



Institut national de la statistique  
et des études économiques

Mesurer pour comprendre


## Estimation en temps réel de la tendance-cycle : Apport de l'utilisation des filtres asymétriques dans la détection des points de retournement

ALAIN QUARTIER-LA-TENTE  
Session 27 : Séries temporelles  
31/03/2022  
Insee et LEMNA

# Introduction (1)

$X_t$  (ex : IPI France) se décompose en plusieurs composantes inobservées :


$$X_t = \quad \quad \quad \text{(décomposition additive)}$$



# Introduction (1)

$X_t$  (ex : IPI France) se décompose en plusieurs composantes inobservées :


$$X_t = \underbrace{TC_t}_{\text{tendance-cycle}} \quad (\text{décomposition additive})$$



# Introduction (1)

$X_t$  (ex : IPI France) se décompose en plusieurs composantes inobservées :


$$X_t = \underbrace{TC_t}_{\text{tendance-cycle}} + \underbrace{S_t}_{\text{saisonnalité}} \quad (\text{décomposition additive})$$



# Introduction (1)

$X_t$  (ex : IPI France) se décompose en plusieurs composantes inobservées :

$$X_t = \underbrace{TC_t}_{\text{tendance-cycle}} + \underbrace{S_t}_{\text{saisonnalité}} + \underbrace{I_t}_{\text{irrégulier}} \quad (\text{décomposition additive})$$




# Introduction (1)

$X_t$  (ex : IPI France) se décompose en plusieurs composantes inobservées :

$$X_t = \underbrace{TC_t}_{\text{tendance-cycle}} + \underbrace{S_t}_{\text{saisonnalité}} + \underbrace{I_t}_{\text{irrégulier}} \quad (\text{décomposition additive})$$

tendance et cycle ici estimés *simultanément*



## Introduction (2)

---

Pour l'analyse conjoncturelle, on étudie généralement des séries désaisonnalisées

$$X_t - S_t = TC_t + I_t$$

## Introduction (2)

---

Pour l'analyse conjoncturelle, on étudie généralement des séries désaisonnalisées

$$X_t - S_t = TC_t + I_t$$

Si bruit important, on peut utiliser un lissage supplémentaire

$$(X_t - S_t) - I_t = TC_t$$



## Introduction (2)

---

Pour l'analyse conjoncturelle, on étudie généralement des séries désaisonnalisées

$$X_t - S_t = TC_t + I_t$$

Si bruit important, on peut utiliser un lissage supplémentaire

$$(X_t - S_t) - I_t = TC_t$$

$TC_t$  généralement estimée sur une série *sans* saisonnalité

## Introduction (2)

---

Pour l'analyse conjoncturelle, on étudie généralement des séries désaisonnalisées

$$X_t - S_t = TC_t + I_t$$

Si bruit important, on peut utiliser un lissage supplémentaire

$$(X_t - S_t) - I_t = TC_t$$

$TC_t$  généralement estimée sur une série *sans* saisonnalité

Méthode de décomposition X-13ARIMA une des plus utilisées : études de méthodes non-paramétriques pour estimer  $TC_t$

# Introduction (3)

---

*Moyennes mobiles* (ou *filtres linéaires*) omniprésents dans l'extraction de la tendance-cycle et la désaisonnalisation (e.g. : X-13ARIMA) :

$$M_{\theta}(X_t) = \sum_{k=-p}^{+f} \theta_k X_{t+k}$$

# Introduction (3)


*Moyennes mobiles* (ou *filtres linéaires*) omniprésents dans l'extraction de la tendance-cycle et la désaisonnalisation (e.g. : X-13ARIMA) :

$$M_{\theta}(X_t) = \sum_{k=-p}^{+f} \theta_k X_{t+k}$$

Appliquer  $M_{\theta}$  sur  $X_t = e^{-i\omega t}$  va avoir deux effets :

$$M_{\theta} X_t = \sum_{k=-p}^{+f} \theta_k e^{-i\omega(t+k)} = \left( \sum_{k=-p}^{+f} \theta_k e^{-i\omega k} \right) \cdot X_t = G_{\theta}(\omega) e^{-i\Phi_{\theta}(\omega)} X_t$$

1. Multiplier le niveau par  $G_{\theta}(\omega)$  (*gain*)
2. Créer un *déphasage*  $\Phi_{\theta}(\omega)/\omega$  : affecte détection des points de retournement



## Introduction (4)

---

➔ Généralement, utilisation de filtres *symétriques* ( $p = f$  et  $\theta_{-i} = \theta_i$ )

## Introduction (4)

---

- ➔ Généralement, utilisation de filtres *symétriques* ( $p = f$  et  $\theta_{-i} = \theta_i$ )
- ➔ Pour l'estimation en **temps réel**, utilisation de filtres *asymétriques* ( $f < p$ )  $\implies$  révision et détection avec retard des points de retournement (*déphasage*)

## Introduction (4)

---

- ➔ Généralement, utilisation de filtres *symétriques* ( $p = f$  et  $\theta_{-i} = \theta_i$ )
- ➔ Pour l'estimation en **temps réel**, utilisation de filtres *asymétriques* ( $f < p$ )  $\implies$  révision et détection avec retard des points de retournement (*déphasage*)

Solution classique : prolonger la série par prévision et utiliser filtre symétrique

- ➔ revient à utiliser des filtres asymétriques optimisés avec certains critères
- ➔ sous-optimal pour séries très variables

## Introduction (4)

---

- ➔ Généralement, utilisation de filtres *symétriques* ( $p = f$  et  $\theta_{-i} = \theta_i$ )
- ➔ Pour l'estimation en **temps réel**, utilisation de filtres *asymétriques* ( $f < p$ )  $\implies$  révision et détection avec retard des points de retournement (*déphasage*)

Solution classique : prolonger la série par prévision et utiliser filtre symétrique

- ➔ revient à utiliser des filtres asymétriques optimisés avec certains critères
- ➔ sous-optimal pour séries très variables

Objectifs cette étude :

- Étudier et comparer des approches récentes pour l'extraction de la tendance-cycle en temps réel : Régression polynomiale locale (Proietti et Luati 2008) ; RKHS (Dagum et Bianconcini 2016) ; Optimisation sous contrainte d'une somme pondérée de critères (Grun-Rehomme *et ali* 2018, Wildi et McElroy, 2019)



## Introduction (4)

---

- ➔ Généralement, utilisation de filtres *symétriques* ( $p = f$  et  $\theta_{-i} = \theta_i$ )
- ➔ Pour l'estimation en **temps réel**, utilisation de filtres *asymétriques* ( $f < p$ )  $\implies$  révision et détection avec retard des points de retournement (*déphasage*)

Solution classique : prolonger la série par prévision et utiliser filtre symétrique

- ➔ revient à utiliser des filtres asymétriques optimisés avec certains critères
- ➔ sous-optimal pour séries très variables

Objectifs cette étude :

- Étudier et comparer des approches récentes pour l'extraction de la tendance-cycle en temps réel : Régression polynomiale locale (Proietti et Luati 2008) ; RKHS (Dagum et Bianconcini 2016) ; Optimisation sous contrainte d'une somme pondérée de critères (Grun-Rehomme *et ali* 2018, Wildi et McElroy, 2019)
- Montrer qu'il est possible d'établir une théorie générale englobant toutes ces méthodes

## Introduction (4)


---

- ➔ Généralement, utilisation de filtres *symétriques* ( $p = f$  et  $\theta_{-i} = \theta_i$ )
- ➔ Pour l'estimation en **temps réel**, utilisation de filtres *asymétriques* ( $f < p$ )  $\implies$  révision et détection avec retard des points de retournement (*déphasage*)

Solution classique : prolonger la série par prévision et utiliser filtre symétrique

- ➔ revient à utiliser des filtres asymétriques optimisés avec certains critères
- ➔ sous-optimal pour séries très variables

Objectifs cette étude :

- Étudier et comparer des approches récentes pour l'extraction de la tendance-cycle en temps réel : Régression polynomiale locale (Proietti et Luati 2008) ; RKHS (Dagum et Bianconcini 2016) ; Optimisation sous contrainte d'une somme pondérée de critères (Grun-Rehomme *et ali* 2018, Wildi et McElroy, 2019)
- Montrer qu'il est possible d'établir une théorie générale englobant toutes ces méthodes
- Présenter le package  rjdfilters

# Sommaire

---

## 1. Introduction

## 2. Méthodes étudiées

### 2.1 Filtre symétrique

### 2.2 Polynômes Locaux


### 2.3 Filtres et Reproducing Kernel Hilbert Space (RKHS)

## 3. Comparaison des méthodes

## 4. Conclusion

# Moyenne mobile symétrique d'Henderson

```
library(rjdfilters)
f <- lp_filter(6, kernel = "Henderson")
plot_coef(f, q = 6, legend = FALSE,
          main="Henderson 13 termes")
```



MM Henderson (utilisé dans X-13ARIMA) largement répandue pour estimer  $TC_t$

MM Henderson préserve les tendances polynomiales de degré 3 et minimise le critère de "lissage" ( $\sum(\nabla^3\theta_i)^2$ )

Sur séries mensuelles : MM de 13 termes généralement

## Polynômes Locaux : `rjdfilters::lp_filter()`

---

Hypothèse :  $y_t = \mu_t + \varepsilon_t$  avec  $\varepsilon_t \stackrel{i.i.d}{\sim} \mathcal{N}(0, \sigma^2)$

$\mu_t$  localement approchée par un polynôme de degré  $d$  :

$$\forall j \in \llbracket -h, h \rrbracket : y_{t+j} = m_{t+j} + \varepsilon_{t+j}, \quad m_{t+j} = \sum_{i=0}^d \beta_i j^i$$

## Polynômes Locaux : `rjdfilters::lp_filter()`

Hypothèse :  $y_t = \mu_t + \varepsilon_t$  avec  $\varepsilon_t \stackrel{i.i.d}{\sim} \mathcal{N}(0, \sigma^2)$

$\mu_t$  localement approchée par un polynôme de degré  $d$  :

$$\forall j \in [-h, h] : y_{t+j} = m_{t+j} + \varepsilon_{t+j}, \quad m_{t+j} = \sum_{i=0}^d \beta_i j^i$$

Estimation en utilisant les WLS avec *noyaux* :  $\hat{\beta} = (X'KX)^{-1}X'Ky$  et

$$\hat{m}_t = \hat{\beta}_0 = w'y = \sum_{j=-h}^h w_j y_{t-j} \rightarrow \text{équivalent à une moyenne mobile symétrique}$$

➔ Filtre de Henderson avec  $d = 3$  et noyau spécifique.

## Filtres asymétriques : `rjdfilters::lp_filter()`

---

1. Même méthode mais moins de données (DAF)  $\iff$  minimiser les révisions sous mêmes contraintes polynomiales
- ➔ **sans biais** mais **beaucoup de variance**
  - ➔ utilisé dans STL

## Filtres asymétriques : `rjdfilters::lp_filter()`

1. Même méthode mais moins de données (DAF)  $\iff$  minimiser les révisions sous mêmes contraintes polynomiales
    - ➔ **sans biais** mais **beaucoup de variance**
    - ➔ utilisé dans STL
  2. Minimisation des révisions sous contraintes polynomiales :
    - 2.1 *Linear-Constant* (LC) :  $y_t$  linéaire and  $v$  reproduit les constantes (*Musgrave*)
    - 2.2 *Quadratic-Linear* (QL) :  $y_t$  quadratique et  $v$  reproduit droites
    - 2.3 *Cubic-Quadratic* (CQ) :  $y_t$  cubique et  $v$  reproduit tendances quadratiques
- ➔ Filtres asymétriques  $v$  dépendent de "IC-Ratio"



## Filtres asymétriques : `rjdfilters::lp_filter()`

1. Même méthode mais moins de données (DAF)  $\iff$  minimiser les révisions sous mêmes contraintes polynomiales

➔ **sans biais** mais **beaucoup de variance**

➔ utilisé dans STL

2. Minimisation des révisions sous contraintes polynomiales :

2.1 *Linear-Constant* (LC) :  $y_t$  linéaire and  $v$  reproduit les constantes (*Musgrave*)

2.2 *Quadratic-Linear* (QL) :  $y_t$  quadratique et  $v$  reproduit droites

2.3 *Cubic-Quadratic* (CQ) :  $y_t$  cubique et  $v$  reproduit tendances quadratiques

➔ Filtres asymétriques  $v$  dépendent de "IC-Ratio"



modèles simples facilement interprétables



Déphasage non contrôlé ➔ méthode étendue dans `rjdfilters::lp_filter()`

## Filtres asymétriques : `rjdfilters::lp_filter()`

1. Même méthode mais moins de données (DAF)  $\iff$  minimiser les révisions sous mêmes contraintes polynomiales

➔ **sans biais** mais **beaucoup de variance**

➔ utilisé dans STL

2. Minimisation des révisions sous contraintes polynomiales :

2.1 *Linear-Constant* (LC) :  $y_t$  linéaire and  $v$  reproduit les constantes (*Musgrave*)

2.2 *Quadratic-Linear* (QL) :  $y_t$  quadratique et  $v$  reproduit droites

2.3 *Cubic-Quadratic* (CQ) :  $y_t$  cubique et  $v$  reproduit tendances quadratiques

➔ Filtres asymétriques  $v$  dépendent de "IC-Ratio"



modèles simples facilement interprétables



Déphasage non contrôlé ➔ méthode étendue dans `rjdfilters::lp_filter()`

## Filtres RKHS : `rjdfilters::rkhs_filter()`

- Utilisation de la théorie des RKHS pour approcher le filtre d'Henderson
- Avec  $K_p$  une **fonction de noyau** définie sur  $[-1, 1]$ , le filtre symétrique :

$$\forall j \in \llbracket -h, h \rrbracket : w_j = \frac{K_p(j/b)}{\sum_{i=-h}^h K_p(i/b)}$$

➔ avec  $b = h + 1$  et  $K_p$  spécifique on retrouve le filtre d'Henderson

- Pour les filtres asymétriques :

$$\forall j \in \llbracket -h, q \rrbracket : w_{a,j} = \frac{K_p(j/b)}{\sum_{i=-h}^q K_p(i/b)}$$


➔  $b$  choisit par optimisation, e.g. minimisant les révisions  $(b_{q,\Gamma})$ , les révisions liées à la fonction de gain  $(b_{q,G})$  et celles liées au déphasage  $(b_{q,\varphi})$

# Filtres asymétriques



Plusieurs extremum

```
library(rjdfilters)
fun <- rkhs_optimization_fun(horizon = 6,
                             leads = 5, degree = 3,
                             asymmetricCriterion = "Timeliness")
plot(fun, 5.6, 12, xlab = "b",
      ylab = "Timeliness", main = "6X5 filter")
```



```
rkhs_optimal_bw()
```

```
##      q=0      q=1      q=2      q=3      q=4      q=5
## 6.0000 6.0000 6.3875 8.1500 9.3500 6.0000
```



Méthode  
généralisable à des  
filtres avec fréquences  
irrégulières

# Sommaire

---

## 1. Introduction

## 2. Méthodes étudiées

## 3. Comparaison des méthodes

### 3.1 Méthodologie

### 3.2 Application sur séries simulées

### 3.3 Un exemple : série des ventes au détail des États-Unis (en log)

## 4. Conclusion

# Méthodologie

---

Comparaison des différentes méthodes sur séries simulées (avec 3 niveaux de variabilité) et séries réelles :

1. Estimation de la tendance-cycle à chaque date en utilisant les différentes méthodes et un filtre symétrique de 13 termes

# Méthodologie

---

Comparaison des différentes méthodes sur séries simulées (avec 3 niveaux de variabilité) et séries réelles :

1. Estimation de la tendance-cycle à chaque date en utilisant les différentes méthodes et un filtre symétrique de 13 termes
2. À chaque date, estimation des points de retournement :
  - redressements :  $y_{t-3} \geq y_{t-2} \geq y_{t-1} < y_t \leq y_{t+1}$
  - ralentissements :  $y_{t-3} \leq y_{t-2} \leq y_{t-1} > y_t \geq y_{t+1}$

Déphasage = temps nécessaire pour détecter le bon point de retournement  
*sans révision*

# Méthodologie

---

Comparaison des différentes méthodes sur séries simulées (avec 3 niveaux de variabilité) et séries réelles :

1. Estimation de la tendance-cycle à chaque date en utilisant les différentes méthodes et un filtre symétrique de 13 termes
2. À chaque date, estimation des points de retournement :
  - redressements :  $y_{t-3} \geq y_{t-2} \geq y_{t-1} < y_t \leq y_{t+1}$
  - ralentissements :  $y_{t-3} \leq y_{t-2} \leq y_{t-1} > y_t \geq y_{t+1}$

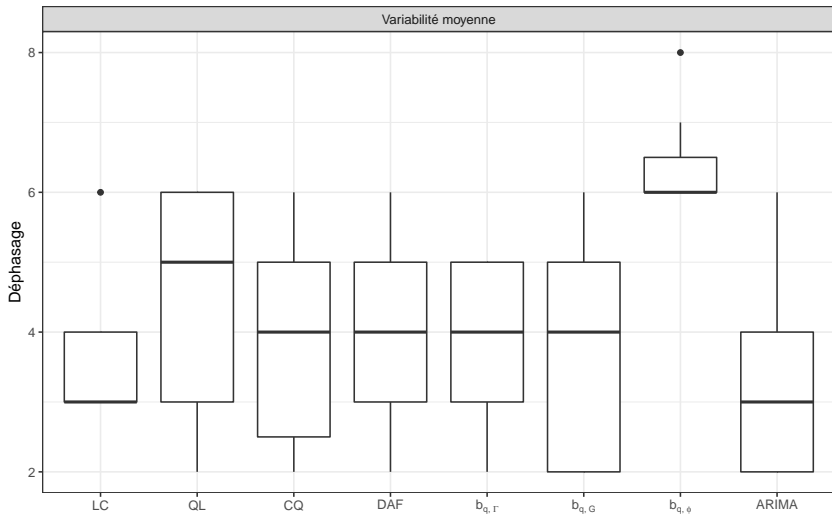
Déphasage = temps nécessaire pour détecter le bon point de retournement *sans révision*

3. Calcul des révisions avec deux critères :

$$\mathbb{E} \left[ \left| \frac{y_{t|t+q} - y_{t|last}}{y_{t|last}} \right| \right] \quad \text{et} \quad \mathbb{E} \left[ \left| \frac{y_{t|t+q} - y_{t|t+q+1}}{y_{t|t+q+1}} \right| \right]$$



# Résultats sur le déphasage (séries simulées)



# Médiane des révisions (séries simulées)

Pour les séries à variabilité moyenne :

Méthode	$q = 0$	$q = 1$	$q = 2$	$q = 3$	$q = 4$	$q = 5$
<b>MAE entre <math>q^e</math> et la dernière estimation</b>						
LC	0,21	0,10	0,03	0,03	0,03	0,01
QL (rel)	1,6	1,0	1,3	1,5	1,3	1,1
CQ (rel)	2,2	1,3	4,2	3,3	2,1	1,6
DAF (rel)	2,3	1,5	4,9	3,5	2,2	1,5
$b_{q,\Gamma}$ (rel)	3,1	2,3	1,1	3,6	3,5	3,9
$b_{q,G}$ (rel)	4,1	4,0	1,1	3,6	3,5	4,0
$b_{q,\varphi}$ (rel)	1,5	1,1	1,0	1,8	2,7	8,7
ARIMA (rel)	1,0	1,0	1,1	1,1	1,1	1,0
<b>MAE entre <math>q^e</math> et la <math>q + 1^e</math> estimation</b>						
LC	0,19	0,10	0,02	0,01	0,07	0,01
QL (rel)	1,6	43,2	0,1	3,1	0,9	1,1
CQ (rel)	2,3	0,2	4,3	7,3	1,4	1,6
DAF (rel)	3,5	2,6	4,6	12,9	1,3	1,5
$b_{q,\Gamma}$ (rel)	2,1	2,9	3,7	0,3	16,2	3,9
$b_{q,G}$ (rel)	3,7	4,7	4,3	0,5	17,0	4,0
$b_{q,\varphi}$ (rel)	1,2	1,4	3,5	5,3	0,7	8,7
ARIMA (rel)	1,1	1,3	0,8	1,8	2,3	1,0

# Médiane des révisions (séries simulées)

Pour les séries à variabilité moyenne :

Méthode	$q = 0$	$q = 1$	$q = 2$	$q = 3$	$q = 4$	$q = 5$
<b>MAE entre <math>q^e</math> et la dernière estimation</b>						
LC	0,21	0,10	0,03	0,03	0,03	0,01
QL (rel)	1,6	1,0	1,3	1,5	1,3	1,1
CQ (rel)	2,2	1,3	4,2	3,3	2,1	1,6
DAF (rel)	2,3	1,5	4,9	3,5	2,2	1,5
$b_{q,\Gamma}$ (rel)	3,1	2,3	1,1	3,6	3,5	3,9
$b_{q,G}$ (rel)	4,1	4,0	1,1	3,6	3,5	4,0
$b_{q,\varphi}$ (rel)	1,5	1,1	1,0	1,8	2,7	8,7
ARIMA (rel)	1,0	1,0	1,1	1,1	1,1	1,0
<b>MAE entre <math>q^e</math> et la <math>q + 1^e</math> estimation</b>						
LC	0,19	0,10	0,02	0,01	0,07	0,01
QL (rel)	1,6	43,2	0,1	3,1	0,9	1,1
CQ (rel)	2,3	0,2	4,3	7,3	1,4	1,6
DAF (rel)	3,5	2,6	4,6	12,9	1,3	1,5
$b_{q,\Gamma}$ (rel)	2,1	2,9	3,7	0,3	16,2	3,9
$b_{q,G}$ (rel)	3,7	4,7	4,3	0,5	17,0	4,0
$b_{q,\varphi}$ (rel)	1,2	1,4	3,5	5,3	0,7	8,7
ARIMA (rel)	1,1	1,3	0,8	1,8	2,3	1,0

# Médiane des révisions (séries simulées)

Pour les séries à variabilité moyenne :

Méthode	$q = 0$	$q = 1$	$q = 2$	$q = 3$	$q = 4$	$q = 5$
<b>MAE entre <math>q^e</math> et la dernière estimation</b>						
LC	0,21	0,10	0,03	0,03	0,03	0,01
QL (rel)	1,6	1,0	1,3	1,5	1,3	1,1
CQ (rel)	2,2	1,3	4,2	3,3	2,1	1,6
DAF (rel)	2,3	1,5	4,9	3,5	2,2	1,5
$b_{q,\Gamma}$ (rel)	3,1	2,3	1,1	3,6	3,5	3,9
$b_{q,G}$ (rel)	4,1	4,0	1,1	3,6	3,5	4,0
$b_{q,\varphi}$ (rel)	1,5	1,1	1,0	1,8	2,7	8,7
ARIMA (rel)	1,0	1,0	1,1	1,1	1,1	1,0
<b>MAE entre <math>q^e</math> et la <math>q + 1^e</math> estimation</b>						
LC	0,19	0,10	0,02	0,01	0,07	0,01
QL (rel)	1,6	43,2	0,1	3,1	0,9	1,1
CQ (rel)	2,3	0,2	4,3	7,3	1,4	1,6
DAF (rel)	3,5	2,6	4,6	12,9	1,3	1,5
$b_{q,\Gamma}$ (rel)	2,1	2,9	3,7	0,3	16,2	3,9
$b_{q,G}$ (rel)	3,7	4,7	4,3	0,5	17,0	4,0
$b_{q,\varphi}$ (rel)	1,2	1,4	3,5	5,3	0,7	8,7
ARIMA (rel)	1,1	1,3	0,8	1,8	2,3	1,0


# Médiane des révisions (séries simulées)

Pour les séries à variabilité moyenne :


Méthode	$q = 0$	$q = 1$	$q = 2$	$q = 3$	$q = 4$	$q = 5$
<b>MAE entre <math>q^e</math> et la dernière estimation</b>						
LC	0,21	0,10	0,03	0,03	0,03	0,01
QL (rel)	1,6	1,0	1,3	1,5	1,3	1,1
CQ (rel)	2,2	1,3	4,2	3,3	2,1	1,6
DAF (rel)	2,3	1,5	4,9	3,5	2,2	1,5
$b_{q,\Gamma}$ (rel)	3,1	2,3	1,1	3,6	3,5	3,9
$b_{q,G}$ (rel)	4,1	4,0	1,1	3,6	3,5	4,0
$b_{q,\varphi}$ (rel)	1,5	1,1	1,0	1,8	2,7	8,7
ARIMA (rel)	1,0	1,0	1,1	1,1	1,1	1,0
<b>MAE entre <math>q^e</math> et la <math>q + 1^e</math> estimation</b>						
LC	0,19	0,10	0,02	0,01	0,07	0,01
QL (rel)	1,6	43,2	0,1	3,1	0,9	1,1
CQ (rel)	2,3	0,2	4,3	7,3	1,4	1,6
DAF (rel)	3,5	2,6	4,6	12,9	1,3	1,5
$b_{q,\Gamma}$ (rel)	2,1	2,9	3,7	0,3	16,2	3,9
$b_{q,G}$ (rel)	3,7	4,7	4,3	0,5	17,0	4,0
$b_{q,\varphi}$ (rel)	1,2	1,4	3,5	5,3	0,7	8,7
ARIMA (rel)	1,1	1,3	0,8	1,8	2,3	1,0

# Estimations successives de la tendance-cycle (1)


**Linear – Constant (LC)**  
Déphasage de 3 mois




**Quadratic – Linear (QL)**  
Déphasage de 2 mois







**Cubic – quadratic (CQ)**  
Déphasage de 2 mois



**DAF**  
Déphasage de 2 mois



# Estimations successives de la tendance-cycle (2)



# Prévisions implicites

Fonction `rjdfilters::implicit_forecast`

$$\forall q, \underbrace{\sum_{i=-h}^0 v_i y_i + \sum_{i=1}^h v_i y_i^*}_{\text{lissage par } v \text{ de la série prolongée}} = \underbrace{\sum_{i=-h}^0 w_i^q y_i + \sum_{i=1}^h w_i^q y_i^*}_{\text{lissage par } w^q \text{ de la série prolongée}} \quad \text{avec } \forall i > q, w_i^q = 0$$

Ce qui est équivalent à :

$$\forall q, \sum_{i=1}^h (v_i - w_i^q) y_i^* = \sum_{i=-h}^0 (w_i^q - v_i) y_i.$$


Matriciellement :

$$\begin{pmatrix} v_1 & v_2 & \dots & v_h \\ v_1 - w_1^1 & v_2 & \dots & v_h \\ \vdots & \vdots & \dots & \vdots \\ v_1 - w_1^{h-1} & v_2 - w_2^{h-1} & \dots & v_h \end{pmatrix} \begin{pmatrix} y_1^* \\ \vdots \\ y_h^* \end{pmatrix} = \begin{pmatrix} w_{-h}^0 - v_{-h} & w_{-(h-1)}^0 - v_{-(h-1)} & \dots & w_0^0 - v_0 \\ w_{-h}^1 - v_{-h} & w_{-(h-1)}^1 - v_{-(h-1)} & \dots & w_0^1 - v_0 \\ \vdots & \vdots & \dots & \vdots \\ w_{-h}^{h-1} - v_{-h} & w_{-(h-1)}^{h-1} - v_{-(h-1)} & \dots & w_0^{h-1} - v_0 \end{pmatrix} \begin{pmatrix} y_{-h} \\ \vdots \\ y_0 \end{pmatrix}.$$




# Prévisions implicites (1)


**Linear – Constant (LC)**  
Déphasage de 3 mois




**Quadratic – Linear (QL)**  
Déphasage de 2 mois



**Cubic – quadratic (CQ)**  
Déphasage de 2 mois




**DAF**  
Déphasage de 2 mois




# Prévisions implicites (2)


$b_{q, \Gamma}$   
Déphasage de 3 mois




$b_{q, G}$   
Déphasage de 2 mois



$b_{q, \phi}$   
Déphasage de 6 mois



Modèle ARIMA  
Déphasage 3 mois



# Conclusion

---

- Dans la construction des filtres asymétriques :
  1. on peut se restreindre à ceux qui conservent les polynômes de degré au plus 1 (et exclure les filtres QL, CQ et DAF)

# Conclusion

---

- Dans la construction des filtres asymétriques :
  1. on peut se restreindre à ceux qui conservent les polynômes de degré au plus 1 (et exclure les filtres QL, CQ et DAF)
  2. on peut utiliser le filtre LC pour les estimations proches de l'estimation finale

# Conclusion

---

- Dans la construction des filtres asymétriques :
  1. on peut se restreindre à ceux qui conservent les polynômes de degré au plus 1 (et exclure les filtres QL, CQ et DAF)
  2. on peut utiliser le filtre LC pour les estimations proches de l'estimation finale
- Dans certains cas des méthodes alternatives à la prévision ARIMA peuvent être utilisées ➔ `rjdfilters` peut aider à comparer les résultats (`rjdfilters::x11()` pour les intégrer dans X-11)

# What next?

---

- Etudes sur d'autres méthodes comme Vasyechko et Grun-Rehomme (2014) ou Feng et Schäfer (2021)

# What next?

---

- Etudes sur d'autres méthodes comme Vasyechko et Grun-Rehomme (2014) ou Feng et Schäfer (2021)
- Utiliser des paramètres différents en fin de période? Impact de la longueur du filtre?

# What next?


---

- Etudes sur d'autres méthodes comme Vasyechko et Grun-Rehomme (2014) ou Feng et Schäfer (2021)
- Utiliser des paramètres différents en fin de période? Impact de la longueur du filtre?
- Impact des points atypiques? quid des méthodes robustes?




# Merci pour votre attention

---

Package  :

 palatej/rjdfilters

Version en développement  AQLT/rjdfilters

 Codes : <https://github.com/AQLT/articles>