

# Méthodes de lissage exponentiel

- ▶ Typiquement dans un modèle de régression, on dispose des observations  $(y_t, \mathbf{x}_t)$ ,  $t = 1, \dots, n$ , avec  $n$  la taille de l'échantillon.
- ▶ On a alors formulé un modèle linéaire de la forme

$$y_t = \mathbf{x}_t^\top \boldsymbol{\beta} + \epsilon_t.$$

- ▶ Pour faire des prévisions à l'instant  $t_0$ , on avait cependant besoin de  $\mathbf{x}_{t_0}$ .

# Données mesurées dans le temps: séries chronologiques

- ▶ Il y a des situations où l'on dispose que d'une série de données.
- ▶ Lorsque les données sont mesurées dans le temps, il est anticipé que ces données soient dépendantes.
- ▶ L'hypothèse de l'échantillon aléatoire ( $X_1, \dots, X_n$  iid) devient alors douteuse.
- ▶ Lorsque les données sont mesurées dans le temps, on dira que  $X_1, \dots, X_n$  est une série chronologique.
- ▶ Formellement, une série chronologique est une réalisation finie d'un processus stochastique.

- ▶ Que faire si l'on dispose que d'une série de données et que l'on désire faire des prévisions?
- ▶ Une stratégie consiste à utiliser le passé de la variable, ou l'historique.
- ▶ En utilisant le passé de la variable, en expliquant la dépendance dans les données, on cherche à proposer des prévisions.

# Méthode classique: lissage exponentiel

- ▶ Le lissage exponentiel est simple et intuitif; c'est l'ancêtre des méthodes plus modernes de séries chronologiques.
- ▶ Il demeure utile afin de motiver les nouveaux modèles, avec les outils vus jusqu'à maintenant.
- ▶ Considérons  $z_1, \dots, z_n$  une série chronologique, réalisation de  $\{Z_t, t \in \mathbb{Z}\}$ .
- ▶ Un modèle possible est d'expliquer  $Z_t$  par le temps lui-même:

$$Z_t = f(t, \beta) + \epsilon_t,$$

où  $f(t, \beta)$  est une fonction connue, fonction du temps, et les erreurs  $\{\epsilon_t\}$  sont non-corrélées.

# Exemples

- ▶ Dans le cas non-saisonnier, on pourrait considérer:

$$Z_t = \beta + \epsilon_t, \text{ modèle avec moyenne constante;}$$

$$Z_t = \beta_0 + \beta_1 t + \epsilon_t, \text{ modèle avec tendance linéaire;}$$

- ▶ Cas saisonnier:

$$Z_t = \beta_0 + \beta_1 \sin(2\pi t/12) + \beta_2 \cos(2\pi t/12) + \epsilon_t,$$

c'est un exemple de modèle sinusoidal;

$$Z_t = \sum_{j=1}^{12} \beta_j I\{t \in \text{période } i\} + \epsilon_t, \text{ modèle avec indicatrices,}$$

avec  $I\{t \in \text{période } i\}$  valant un si  $t$  est dans la période  $i$ ,  
 $i = 1, \dots, 12$ .

# Méthodes d'estimation

- ▶ Une première méthode d'estimation pourrait être les moindres carrés ordinaires:

$$\min \sum_{t=1}^n \{z_t - f(t, \beta)\}^2$$

- ▶ On verra cependant qu'une méthode plus naturelle consistera à utiliser les moindres carrés pondérés:

$$\min \sum_{t=1}^n w_t \{z_t - f(t, \beta)\}^2$$

- ▶ Les  $w_t$  sont des poids, qui sont choisis tels qu'ils décroissent de manière exponentielle:

$$w_t = w^{n-t}, \quad t = 1, \dots, n.$$

# Choix du coefficient $w$

- ▶ Le coefficient  $w$  doit être choisi par l'utilisateur.
- ▶ Il aura un impact direct sur l'importance des observations récentes relativement aux données passées. Par exemple  $w = 0.9$ .
- ▶ Ce cadre des moindres carrés pondérés avec ce choix de poids mène à la méthode générale du lissage exponentiel.

# Modèle avec moyenne constante

- ▶ Considérons le modèle  $Z_t = \beta + \epsilon_t$ . Sous forme matricielle on aura alors:

$$\mathbf{Z} = \beta \mathbf{1} + \boldsymbol{\epsilon},$$

avec  $\mathbf{Z} = (Z_1, \dots, Z_n)^\top$  et  $\mathbf{1} = (1, \dots, 1)^\top$ .

- ▶ La variable à l'horizon  $l$  est alors:

$$Z_{n+l} = \beta + \epsilon_{n+l}.$$

- ▶ La prévision pour  $Z_{n+l}$  est alors:

$$Z_n(l) = \beta,$$

en autant que  $\beta$  soit connu.

# Estimation de $\beta$ dans le modèle avec moyenne constante

- ▶ Si on utilise les moindres carrés ordinaires, on trouve:

$$\begin{aligned}\hat{\beta} &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}, \\ &= (\mathbf{1}^T \mathbf{1})^{-1} \mathbf{1}^T \mathbf{Z}, \\ &= n^{-1} \sum_{t=1}^n Z_t, \\ &= \bar{Z}_n.\end{aligned}$$

- ▶ On note que  $\bar{Z}_n = \sum_{t=1}^n \{(1/n)Z_t\}$ .
- ▶ L'utilisation des moindres carrés entraîne que chaque observation a un poids de  $1/n$ .

# Modification des poids

- ▶ Les données  $z_t$  sont observées dans le temps.
- ▶ Intuitivement, il semble raisonnable d'attribuer plus de poids aux observations récentes, et moins aux observations passées.
- ▶ Une façon: pondérer de façon que les poids décroissent géométriquement dans le temps.
- ▶ Cette idée amène la prévision suivante:

$$\hat{z}_n(l) = c \left( z_n + w z_{n-1} + w^2 z_{n-2} + \dots + w^{n-1} z_1 \right),$$

avec  $w \in (0, 1)$  et  $c \sum_{t=0}^{n-1} w^t = 1$ .

# Justification théorique

- ▶ En fait, si on considère le problème des moindres carrés pondérés suivant:

$$\min_{\beta} \sum_{j=0}^{n-1} w^j \{z_{n-j} - \beta\}^2$$

- ▶ Les moindres carrés pondérés donnent:

$$\begin{aligned}\hat{\beta} &= (\mathbf{X}^T \mathbf{W}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}^{-1} \mathbf{y}, \\ &= \frac{\sum_{j=0}^{n-1} w^j z_{n-j}}{\sum_{j=0}^{n-1} w^j}, \\ &= \frac{1-w}{1-w^n} \sum_{j=0}^{n-1} w^j z_{n-j},\end{aligned}$$

avec  $\mathbf{X} = \mathbf{1} = (1, \dots, 1)^T$ ,  $\mathbf{y} = (z_n, \dots, z_1)^T$  et  $\mathbf{W} = \text{diag}(1, 1/w, \dots, 1/w^{n-1})$ .

# Facteur d'amortissement

- ▶ On rappelle que  $c \sum_{t=0}^{n-1} w^t = 1$ .
- ▶ Utilisant les résultats sur les séries géométriques:

$$\sum_{t=0}^{n-1} w^t = \frac{1 - w^n}{1 - w},$$

- ▶ Puisque  $w \in (0, 1)$ , ceci implique:

$$c = \frac{1 - w}{1 - w^n} \rightarrow 1 - w,$$

lorsque  $n \rightarrow \infty$ .

- ▶ Typiquement  $w \in (0.7, 0.95)$ .

# Étude en fonction de $w$

- ▶ Avec  $c = \frac{1-w}{1-w^n}$ , on remarque que la prévision devient:

$$\hat{z}_n(l) = \frac{1-w}{1-w^n} \left( z_n + w z_{n-1} + w^2 z_{n-2} + \dots + w^{n-1} z_1 \right),$$

- ▶ Le poids associé à chaque donnée est donc  $\frac{1-w}{1-w^n} w^j$ . On aura:

$$\lim_{w \rightarrow 1} \frac{1-w}{1-w^n} = \frac{0}{0};$$
$$\lim_{w \rightarrow 1} \frac{-1}{-nw^{n-1}} = \frac{1}{n}.$$

- ▶ Si  $w$  est proche de un, tous les poids sont grands ou plutôt de même importance (et proches de  $1/n$ ).
- ▶ Les prévisions seront lisses et on parlera d'un lissage fort.
- ▶ Si  $w \ll 1$ , les prévisions vont reposer sur les dernières données; ce sera moins lisse.

# Astuce décisive: connaissance du passé infini

- ▶ La prévision devrait dépendre sur les données  $z_1, \dots, z_n$ :

$$\hat{z}_n(l) = \frac{1-w}{1-w^n} \left( z_n + w z_{n-1} + w^2 z_{n-2} + \dots + w^{n-1} z_1 \right),$$

- ▶ Cependant, compte tenu que  $w^n \rightarrow 0$  rapidement, et compte tenu d'astuces théoriques, il est souvent commode de supposer que l'on dispose de tout l'historique:

$$\hat{z}_n(l) = (1-w) \left( z_n + w z_{n-1} + w^2 z_{n-2} + \dots \right),$$

où l'on s'est permis de laisser tendre  $n \rightarrow \infty$  et donc  $\frac{1-w}{1-w^n} \rightarrow 1-w$ , lorsque  $n \rightarrow \infty$ .

# Premier lissage des observations

- ▶ La prévision:

$$\hat{z}_n(l) = (1 - w) \left( z_n + w z_{n-1} + w^2 z_{n-2} + \dots \right),$$

est appelée *premier lissage des observations*.

- ▶ Le facteur  $\lambda = 1 - w$  est appelée *constante de lissage*.
- ▶ On a mentionné que  $w \in (0.7, 0.95)$ , donc typiquement  $\lambda \in (0.05, 0.3)$ . Ce sont des règles empiriques.
- ▶ Le premier lissage est parfois noté  $S_n$ :

$$S_n = \lambda \sum_{j=0}^{\infty} w^j z_{n-j}, \quad \forall l \geq 1.$$

- ▶ On note que  $S_n$  est indépendant de l'horizon  $l$

# Mise à jour des prévisions

- ▶ Sujet qui historiquement a assuré le succès de la méthode.
- ▶ Repose sur une utilisation astucieuse de la connaissance du passé infini (pas immédiatement évident à réaliser).
- ▶ Ceci repose sur l'argumentation suivante:

$$\begin{aligned}\hat{Z}_n(l) = S_n &= \lambda \sum_{j=0}^{\infty} w^j z_{n-j} = \lambda z_n + \lambda \sum_{j=1}^{\infty} w^j z_{n-j}, \\ &= \lambda z_n + \lambda w \sum_{j=1}^{\infty} w^{j-1} z_{n-j} = \lambda z_n + \lambda w \sum_{j=0}^{\infty} w^j z_{n-j-1}, \\ &= \lambda z_n + w \left\{ \lambda \sum_{j=0}^{\infty} w^j z_{(n-1)-j} \right\}, \\ &= \lambda z_n + w S_{n-1}.\end{aligned}$$

- ▶ On vient de voir:

$$\hat{z}_n(l) = S_n = \lambda z_n + wS_{n-1}.$$

- ▶ On peut écrire également:

$$\hat{z}_n(1) = \lambda z_n + w\hat{z}_{n-1}(1).$$

- ▶ On remarque que  $\hat{z}_n(1)$  est la prévision d'horizon un.
- ▶ Une autre écriture est:

$$\begin{aligned} S_n &= (1 - w)z_n + (w - 1 + 1)S_{n-1}, \\ &= S_{n-1} + (1 - w)(z_n - S_{n-1}). \end{aligned}$$

- ▶ La formule:

$$S_n = S_{n-1} + (1 - w)(z_n - S_{n-1}).$$

peut s'écrire alternativement comme:

$$\hat{z}_n(1) = \hat{z}_{n-1}(1) + (1 - w)(z_n - \hat{z}_{n-1}(1)).$$

- ▶ L'expression précédente est utile car elle indique comment les prévisions sont mises à jour quand une nouvelle observation devient disponible.
- ▶ C'est un exemple de modèle à correction d'erreurs.

- ▶ On postule l'utilisation de  $S_n = \lambda \sum_{j \geq 0} w^j z_{n-j}$ .
- ▶ On exploite les récursions  $S_n = \lambda z_n + w S_{n-1}$ .
- ▶ Les récursions donnent:

$$\begin{aligned} S_n &= \lambda z_n + w(\lambda z_{n-1} + w S_{n-2}), \\ &= \lambda z_n + \lambda w z_{n-1} + w^2 S_{n-2}, \\ &= \dots, \\ &= \lambda z_n + \lambda w z_{n-1} + \lambda w^2 z_{n-2} + \dots + w^n S_0. \end{aligned}$$

- ▶ On aura besoin de  $\lambda$  et de  $S_0$ : la prévision  $S_n$  devient calculable.

- ▶ La formule est:

$$S_n = \lambda z_n + \lambda w z_{n-1} + \lambda w^2 z_{n-2} + \dots + w^n S_0.$$

- ▶ Si  $n$  est grand et  $w$  petit alors l'influence de  $S_0$  devrait être faible.
- ▶ Si  $w$  est proche de un, on peut prendre  $S_0 = \bar{z}_n$ .
- ▶ Si  $w$  est loin de un, on pourrait prendre  $S_0 = z_1$ .

- ▶ On considère les erreurs de prévision d'horizon un suivantes:

$$\begin{aligned}e_t(1) &= z_{t+1} - S_t, \\ &= z_{t+1} - \hat{z}_t(1), \quad t = 1, \dots, n,\end{aligned}$$

- ▶ On considère la somme des carrés suivante:

$$\text{RSS}(\lambda) = \sum_{t=0}^{n-1} e_t^2(1).$$

- ▶ On minimise en  $\lambda$ :

$$\min_{\lambda} \text{RSS}(\lambda)$$

- ▶ En pratique on peut choisir une palette de valeurs de  $\lambda \in \{0.05, 0.06, \dots, 0.30\}$ .

# Diagnostiquer un lissage exponentiel

- ▶ Les 'résidus' dans ce cas-ci sont les erreurs de prévision d'horizon un:

$$e_t(1) = z_{t+1} - S_t, \quad t = 0, \dots, n-1.$$

- ▶ Deux aspects sont souvent cernés:
  1. Absence de corrélation dans les erreurs de prévision. On fait un test de bruit blanc sur les  $e_t(1)$ :

$$r(k) = \frac{\sum_{t=k}^{n-1} \{e_t(1) - \bar{e}\} \{e_{t-k}(1) - \bar{e}\}}{\sum_{t=0}^{n-1} \{e_t(1) - \bar{e}\}^2}$$

2. Prévisions non-biaisées. On teste formellement  $H_0 : \mu_e = 0$ , avec  $\mu_e$  l'espérance des erreurs de prévision un.

## Diagnostiquer un lissage exponentiel (suite)

- ▶ Pour tester  $\mu = 0$  sur un échantillon  $X_1, \dots, X_n$  la statistique est  $n^{1/2}\bar{x}/s$ , avec  $\bar{x}$  et  $s^2$  la moyenne et la variance échantillonnelles, respectivement.
- ▶ Les 'observations' sont les  $e_t(1) = z_{t+1} - S_t$ ,  $t = 0, \dots, n-1$ .
- ▶ Pour tester formellement  $H_0 : \mu_e = 0$ , on calcule la statistique:

$$n^{1/2}\bar{e}/s_e,$$

avec  $\bar{e} = n^{-1} \sum_{t=0}^{n-1} e_t$  et  $s_e^2 = n^{-1} \sum_{t=0}^{n-1} \{e_t(1) - \bar{e}\}^2$ .

- ▶ On rejette  $H_0$  au niveau 5% si:

$$|n^{1/2}\bar{e}/s_e| > 1.96.$$

# Intervalle de prévision

- ▶ On remarque que:

$$\begin{aligned}\text{var}(S_n) &= \text{var}\left(\lambda \sum_{j \geq 0} w^j z_{n-j}\right) = \lambda^2 \sigma^2 \sum_{j \geq 0} w^{2j}, \\ &= \sigma^2 \lambda^2 \frac{1}{1 - w^2}.\end{aligned}$$

- ▶ Ainsi l'erreur quadratique moyenne de prévision  $E\{(Z_{n+1} - S_n)^2\}$  devient:

$$E\{(Z_{n+1} - S_n)^2\} = \sigma^2 + \sigma^2 \lambda^2 \frac{1}{1 - w^2} = \sigma^2 \frac{2\lambda}{1 - w^2}$$

- ▶ Il peut être montré qu'un intervalle de prévision est:

$$S_n \pm q_{1-\alpha/2} s_e,$$

$$\text{avec } s_e^2 = n^{-1} \sum_{t=0}^{n-1} \{e_t(1) - \bar{e}\}^2.$$