

STT-6615

*Séries chronologiques
univariées*

Pierre Duchesne

Courriel: duchesne@dms.umontreal.ca

Téléphone: 343-7267

Bureau: 4251

Web: www.dms.umontreal.ca/~duchesne

Plan du cours

- ▶ 1. Caractéristiques principales des séries chronologiques.
- ▶ 2. Modèles de régression et modèles AutoRégressifs Moyennes Mobiles Intégrés (ARIMA).
- ▶ 3. Modèles AutoRégressifs Conditionnellement Hétéroskédastiques (ARCH) et quelques généralisations (GARCH).

Barème

- ▶ **Le barème proposé est le suivant:**
 - ▶ Examen final: 40%;
 - ▶ Devoirs (total de trois devoirs, tous sur le site): 60%.

- ▶ **Ouvrages de références:**
 - ▶ Shumway, R. H. et Stoffer, D. S. (2017), *Time Series Analysis and Its Applications, With R Examples*, 4^{ième} édition, Springer, New York.
 - ▶ Tsay, R. S. (2005), *Analysis of Financial Time Series*, 2^{ième} édition, Wiley, New York.
 - ▶ Tsay, R. S. (2013), *An Introduction to Analysis of Financial Data With R*, Wiley, New York.

STT-6615

*Séries chronologiques
univariées*

Chapitre 1

*Caractéristiques principales
des séries chronologiques*

Caractéristiques des séries chronologiques

- ▶ On dispose d'observations mesurées à différents points dans le temps.
 - ▶ Exemple 1: années, mois (exemple: séries chronologiques reposant sur des données macro-économiques);
 - ▶ Exemple 2: jours, heures (données à hautes fréquences);
 - ▶ Exemple 3: transactions d'un indice boursier en temps réel; données à ultra-hautes fréquences (instants irréguliers).
- ▶ Dépendance introduite car l'échantillonnage implique des points observés de manière adjacente dans le temps.
- ▶ Techniques statistiques classiques: Typiquement, une hypothèse souvent rencontrée porte sur l'observations de données indépendantes et identiquement distribuées (*iid*). On ne veut pas faire cette hypothèse.

Analyse des séries chronologiques

- ▶ Approche systématique visant à répondre de manière statistique aux questions posées par cette dépendance temporelle;
 - ▶ Formulation de modèles;
 - ▶ Mesures de dépendance;
 - ▶ Description de la dépendance, description des données.
- ▶ L'analyse des séries chronologiques est une discipline de la statistique;
 - ▶ Des modèles et encore des modèles;
 - ▶ Estimation de paramètres, propriétés des estimateurs; estimation et tests d'hypothèses;
 - ▶ Calcul des prévisions.
- ▶ Une série chronologique est une réalisation finie d'un processus stochastique;
 - ▶ Certaines notions sur les probabilités et processus stochastiques sont nécessaires.

Exemples d'applications

- ▶ **Économie et finance:** indices économiques, financiers, boursiers (taux de change, taux de chômage), volatilité (variance conditionnelle);
- ▶ **Sciences sociales:** étude des populations humaines dans le temps (exemple: nombre de naissances);
- ▶ **Sciences environnementales:** mesures de crues des eaux, mesures de la qualité des eaux dans le temps en utilisant des indices appropriés;
- ▶ **Épidémiologie, médecine:** évolution de nouveaux cas d'une maladie dans le temps; mesures de pression sanguine dans le temps; etc.

Deux approches complémentaires

- ▶ 1. Approche dans le **domaine du temps**, dite aussi approche temporelle.
- ▶ 2. Approche dans le **domaine des fréquences**, dite aussi approche spectrale.

Étude dans le domaine du temps

- ▶ Motivée par l'hypothèse que la **corrélation** entre les observations est mieux expliquée en exprimant la **valeur courante en fonction des valeurs passées**.
- ▶ Formulation de modèles où les valeurs futures s'expriment sous forme de modèles **paramétriques** des valeurs actuelles et passées.
- ▶ Exemple: Modèle de régression linéaire classique de la valeur présente sur les valeurs passées. Particulièrement utile dans un contexte de prévision.
- ▶ L'approche domine en économie, économétrie et finance.

Exemples

- ▶ Régression linéaire simple avec tendance:

- ▶ $X_t = \beta_0 + \beta_1 t + w_t$

- ▶ Dans cet exemple la variable explicative est l'indice du temps. On parle de la présence d'une tendance linéaire.

- ▶ Régression linéaire simple avec input/output:

- ▶ $Y_t = \beta_0 + \beta_1 X_t + w_t$

- ▶ Régression linéaire avec input/output et valeurs retardées:

- ▶ $Y_t = \sum_{r=-\infty}^{\infty} \beta_r X_{t-r} + w_t$

- ▶ Calcul des prévisions est naturel pour ces modèles.

Approche classique pour modéliser la saisonnalité

- ▶ On peut considérer une décomposition additive:

- ▶ $X_t = T_t + S_t + w_t$

- ▶ La composante T_t est une composante de tendance, par exemple:

- ▶ $T_t = \beta_0 + \beta_1 t$

- ▶ La composante S_t est la composante de saisonnalité, par exemple:

- ▶ $S_t = \sum_{i=1}^s \delta_i IND_{t,i}$

- ▶ $S_t = \sum_{i=1}^m A_i \sin\left(\frac{2\pi i}{s} t + \phi_i\right)$

- ▶ Dans la première écriture, $IND_{t,i}$ est la fonction indicatrice qui vaut un si l'observation t se trouve dans la période i , $i = 1, \dots, s$.
- ▶ Le terme d'erreur est w_t .

Étude dans le domaine du temps (suite)

- ▶ Approche générale de Box et Jenkins (d'après un ouvrage célèbre): développement d'une classe de modèles, les modèles autorégressifs moyennes mobiles (modèles AR, MA, ARMA, ARMA intégrés ou ARIMA).
- ▶ Exemple d'un processus autorégressif: $X_t = \phi_1 X_{t-1} + w_t$
- ▶ Exemple d'un processus moyenne mobile: $X_t = w_t + \theta w_{t-1}$
- ▶ Extensions: modèles à fonction de transferts, modèles AR vectoriels (VAR) et ARMA vectoriels (VARMA).
- ▶ Exemple d'un VAR(1):
$$\begin{pmatrix} X_t \\ Y_t \end{pmatrix} = \begin{pmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{pmatrix} \begin{pmatrix} X_{t-1} \\ Y_{t-1} \end{pmatrix} + \begin{pmatrix} w_{1t} \\ w_{2t} \end{pmatrix}$$

Étude dans le domaine des fréquences

- ▶ Caractéristique d'intérêt: étude des variations périodiques ou sinusoïdales systématiques qui sont présentes de manière naturelle dans les données.
- ▶ Analyse spectrale: on partitionne les diverses sources de variations périodiques.
- ▶ Table d'Analyse de Variance (ANOVA): chaque fréquence (de Fourier) a une mesure de variabilité associée.
- ▶ L'outil de base est la **densité spectrale** et une technique d'estimation possible de la densité spectrale est le **périodogramme**.


Étude dans le domaine des fréquences (suite)

- ▶ Approche souvent utile dans l'étude des phénomènes biologiques et physiques:
 - ▶ Étude de la reconnaissance vocale;
 - ▶ Étude de l'imagerie cérébrale (chocs périodiques influençant certaines régions du cerveau);
 - ▶ Étude de données sismiques;
 - ▶ Applications en aéronautique (enregistrement des vibrations sur les ailes des avions).
- ▶ L'étude de la densité spectrale peut révéler des saisonnalités dans les données.
 - ▶ Application pour étudier la périodicité des tâches solaires.

Exemple: bénéfice par action pour Johnson & Johnson

Bénéfices par action trimestriels, Johnson & Johnson, 1960-I à 1980-IV

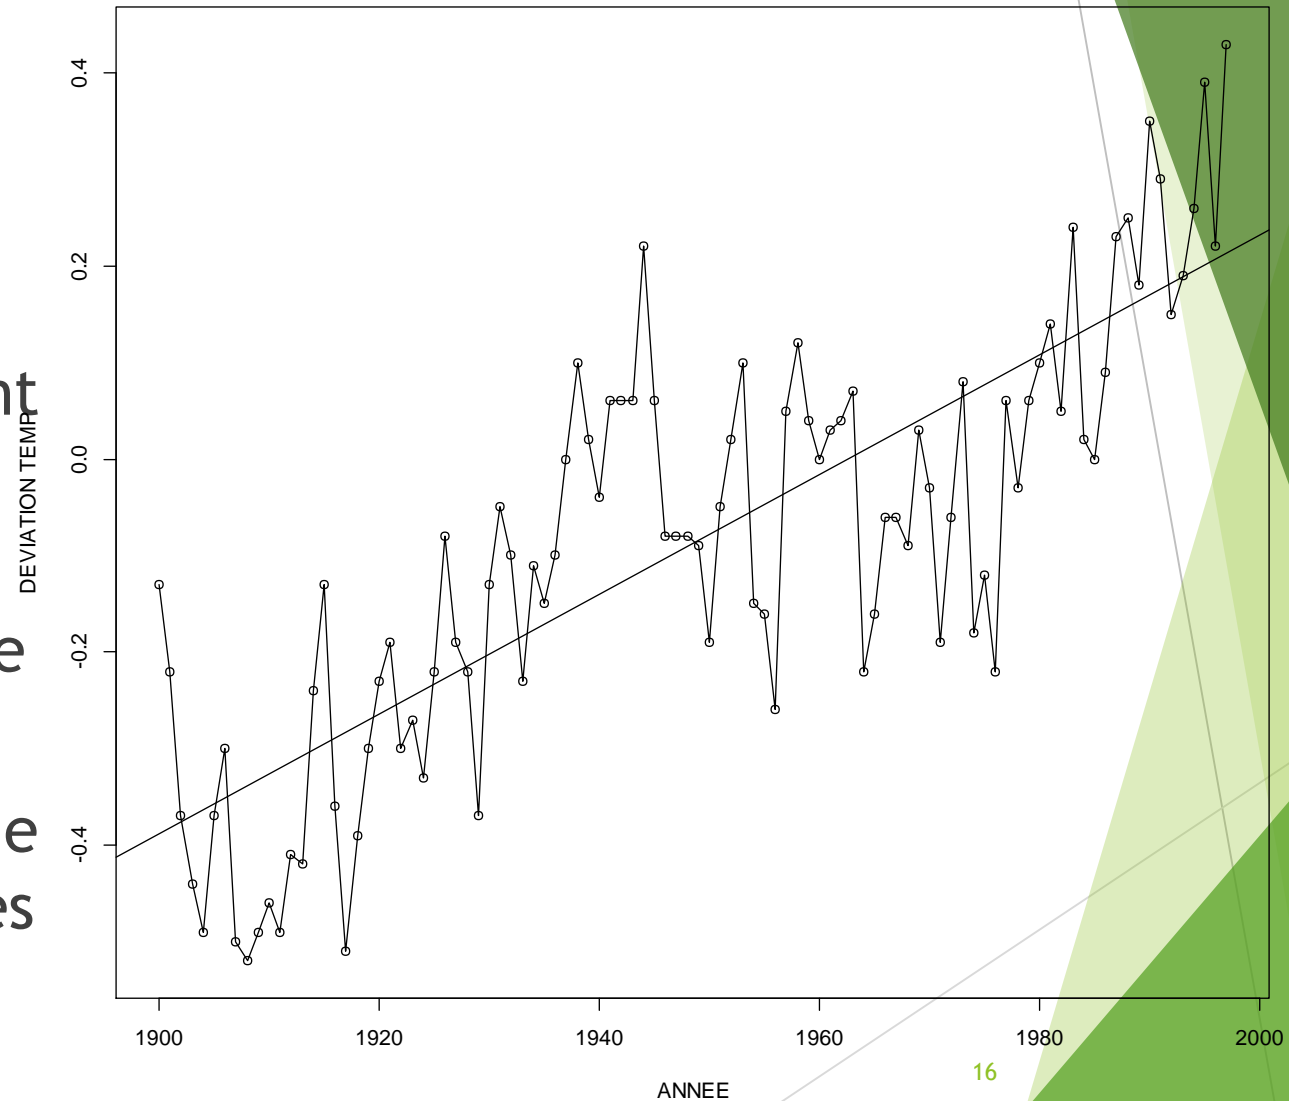
- ▶ Bénéfice par action trimestriels (EPS = *earnings per share*) pour la compagnie américaine Johnson & Johnson.
- ▶ 84 trimestres pour un total de 21 ans.
- ▶ Composante de tendance; variation régulière superposée sur la tendance; saisonnalité.



Exemple: étude du réchauffement planétaire

Déviations annuelles de la temp. globale (1900-1997), degrés Celcius

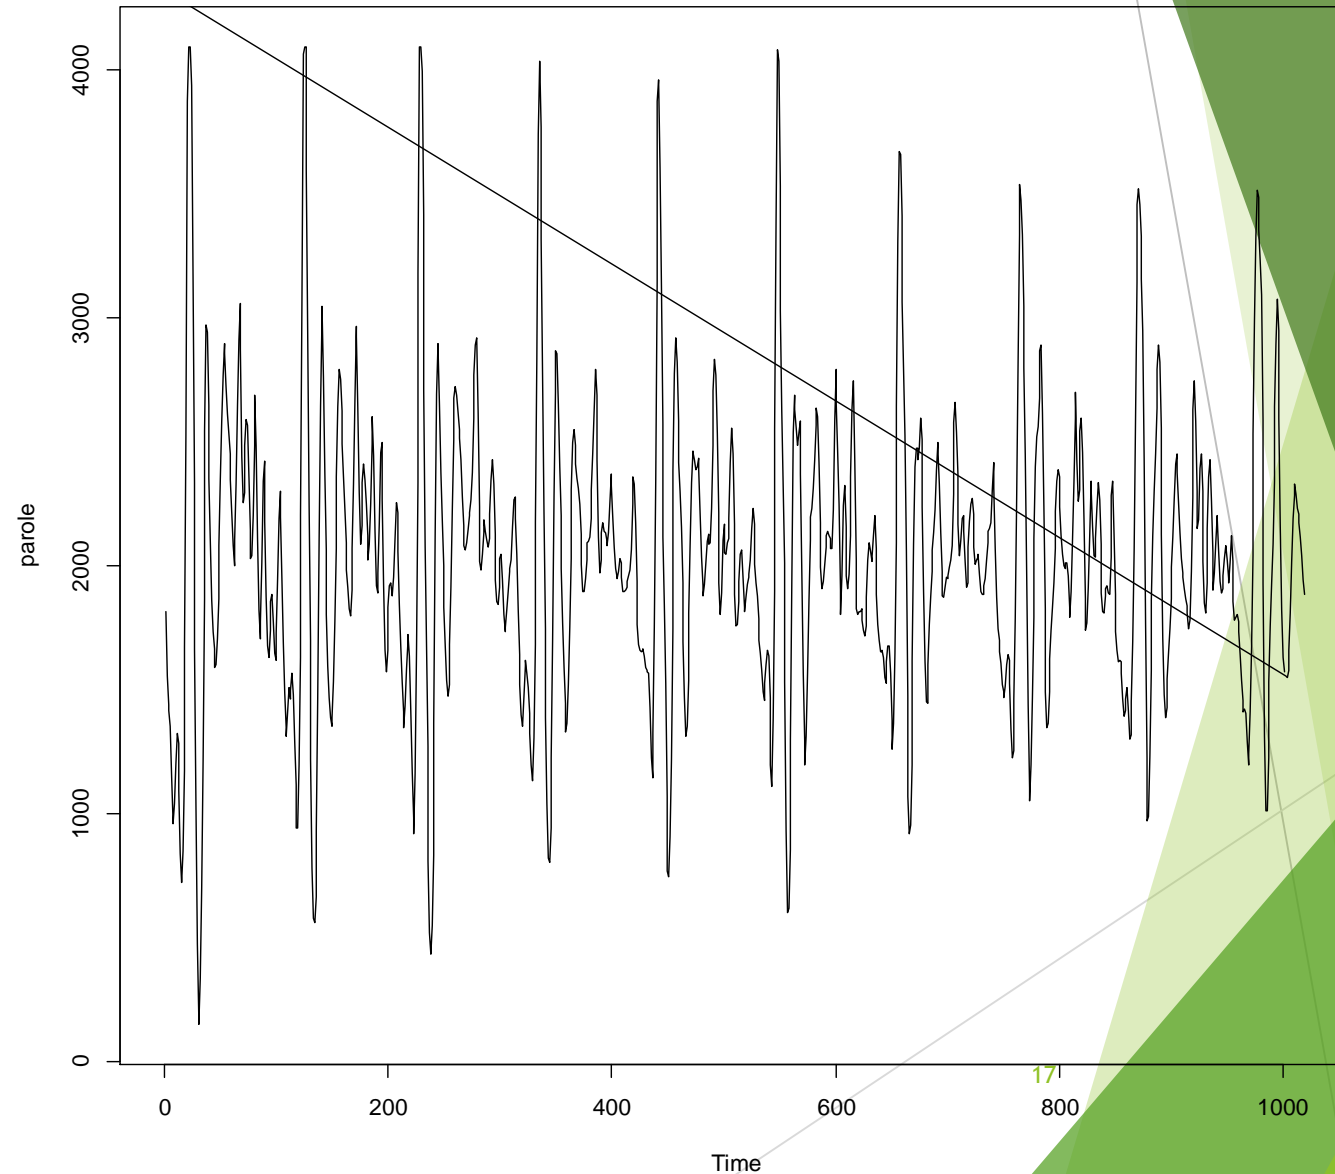
- ▶ Variations en température (degrés Celcius); 1900-1997.
- ▶ Présence d'une tendance;
- ▶ Argument en faveur de l'hypothèse de réchauffement de la planète;
- ▶ Présence d'une tendance: activité humaine ou tendance naturelle?
- ▶ Tendance plus importante que l'explication des composantes périodiques.



Exemple: données portant sur la parole

Aaa...hhh

- ▶ Enregistrement de la syllabe « Aaa...hhh » échantillonnée à 10 000 points par seconde (un dixième de seconde fournissant environ 1000 points);
- ▶ Nature répétitive du signal; périodicités régulières;
- ▶ Applications: reconnaissance de la parole;
- ▶ Traduction du signal en mots?
- ▶ Analyse spectrale est utile ici.




Exemple: El Nino et la population des poissons

- ▶ Indice climatique *Southern Oscillation Index* (SOI) et le recrutement (nombre de nouveaux poissons);
- ▶ Période couverte de 453 mois (1950-1987);
- ▶ SOI = mesure de changement de la pression climatique (reliée à la température à la surface de la mer dans le centre du Pacifique);
- ▶ Le centre de l'océan Pacifique se réchauffe chaque trois à sept ans dû à l'effet El Nino.
- ▶ On dispose de deux séries chronologiques; il est naturel de vouloir étudier les relations entre les deux.

Exemple: El Nino et la population des poissons (suite)

- ▶ Comportement périodique (cycles) dans chaque série;
- ▶ Les cycles ne se répètent pas au même rythme; plus rapide pour SOI;
- ▶ La série de recrutement affiche des cycles; un cycle annuel et un cycle d'environ 50 mois;
- ▶ Relations entre les séries: on aimerait vérifier si la population des poissons dépend de l'indice SOI.



Processus stochastique et séries chronologiques

- ▶ Un processus stochastique est une collection de variables aléatoires;
- ▶ On va noter $\{X_t, t \in \mathbb{Z}\}$ ou encore simplement $\{X_t\}$.
- ▶ Une variable aléatoire sera notée X_t ; le processus quant à lui $\{X_t\}$.
- ▶ Une série chronologique est une réalisation finie d'un processus stochastique: X_1, \dots, X_n , où n est la taille de la série chronologique (taille de l'échantillon).

Caractéristiques visuelles des séries chronologiques

- ▶ Visuellement, ce qui distinguait les exemples précédents était principalement le **degré de lissage**.
- ▶ Explication possible de ce lissage: conséquence du fait que les points adjacents sont corrélés, et la variable X_t peut être fonction de son passé X_{t-1}, X_{t-2}, \dots .
- ▶ Le processus stochastique le plus simple est le **bruit blanc**, suite de variables aléatoires, chacune d'espérance mathématique nulle et de variance finie. Ces variables sont:
 - ▶ non-corrélées (bruit blanc faible) ou
 - ▶ indépendantes (bruit blanc fort).

Bruit blanc

- ▶ Le processus stochastique le plus simple est le bruit blanc $\{w_t, t \in \mathbb{Z}\}$, suite de variables aléatoires, telle que chaque variable est d'espérance mathématique nulle et de variance $\sigma^2 < \infty$.
- ▶ **Bruit blanc faible:** « bruit blanc » est un terme qui vient de l'ingénierie qui utilise ce modèle comme bruit.
- ▶ **Blanc:** comme la lumière blanche; toutes les oscillations périodiques possibles sont présentes avec une force égale. La densité spectrale est une constante.
- ▶ **Bruit blanc *Gaussien*:** les variables aléatoires w_t en cause sont chacune de loi normale et sont indépendantes: $w_t \sim iid N(0, \sigma^2)$.


Bruit blanc fort et bruit blanc faible

- ▶ **Bruit blanc fort:** le processus $\{w_t, t \in \mathbb{Z}\}$ est constitué de variables aléatoires *indépendantes et identiquement distribuées* (iid) d'espérance mathématique nulle et de variance $\sigma^2 < \infty$.
- ▶ **Bruit blanc faible:** le processus $\{w_t, t \in \mathbb{Z}\}$ est constitué de variables aléatoires *non-corrélées*, d'espérance mathématique nulle et de variance $\sigma^2 < \infty$.
- ▶ **Le bruit blanc Gaussien est un bruit blanc fort.**

Exemple: bruit blanc Gaussien

500 réalisations d'un bruit blanc gaussien


- ▶ 500 réalisations *iid* d'une $N(0,1)$;
- ▶ Série pas très lisse;
- ▶ Points adjacents ne sont pas corrélés.




Exemple: Logarithme des rendements mensuels pour IBM et S&P 500

- ▶ Considérons une série de prix $\{P_t, t \in \mathbb{Z}\}$. Les rendements sont définis comme:
 - ▶ $R_t = (P_t - P_{t-1})/P_{t-1}$.
- ▶ Définition des log(rendements):
 - ▶ $\log(1 + R_t) = \log(P_t/P_{t-1})$
- ▶ Données mensuelles (janvier 1926 à décembre 1999).
- ▶ Souvent les rendements sont des bruits blancs (effets de microstructure pourraient occasionner de la corrélation).
- ▶ S&P 500 est un bruit blanc faible, mais pas un bruit blanc fort.

IBM



indice S&P 500



Exemple: moyenne mobile


- ▶ Soit $\{w_t, t \in \mathbb{Z}\}$ un bruit blanc *iid* Gaussien.
- ▶ Considérons la moyenne mobile:
- ▶
$$v_t = \frac{(w_{t-1} + w_t + w_{t+1})}{3}$$
- ▶ Version du bas plus lisse; oscillations plus lentes sont mises de l'avant; certaines oscillations plus rapides sont éliminées.

Commandes R:


```
w <- rnorm(500, 0, 1)
```

```
v <- filter(w, sides=2, rep(1,3)/3)
```

500 réalisations d'un bruit blanc gaussien



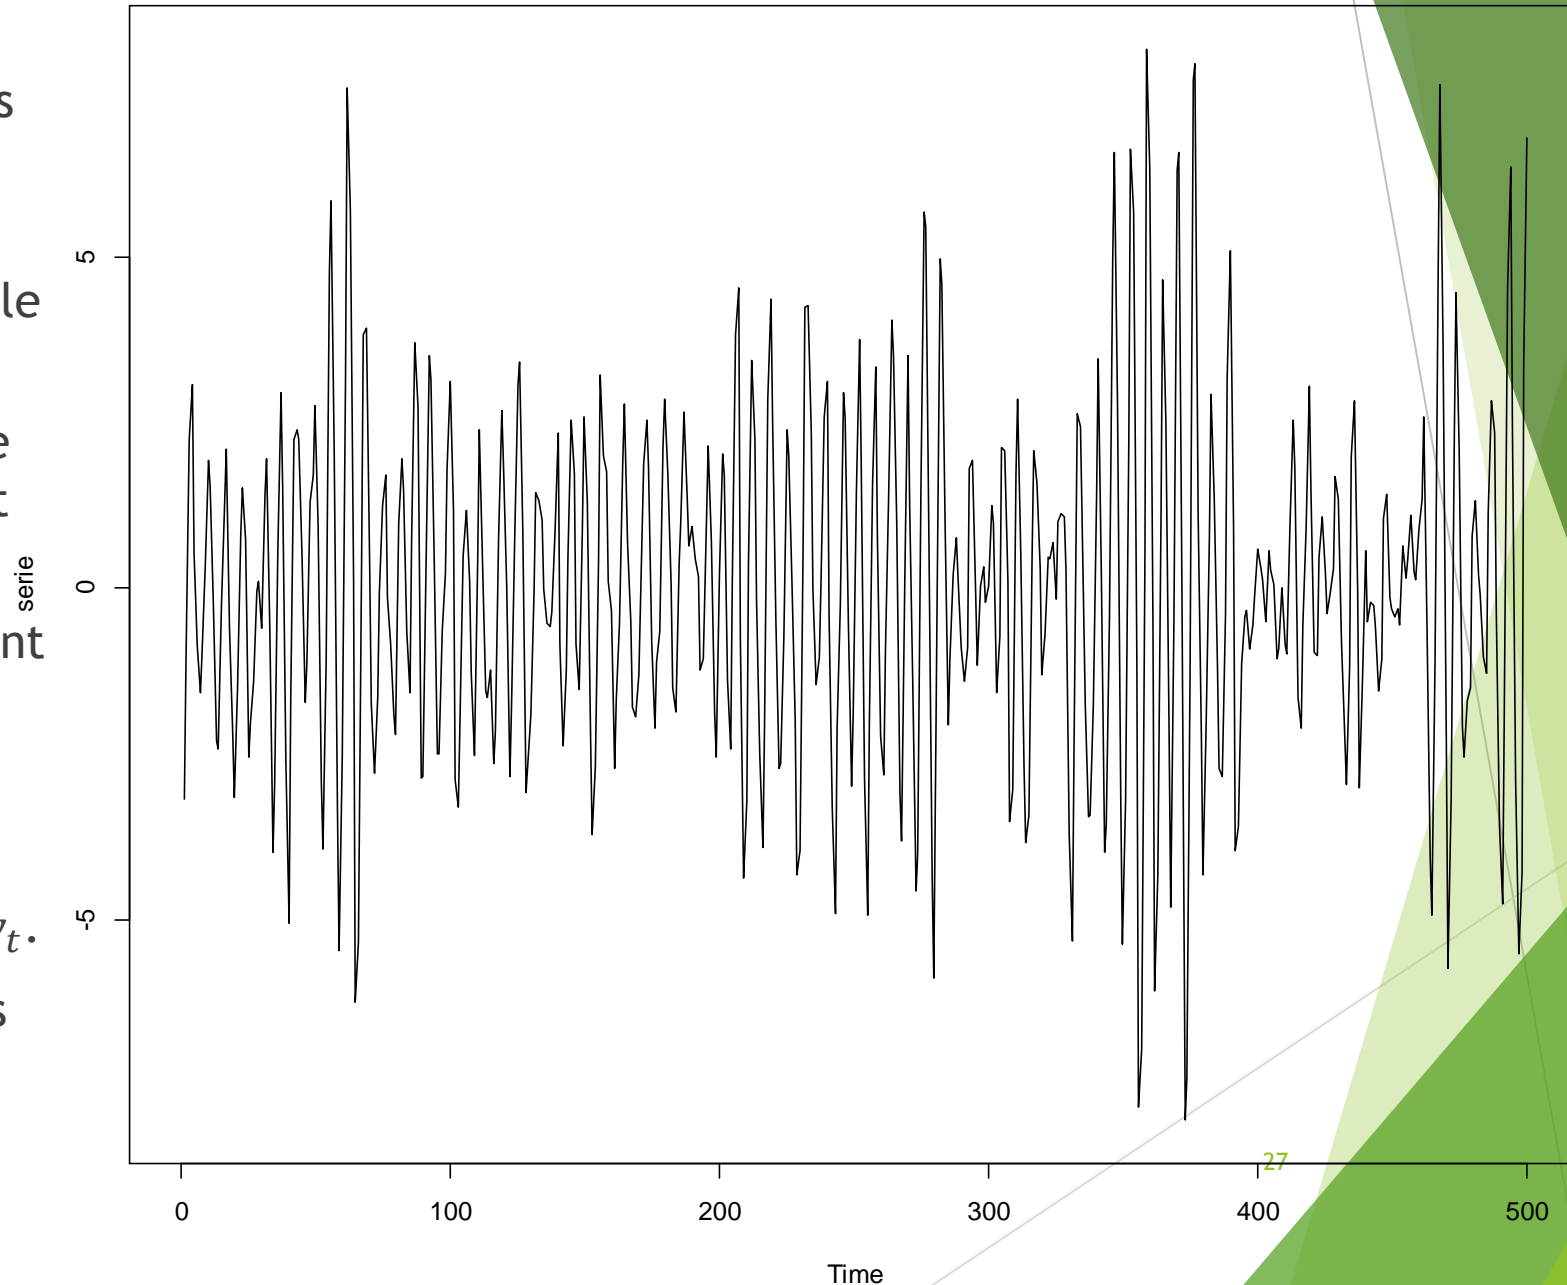
Exemple d'une moyenne mobile



Exemple: autorégression

Exemple d'une série autorégressive

- ▶ Certaines séries chronologiques ne sont pas compatibles avec les moyennes mobiles.
- ▶ Exemple: Série sur la parole « Aaa...hhh ».
- ▶ Comportement oscillatoire particulier: comportement sinusoïdal;
- ▶ Les *autorégressions* peuvent générer ce genre de phénomènes;
- ▶ Exemple:
$$X_t = X_{t-1} - 0.90 X_{t-2} + w_t.$$
- ▶ Note: problème de valeurs initiales X_0 et X_{-1} .



Exemple: signal plus un bruit

► Plusieurs modèles supposent un signal avec une certaine variation périodique, contaminé par l'ajout d'un bruit. Soit encore $\{w_t, t \in \mathbb{Z}\}$ un bruit blanc *iid* Gaussien.

► Signal principal: $Y_t = \cos\left(\frac{2\pi t}{50}\right)$

► 1) signal non contaminé;


► 2) $Y_t = \cos\left(\frac{2\pi t}{50}\right) + w_t$;

► 3) $Y_t = \cos\left(\frac{2\pi t}{50}\right) + 5w_t$.


► L'ajout du bruit blanc obscurci le signal.

► L'analyse spectrale est une technique cherchant à détecter les signaux réguliers ou périodiques.


Signal: Vague cosinus



Vague cosinus + bruit gaussien



Vague cosinus + 5 * bruit gaussien



Mesures de dépendance

- ▶ Supposons que l'on dispose d'une série chronologique observée aux temps t_1, t_2, \dots, t_n , pour $n \geq 1$.
- ▶ Une description complète est fournie par la fonction de répartition conjointe:
 - ▶ $F_{X_{t_1}, X_{t_2}, \dots, X_{t_n}}(c_1, c_2, \dots, c_n) = P(X_{t_1} \leq c_1, \dots, X_{t_n} \leq c_n)$
- ▶ La fonction de répartition est souvent difficile à utiliser, sauf dans le cas particulier où le processus $\{X_t, t \in \mathbb{Z}\}$ est un processus *iid*:
 - ▶ $F_{X_{t_1}, X_{t_2}, \dots, X_{t_n}}(c_1, c_2, \dots, c_n) = \prod_{t=1}^n F_X(c_t)$.
- ▶ Dans la formule précédente, $F_X(\cdot)$ est la fonction de répartition de X_t .
- ▶ Un cas particulier important où l'on peut décrire la loi conjointe et dans le cas d'un processus Gaussien: la loi conjointe est alors multinormale.

Densité de X_t

- ▶ Dans notre contexte, il peut être d'intérêt de connaître la densité de X_t :
 - ▶ $F_{X_t}(x) = P(X_t \leq x)$;
 - ▶ $f_{X_t}(x) = \frac{\partial F_{X_t}(x)}{\partial x}$.
- ▶ À moins d'indications contraires, il n'est pas trop restrictif pour nous de supposer l'existence des densités.