}=\mathrm{as} \cdot \operatorname{vector}(\mathrm{X}), \mathrm{T}=\mathrm{as} \cdot \operatorname{vector}(\mathrm{T}), \mathrm{S}=$ as. $\operatorname{vector}(\mathrm{S}))$
$>\operatorname{regT}=\operatorname{lm}\left(\mathrm{x}^{\sim} \mathrm{T}\right.$, data$\left.=\mathrm{B}\right)$
$>\operatorname{plot}(X)$
> abline(regT, col="red")

Méthode de Buys Balot - la tendance


## Méthode de Buys Balot - la tendance

Posons $\widehat{Y}_{t}=X_{t}-\left(\widehat{\beta}_{0}+\widehat{\beta}_{1} t\right)$
> X1=predict (regT)
> $\mathrm{B} \$ \mathrm{X} 1=\mathrm{X} 1$
$>\mathrm{Y}=\mathrm{B} \$ \mathrm{X} 1$
> plot(X,xlab="",ylab="")
> YU=apply (cbind (X,Y), 1, max)
> YL=apply (cbind (X,Y), $1, \min )$
> i=which(is.na(Y)==FALSE)
> polygon(c(T[i],rev(T[i])),c(Y[i],rev(YU[i])),col="blue")
> polygon(c(T[i],rev(T[i])),c(Y[i],rev(YL[i])),col="red")
> lines ( $\mathrm{B} \$ \mathrm{~T}, \mathrm{Y}, \mathrm{l}_{\mathrm{wd}}=3$ )

Méthode de Buys Balot - la tendance


## Méthode de Buys Balot - le cycle

On cherche un cycle mensuel (de période $s=12$ ). Supposons

$$
\widehat{Y}_{t}=\sum_{k=0}^{s-1} \gamma_{k} \mathbf{1}(t=k \text { mod. } s)+Z_{t}
$$

> $\mathrm{B} \$ \mathrm{res} 1=\mathrm{X}-\mathrm{X} 1$
> regS $=1 \mathrm{~lm}$ (res1~0+as.factor(S), data=B)
> B\$X2=predict(regS)
> plot( $B \$ S, B \$ r e s 1, x l a b=" s a i s o n n a l i t \backslash ' e ")$
> lines(B\$S[1:4],B\$X2[1:4], col="red",1wd=2)
> lines ( $\mathrm{B} \$ \mathrm{~S}[5: 13], \mathrm{B} \$ \mathrm{X} 2[5: 13]$, col="red", $1 \mathrm{wd}=2$ )

Remarque mod. est l'opérateur de calcul du reste de la division euclidienne, ex :

$$
27 \bmod .12=27-(12 \times 2)=3
$$

Méthode de Buys Balot - le cycle


## Méthode de Buys Balot - le cycle

Alors

$$
X_{t}=\underbrace{\widehat{\beta}_{0}+\widehat{\beta}_{1} t}_{\text {tendance linéaire }}+\underbrace{\sum_{k=0}^{s-1} \widehat{\gamma}_{k} \mathbf{1}(t=k \bmod . s)}_{\text {cycle }}+Z_{t}
$$

> plot(X,xlab="",ylab="")
> YU=apply (cbind (X,Y), 1, max)
> YL=apply(cbind (X,Y),1,min)
> i=which(is.na(Y)==FALSE)
> polygon(c(T[i],rev(T[i])),c(Y[i],rev(YU[i])),col="blue")
> polygon(c(T[i],rev(T[i])),c(Y[i],rev(YL[i])),col="red")
> lines(B\$T,Y,lwd=3)

Méthode de Buys Balot - tendance et cycle


## Méthode de Buys Balot - prévision

On peut alors faire de la prévision, en supposant le bruit $Z_{t}$ i.i.d., i.e.

```
    T}\mp@subsup{\widehat{X}}{T+h}{}=\mathbb{E}(\mp@subsup{X}{T+h}{}|\mp@subsup{X}{1}{}\cdots,\mp@subsup{X}{T}{})=\mp@subsup{\widehat{\beta}}{0}{}+\mp@subsup{\widehat{\beta}}{1}{}[T+h]+\mp@subsup{\sum}{k=0}{s-1}\mp@subsup{\widehat{\gamma}}{k}{}\mathbf{1}(T+h=k\operatorname{mod.}s
> n=length(T)
> T0=T[(n-23):n]+2
> plot(X,xlim=range(c(T,T0)))
> X1p=predict(regT,newdata=data.frame(T=T0))
> Yp=X1p+B$X2[(n-23):n]
> se=sd(X-Y)
> YpU=Yp+1.96*se
> YpL=Yp-1.96*se
> polygon(c(TO,rev(TO)),c(YpU,rev(YpL)),col="yellow",border=NA)
> lines(T0,Yp,col="red",lwd=3)
> lines(B$T,Y,lwd=3,col="red")
```


## Méthode de Buys Balot - prévision



## Formalisation de Buys-Ballot (1847)

> sncf=read.table(

+ "http://freakonometrics.blog.free.fr/public/data/sncf.csv",
+ header=TRUE,sep=";")
> SNCF=ts(as.vector (t (as.matrix (sncf[,2:13]))),
+ , start $=c(1963,1)$, frequency $=12)$
> plot(SNCF,lwd=2,col="purple")



## Formalisation de Buys-Ballot (1847)

La série $X_{t}$ est la somme de 2 composantes déterministes : une tendance $Z_{t}$, d'une saisonnalité $S_{t}$ et d'une composante aléatoire $\varepsilon_{t}$

$$
X_{t}=Z_{t}+S_{t}+\varepsilon_{t}
$$

On suppose que $Z_{t}$ et $S_{t}$ sont des combinaisons linéaires de fonctions connues dans le temps, $Z_{t}^{i}$ et $S_{t}^{j}$, i.e.

$$
\left\{\begin{array}{l}
Z_{t}=\beta_{0}+Z_{t}^{1} \beta_{1}+Z_{t}^{2} \beta_{2}+\ldots+Z_{t}^{m} \beta_{m} \quad\left(\mathrm{ex}: \beta_{0}+\beta_{1} \cdot t\right) \\
S_{t}=S_{t}^{1} \gamma_{1}+S_{t}^{2} \gamma_{2}+\ldots+S_{t}^{s} \gamma_{n}
\end{array}\right.
$$

Le but est d'estimer les $\beta_{1}, \ldots, \beta_{m}$ et $\gamma_{1}, \ldots, \gamma_{n}$ à partir des $T$ observations.

$$
X_{t}=\sum_{i=1}^{m} Z_{t}^{i} \beta_{i}+\sum_{j=1}^{s} S_{t}^{j} \gamma_{j}+\varepsilon_{t} \text { pour } t=1, \ldots, T
$$

## Formalisation de Buys-Ballot (1847)

La forme de $S_{t}$ dépend du type de données, et de la forme de la saisonnalité. On considèrera ici des fonctions $S_{t}^{i}$ indicatrices,

$$
S_{t}^{i}=\left\{\begin{array}{l}
0 \text { si } t=\operatorname{mois} i \\
1 \text { si } t \neq \operatorname{mois} i
\end{array} \quad \text { ou } S_{t}^{i}=\left\{\begin{array}{l}
0 \text { si } t=0[\text { modulo } i] \\
1 \text { si } t \neq 0[\text { modulo } i]
\end{array}\right.\right.
$$

Example : Considérons des données trimestrielles,

$$
X_{t}=\underbrace{\alpha+\beta \cdot t}_{Z_{t}}+\underbrace{\gamma_{1} S_{t}^{1}+\gamma_{2} S_{t}^{2}+\gamma_{3} S_{t}^{3}+\gamma_{4} S_{t}^{4}}_{S_{t}}+\varepsilon_{t}
$$

Que l'on peut écrire de façon matricielle,

$$
\left(\begin{array}{c}
5130 \\
6410 \\
8080 \\
5900 \\
5110 \\
6680 \\
8350 \\
5910 \\
5080 \\
\vdots \\
X_{t}
\end{array}\right)=\left(\begin{array}{cccccc}
1 & 1 & 1 & 0 & 0 & 0 \\
1 & 2 & 0 & 1 & 0 & 0 \\
1 & 3 & 0 & 0 & 1 & 0 \\
1 & 4 & 0 & 0 & 0 & 1 \\
1 & 5 & 1 & 0 & 0 & 0 \\
1 & 6 & 0 & 1 & 0 & 0 \\
1 & 7 & 0 & 0 & 1 & 0 \\
1 & 8 & 0 & 0 & 0 & 1 \\
1 & 9 & 1 & 0 & 0 & 0 \\
\vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\
1 & t & S_{t}^{1} & S_{t}^{2} & S_{t}^{3} & S_{t}^{4}
\end{array}\right)\left(\begin{array}{c}
\alpha \\
\beta \\
\gamma_{1} \\
\gamma_{2} \\
\gamma_{3} \\
\gamma_{4}
\end{array}\right)+\left(\begin{array}{c}
\varepsilon_{1} \\
\varepsilon_{2} \\
\varepsilon_{3} \\
\varepsilon_{4} \\
\varepsilon_{5} \\
\varepsilon_{6} \\
\varepsilon_{7} \\
\varepsilon_{8} \\
\varepsilon_{9} \\
\vdots \\
\varepsilon_{t}
\end{array}\right)
$$

## Formalisation de Buys-Ballot (1847)

Remark : pour transformer les données en données trimestrielles (et non plus mensuelles)
$>$ SNCFQ= ts(apply(matrix(as.numeric(SNCF), 3,length(SNCF)/3),2, sum),

+ start $=c(1963,1)$, frequency $=4)$
> plot(SNCFQ,col="red")
$>$ SNCFQ

|  | Qtr1 | Qtr2 | Qtr3 | Qtr4 |
| :--- | :--- | :--- | :--- | :--- |
| 1963 | 5130 | 6410 | 8080 | 5900 |
| 1964 | 5110 | 6680 | 8350 | 5910 |
| 1965 | 5080 | 6820 | 8190 | 5990 |
| 1966 | 5310 | 6600 | 8090 | 6020 |

... etc.

## Formalisation de Buys-Ballot (1847)

Le graphique des données trimestrielles est le suivant


## Formalisation de Buys-Ballot (1847)

On considère un modèle de la forme

$$
X_{t}=\sum_{i=1}^{m} Z_{t}^{i} \beta_{i}+\sum_{j=1}^{s} S_{t}^{j} \gamma_{j}+\varepsilon_{t} \text { pour } t=1, \ldots, T
$$

La méthode des moindres carrés ordinaires consiste à choisir les $\beta_{i}$ et $\gamma_{j}$ de façon à minimiser le carré des erreurs

$$
\begin{aligned}
\left(\widehat{\beta}_{i}, \widehat{\gamma}_{j}\right) & =\arg \min \left\{\sum_{t=1}^{T} \varepsilon_{t}^{2}\right\} \\
& =\arg \min \left\{\sum_{t=1}^{T}\left[X_{t}-\sum_{i=1}^{m} Z_{t}^{i} \beta_{i}+\sum_{j=1}^{s} S_{t}^{j} \gamma_{j}\right]^{2}\right\}
\end{aligned}
$$

## Formalisation de Buys-Ballot (1847)

```
> T = seq(from=1963,to=1980.75,by=.25)
> Q = rep(1:4,18)
> reg=lm(SNCFQ~0+T+as.factor(Q))
> summary(reg)
```

Coefficients:


Signif. codes: $0{ }^{\prime} * * * ’ 0.001$ '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 552.7 on 67 degrees of freedom
Multiple R-squared: 0.9953, Adjusted R-squared: 0.995
F-statistic: 2846 on 5 and 67 DF, p-value: < 2.2e-16
> plot(T,residuals(reg),type="l")


## Formalisation de Buys-Ballot (1847) : prévision

Soit $h \geq 1$. On suppose que le modèle reste valide en $T+h$ c'est à dire que

$$
X_{T+h}=\sum_{i=1}^{m} Z_{T+h}^{i} \beta_{i}+\sum_{j=1}^{s} S_{T+h}^{j} \gamma_{j}+\varepsilon_{T+h}
$$

avec $\mathbb{E}\left(\varepsilon_{T+h}\right)=0, V\left(\varepsilon_{T+h}\right)=\sigma^{2}$ et $\operatorname{cov}\left(\varepsilon_{t}, \varepsilon_{T+h}\right)=0$ pour $t=1, \ldots, T$. La variable $X_{T+h}$ peut être approchée par

$$
{ }_{T} \widehat{X}_{T+h}=\sum_{i=1}^{m} Z_{T+h}^{i} \widehat{\beta}_{i}+\sum_{j=1}^{n} S_{T+h}^{j} \widehat{\gamma}_{j} .
$$

Cette prévision est la meilleur (au sens de l'erreur quadratique moyenne) prévision, linéaire en $X_{1}, \ldots, X_{T}$ et sans biais.

## Formalisation de Buys-Ballot (1847) : prévision

Un intervalle de confiance de cette prévision est de la forme

$$
\left[\widehat{X}_{T}(h)-\phi_{1-\alpha / 2} \sqrt{\widehat{e}_{h}} ; \widehat{X}_{T}(h)+\phi_{1-\alpha / 2} \sqrt{\widehat{e}_{h}}\right]
$$

où $\phi_{1-\alpha / 2}$ est le quantile d'ordre $\alpha$ de la loi de Student à $T-m-n$ degrés de liberté, et où

$$
\begin{aligned}
\widehat{e}_{h} & =\widehat{\mathbb{E}}\left(\left[\widehat{X}_{T}(h)-X_{T+h}\right]^{2}\right)=\widehat{V}\left(\sum_{i=1}^{m} Z_{T+h}^{i} \widehat{\beta}_{i}+\sum_{j=1}^{n} S_{T+h}^{j} \widehat{\gamma}_{j}-\varepsilon_{T+h}\right) \\
& =\left[\widehat{\beta}^{\prime} \mid \widehat{\gamma}^{\prime}\right]\left[\widehat{V}\binom{\widehat{\beta}}{\widehat{\gamma}}\right]\left[\begin{array}{c}
\widehat{\beta} \\
\widehat{\gamma}
\end{array}\right]+s^{2}
\end{aligned}
$$

## Méthode de Buys Balot et température

On peut le faire sur la modélisation de la température

```
> TEMP=read.table("http://freakonometrics.blog.free.fr/public
/data/TN_STAID000038.txt",header=TRUE, sep=", ")
> D=as.Date(as.character(TEMP$DATE),"%Y%m%d")
> T=TEMP$TN/10
> plot(D,T,col="light blue",xlab="Temp\'erature minimale
journali\'ere Paris",ylab="",cex=.5)
```

1. Estimer la tendance linéaire $X_{t}=\left[\beta_{0}+\beta_{1} \cdot t\right]+Y_{t}$
> abline (h=0,lty=2,col="grey")
> abline(lm( $\left.\mathrm{T}^{\sim} \mathrm{D}\right)$, lWd=2,col="red")

> X=T-predict (lm(T~D))
> plot(D, X,col="light blue", xlab="", ylab="", cex=.5)
> abline(h=0,lty=2,col="grey")
> abline(lm(X~D),lwd=2,col="red")
2. Représenter la série résiduelle $Y_{t}=X_{t}-\left[\beta_{0}+\beta_{1} \cdot t\right]$

> day=as.POSIXlt(D)\$yday+1
> plot(day,X,col="light blue", xlab="", ylab="", cex=.5)
> abline(h=0,lty=2,col="grey")
> s=tapply(X, as.factor (day), mean)
> lines(1:366,s,col="red")
> cycle=as.vector(s[day])
3. Représenter la série résiduelle en fonction de la période supposée $Y_{t}, t \bmod s$,

> plot(D,X,col="light blue",xlab="",ylab="", cex=.5)
> abline(h=0,lty=2,col="grey")
> lines(D,cycle,lwd=2,col="red")
4. Construire la série résiduelle $Y_{t}=S(t)+Z_{t}$,

> plot(D,X,col="light blue",xlab="",ylab="", cex=.5,
xlim=as.Date(as.character (c("1990/01/01", "2000/01/01"),
"\%Y/\%m/\%d")))
> abline(h=0,lty=2,col="grey")
> lines(D,cycle,lwd=2,col="red")
> $\mathrm{Z}=\mathrm{X}$-cycle
> plot(D,Z,col="light blue",xlab="",ylab="", cex=.5)
5. ... analyser la série résiduelle $Z_{t}$,


## Une (courte) introduction aux autocorrélations

La série résiduelle n'est pas un bruit blanc : fortes auto-corrélations....



## Lissage exponentiel (simple)

À partir d'une série $\left(X_{t}\right)$ on va construire une série $\left(L_{t}\right)$ telle que

$$
L_{t}=\alpha X_{t}+(1-\alpha) L_{t-1}, \text { o ̀ ù } \alpha \in(0,1)
$$

$\operatorname{avec} L_{0}=X_{0}$.
> library(datasets)
> X=as.numeric(Nile)
> Lissage=function(a)\{
$+\mathrm{T}=$ length (X)
$+\mathrm{L}=\mathrm{rep}(\mathrm{NA}, \mathrm{T})$
$+\mathrm{L}[1]=\mathrm{X}[1]$
$+\operatorname{for}(t$ in 2:T) $\{\mathrm{L}[\mathrm{t}]=\mathrm{a} * \mathrm{X}[\mathrm{t}]+(1-\mathrm{a}) * \mathrm{~L}[\mathrm{t}-1]\}$

+ return(L)
$+3$
> plot (X,type="b", cex=.6)
> lines(Lissage(.2), col="red")



## Lissage exponentiel (simple)

On parle de lissage exponentiel car

$$
\begin{aligned}
L_{t} & =\alpha X_{t}+(1-\alpha) L_{t-1} \\
& =\alpha\left(X_{t}+(1-\alpha) X_{t-1}\right)+(1-\alpha)^{2} L_{t-2} \\
& \cdots \\
& =\alpha\left(X_{t}+(1-\alpha) X_{t-1}+\cdots+(1-\alpha)^{k} X_{t-k}+\cdots\right)+(1-\alpha)^{t} X_{0}
\end{aligned}
$$

Cette progression géométrique est une discrétisation de la fonction exponentielle... L'idée est que si l'on cherche à faire une prévision, pour un horizon $h$, à partir de $t$, on pose

$$
{ }_{t} \widehat{X}_{t+h}=L_{t}
$$

## Lissage exponentiel (simple)

> plot(HoltWinters(X,beta=FALSE,gamma=FALSE)\$fitted[,1],col="red")
> lines(predict(hw,n.ahead=50), col="red",lwd=2)


## Lissage exponentiel (simple)

Le poids optimal $\alpha$ sera celui qui minimise l'erreur commise à un horizon $h=1$, i.e.

$$
\left.\alpha^{\star}=\operatorname{argmin}\left\{\sum_{t=0}^{T-1} L_{t}-X_{t+1}\right]^{2}\right\}
$$

```
> V=function(a){
+ T=length(X)
+ L=erreur=rep(NA,T)
+ erreur[1]=0
+ L[1]=X[1]
+ for(t in 2:T){
+ L[t]=a*X[t]+(1-a)*L[t-1]
+ erreur[t]=X[t]-L[t-1] }
+ return(sum(erreur^2))
+ }
> optimize(V,c(0,.5))$minimum
[1] 0.246581
```


## Lissage exponentiel (simple)



## Lissage exponentiel (simple)

> hw=HoltWinters(X,beta=FALSE,gamma=FALSE)
$>\mathrm{hw}$
Holt-Winters exponential smoothing without trend an seasonal comp.

Call:
HoltWinters $(\mathrm{x}=\mathrm{X}$, beta $=$ FALSE, gamma $=$ FALSE, l.start $=\mathrm{X}[1]$ )

Smoothing parameters:
alpha: 0.2465579
beta : FALSE
gamma: FALSE
> plot(hw)
> points(2:(length(X)+1),Vectorize(Lissage)(.2465), col="blue")

Holt-Winters filtering


## Lissage exponentiel (double)

On va maintenant construire deux séries,

$$
\left\{\begin{array}{l}
L_{t}=\alpha X_{t}+(1-\alpha)\left(L_{t-1}+B_{t-1}\right) \\
B_{t}=\beta\left(L_{t}-L_{t-1}\right)+(1-\beta) B_{t-1}
\end{array}\right.
$$

où $0<\alpha, \beta<1$, avec les conditions initiales $L_{0}=X_{0}$ et $B_{0}=X_{1}-X_{0}$. Cette fois, la prédition s'écrit

$$
{ }_{t} \widehat{X}_{t+h}=L_{t}+h B_{t}
$$

C'est une généralisation du lissage simple au sens où on autorise la série à avoir une tendance linéaire.

## Lissage exponentiel (double)



## Lissage exponentiel (double)

```
> Lissage=function(a,b){
+ T=length(X)
+ L=B=rep(NA,T)
+ L[1]=X[1]; B[1]=0
+ for(t in 2:T){
+ L[t]=a*X[t]+(1-a)*(L[t-1]+B[t-1])
+ B[t]=b*(L[t]-L[t-1])+(1-b)*B[t-1] }
+ return(L)
+ }
```


## Lissage exponentiel (double)

Holt-Winters filtering


## Lissage exponentiel (double)

Là encore, les poids optimaux $(\alpha, \beta)$ minimisent l'erreur commise à un horizon $h=1$, i.e.

$$
\left.\left(\alpha^{\star}, \beta^{\star}\right)=\operatorname{argmin}\left\{\sum_{t=0}^{T-1}{ }_{t} \widehat{X}_{t+1}-X_{t+1}\right]^{2}\right\}
$$

```
> V=function(P){
+ a=P[1];b=P[2]
+ T=length(X)
+ L=B=erreur=rep(NA,T)
+ erreur[1:2]=0
+ L[2]=X[1]; B[2]=X[2]-X[1]
+ for(t in 3:T){
+ L[t]=a*X[t]+(1-a)*(L[t-1]+B[t-1])
+ B[t]=b*(L[t]-L[t-1])+(1-b)*B[t-1]
+ erreur[t]=X[t]-(L[t-1]-B[t-1]) }
+ return(sum(erreur^2))
+ }
> nlm(V,c(.5,.5))$estimate
[1] 0.40972695 0.05007216
```


## Lissage exponentiel (double)

> hw=HoltWinters(X,gamma=FALSE,l.start=X[1])
$>\mathrm{hw}$
Holt-Winters exponential smoothing with trend and without seasonal component.

Call:
HoltWinters ( $\mathrm{x}=\mathrm{X}$, gamma $=$ FALSE, l.start $=\mathrm{X}[1]$ )

Smoothing parameters:

```
alpha: 0.4200241
beta : 0.05973389
gamma: FALSE
```


## Lissage exponentiel saisonnier - Holt Winters (1960)

On va maintenant construire trois séries. Le lissage saisonnier peut se faire de manière additive ou multiplicative.

Pour le modèle saisonnier additif, de saisonnalité $s$, pour $t>s$

$$
\left\{\begin{array}{l}
L_{t}=\alpha\left[X_{t}-S_{t-s}\right]+(1-\alpha)\left(L_{t-1}+B_{t-1}\right) \\
B_{t}=\beta\left(L_{t}-L_{t-1}\right)+(1-\beta) B_{t-1} \\
S_{t}=\gamma\left(X_{t}-L_{t}\right)+(1-\gamma) S_{t-s}
\end{array}\right.
$$

où $0<\alpha, \beta, \gamma<1$, avec les conditions initiales

$$
L_{s}=\frac{X_{1}+\cdots+X_{s}}{s} \text { et } B_{s}=\frac{1}{s}\left(\frac{X_{s+1}-X_{1}}{s}+\cdots+\frac{X_{2 s}-X_{s}}{s}\right)
$$

avec $S_{t}=X_{t}-L_{s}$ pour $t=1, \cdots, s$. Cette fois, la prédition s'écrit

$$
{ }_{t} \widehat{X}_{t+h}=L_{t}+h B_{t}+S_{t+h-s}
$$

## Lissage exponentiel saisonnier - Holt Winters (1960)

Les poids optimaux $(\alpha, \beta, \gamma)$ minimisent l'erreur commise à un horizon $h=1$, en supposant la saisonnalité $s$ donnée

$$
\left.\left(\alpha^{\star}, \beta^{\star}, \gamma^{\star}\right)=\operatorname{argmin}\left\{\sum_{t=0}^{T-1} t \widehat{X}_{t+1}-X_{t+1}\right]^{2}\right\}
$$

```
> Lissage=function(a, b, c, s)\{
\(+\mathrm{T}=\) length (X)
\(+\mathrm{L}=\mathrm{B}=\mathrm{C}=\mathrm{pred}=\mathrm{rep}(\mathrm{NA}, \mathrm{T})\)
\(+\mathrm{L}[\mathrm{s}]=\operatorname{mean}(\mathrm{X}[1: \mathrm{s}]) ; \mathrm{B}[1: \mathrm{s}]=\mathrm{mean}(\mathrm{X}[(\mathrm{s}+1):(2 * \mathrm{~s})]-\mathrm{X}[1: \mathrm{s}]) / \mathrm{s}\)
\(+C[1: s]=X[1: s]-m e a n(X[1: s])\)
+ for \((t\) in ( \(s+1):(T-1))\{\)
\(+\mathrm{L}[\mathrm{t}]=\mathrm{a} *(\mathrm{X}[\mathrm{t}]-\mathrm{C}[\mathrm{t}-\mathrm{s}])+(1-\mathrm{a}) *(\mathrm{~L}[\mathrm{t}-1]+\mathrm{B}[\mathrm{t}-1])\);
\(+\mathrm{B}[\mathrm{t}]=\mathrm{b} *(\mathrm{~L}[\mathrm{t}]-\mathrm{L}[\mathrm{t}-1])+(1-\mathrm{b}) * \mathrm{~B}[\mathrm{t}-1]\);
\(+\mathrm{C}[\mathrm{t}]=\mathrm{c} *(\mathrm{X}[\mathrm{t}]-\mathrm{L}[\mathrm{t}])+(1-\mathrm{c}) * \mathrm{C}[\mathrm{t}-\mathrm{s}]\);
\(+\operatorname{pred}[\mathrm{t}]=(\mathrm{L}[\mathrm{t}]+\mathrm{B}[\mathrm{t}])+\mathrm{C}[\mathrm{t}-\mathrm{s}]\}\);
+ return(pred)\}
```

> source("http://freakonometrics.blog.free.fr/public/data/sourcets.R")
> X=autoroute7


## Lissage exponentiel saisonnier - Holt Winters (1960)

> hw=HoltWinters(X,seasonal="additive")
$>\mathrm{hw}$
Holt-Winters exponential smoothing with trend and additive seasonal component.

Call:
HoltWinters(x = X, seasonal = "additive")

Smoothing parameters:

```
alpha: 0.01340761
beta : 0.01853709
gamma: 0.2473586
```


## Lissage exponentiel saisonnier - Holt Winters (1960)

Il existe aussi un modèle saisonnier multiplicatif, de saisonnalité $s$, pour $t>s$

$$
\left\{\begin{array}{l}
\left.L_{t}=\alpha X_{t} \cdot S_{t-s}^{-1}\right]+(1-\alpha)\left(L_{t-1}+B_{t-1}\right) \\
B_{t}=\beta\left(L_{t}-L_{t-1}\right)+(1-\beta) B_{t-1} \\
S_{t}=\gamma\left(X_{t} \cdot L_{t}^{-1}\right)+(1-\gamma) S_{t-s}
\end{array}\right.
$$

où $0<\alpha, \beta, \gamma<1$, avec les conditions initiales

$$
L_{s}=\frac{X_{1}+\cdots+X_{s}}{s} \text { et } B_{s}=\frac{1}{s}\left(\frac{X_{s+1}-X_{1}}{s}+\cdots+\frac{X_{2 s}-X_{s}}{s}\right)
$$

avec $S_{t}=X_{t} \cdot L_{s}^{-1}$ pour $t=1, \cdots, s$. Cette fois, la prédition s'écrit

$$
{ }_{t} \widehat{X}_{t+h}=\left(L_{t}+h B_{t}\right) \cdot S_{t+h-s}
$$

## La stationnarité des séries temporelles

Un processus $\left(Y_{t}\right)$ est stationnaire au sens fort si pour tout $n, t_{1}, \ldots, t_{n}$ et $h \in \mathbb{N}$,

$$
\mathcal{L}\left(Y_{t_{1}}, \ldots, Y_{t_{n}}\right)=\mathcal{L}\left(Y_{t_{1}+h}, \ldots, Y_{t_{n}+h}\right)
$$

Un processus $\left(Y_{t}\right)$ est stationnaire au sens faible si

- la moyenne du processus est constante $: \mathbb{E}\left(Y_{t}\right)=m$ pour tout $t \in \mathbb{Z}$,
- les autocovariances ne dépendent que de la différence entre les observations: $\operatorname{cov}\left(X_{t}, X_{s}\right)=\gamma(|t-s|)$
En particulier, la variance de $Y_{t}$ est constante : $\operatorname{Var}\left(Y_{t}\right)=\sigma^{2}$.
Example : si $\left(X_{t}, t \in \mathbb{Z}\right)$ est un processus stationnaire, et si $\left(a_{i}, i \in \mathbb{Z}\right)$ est une suite de réels absolument convergente, i.e. $\sum_{i \in \mathbb{Z}}\left|a_{i}\right|<+\infty$, alors, le processus $\left(Y_{t}\right)$ défini par

$$
Y_{t}=\sum_{i \in \mathbb{Z}} a_{i} X_{t-i}, \text { pour tout } t \in \mathbb{Z}
$$

est un processus stationnaire.

## Les non-stationnarités

$\left(X_{t}\right)$ est un processus non-stationnaire TS s'il peut s'écrire sous la forme $X_{t}=f(t)+Z_{t}$ où $f(t)$ est une fonction (déterministe) du temps, et $\left(Z_{t}\right)$ est un processus stationnaire.

Example : $X_{t}=\alpha+\beta t+\varepsilon_{t}$
$\left(X_{t}\right)$ est un processus non-stationnaire DS - ou intégré d'ordre $d$, noté $I(d)$ - si le processus obtenu après $d$ différenciation est stationnaire : $Z_{t}=\Delta^{d} X_{t}$ est stationnaire, où $\Delta X_{t}=X_{t}-X_{t-1}$.

Example : $X_{t}=X_{t-1}+\varepsilon_{t}$.

Stationnarité, série \# 1


Stationnarité, série \# 1


Stationnarité, série \# 1


Stationnarité, série \# 2


Stationnarité, série \# 2


$$
X_{t}=a+b \cdot t+\varepsilon_{t} \text { où } \varepsilon_{i} \sim \mathcal{N}(0,1) \text { i.i.d. }
$$

Stationnarité, série \# 2


Stationnarité, série \# 3


Stationnarité, série \# 3


Stationnarité, série \# 3


Stationnarité, série \# 4


Stationnarité, série \# 4


Stationnarité, série \# 4


## Stationnarité, série \# 5



## Stationnarité, série \# 5



## Stationnarité, série \# 5



## Autocovariance et autocorrélation

Soit $\left(X_{t}\right)$ une série stationnaire. Alors pour tout $t$ et pour tout $h$, $\operatorname{cov}\left(X_{t}, X_{t+h}\right)=\mathbb{E}\left(\left[X_{t}-\mu\right]\left[X_{t+h}-\mu\right]\right)=\gamma(h)$, indépendante de $t$.

La fonction $\gamma(\cdot)$ sera appelée fonction d'autocovariance
On notera que $\operatorname{Var}\left(X_{t}\right)=\gamma(0)$.
On peut poser

$$
\rho(h)=\operatorname{cor}\left(X_{t}, X_{t+h}\right)=\frac{\gamma(h)}{\gamma(0)} .
$$

La fonction $\rho(\cdot)$ sera appelée fonction d'autocorrélation

## Matrice d'autocorrélations

On appelera matrice d'autocorrélation du vecteur ( $X_{t}, X_{t-1}, \ldots, X_{t-h+1}$ )

$$
\mathcal{R}(h)=\left[\begin{array}{cccccc}
1 & \rho(1) & \rho(2) & & & \rho(h-1) \\
\rho(1) & 1 & \rho(1) & & & \rho(h-2) \\
\rho(2) & \rho(1) & 1 & \ddots & & \rho(h-3) \\
& & \ddots & \ddots & \ddots & \\
& & & \ddots & 1 & \rho(1) \\
\rho(h-1) & \rho(h-2) & \rho(h-3) & & \rho(1) & 1
\end{array}\right]
$$

i.e.

$$
\mathcal{R}(h)=\left[\begin{array}{cc}
\mathcal{R}(h-1) \\
{\left[\begin{array}{lll}
\rho(h-1) & \cdots & \rho(1)
\end{array}\right]} & {\left[\begin{array}{c}
\rho(h-1) \\
\vdots \\
\rho(1)
\end{array}\right]} \\
1
\end{array}\right]
$$

Notons que $\operatorname{det} \mathcal{R}(h) \geq 0$ pour tout $h \in \mathbb{N} \backslash\{0\}$

Relations sur les fonctions d'autocorrélation
$\operatorname{det} \mathcal{R}(2) \geq 0$ implique que pour $(\rho(1), \rho(2))$,

$$
[1-\rho(2)]\left[1+\rho(2)-2 \rho(1)^{2}\right] \geq 0
$$

en plus des conditions $-1 \leq \rho(1), \rho(2) \leq 1$, i.e.

$$
\left\{\begin{array}{l}
1-\phi_{1}+\phi_{2}>0 \\
1+\phi_{1}-\phi_{2}>0 \\
\phi_{1}^{2}+4 \phi_{2}>0
\end{array}\right.
$$

## Relations sur les fonctions d'autocorrélation



Figure 3.2 Typical autocorrelation and partial autocorrelation functions $\rho_{k}$ and $\phi_{k k}$ for various stationary AR(2) models. (From [183].)
(via Box, Jenkins \& Reinsel (1994)).

## Estimation de $\rho$ et de $\gamma$

Considérons un ensemble d'observations $X_{1}, \ldots, X_{T}$.
La moyenne empirique est donnée par

$$
\bar{X}_{T}=\frac{1}{T} \sum_{t=1}^{T} X_{t}
$$

La fonction d'autocovariance empirique est donnée par

$$
\widehat{\gamma}_{T}(h)=\frac{1}{T-h} \sum_{t=1}^{T-h}\left(X_{t}-\bar{X}_{T}\right)\left(X_{t-h}-\bar{X}_{T}\right)
$$

et la fonction d'autocorrélation empirique est donnée par

$$
\widehat{\rho}_{T}(h)=\frac{\widehat{\gamma}_{T}(h)}{\widehat{\gamma}_{T}(0)} .
$$

## Estimation de $\rho$ et de $\gamma$

Proposition 1. Si $\left(X_{t}\right)$ est un processus linéaire, au sens où il satisfait $X_{t}=\sum_{j \in \mathbb{Z}} \phi_{j} \varepsilon_{t-j}$ où $\left(\varepsilon_{t}\right)$ est une suite de variables i.i.d. centrées, telle que $\mathbb{E}\left(\varepsilon_{t}^{4}\right)=\eta \mathbb{E}\left(\varepsilon_{t}^{2}\right)^{2}<+\infty$, où les $\phi_{j}$ définissent une série absolument convergente, et où $\eta$ est une constante positive, alors, on a la formule dite de Bartlett,

$$
\lim _{T \rightarrow \infty} T \operatorname{cov}\left(\widehat{\gamma}_{T}(h), \widehat{\gamma}_{T}(k)\right)=\eta \gamma(h) \gamma(k)+\sum_{i=-\infty}^{+\infty} \gamma(i) \gamma(i+k-h)+\gamma(i+k) \gamma(i-h)
$$

## Estimation de $\rho$ et de $\gamma$

Proposition 2. Si $\left(X_{t}\right)$ est un processus linéaire, au sens où il satisfait $X_{t}=\sum_{j \in \mathbb{Z}} \phi_{j} \varepsilon_{t-j}$ où $\left(\varepsilon_{t}\right)$ est une suite de variables i.i.d. centrées, telle que $\mathbb{E}\left(\varepsilon_{t}^{4}\right)=\eta \mathbb{E}\left(\varepsilon_{t}^{2}\right)^{2}<+\infty$, et $\varepsilon_{t} \sim \mathcal{N}\left(0, \sigma^{2}\right)$, et où les $\phi_{j}$ définissent une série absolument convergente, et où $\eta$ est une constante positive, alors, on a, pour tout $p \geq 0$,

$$
\sqrt{n}\left(\begin{array}{c}
\widehat{\gamma}_{T}(0) \\
\vdots \\
\widehat{\gamma}_{T}(p)
\end{array}\right) \rightarrow \mathcal{N}\left(\left(\begin{array}{c}
\gamma(0) \\
\vdots \\
\gamma(p)
\end{array}\right), V\right),
$$

où $V$ est la matrice de variance-covariance définie par

$$
V=\left[\eta \gamma(h) \gamma(k)+\sum_{i=-\infty}^{+\infty} \gamma(i) \gamma(i+k-h)+\gamma(i+k) \gamma(i-h)\right]_{h, k=0, \ldots, p}
$$

## Les bruits blancs

Un processus $\left(\varepsilon_{t}\right)$ est un bruit blanc fort si les varaibles $\varepsilon_{t}$ sont indépendantes, identiqueent distribées, et centrées (i.e $\mathbb{E}\left(\varepsilon_{t}\right)=0$ ).

Un processus $\left(\varepsilon_{t}\right)$ est un bruit blanc faible si les varaibles $\varepsilon_{t}$ sont orthogonales (ou non-corrélées), de même variance et centrées.

## Les tests de bruits blancs (faibles)

$\left(\varepsilon_{t}\right)$ est un bruit blanc (faible) s'il est centré, et si $\rho(h)=0$ pour tout $h \neq 0$.
On peut utiliser la statistique de Box \& Pierce $(Q)$ ou la statistique de Ljung \& Box $\left(Q^{\prime}\right)$ définies - à partir des $r_{i}=\widehat{\rho}(i)$ - par

$$
Q(k)=n \sum_{i=1}^{k} r_{i}^{2} \text { et } Q^{\prime}(k)=n(n+2) \sum_{i=1}^{k} \frac{r_{i}^{2}}{n-i},
$$

qui sont à comparer aux quantiles du chi-deux à $k$ degrés de liberté. Pour rappel,

$$
H_{0}: \rho(1)=\ldots=\rho(k)=0
$$

## Les tests de bruits blancs (faibles)

Soit $\left(\varepsilon_{t}\right)$ un bruit blanc simulé
> E=rnorm (120)
> Box.test(E,lag=6,type="Box-Pierce")

```
Box-Pierce test
```

data: E
$X$-squared $=6.3143, \mathrm{df}=6, \mathrm{p}$-value $=0.3889$
> Box.test(E,lag=6,type="Ljung-Box")

```
Box-Ljung test
```

data: E
$X$-squared $=6.5849, \mathrm{df}=6, \mathrm{p}$-value $=0.3609$

## Les tests de bruits blancs (faibles)

> BP=function(h) Box.test(E,lag=h,type="Box-Pierce")\$statistic
> LB=function(h) Box.test(E,lag=h,type="Ljung-Box")\$statistic
> plot(1:24,Vectorize(LB) (1:24),type="b", col="blue",ylim=c (0,35))
> points(1:24,Vectorize(BP) (1:24),type="b",col="red",pch=2)
> lines(1:24,qchisq(.95,1:24),lty=2)


## Les tests de bruits blancs (faibles)

> BP=function(h) Box.test(E,lag=h,type="Box-Pierce")\$p.value
> LB=function(h) Box.test(E,lag=h,type="Ljung-Box")\$p.value
> plot (1:24,Vectorize(LB) (1:24),ylim=c (0,1), type="b", col="blue")
> points (1:24,Vectorize(BP) (1:24),ylim=c(0,1),type="b", col="red",pch=2)
> abline (h=.05,lty=2)


## Les tests de bruits blancs (faibles)

Soit $\left(X_{t}\right)$ la moyenne mobile du bruit blanc, $X_{t}=\alpha \varepsilon_{t}+[1-\alpha] \varepsilon_{t-1}$
$>\mathrm{X}=.8 * \mathrm{E}[2: 120]+.2 * \mathrm{E}[1: 119]$
> Box.test (X,lag=6,type="Box-Pierce")

Box-Pierce test
data: X
X-squared $=11.3128, \mathrm{df}=6, \mathrm{p}$-value $=0.07918$
> Box.test (X,lag=6,type="Ljung-Box")

Box-Ljung test
data: X
$X$-squared $=11.6793, \mathrm{df}=6, \mathrm{p}$-value $=0.06952$

## Les tests de bruits blancs (faibles)

> BP=function(h) Box.test(X,lag=h,type="Box-Pierce")\$statistic
> LB=function(h) Box.test(X,lag=h,type="Ljung-Box")\$statistic
> plot(1:24,Vectorize(LB) (1:24),type="b", col="blue",ylim=c (0,35))
> points(1:24,Vectorize(BP) (1:24),type="b",col="red",pch=2)
> lines(1:24,qchisq(.95,1:24),lty=2)


## Les tests de bruits blancs (faibles)

> BP=function(h) Box.test(X,lag=h,type="Box-Pierce")\$p.value
> LB=function(h) Box.test(X,lag=h,type="Ljung-Box")\$p.value
> plot(1:24,Vectorize(LB) (1:24),ylim=c ( 0,1 ), type="b", col="blue")
> points(1:24,Vectorize(BP)(1:24),ylim=c (0,1),type="b", col="red",pch=2)
> abline(h=.05,lty=2)


## Les processus Gaussiens

Le vecteur $\boldsymbol{X}=\left(X_{1}, \ldots, X_{d}\right)$ est un vecteur gaussien si toute combinaison linéaire des $X_{i}$ est une variable gaussienne, i.e. pour tout $\boldsymbol{a} \in \mathbb{R}^{d}, \boldsymbol{a}^{\prime} \boldsymbol{X}$ est une variable gaussienne. Sa densité s'écrit alors

$$
f(\boldsymbol{x})=\frac{1}{(2 \pi)^{d / 2} \sqrt{\operatorname{det} \Sigma}} \exp \left(-\frac{1}{2}(\boldsymbol{x}-\mu)^{\prime} \Sigma^{-1}(\boldsymbol{x}-\mu)\right)
$$

où $\mu \in \mathbb{R}^{d}$ et $\Sigma$ est une matrice hermitienne positive $d \times d$.
Le processus $\left(X_{t}\right)$ est un processus gaussien si tout système fini extrait est un vecteur aléatoire gaussien, i.e. pour tout $n$, pour tout $t_{1}, \ldots, t_{n},\left(X_{t_{1}}, \ldots, X_{t_{n}}\right)$ est un vecteur gaussien.

## Température journalière $\left(X_{t-1}, X_{t}\right)$




## Température journalière $\left(X_{t-2}, X_{t}\right)$




Température journalière $\left(X_{t-3}, X_{t}\right)$



## La propriété de Markov

$\left(X_{t}\right)$ est un Markovien à l'ordre $k$ si

$$
\mathcal{L}\left(X_{t} \mid X_{t-1}, X_{t-2}, X_{t-3}, \ldots\right)=\mathcal{L}\left(X_{t} \mid X_{t-1}, \ldots, X_{t-k}\right)
$$

qui peut se réécrire, à l'ordre 1 ,

$$
\left(X_{t} \mid X_{t-1}, X_{t-2}, X_{t-3}, \ldots\right) \stackrel{\mathcal{L}}{=}\left(X_{t} \mid X_{t-1}\right)
$$

Il est possible de montrer que cette relation est équivalente à

$$
X_{t}=g\left(X_{t-1}, \varepsilon_{t}\right), \text { où }\left(\varepsilon_{t}\right) \text { est un bruit blanc. }
$$

Par exemple, les processus $A R(1): X_{t}=\alpha+\beta X_{t-1}+\varepsilon_{t}$, où $\left(\varepsilon_{t}\right)$ est un bruit blanc indépendant du passé du processus, est markovien.

## La propriété de martingale

Soit $\left\{\mathcal{F}_{t}, t \in \mathbb{N}\right\}$ la filtration naturelle associée au processus $\left(X_{t}\right)$. $\left(X_{t}\right)$ est une martingale si et seulement si, pour tout $t$,

$$
\mathbb{E}\left(X_{t+1} \mid \mathcal{F}_{t}\right)=\mathbb{E}\left(X_{t+1} \mid \underline{X}_{t}\right)=X_{t}
$$

presque sûrement.

## L'opérateur retard $L$

On définit l'opérateur retard $L$ par $L: X_{t} \longmapsto L\left(X_{t}\right)=L X_{t}=X_{t-1}$ et l'opérateur avance $F$ par $F: X_{t} \longmapsto F\left(X_{t}\right)=F X_{t}=X_{t+1}$. On notera alors

$$
L^{p}=\underbrace{L \circ L \circ \ldots \circ L}_{p \text { fois }} \text { où } p \in \mathbb{N} \text {, }
$$

avec la convention $L^{0}=\mathbb{I}$ et $L^{-1}=F$. Et de façon analogue, $L^{-p}=F^{p}$ pour $p \in \mathbb{N}$.

Aussi, $L^{p}\left(X_{t}\right)=X_{t-p}$

## L'opérateur retard $L$

On peut définir un polynôme d'opérateurs retards de la manière suivante : soit $P$ un polynôme réel (de degré $k$ ),

$$
P(z)=\alpha_{0}+\alpha_{1} z+\cdots+\alpha_{k} z^{k} .
$$

L'opérateur $P(L)$ associe à une série $\left(X_{t}\right)$ la série $\left(Y_{t}\right)$ définie

$$
Y_{t}=P(L)\left(X_{t}\right)=\alpha_{0} X_{t}+\alpha_{1} X_{t-1}+\cdots+\alpha_{k} X_{t-k}
$$

Par exemple, on peut considérer une moyenne glissante

$$
Y_{t}=\frac{1}{12}\left[X_{t}+X_{t-1}+\cdot+X_{t-12}\right]
$$

## Inversibilité de $P(L)$

Considérons $P(z)=1-\lambda z$ (de racine $\lambda^{-1}$ ).
Proposition 3. $S i\|\lambda\|<1$ (ou $\left\|\lambda^{-1}\right\|>1$ ) alors $1-\lambda L$ est inversible, et de plus,

$$
(1-\lambda L)^{-1}=\sum_{k=0}^{\infty} \lambda^{k} L^{k}
$$

Si $\|\lambda\|=1$, alors $1-\lambda L$ n'est pas inversible.
Remark Tout polynôme $P(L)=1+a_{1} L+\ldots+a_{n} L^{n}$ peut s'écrire

$$
P(z)=a_{n}\left(z-z_{1}\right)\left(z-z_{2}\right) \ldots\left(z-z_{n}\right),
$$

correspondant à la décomposition en éléments simples ( $z_{i}$ étant les racines du polynôme).

## Inversibilité de $P(L)$

On peut écrire

$$
P(L)=\prod_{i=1}^{n}\left(1-\lambda_{i} L\right) \text { où } \lambda_{i}=\frac{1}{z_{i}}
$$

Si pour tout $i,\left|\lambda_{i}\right| \neq 1$, alors $P(L)$ est inversible, et

$$
P(L)=\prod\left(1-\lambda_{i} L\right)=\underbrace{\prod_{\left|\lambda_{i}\right|<1}\left(1-\lambda_{i} L\right) \prod_{P_{2}(L)}\left(1-\frac{1}{\lambda_{i}} F\right) \prod_{P_{3}(L)}^{\left|\lambda_{i}\right|>1}\left(-\lambda_{i} L\right)}_{P_{1}(L)},
$$

## Les autocorrélations partielles

On suppose ici que que le processus $\left(X_{t}\right)$ est stationnaire, et centré, $\mathbb{E}\left(X_{t}\right)=0$ pour tout $t$.

Pour une série stationnaire $\left(X_{t}\right)$, on définit la fonction d'autocorrélation partielle $h \mapsto \psi(h)$ par

$$
\psi(h)=\operatorname{corr}\left(\widehat{X}_{t}, \widehat{X}_{t-h}\right)
$$

où

$$
\left\{\begin{array}{l}
\widehat{X}_{t-h}=X_{t-h}-E L\left(X_{t-h} \mid X_{t-1}, \ldots, X_{t-h+1}\right) \\
\widehat{X}_{t}=X_{t}-E L\left(X_{t} \mid X_{t-1}, \ldots, X_{t-h+1}\right)
\end{array}\right.
$$

Il est équivalent de connaître $\rho$ et $\psi$.

Les autocorrélations partielles

$$
\mathcal{R}(h)=\left[\begin{array}{ccccccc}
1 & \rho(1) & \rho(2) & & \rho(h-3) & \rho(h-2) & \rho(h-1) \\
\rho(1) & 1 & \rho(1) & & \rho(h-4) & \rho(h-3) & \rho(h-2) \\
\rho(2) & \rho(1) & 1 & \ddots & \rho(h-5) & \rho(h-4) & \rho(h-3) \\
& & \ddots & \ddots & \ddots & & \\
\rho(h-3) & \rho(h-4) & \rho(h-5) & \ddots & 1 & \rho(1) & \rho(2) \\
\rho(h-2) & \rho(h-3) & \rho(h-4) & & \rho(1) & 1 & \rho(1) \\
\rho(h-1) & \rho(h-2) & \rho(h-3) & & \rho(2) & \rho(1) & 1
\end{array}\right]
$$

et on introduit de façon analogue la matrice $\mathcal{R}^{*}(h)$ obtenue...

## Les autocorrélations partielles

...en remplaçant la dernière colonne de $\mathcal{R}(h)$ par le vecteur $[\rho(1), \ldots, \rho(h)]^{\prime}$,

$$
\mathcal{R}^{*}(h)=\left[\begin{array}{ccccccc}
1 & \rho(1) & \rho(2) & & \rho(h-3) & \rho(h-2) & \rho(1) \\
\rho(1) & 1 & \rho(1) & & \rho(h-4) & \rho(h-3) & \rho(2) \\
\rho(2) & \rho(1) & 1 & \ddots & \rho(h-5) & \rho(h-4) & \rho(3) \\
& & \ddots & \ddots & \ddots & & \\
\rho(h-3) & \rho(h-4) & \rho(h-5) & \ddots & 1 & \rho(1) & \rho(h-2) \\
\rho(h-2) & \rho(h-3) & \rho(h-4) & & \rho(1) & 1 & \rho(h-1) \\
\rho(h-1) & \rho(h-2) & \rho(h-3) & & \rho(2) & \rho(1) & \rho(h)
\end{array}\right]
$$

Il est alors possible de montrer que

$$
\psi(h)=\frac{\left|\mathcal{R}^{*}(h)\right|}{|\mathcal{R}(h)|} \text { pour tout } h
$$

## Les autocorrélations partielles

On peut obtenir cette fonction via
> X=rnorm(100)
> as.vector (pacf(X))

Partial autocorrelations of series 'X', by lag

| 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
| ---: | ---: | ---: | ---: | ---: | ---: | ---: | ---: | ---: |
| -0.004 | -0.027 | -0.108 | -0.116 | -0.105 | -0.153 | 0.023 | -0.002 | -0.025 |

Remark pour une série stationnaire $\left(X_{t}\right)$

$$
\psi_{X}(1)=\rho_{X}(1) \text { et } \psi_{X}(2)=\frac{\left[\rho_{X}(2)-\rho_{X}(1)^{2}\right]}{\left[1-\rho_{X}(1)^{2}\right]}
$$

