

Classification de séries temporelles

Applications à la prévision et la désaisonnalisation

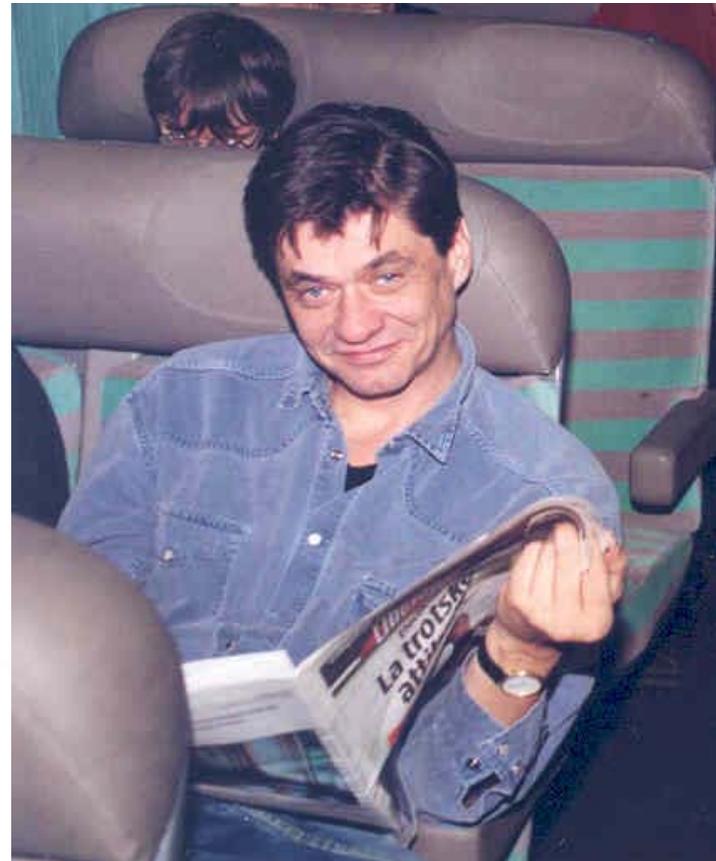
JMS - 23 mars 2009

Dominique Ladiray
DSCT



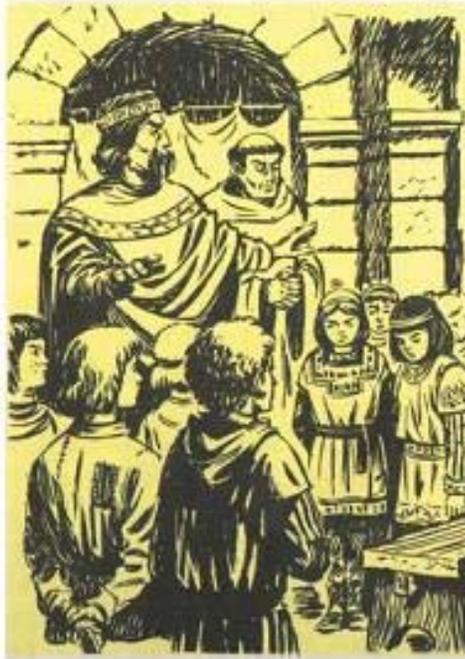


- › En hommage à Jean-Michel.
Sans lui, ces JMS ont un petit
goût amer

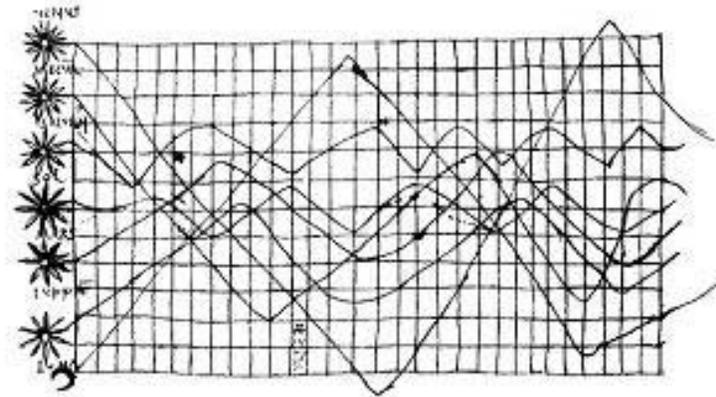




Classification et séries temporelles



Quelque part entre 768 et 814



Macrobius (Saturnales, 395)

- › Deux disciplines très anciennes dont les chemins se sont rarement croisés jusqu'à récemment.



Introduction

- › La classification
 - Regrouper les individus en groupes homogènes
 - 2 individus du même groupe se ressemblent ; 2 individus de 2 groupes distincts sont différents.
 - Une méthode « naturelle » et exploratoire ancienne pour les données d'enquête
 - Principes de la CAH : Andanson, Histoire naturelle du Sénégal, 1757. Mais, bien avant, Charlemagne déjà
- › Comment transposer ces méthodes aux cas des séries temporelles et pourquoi faire ? (prévision, désaisonnalisation)
- › Exposé volontairement peu technique



Plan

- › Comment classer des individus ?
 - Distances et stratégies
- › Le cas spécifique des séries temporelles
 - Les problèmes
 - Quelques idées et méthodes pour y remédier
- › Application à la désaisonnalisation
 - Les différentes facettes de la saisonnalité
- › Application à la prévision
 - A la recherche d'un modèle



Distances et stratégies

- › Regrouper les individus en classes homogènes
 - Les individus d'une même classe sont « proches »
 - Notion de distance-similarité
 - \exists centaines de distances/similarités (dont euclidienne)
- › Rendre les classes les plus différentes possibles
 - Stratégie d'agrégation de classes
 - \exists dizaines de stratégies
 - Dont Ward: maximiser la variance inter-classes
- › Le choix de la distance et de la stratégie dépend du problème à traiter Un petit exemple



Distance-similarité Un concept très relatif





Restons politiquement correct





Quelques méthodes

- › Méthodes de partitionnement
 - On définit a priori un nombre de classes et on cherche une partition de la population
 - Centres mobiles, nuées dynamiques
- › Méthodes hiérarchiques
 - Ascendantes, descendantes
 - Arbre de classification (dendogramme)
- › Peut-on adapter ces méthodes au cas des séries temporelles ?



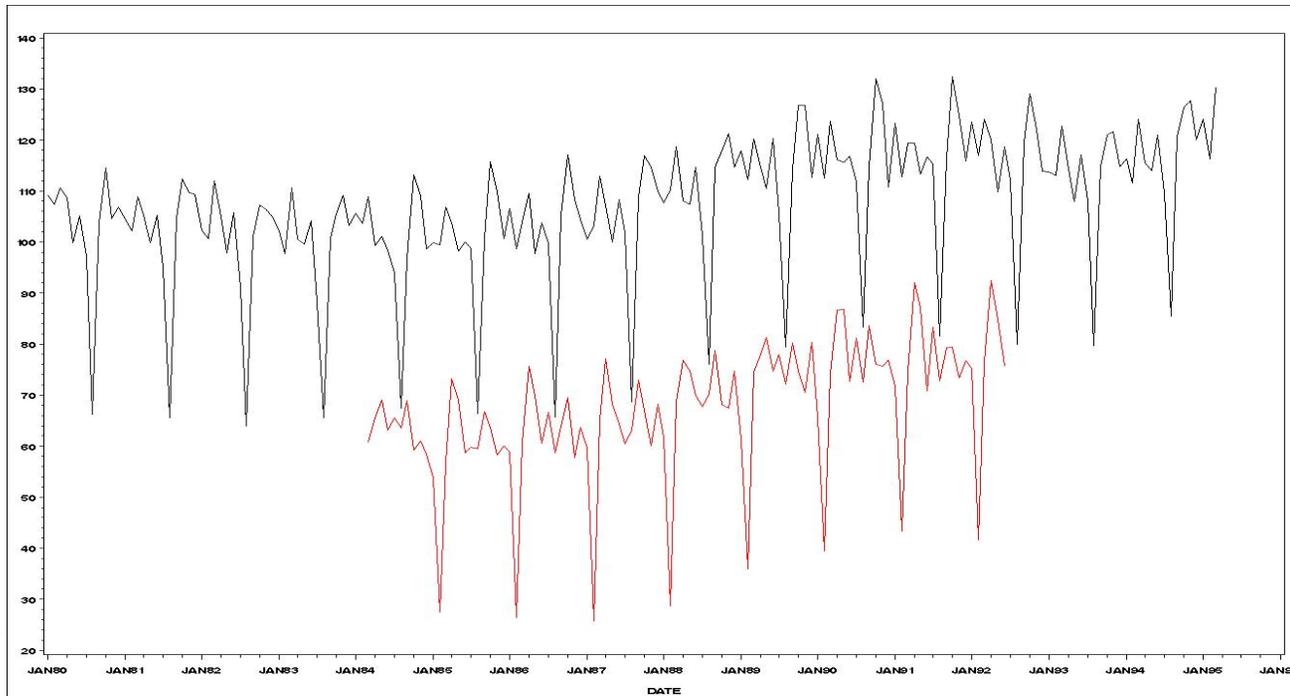
Une explosion d'intérêt

- › Depuis 20 ans arrivée d'immenses bases de séries temporelles
 - Génome humain, consommation d'énergie, météorologie, reconnaissance de la parole, de l'écriture etc.
- › Besoin de méthodes pour explorer ces bases
- › Depuis 20 ans, des centaines de papier pour indexer, classer, discriminer les séries temporelles
- › Passage à l'économie plus récent (séries plus courtes et moins nombreuses)



Le problème fondamental

› Similarité ?



- › Distance euclidienne pas toujours adaptée.
- › Que faire ?

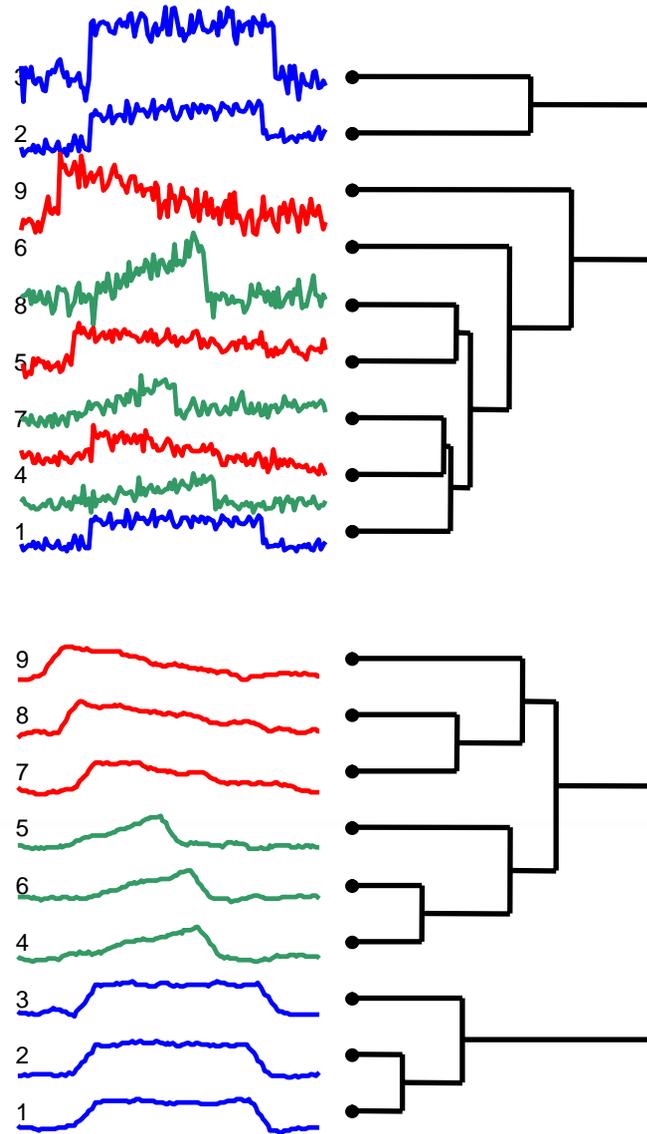
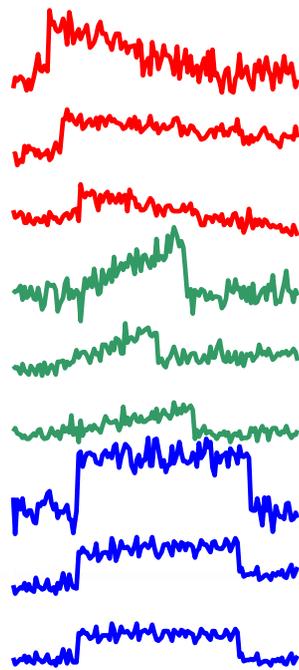


Quelques idées

- › Préparer les données à la classification
 - Lissage, changement d'échelle, enlever la tendance etc.
- › Inventer de nouvelles distances
 - Exemple : Dynamic Time Warping
(To warp : voiler, gondoler, courber)
- › Décrire les données de façon plus « économe »
 - Fonctions d'autocorrélation, Spectre, ondelettes etc.
- › Modélisation stochastique les données
 - Modèles AR ou ARIMA, markovien caché (HMM) etc.
 - Distances spéciales (Corduas et Piccolo, 2008).

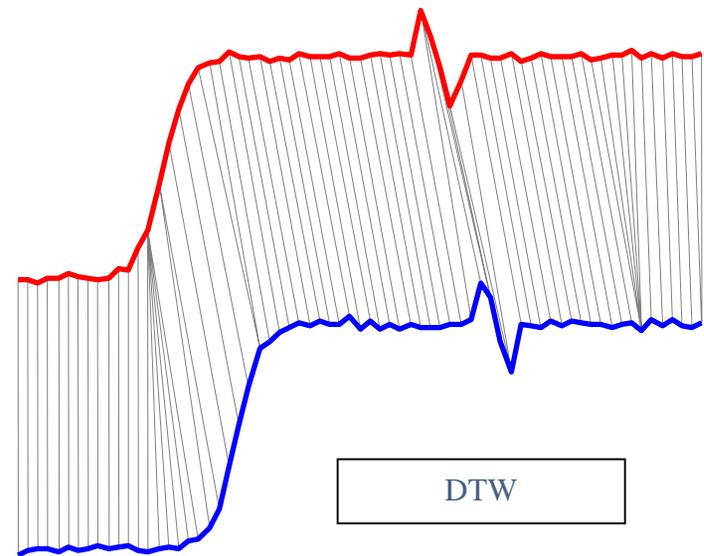
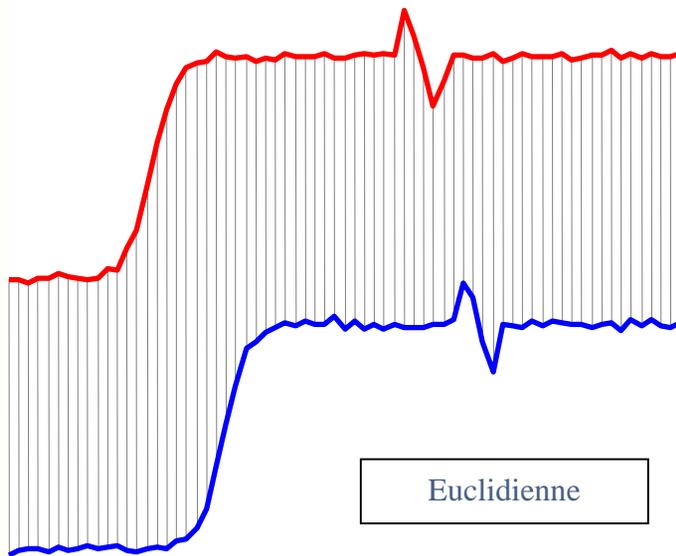


Préparer les données





Dynamic Time Warping



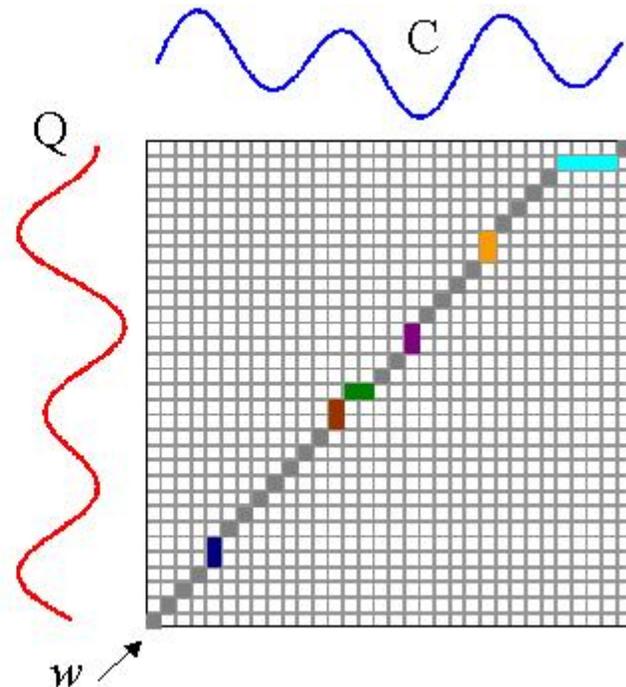
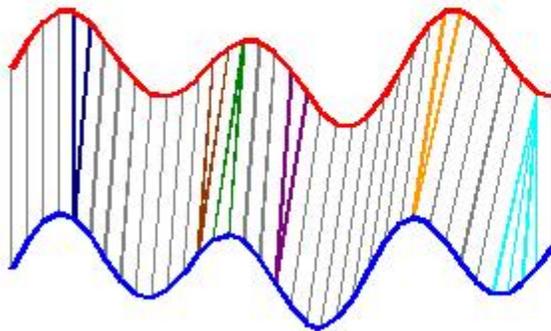
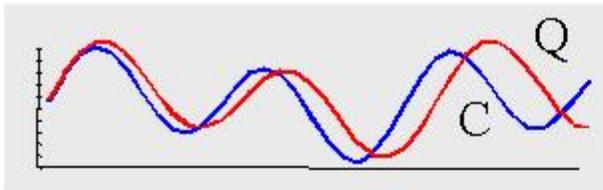
- › Enquêtes de conjoncture
- › Mais coûteux en temps de calcul



Calcul de la distance DTW

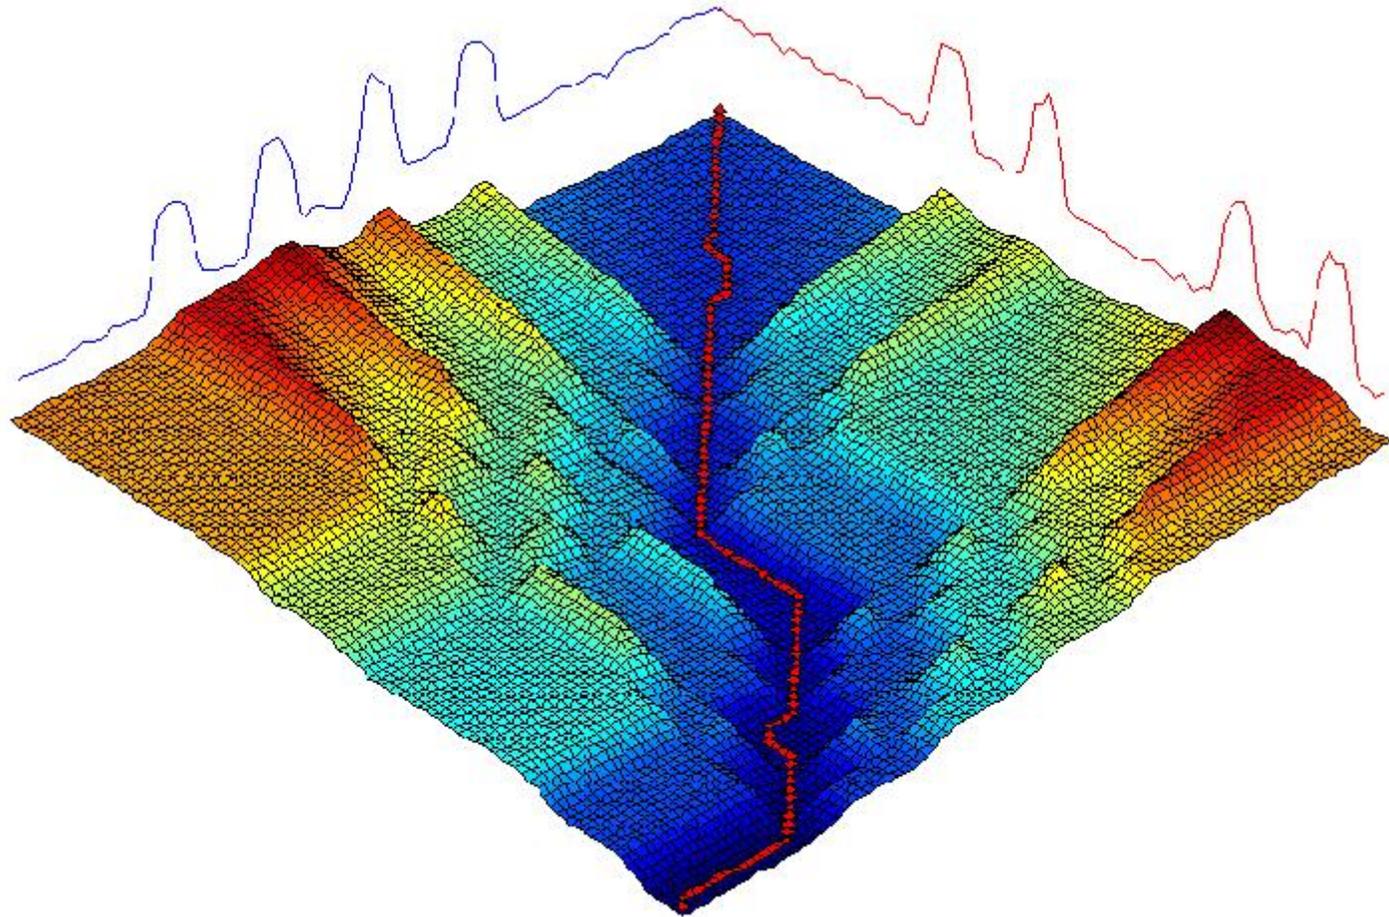
- › Tout chemin dans la matrice des distances est une « courbure du temps ». On choisit la « meilleure », la « plus courte »

$$DTW(Q, C) = \underset{w}{\text{Min}} \frac{1}{N} \sum_{k=1}^{k=N} w_k$$





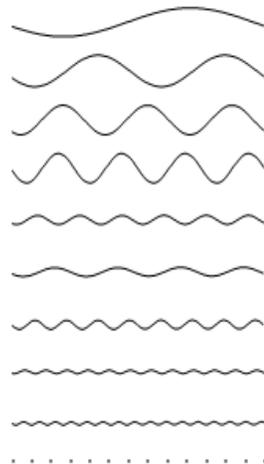
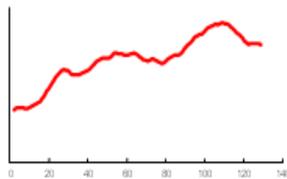
Un exemple réel





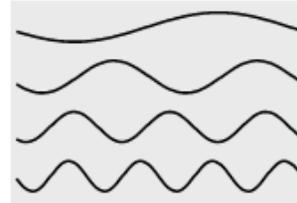
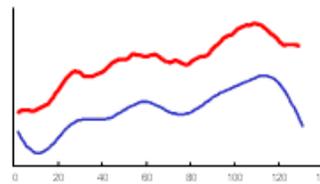
« Réduire » les données : un exemple

Série brute, coefficients de Fourier et fonctions associées

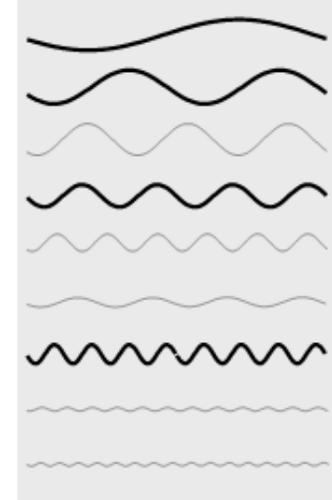
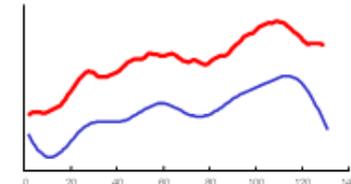


0.4995	1.5698
0.5264	<u>1.0485</u>
0.5523	0.7160
0.5761	<u>0.8406</u>
0.5973	0.3709
0.6153	<u>0.4670</u>
0.6301	0.2667
0.6420	<u>0.1928</u>
0.6515	0.1635
0.6596	<u>0.1602</u>
0.6672	0.0992
0.6751	<u>0.1282</u>
0.6843	0.1438
0.6954	<u>0.1416</u>
0.7086	0.1400
0.7240	<u>0.1412</u>
0.7412	0.1530
0.7595	<u>0.0795</u>
0.7780	0.1013
0.7956	<u>0.1150</u>
0.8115	0.1801
0.8247	<u>0.1082</u>
0.8345	0.0812
0.8407	<u>0.0347</u>
0.8431	0.0052
0.8423	<u>0.0017</u>
0.8387	0.0002
...	...

Décomposition sur les 4 premières fonctions



Décomposition sur les 4 plus importantes fonctions



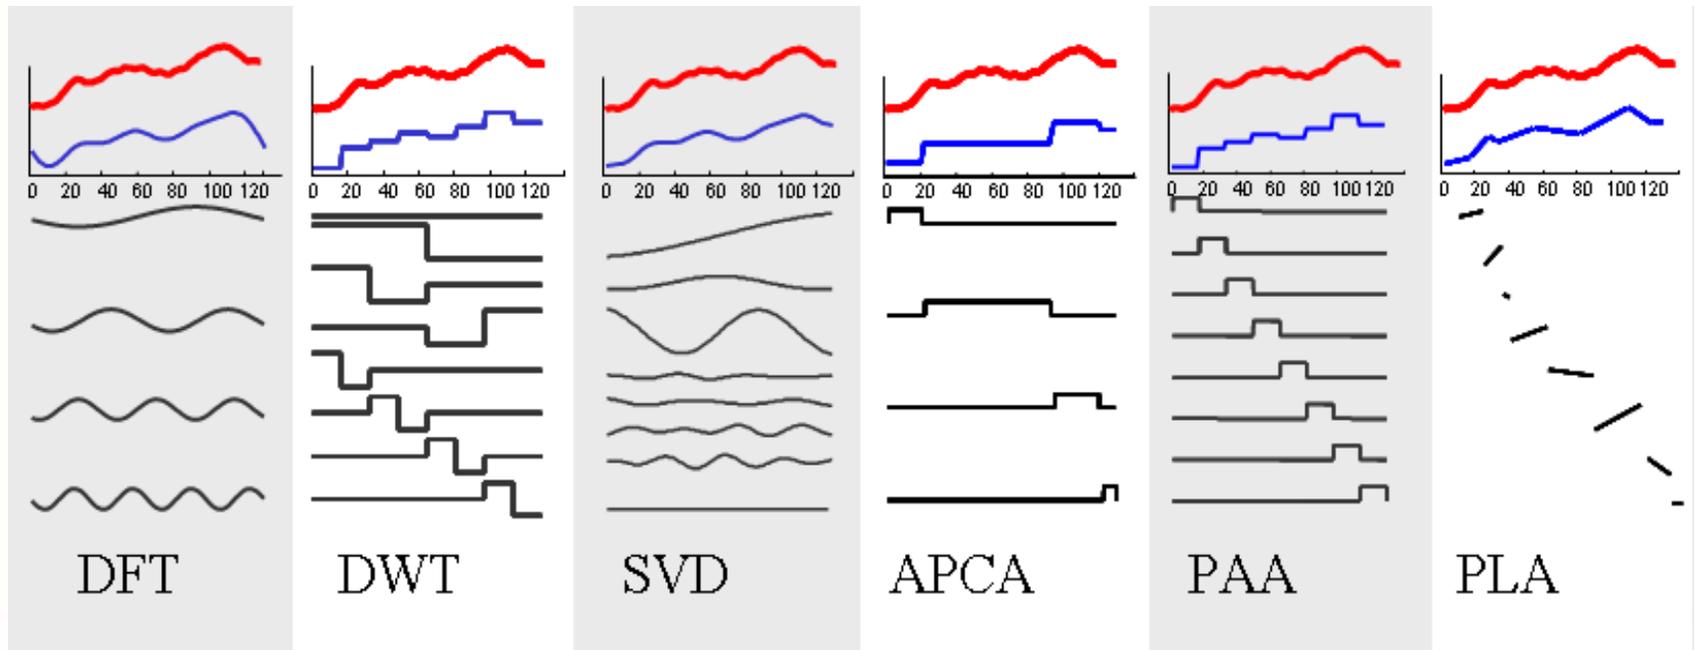


De nombreuses autres idées

- › Fonctions d'autocorrélation directe, inverse, partielle (ACF, PACF, IACF) (Maballée and Maballée, 1911; Wang and Wang., 2000);
- › Transformée de Fourier discrète (DFT) (Agrawal et al., 1993);
- › Transformées par ondelettes, utilisant les bases de Daubechies, Haar (DWT) ou autres (Huntala et al., 1997);
- › Polynômes de Chebyshev (Ng and Cai, 2004)
- › Codage du Cepstrum (LPC), (Kalpakis et al., 2001);
- › Décomposition en valeurs singulières via une ACP par exemple (Korn et al., 1997; Cleveland, 2004);
- › Approximations linéaires par morceaux (Morikane et al., 2001);



Un petit dessin pour mieux comprendre





La désaisonnalisation

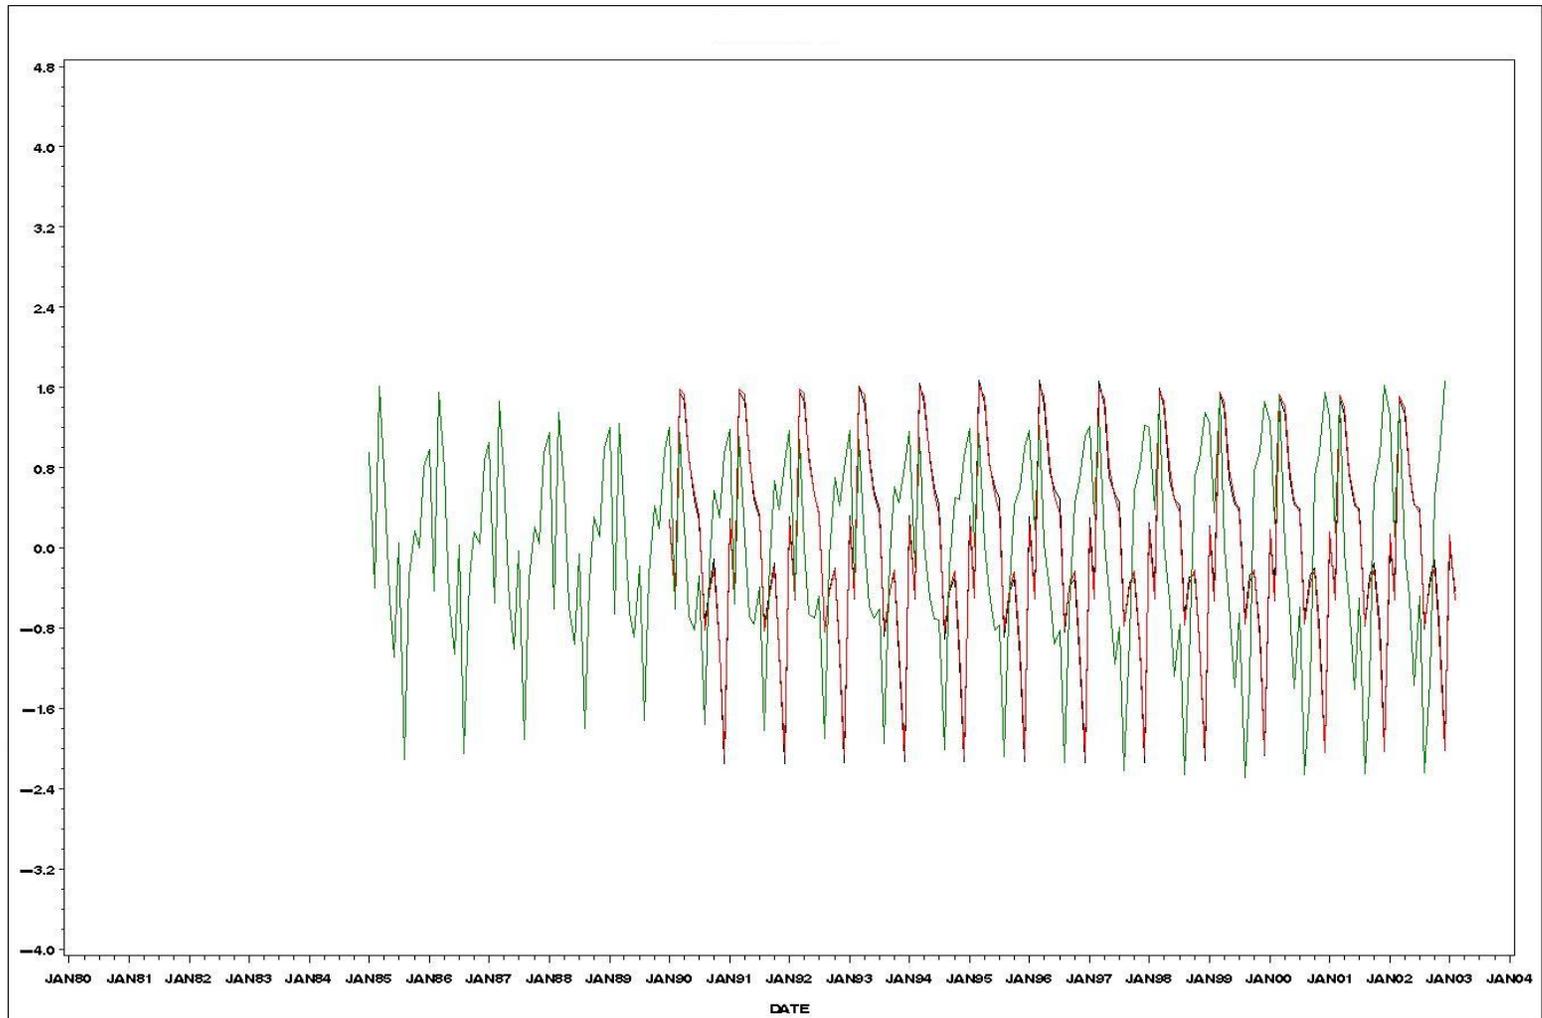
- › Un modèle complexe

$$X_t = TC_t + S_t + TD_t + MH_t + O_t + I_t$$

- › Où seule la série X_t est observable.
- › A quoi ressemble la saisonnalité S_t ?
- › Désaisonnalisation de 1100 séries mensuelles de la base Euro-Indicateurs avec Tramo-Seats et X12-Arima
- › On classe ensuite les spectres des 2200 composantes saisonnières obtenues

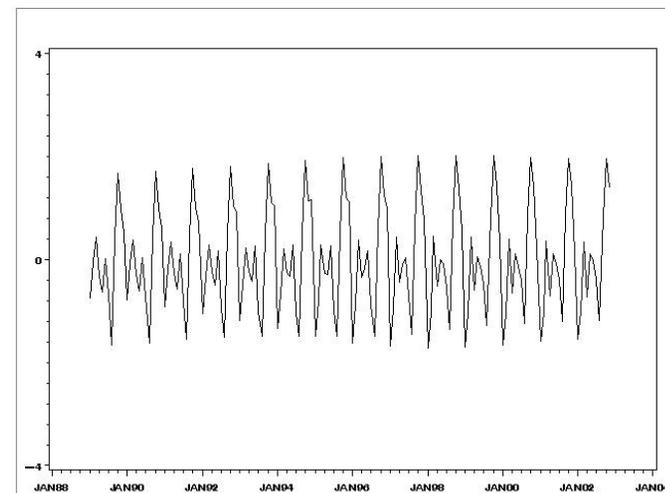
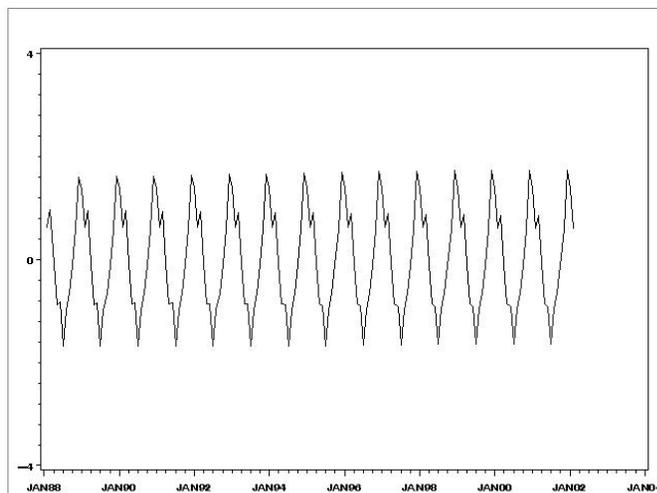
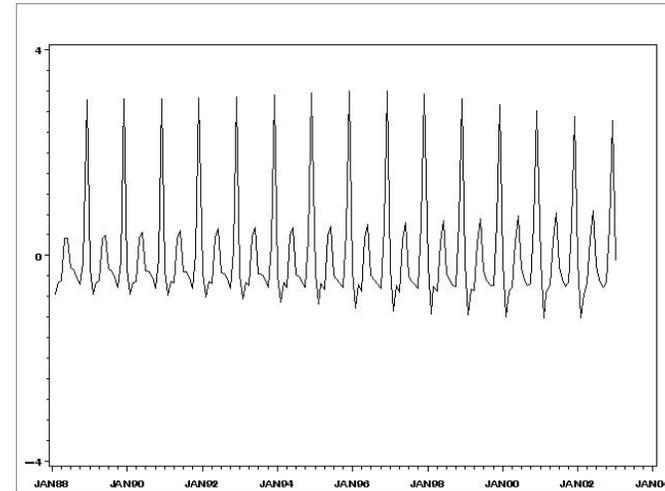
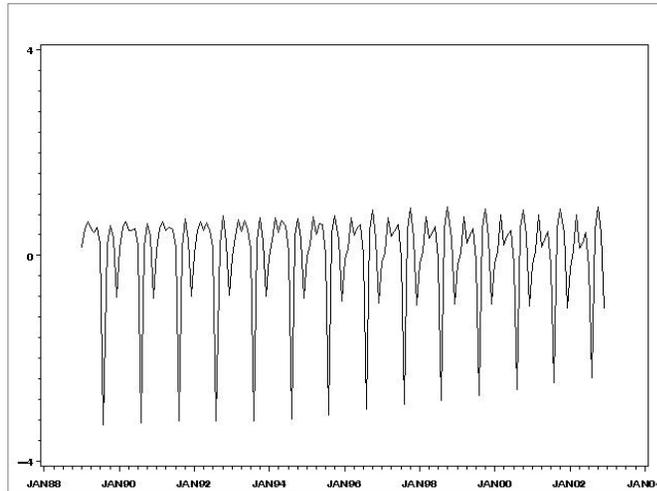


Quelques parangons





Quelques saisonnalités caractéristiques





Les séries « Frankenstein »

- › La classification des diverses composantes permet de définir des composantes « types » :
 - Tendances-cycles, saisonnalité, effets de jours ouvrables

- › Et donc, par combinaison, de définir des séries « Frankenstein », de « fausses-vraies » séries qui permettent:
 - D'évaluer la qualité des méthodes de désaisonnalisation
 - De tester de nouvelles méthodes;
 - De proposer des valeurs par défaut adaptées pour les paramètres des logiciels.



Application à la prévision économique

- › Problème : le PIB trimestriel de la zone Euro est publié à $t+45$, beaucoup plus tard que le PIB américain.
- › Peut-on publier plus tôt ?
 - Très difficile d'accélérer la production
 - ⇒ Utiliser des modèles économétriques
- › On connaît en effet beaucoup de choses sur le trimestre qui vient de s'écouler :
 - 2 mois au moins d'IPI, CA etc.
 - enquêtes de conjoncture
- › Comment trouver un modèle ?????



Qu'est-ce qu'un bon modèle ?

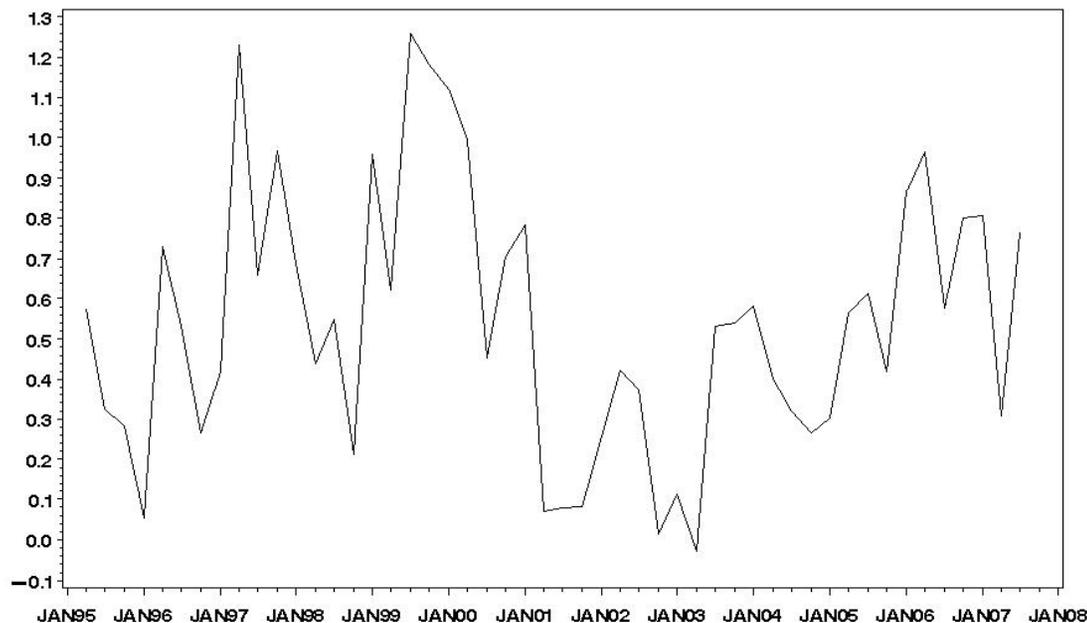
- › Plusieurs caractéristiques importantes :
 - il doit être simple, c'est-à-dire ne faire intervenir qu'un nombre limité de variables,
 - il doit être interprétable : les relations exprimées doivent avoir un sens économique,
 - il doit être stable dans le temps, et en particulier ne doit pas être remis en cause chaque mois,
 - et enfin, il doit avoir un bon pouvoir prédictif.

- › Mélange de caractéristiques « économiques » (1,2) et « statistiques » (3,4)



La variable à expliquer

- › Le glissement trimestriel du PIB de la zone Euro (EA13)



- › Ajustement automatique d'un $(0,1,1)$ par Tramo : $Rmse=0.29$



Les variables explicatives

- › Facile de trouver une vingtaine de variables candidates :
 - IPI, CA, Commandes, Immatriculations, enquêtes de conjoncture, IPC, prix de l'énergie, construction etc.
- › 20 variables, 13 pays + EA, 2 retards ?
 - $20 \times (13 + 1) \times 3 = 840$ variables potentielles
- › Plus de 20 milliards de modèles à 4 variables !!!!
- › Comment choisir ?????



La sélection de variables

- › Vous devez (?) réduire le nombre d'exogènes
 - Approche usuelle par tâtonnement : ne marche pas !!!
Principe Shadok: « *Plus ça rate, plus on a de chances que ça marche !* »
 - Approche du NIESR (J. Mitchell)
Partir d'un ensemble très réduit de variables et évaluer tous les modèles possibles
 - Approche GETS (General to specific; Hendry)
Partir d'un modèle sur-paramétré et utiliser des tests statistiques pour le simplifier
 - Approche par Analyse Factorielle Dynamique
Résumer l'ensemble des variables en quelques facteurs
 - Approche par classification



Les variables explicatives

- › Exemple
 - On veut “prévoir” 2007Q4 à 30 jours..
 - On regarde ce qui est disponible au 30/01/2008

- › Variables de la base Euro-Indicateurs
 - 668 mensuelles; 162 trimestrielles
 - Nettoyage des variables (points atypiques)
 - Prévision des mensuelles et trimestrialisation



Classification et sélection

› Sélection des variables

- Classification des exogènes en groupes de variables “semblables”
- Sélection de quelques variables dans chaque classe en utilisant des tests de Causalité, des corrélations etc. Ou bien prendre les facteurs principaux de chaque classe
- Exemple: 8 classes, 2 variables par classe, 2 retards
→ 48 variables potentielles → 200,000 modèles à 4 exogènes.



Evaluation des modèles

- › Première sélection des modèles par régression MCO stepwise
 - R-square, Mallow's Cp, Adjusted R-square etc.
- › Evaluation complète des modèles (régression avec auto-corrélation des erreurs)
 - Toute la batterie de tests traditionnels
 - Cohérence de signe avec Y, erreurs de prévisions à l'horizon 1 et 2 etc.
- › Liste de n modèles classés par « pertinence statistique »



Choix des modèles

- › Le choix final du modèle est alors basé sur des critères statistiques et sur des « critères d'expert » :
 - Le modèle a-t-il toutes les qualités statistiques requises ?
 - Est-il suffisamment simple et robuste ?
 - Est-il pertinent du point de vue économique et interprétable ? En général NON !!!

- › Mais peut-être facilement amélioré en utilisant des variables de la même classe !!



Exemple

Rang	Modèle	R2	RMSE
1	ET_BAL_GR IO_PL IP_EA13 UE_NL	0,933	0,133
2	IO_PL IP_EA13 UE_NL	0,921	0,136
3	IO_PL IP_EA13 IT_RT_IE UE_NL	0,876	0,141
4	EPI_BU_PL IO_PL IP_EA13 UE_FR	0,869	0,144
5	IO_PL IP_EA13 IP_PT UE_NL	0,862	0,148
6	DIT_EA13 IO_PL IP_EA13 UE_NL	0,856	0,148
7	IO_PL IP_EA13 IT_RT_IE UE_FR	0,855	0,148
8	IO_PL IP_EA13 SV_PR_ES UE_FR	0,855	0,151
9	IOB_EA13 IO_PL IP_EA13 IT_RT_IE	0,851	0,153
100	PIB_EA13_1 PIB_EA13_2	0,257	0,296
101	PIB_EA13_1	0,226	0,296
102	PIB_EA13_2	0,040	0,298

- › Modèle 2 : IO_PL, IP_EA13, UE_NL
 - IO_PL est proche de EXP_EA13
 - UE_NL est proche de UN_EA13
- › Nouveau modèle : EXP_EA13, IP_EA13, UN_EA13 (Rmse=0.15)



Les 2 modèles

