

# Série Chronologique : approches déterministes

**J.N. Bacro**

*M2 ESDB, Université Montpellier*

2021/2022

# Introduction - Motivations

---

## Définition :

Une série chronologique (ou temporelle) est une suite finie de données ordonnées, indexées par le temps :

$$(y_t)_{t=1,\dots,T} \text{ ou encore } (y_1, \dots, y_T)$$

$\rightsquigarrow y_t$  : valeur observée à l'instant  $t$ .

Le plus souvent, le pas de temps est régulier : seconde, minute, heure, jour, mois, semestre, année ...


*Remarque :*

a priori, les observations  $y_t$  **ne sont pas indépendantes !**

Domaines d'applications ? *tous !*


# Exemples

Los Angeles : cumul annuel des pluies




# Exemples

Abondance annuelle lièvres canadiens




# Exemples

Traffic aérien



# Exemples

---



**Figure 1.4** Returns of the NYSE. The data are daily value weighted market returns from February 2, 1984 to December 31, 1991 (2000 trading days). The crash of October 19, 1987 occurs at  $t = 938$ .

# Séries temporelles : introduction - motivations

---

## Objectifs ?

Essentiellement deux :

1. **expliquer/comprendre le mécanisme** déterministe et/ou stochastique qui conduit à la série observée ;
  - **approche descriptive** : *décrire* la série au sens de la détermination des différentes composantes qui la constituent ; *éliminer* des composantes pour mieux appréhender le comportement de la série (*série corrigée des variations saisonnières*) ;
  - **modéliser** le comportement de la série au travers d'une approche purement déterministe ou couplée à une approche stochastique.  
*↪ mettre en évidence une modélisation aussi pertinente que possible du phénomène temporel observé ;*
2. **prédire des réalisations futures** sur la base de celles obtenues dans le passé.

# Séries temporelles : introduction - motivations

---

Quelques questions typiques :

- quels effets des *saisons* sur
  - le volume des ventes
  - le nombre de décès observé pour une maladie donnée
  - ...


↪ *série corrigée des variations saisonnières*

- que dire de la tendance générale de la série ? de la tendance après une date  $t_0$  ?
- quelle prédiction pour une réalisation dans une unité de temps ? dix unités de temps ?
- ...

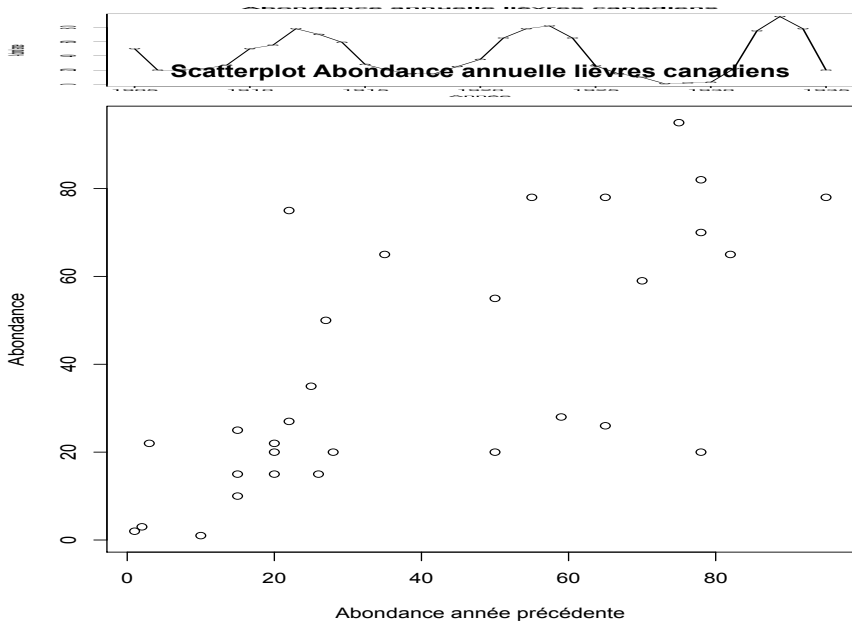
↪ **caractériser une dépendance temporelle** dans les observations ...



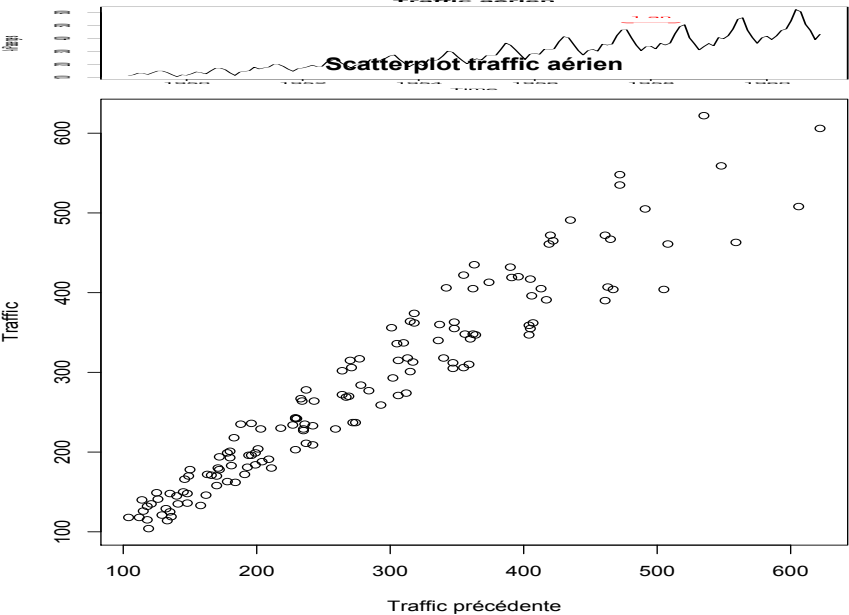
# Exemple : Los-Angeles Cumul annuel des pluies



# Exemple : Abondance des lièvres



# Exemples



# Décomposition d'une série temporelle

---

Une série temporelle peut être décomposée selon les différentes composantes :

1. **la tendance** ( $f_t, 1 \leq t \leq T$ ) :

↪ représente l'évolution à long terme de la grandeur étudiée, et traduit l'aspect général de la série.

2. **le cycle** (ou cycle conjoncturel) ( $c_t, 1 \leq t \leq T$ ) :

↪ regroupe les variations autour de la tendance avec des alternances de phases d'expansion et de récession. Ces phases durent généralement plusieurs années, mais n'ont pas de durée fixe.

### 3. **les variations saisonnières** ( $s_t, 1 \leq t \leq T$ )

↪ sont liées au rythme imposé par les saisons météorologiques (production agricole, consommation de gaz, ...), les activités économiques et sociales (fêtes, vacances, soldes, etc) ;

**Rmq** : nature périodique, c'est-à-dire qu'il existe un entier  $p$ , appelé **période**, tel que

$$s_i = s_{i+p}, \text{ pour tout } i \geq 1.$$

Cette composante est donc entièrement déterminée par ses  $p$  premières valeurs  $s_1, s_2, \dots, s_p$ .

### 4. **les fluctuations irrégulières** ( $e_t, 1 \leq t \leq T$ )

↪ ont souvent un effet de faible intensité et de courte durée et sont de nature aléatoire, ce qui signifie que dans un cadre purement descriptif, elles ne sont pas expliquées.

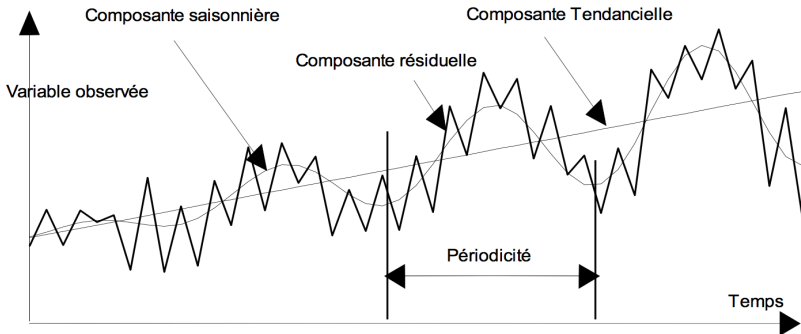
### 5. **les variations accidentelles**

↪ ce sont des valeurs isolées anormalement élevées ou faibles, le plus souvent explicables (Mai 68, réunification de l'Allemagne, tempête, ...).

# Décomposition d'une série : en pratique ?

Le plus souvent uniquement 3 composantes :

- la tendance (*trend*) ;
- la saisonnalité (intégrant une période, éventuellement un cycle) ;
- les fluctuations irrégulières (*résidus*) intégrant des évènements exceptionnels éventuels.



# Modèles pour la décomposition d'une série temporelle

---

La forme générale d'un modèle est la suivante :

$$y_t = \phi(t, y_{t-1}, y_{t-2}, \dots, y_1) + \varepsilon_t$$

où  $\phi(\cdot)$  désigne une **fonction déterministe** et  $\varepsilon$  un **résidu aléatoire**.

Approche classique :

la **partie déterministe est constituée d'une tendance  $f_t$  et de composantes saisonnières périodiques  $s_t$** .

# Modèles pour la décomposition d'une série temporelle

---

Deux approches possibles :

- **modèle additif** :

somme parties déterministe et aléatoire

$$y_t = f_t + s_t + \varepsilon_t$$

*les composantes tendantielle et résiduelle sont indépendantes des variations saisonnières ;*

- **modèle multiplicatif** :

l'amplitude de la série croît en fonction du temps

*↪ interaction entre la composante tendantielle et les composantes saisonnière et/ou aléatoire*

$$y_t = f_t(1 + s_t) + \varepsilon_t \quad \text{ou} \quad y_t = f_t(1 + s_t)(1 + \varepsilon_t)$$

Dans tous les cas on suppose :  $\sum_j s_j = 0$  et  $\sum_t \varepsilon_t = 0$ .



# Décomposition déterministe d'une série temporelle : estimer la composante tendantielle $f_t$

---

Principales approches considérées (détaillées dans la suite !) :

- régression linéaire
- moyenne mobile
- lissage exponentiel
- ...

*Remarque :*

si l'on veut faire des prédictions, il faut que la méthode utilisée permette de prédire les valeurs de tendance associées ...

# Décomposition déterministe d'une série temporelle : estimer la composante saisonnière $S_t$

---

*Idée générale* : connaissant la tendance  $f_t$ , on néglige la composante irrégulière ...

## Modèle additif :

- pour toute saison  $A_j$ ,  $j = 1, \dots, p$  on calcule les différences entre l'observation  $y_t$  et la tendance  $f_t$  ;
- pour la saison donnée  $A_j$ , on calcule la moyenne des différences associées ( $n_j$  mesures pendant  $A_j$ ) :

$$S'_j = \frac{1}{n_j} \sum_{t \in A_j} (y_t - f_t),$$

- on calcule la moyenne des coefficients saisonniers :

$$\bar{S}' = \frac{1}{p} \sum_p S'_j ;$$

- coefficients saisonniers :

$$s_j = S'_j - \bar{S}'$$

pour respecter l'hypothèse de modélisation.

# Décomposition déterministe d'une série temporelle : estimer la composante saisonnière $s_t$

---

**Modèle multiplicatif :**  $y_t = f_t(1 + s_t) + \varepsilon_t$

- on pose  $S_j = 1 + s_j$  pour toute saison  $A_j$  ;
- pour les  $t$  de la saison  $A_j$ , on calcule  $r_t = \frac{y_t}{f_t}$  ;
- pour toute saison  $A_j$  fixée, on calcule  $S'_j = \frac{1}{n_j} \sum_{t \in A_j} r_t$  ;
- on calcule  $\bar{S}' = \frac{1}{p} \sum_j S'_j$  ;
- coefficients saisonniers :

$$S_j = \frac{S'_j}{\bar{S}'}$$

On a alors :  $\sum_{j=1}^p S_j = p$ , ce qui correspond bien à  
 $\sum_{j=1}^p S_j = \sum_{j=1}^p (1 + s_j) = p + 0 = p$ .

# Décomposition déterministe d'une série temporelle : estimer la composante irrégulière $\varepsilon_t$

---

Déduit de la série d'observation en tenant compte des composantes tendancielle et saisonnière :

**Modèle additif :**

pour tout  $t \in A_j$ ,  $j = 1, \dots, p$ ,

$$\varepsilon_t = y_t - (f_t + s_j)$$

**Modèle multiplicatif :**

pour tout  $t \in A_j$ ,  $j = 1, \dots, p$ ,

$$\varepsilon_t = y_t - f_t(1 + s_j)$$

*La série aléatoire  $(\varepsilon_t)_{t=1, \dots, T}$  pourra ensuite être modélisée à l'aide de modèles stochastiques ...*

# Série corrigée des variations saisonnières : une approche empirique

---

Une méthode simple pour obtenir une version approchée de la série corrigée des variations saisonnières est obtenue en supprimant la composante saisonnière de la série.

## **Modèle additif :**

pour tout  $t \in A_j$ ,

$$y_t^{CVS} = y_t - s_j = f_t + \varepsilon_t$$

## **Modèle multiplicatif :**

pour tout  $t \in A_j$ ,

$$y_t^{CVS} = \frac{y_t}{S_j} = f_t(1 + \varepsilon_t)$$

# Série lissée des prédictions

---

## Définition

On appelle série lissée des prédictions la série des prédictions  $\hat{y}_t$  obtenue en négligeant la composante résiduelle de la série de départ.

Pour un modèle additif :  $\hat{y}_t = f_t + s_t$ .

Pour un modèle multiplicatif :  $\hat{y}_t = f_t(1 + s_t)$ .

## *Remarque :*

La série lissée est utilisée pour prédire des réalisations de la série : si l'on reste dans la gamme de temps correspondant aux observations, on obtient une prédiction hors fluctuations ; si l'on peut extrapoler la tendance, on peut prédire pour des temps futurs.

# Lissage de la série

---

## Objectifs :

1. en descriptif : "lisser" les aléas et fluctuations afin d'**extraire la tendance** de la série ;
2. en prédictif : ajuster une fonction du temps à des données et **extrapoler**  $\rightsquigarrow$  *Prévision !*

question : donner plus de poids aux observations les plus récentes ?

## Méthodes ?

Peuvent se distinguer selon l'objectif cherché (décrire /modéliser)

- Moyenne mobile ;
- Régression linéaire ou non linéaire ;
- Lissage exponentiel simple ;
- Lissage exponentiel selon la méthode de Holt-Winters ;
- ...

# Lissage : l'approche par moyenne mobile

Permet de faire ressortir la composante tendancielle de la série :

Moyenne mobile d'ordre  $k$  :

- $k$  impair,  $k = 2m + 1$  :

$$MM(k)_{t_i} \equiv z_{t_i} = \frac{\overbrace{y_{t_i-m} + \dots + y_{t_i-1}}^{m \text{ termes}} + y_{t_i} + \overbrace{y_{t_i+1} \dots + y_{t_i+m}}^{m \text{ termes}}}{2m + 1}$$

avec  $m = \frac{k-1}{2}$ .

- $k$  pair,  $k = 2m$  :

$$MM(k)_t \equiv z_{\frac{t_i+t_{i+1}}{2}} = \frac{\overbrace{y_{t_i-m+1} + \dots + y_{t_i-1}}^{m-1 \text{ termes}} + y_{t_i} + \overbrace{y_{t_{i+1}} + \dots + y_{t_{i+1}+m-1}}^{m \text{ termes}}}{2m}$$

avec  $m = \frac{k}{2}$ .



## Lissage : l'approche par moyenne mobile

Le tableau suivant présente les moyennes mobiles d'ordre 2, 3 et 4 d'une même série.

date $t_i$	date $\frac{t_i+t_{i+1}}{2}$	observ. $y_i$	$MM(2)$	$MM(3)$	$MM(4)$
01-01		5			
	15-01		$\frac{5+4}{2} = 4.5$		
01-02		4		$\frac{5+4+6}{3} = 5$	
	15-02		$\frac{4+6}{2} = 5$		$\frac{5+4+6+8}{4} = 5.75$
01-03		6		$\frac{4+6+8}{3} = 6$	
	15-03		$\frac{6+8}{2} = 7$		$\frac{4+6+8+7}{4} = 6.25$
01-04		8		$\frac{6+8+7}{3} = 7$	
	15-04		$\frac{8+7}{2} = 7.5$		$\frac{6+8+7+9}{4} = 7.50$
01-05		7		$\frac{8+7+9}{3} = 8$	
	15-05		$\frac{7+9}{2} = 8$		$\frac{8+7+9+8}{4} = 8.00$
01-06		9		$\frac{7+9+8}{3} = 8$	
	15-06		$\frac{9+8}{2} = 8.5$		
01-07		8			

## Lissage : l'approche par moyenne mobile

---

Pour se ramener aux temps d'observation  $t_i$  dans le cas d'une moyenne mobile d'ordre pair  $k = 2m$ , on introduit la notion de *moyenne mobile centrée*

$$MMC(k)_{t_j} = \frac{MM(k)_{\frac{t_{j-1}+t_j}{2}} + MM(k)_{\frac{t_j+t_{j+1}}{2}}}{2}$$

c'est-à-dire

$$MMC(k)_{t_j} = \frac{\frac{1}{2}y_{t_j-m} + y_{t_j-m+1} + \dots + y_{t_j} + \dots + y_{t_j+m-1} + \frac{1}{2}y_{t_j+m}}{2m}$$

↪ MMC(4) du tableau précédent ?

## Décomposition : un exemple avec R

Retour sur la série des passagers avion :


1) Représentation sans utiliser la spécificité *série chronologique* :

```
#On etudie les variations mensuelles du nombre
#de passagers d'une compagnie aerienne.
# On s'aperçoit qu'il y a des pics annuels
#####

data(AirPassengers)
plot(AirPassengers, main = "Traffic a\'erien")
arrows(x0 = 1957.5, y0 = 520, x1 = 1958.5, y1 = 520,
col = 2,code = 3, length = 0.1)
  text(x = 1958, y = 560, "1 an", col = 2)
```

# Décomposition d'une série : un exemple avec R

Traffic aérien



## Décomposition : un exemple avec R

---

Spécificité *série chronologique* ? ... un exemple :

```
# mise en serie chro
#####
data2=ts(c(12,31,22,24,30),start=c(2006,2), frequency=4)

donne

> data2=ts(c(12,31,22,24,30),start=c(2006,2), frequency=4)
> data2
```

	Qtr1	Qtr2	Qtr3	Qtr4
2006		12	31	22
2007	24	30		

## Décomposition : un exemple avec R

Représentation de la série des passagers en utilisant la spécificité *série chronologique* :


```
# mise en serie chro  
#####
```

```
ts.AirPass=ts(AirPassengers,start=1,frequency=12)  
plot(ts.AirPass, main="Traffic Aerien")
```

# Décomposition : un exemple avec R

---

Traffic Aerien



## Moyenne mobile : quelle(s) fonction(s) R

---

Fonction : *filter()* (pour filtrage linéaire)

```
filter(x, filter, method = c("convolution", "recursive"))
#applique un filtre linéaire à une série
#temporelle, avec convolution : moyenne mobile,
#recursive : autoregression
#pour une moyenne mobile sur trois périodes:
#filter(x, c(1/3, 1/3, 1/3))
filter(AirPassengers,c(1/3, 1/3, 1/3))
filter(AirPassengers,c(1, 1/2, 1/2,1))
```

Remarque : fonction *SMA()* pour moyenne uniquement sur  $n$  valeurs du passé.

```
library(TTR)
SMA(AirPassengers)
SMA(AirPassengers,n=12)
```



# Moyenne mobile : quelques propriétés

---

1. filtrage : neutralise certaines composantes et laisse invariante d'autres !

- une moyenne mobile de longueur  $2m + 1$  est d'expression générale

$$\alpha_{t_i-m}y_{t_i-m} + \dots + \alpha_{t_i-1}y_{t_i-1} + \alpha_{t_i}y_{t_i} + \alpha_{t_i+1}y_{t_i+1} + \dots + \alpha_{t_i+m}y_{t_i+m}$$

Elle est dite *symétrique* si ses coefficients vérifient

$$\alpha_{t_i+j} = \alpha_{t_i-j}, \quad \forall 0 \leq j \leq m.$$

Si  $\alpha_i = \frac{1}{2m}$ ,  $\forall i$ , la moyenne mobile est *arithmétique*.

Notation générale :  $M[2m + 1; \alpha_m, \alpha_{m-1}, \dots, \alpha_0]$

- $M[2m + 1, 1, 1, \dots, 1]$  annule les séries périodiques de période  $2m + 1$  ;

Rmq : le choix de coefficients tous égaux à 1 ou  $\frac{1}{2m}$  ou autres n'influent alors que sur la tendance.

## Moyenne mobile : quelques propriétés

---

pour annuler une périodicité paire  $2m$ , on utilise

$$M[2m + 1; \frac{1}{4m}, \frac{1}{2m}, \dots, \frac{1}{2m}]$$

↪ série annuelle :  $M[13; \frac{1}{2}, 1, 1, 1, 1, 1, 1]$  pour filtrer la saisonnalité mensuelle de période 12.

$$\frac{1}{24}(f_1 + s_1) + \frac{1}{12}(f_2 + s_2) + \dots + \frac{1}{12}(f_{12} + s_{12}) + \frac{1}{24}(f_{13} + s_1)$$

2. Moyenne mobile symétrique laisse invariante toute composante tendancielle de type  $at + b$ .
3. lisse la composante résiduelle.
4. *Attention* : Effet de *Slutsky-Yule*  
effet de corrélation induit par la transformation moyenne mobile qui pourrait faire croire à une périodicité qui n'existe pas dans la série de départ.

# Lissage : moyenne mobile

---

Effet du coefficient de lissage  $k$  ?

$k$  petit : lissage faible ;  $k$  grand : lissage fort

Choix de  $k$  ?

en fonction de la saisonnalité ou en minimisant les erreurs de prédiction.

# Décomposition d'une série selon utilisant un filtrage linéaire : un exemple avec R


---

On peut récupérer directement les 3 composantes de la série via la fonction *decompose()* ; les séries correspondantes sont obtenues via les \$ trend, seasonal ou random.

```
AirPassager.dec=decompose(ts.AirPass)  
plot(AirPassager.dec)
```

# Décomposition d'une série selon utilisant un filtrage linéaire : un exemple avec R

Decomposition of additive time series



## Décomposition selon les 3 composantes : un exemple avec R

---

```
decompose(x, type = c("additive", "multiplicative"),  
  filter = NULL)
```

### Arguments

`x` A time series.

`type` The type of seasonal component.

Can be abbreviated.

### `filter`

A vector of filter coefficients in reverse time order (as for AR or MA coefficients), used for filtering out the seasonal component.

If NULL, a moving average with symmetric window is performed.

# Lissage : l'approche régression

---

On fait l'hypothèse que la tendance peut être représentée par une courbe dont l'allure générale selon le temps sera définie a priori . . .

Fonctions classiques :

- régression linéaire simple ou polynomiale ;
- dépendance exponentielle du type  $y_t = \alpha e^{\beta t}$  ou  $y_t = \alpha \beta^t$  ;
- $y_t = \frac{a}{1+be^{-ct}}$  (logistique) ;
- $y = ab^{k^t}$  (Gompertz).

Les paramètres des modèles sont estimés par moindres carrés (après éventuelle linéarisation).

# Lissage : le lissage exponentiel simple

---

## Définition

*Idee : donner plus de poids aux réalisations récentes qu'anciennes.*

$$\widehat{Y}_{t+1} = \lambda \sum_{j=0}^t (1 - \lambda)^j y_{t-j}$$

$\lambda$  : constante de lissage ;

*plus  $\lambda$  proche de 1, plus décroissance rapide.*

*Equation de récurrence :*

$$\widehat{y}_{t+1} = \lambda y_t + (1 - \lambda) \widehat{y}_t = \widehat{y}_t + \lambda(y_t - \widehat{y}_t) \quad 0 < \lambda \leq 1$$

avec  $\widehat{y}_1 = y_1$



# Lissage exponentiel simple

---

## Remarques :

- $\lambda$  proche de 1 : on privilégie la dernière observation ;
- $\lambda$  proche de 0 : les observations lointaines ont plus d'influence ;
- choix du  $\lambda$  : empirique, ou en minimisant un critère d'erreur.

$$RMSE = \sqrt{\sum_{t=1}^N (\hat{y}_t - y_t)^2}$$

- La prédiction est constante après la dernière observation

## Note :

il existe un lissage exponentiel "double" permettant d'intégrer une composante tendancielle linéaire.

# Lissage exponentiel : méthode de Holt-Winters

---

Généralisation du lissage exponentiel simple basée sur 3 équations récursives permettant de prendre en compte (éventuellement)

- une tendance linéaire
- une saisonnalité additive (coeffs  $a_t$  et  $b_t$  changent selon saison ; il existe une approche cadre multiplicatif)

**Modèle (forme général) :**

$$y_{t+k} = a_t + b_t k + s_{t+k} + E_{t+k}$$

**Estimations :** (choix de  $\lambda, \beta, \gamma$  dans  $[0, 1]$ )

- niveau:  $\widehat{a}_t = \lambda y_t + (1 - \lambda) \widehat{y}_t$
- pente:  $\widehat{b}_t = \beta (\widehat{a}_t - \widehat{a}_{t-1}) + (1 - \beta) \widehat{b}_{t-1}$
- saisonnalité:  $\widehat{s}_{t+1} = \gamma (y_t - \widehat{a}_t) + (1 - \gamma) \widehat{s}_{t-p}$

**Prévision :**

$$\widehat{y}_{t+k} = \widehat{a}_t + \widehat{b}_t k + \widehat{s}_{t+k}$$

## Méthode de Holt-Winters : exemple

---

```
AirPassengersforecasts<-HoltWinters(AirPassengers,  
beta=FALSE, gamma=FALSE)# pour lissage expo simple  
> AirPassengersforecasts  
Holt-Winters exponential smoothing without  
trend and without seasonal component.
```

```
Call: HoltWinters(x = AirPassengers,  
+ beta = FALSE, gamma = FALSE)
```

```
Smoothing parameters:
```

```
alpha: 0.9999339
```

```
beta : FALSE
```

```
gamma: FALSE
```


```
Coefficients:
```

```
 [,1]
```

```
a 431.9972
```

# Prévision

Holt-Winters filtering



## Un exemple

Total annual rainfall, inches, London, England, 1813-1912


23.56	26.07	21.86	31.24	23.65	23.88
26.41	22.67	31.69	23.86	24.11	32.43
23.26	22.57	23.00	27.88	25.32	25.08
27.76	19.82	24.78	20.12	24.34	27.42
19.44	21.63	27.49	19.43	31.13	23.09
25.85	22.65	22.75	26.36	17.70	29.81
22.93	19.22	20.63	35.34	25.89	18.65
23.06	22.21	22.18	18.77	28.21	32.24
22.27	27.57	21.59	16.93	29.48	31.60
26.25	23.40	25.42	21.32	25.02	33.86
22.67	18.82	28.44	26.16	28.17	34.08
33.82	30.28	27.92	27.14	24.40	20.35
26.64	27.01	19.21	27.74	23.85	21.23
28.15	22.61	19.80	27.94	21.47	23.52
22.86	17.69	22.54	23.28	22.17	20.84
38.10	20.65	22.97	24.26	23.01	23.67
26.75	25.36	24.79	27.88		

## Un exemple

```
> rain<-scan("Data-Pluie-Englang.txt",skip=1)
> raindata=ts(rain,start=c(1813))
> raindata
> plot.ts(raindata)
```

# Prévision

## Pluie en Angleterre



```
> rainforecasts=HoltWinters(raindata, beta=FALSE,  
gamma=FALSE)  
> rainforecasts  
Holt-Winters exponential smoothing without trend and  
without seasonal component.
```

```
Call: HoltWinters(x = raindata, beta = FALSE, gamma = FALSE)
```

```
Smoothing parameters:
```

```
alpha: 0.03909939
```

```
beta : FALSE
```

```
gamma: FALSE
```

```
Coefficients:
```


```
    [,1]
```

```
a 24.78146
```



# Prévision

Holt-Winters filtering




```
library(forecast)
# prediction a horizon 8, avec IC a 80 et 95%
pred=forecast.HoltWinters(rainforecasts,h=8)
  Point Forecast    Lo 80    Hi 80    Lo 95    Hi 95
1907         24.78146 19.16634 30.39658 16.19387 33.36904
1908         24.78146 19.16205 30.40087 16.18731 33.37560
1909         24.78146 19.15776 30.40515 16.18076 33.38216
1910         24.78146 19.15348 30.40944 16.17420 33.38871
1911         24.78146 19.14920 30.41372 16.16766 33.39526
1912         24.78146 19.14492 30.41800 16.16112 33.40180
1913         24.78146 19.14065 30.42227 16.15458 33.40834
1914         24.78146 19.13637 30.42654 16.14805 33.41487

plot.forecast(pred) # ou plot(pred)
```

# Prévision

Forecasts from HoltWinters



## Fonction HoltWinters() pour lissage série chronologique

```
# lissage exponentiel simple :
y_lisse <- HoltWinters(y,alpha=,beta=FALSE,gamma=FALSE)

# un lissage exponentiel double param\`etre alpha\`
y_lisse <- HoltWinters(y,alpha=alpha,beta=beta,gamma=FALSE)
# avec  $\alpha = 1 - (\alpha')^2$ ,  $\beta = (1 - \alpha') / (1 + \alpha')$ 

# un lissage de Holt-Winters sans composante saisonni\`ere
y_lisse <- HoltWinters(y,alpha=alpha,beta=beta,
gamma=FALSE)

# un lissage Holt-Winters additif ou multiplicatif :
y_lisse <- HoltWinters(y,alpha=alpha,beta=beta,
gamma=gamma,seasonal="add")

y_lisse <- HoltWinters(y,alpha=alpha,beta=beta,gamma=gamma,
seasonal="mul")
```

## Fonction predict pour la prediction en série chronologique

For time-series prediction :

```
predict.ar, predict.Arima, predict.arima0,  
predict.HoltWinters, predict.StructTS.
```

Par exemple :

```
rainlisse <- HoltWinters(rain,alpha=,beta=FALSE,  
gamma=FALSE)  
plot(rainlisse)  
p= predict(rainlisse,n.ahead=8)  
plot(rainlisse,p)
```

## Exemple -TP

Etudier la série 1293 1209 1205 1273 1220 1290 1243 1203 1390 1360 1353 1343 1364 1330 1377 1332, qui représente des valeurs de CA de Janvier 1988 à Avril 1989.

On utilisera les approches précédemment vues . . .

le saut de septembre 88 est-il bien pris en compte selon les méthodes utilisées ?