

Comment juger de la qualité d'une désaisonnalisation ?

Himpens Stéphanie
Unité Méthodologie d'Entreprises (INSEE)



Caractéristiques des désaisonnalisations pratiquées au DSCT (Département des Statistiques de Court Terme) de l'INSEE

Séries désaisonnalisées

IPI : 91 séries (niveau **NACE3**)

Indices de chiffres d'affaires : 440 séries (niveau **NACE3** dans l'industrie et **NACE5** dans les autres secteurs).

Toutes les séries sont **mensuelles**.

Organisation des désaisonnalisations

En conformité avec les recommandations des lignes directrices européennes, deux types de campagnes existent :

Chaque année, recherche complète des paramètres de désaisonnalisation de toutes les séries

Chaque mois, utilisation des paramètres choisis précédemment. Les valeurs extrêmes (outliers) sont identifiées uniquement sur la période récente.

=> Ceci correspond à un ajustement de type concurrent partiel.

Organisation des désaisonnalisations

Désaisonnalisation de type indirecte :

Les séries CVS-CJO des agrégats sont estimées comme des moyennes pondérées des séries désaisonnalisées qui les constituent.

Des diagnostics nombreux dans Demetra+

Nombre de diagnostics

+ 2

+ 1

+ 4

+ 3

etc.

Spec: Source : User Name : RF104

- [-] Main results
 - ... Charts
 - ... Table
 - ... S-I ratio
- [-] Pre-processing (RegArima)
 - ... Pre-adjustment series
- ... Arima
- ... Regressors
- [-] Residuals
 - ... Statistics
 - ... Distribution
- [-] Decomposition (X11)
- [-] Diagnostics

Pre-processing (RegArima)

Estimation span: [1-1990 : 2-2011]
Series has been log-transformed
Trading days effects (6 variables)
No easter effect
No outliers found

Diagnostics

summary
Good

basic checks
definition: Good (0.000)
annual totals: Uncertain (0.014)

visual spectral analysis
spectral seas peaks: Good
spectral td peaks: Good

~45 « diagnostics »

à vérifier par série

stique 2012

De la nécessité de résumer l'information

- Impossible de les vérifier TOUS les diagnostics précédents dans le cas où l'on souhaite désaisonnaliser plusieurs centaines de séries
- Ces diagnostics concernent différentes parties du traitement ayant des influences les unes sur les autres.
- Impossibilité parfois de rendre la totalité des diagnostics satisfaisants dans les délais.

=> nécessité de résumer l'information sur la qualité au niveau de chaque série afin de visualiser rapidement les cas les plus problématiques.

Le Résumé de la qualité dans Demetra+ (nœud Main Result)



Résumé de la qualité dans Demetra+

- Des règles d'agrégation permettent d'évaluer la qualité globale de désaisonnalisation de chaque série

- Une évaluation de la qualité sous forme de **commentaires** au niveau d'une **sélection restreinte de diagnostics** (non modifiable par l'utilisateur)
- 6 commentaires de qualité : Undefined, **Error**, **Severe**, **Bad**, **Uncertain** et **Good**

summary
Good

basic checks
definition: Good (0.000)
annual totals: Uncertain (0.014)

visual spectral analysis
spectral seas peaks: Good
spectral td peaks: Good

regarima residuals
normality: Bad (0.001)
independence: Good (0.575)
spectral td peaks: Good (0.177)
spectral seas peaks: Uncertain (0.021)

Résumé de la qualité dans Demetra+

Series	Method	Esti...	Pro...	Quality
RF061	X12	Fre...	Valid	Good
RF062	X12[RS...	Fre...	Valid	Good
RF081	X12	Fre...	Valid	Good
RF089	X12	Fre...	Valid	Severe
RF101	X12	Fre...	Valid	Severe
RF103	X12	Fre...	Valid	Uncer...
RF104	X12	Fre...	Valid	Good
RF105	X12	Fre...	Valid	Severe
RF106	X12	Fre...	Valid	Good
RF107	X12	Fre...	Valid	Good
RF108	X12	Fre...	Valid	Good
RF109	X12	Fre...	Valid	Uncer...
RF110	X12	Fre...	Valid	Good
RF120	X12	Fre...	Valid	Good
RF131	X12	Fre...	Valid	Good
RF132	X12	Fre...	Valid	Good
RF133	X12	Fre...	Valid	Severe

- Le résumé de la qualité apparaît dans la fenêtre listant les séries

Limites du résumé de la qualité de Demetra+

- Impossibilité de choisir les diagnostics utilisés dans le résumé de la qualité
- La pondération des diagnostics est très sommaire (agrégation de commentaires)
- Pas de visualisation possible de la qualité des différents groupes de diagnostics au niveau de toutes les séries (dans une table par exemple)

=> Réalisation d'un bilan qualité sous SAS.

Le bilan qualité élaboré au DSCT



Le Bilan qualité

Le fait de disposer d'une évaluation synthétique de la qualité ne dispense pas de vérifier les diagnostics dans Demetra+.

Une vérification systématique des diagnostics du nœud « Main Result » de Demetra+ est effectuée pour chacune des séries

L'ensemble des diagnostics détaillés est consulté en cas de qualité insatisfaisante

The screenshot shows the Demetra+ interface. On the left, a tree view under 'Spec:' lists various diagnostic options: 'Main results' (circled in red), 'Charts', 'Table', 'S-I ratio', 'Pre-processing (RegArima)', 'Pre-adjustment series', 'Arima', 'Regressors', 'Residuals', 'Statistics', 'Distribution', 'Decomposition (X11)', and 'Diagnostics'. A large red arrow points from the 'Main results' node down to the 'Diagnostics' node. On the right, the 'Source : User' panel displays a summary of results under 'Pre-processing' and 'Diagnostics'. The 'summary' section shows 'Good' in green. The 'basic checks' section shows 'definition: Good (I)' in green and 'annual totals: Unc' in orange.

Le Bilan qualité

Des notes (valeurs numériques) sont calculés à l'aide de programmes SAS.

La qualité globale du modèle ARIMA est évaluée par une moyenne pondérée des autres notes.

Dans les colonnes ci-dessous, la note est égale à 100 si le test est non rejeté à 5% pour la série, à 50 si le test est rejeté à 5% mais non rejeté à 1% et à 0 si il est rejeté à 1%.

	series names	Note de qualité globale des outliers	...	Note de qualité globale du modèle ARIMA	Note associé au test de Box-Pierce	Note associée au test de Ljung-Box	Note sur la statistique de Ljung-Box sur le carré des résidus	Note sur la statistique de Box-Pierce sur le carré des résidus	Note sur la normalité	Note sur le test du Kurtosis	Note sur le test du Skweness
1	_4511Z	100		67	100	100	100	100	50	100	0
2	_4519Z	97		100	100	100	100	100	100	100	100
3	_4520A	.		100	100	100	100	100	100	100	100
4	_4520B	100		100	100	100	100	100	100	100	100

Le Bilan qualité

Les différents groupes de diagnostics sont :

- ✿ La qualité de la modélisation ARIMA
- ✿ La qualité des points aberrants (nombre et concentration)
- ✿ La qualité de décomposition (effets résiduels et orthogonalité des composantes)
- ✿ La qualité des révisions de type “History” (+stabilité des outliers détectés)

Le Bilan Qualité

Des moyennes pondérées des notes servent à évaluer la qualité des agrégats (désaisonnalisation indirecte). Les résultats sont résumés dans un fichier Excel :

			Note globale	Qualité du modèle reg-ARIMA				
			Note sur 20 points (modèle ARIMA et qualité de décomposition)	Tests du bruit blanc		Tests d'hétéroscédasticité		Examen des points aberrants
		Pondérations		Ljung-Box	Box-Pierce	Ljung-Box ² (sur le carré des résidus)	Box-Pierce ² (sur le carré des résidus)	% de points aberrants dans la série (doit être < 5%)
G		553 181 753	19	4	4	4	4	4
	45 Commerce et réparation	166 625 724	18	4	4	4	4	4
	45.11Z Commerce de voitures et de véhicules automobiles légers	103 915 133	18	4	4	4	4	4
	45.19Z Commerce d'autres véhicules automobiles	9 705 758	20	4	4	4	4	4
	45.20A Entretien et réparation de véhicules automobiles légers	16 907 061	20	4	4	4	4	4

Comparaisons de qualité et de résultats


Les fichiers sont élaborés de façon à mettre en avant les séries présentant une **amélioration** ou une **dégradation** de leur qualité.

Comp_Spécif	Comp_Qualité	Comp_Révisions
-------------	---------------------	----------------

Série	Pond	Tendance	Différences Qualité Nouveau/Ancien					
			Diff Note ARIMA	Diff Note Outliers	Diff Note CJO res	Diff Note CVS res	Diff Note Qualité Décomp	Diff Qualité Dem+
_4511Z	103 915 133	0	-11.1	0.0	0.0	0.0	0.0	0
_4519Z	9 705 758	0	0.0	0.0	0.0	0.0	0.0	0
_4520A	16 907 061	0	0.0	0.0	0.0	0.0	0.0	0
_4520B	2 175 770	0	0.0	0.0	0.0	0.0	0.0	1
_4531Z	16 759 511	0	-22.2	0.0	0.0	0.0	0.0	0
_4532Z	12 325 051	0	-11.1	5.6	0.0	0.0	0.0	0
_4540Z	4 837 440	0	22.2	5.6	100.0	0.0	0.0	0
_4711A	1 933 163	0	0.0	0.0	0.0	0.0	0.0	0
_4711B	5 472 522	0	0.0	8.3	100.0	0.0	0.0	0
_4711C	5 069 115	0	22.2	0.0	0.0	0.0	0.0	-1

Comparaisons de qualité et de résultats

Il est ensuite possible de connaître les différences dans les deux jeux de spécifications grâce à un autre onglet.



Différences entre les deux jeux de spécifications (0 = éléments différents, 1 = éléments identiques)

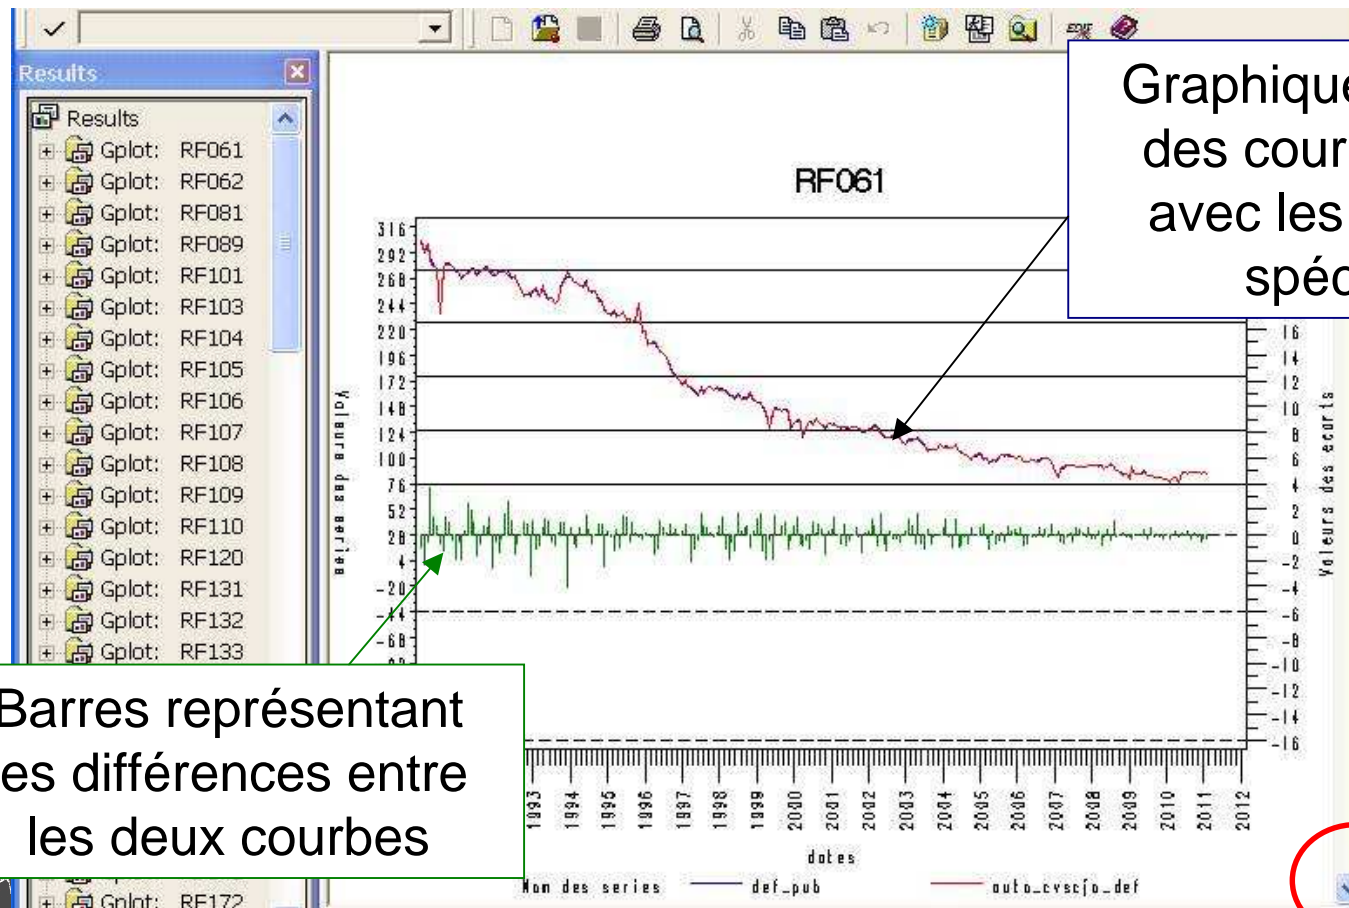
Détails des deux jeux de spécifications

Série	Séries suivies en tendance	Résumé				Modèle		Transformation	
		Modèles ARIMA égaux	Type transformation égaux (Add/Mult)	Jeux de régresseurs cjo égaux	Nombre outliers égaux	Nouveau	Ancien	Nouveau	Ancien
_4511Z	0	0	1	0	1	(0 1 1)(1 1 0)	(0 1 1)(0 1 1)	None	None
_4519Z	0	1	1	0	1	(0 1 1)(0 1 1)	(0 1 1)(0 1 1)	None	None
_4520A	0	1	1	0	0	(0 1 1)(0 1 1)	(0 1 1)(0 1 1)	Logarithm	Logarithm
_4520B	0	1	1	0	1	(0 1 1)(0 1 0)	(0 1 1)(0 1 0)	None	None
_4531Z	0	0	0	1	0	(1 1 0)(0 1 1)	(1 1 0)(0 1 0)	Logarithm	None

Séries suivies en tendance

Comparaisons de qualité et de résultats

Les graphiques superposant les résultats obtenus avec les différentes versions de spécifications sont tracés sous SAS. Il est possible de les faire défiler rapidement.



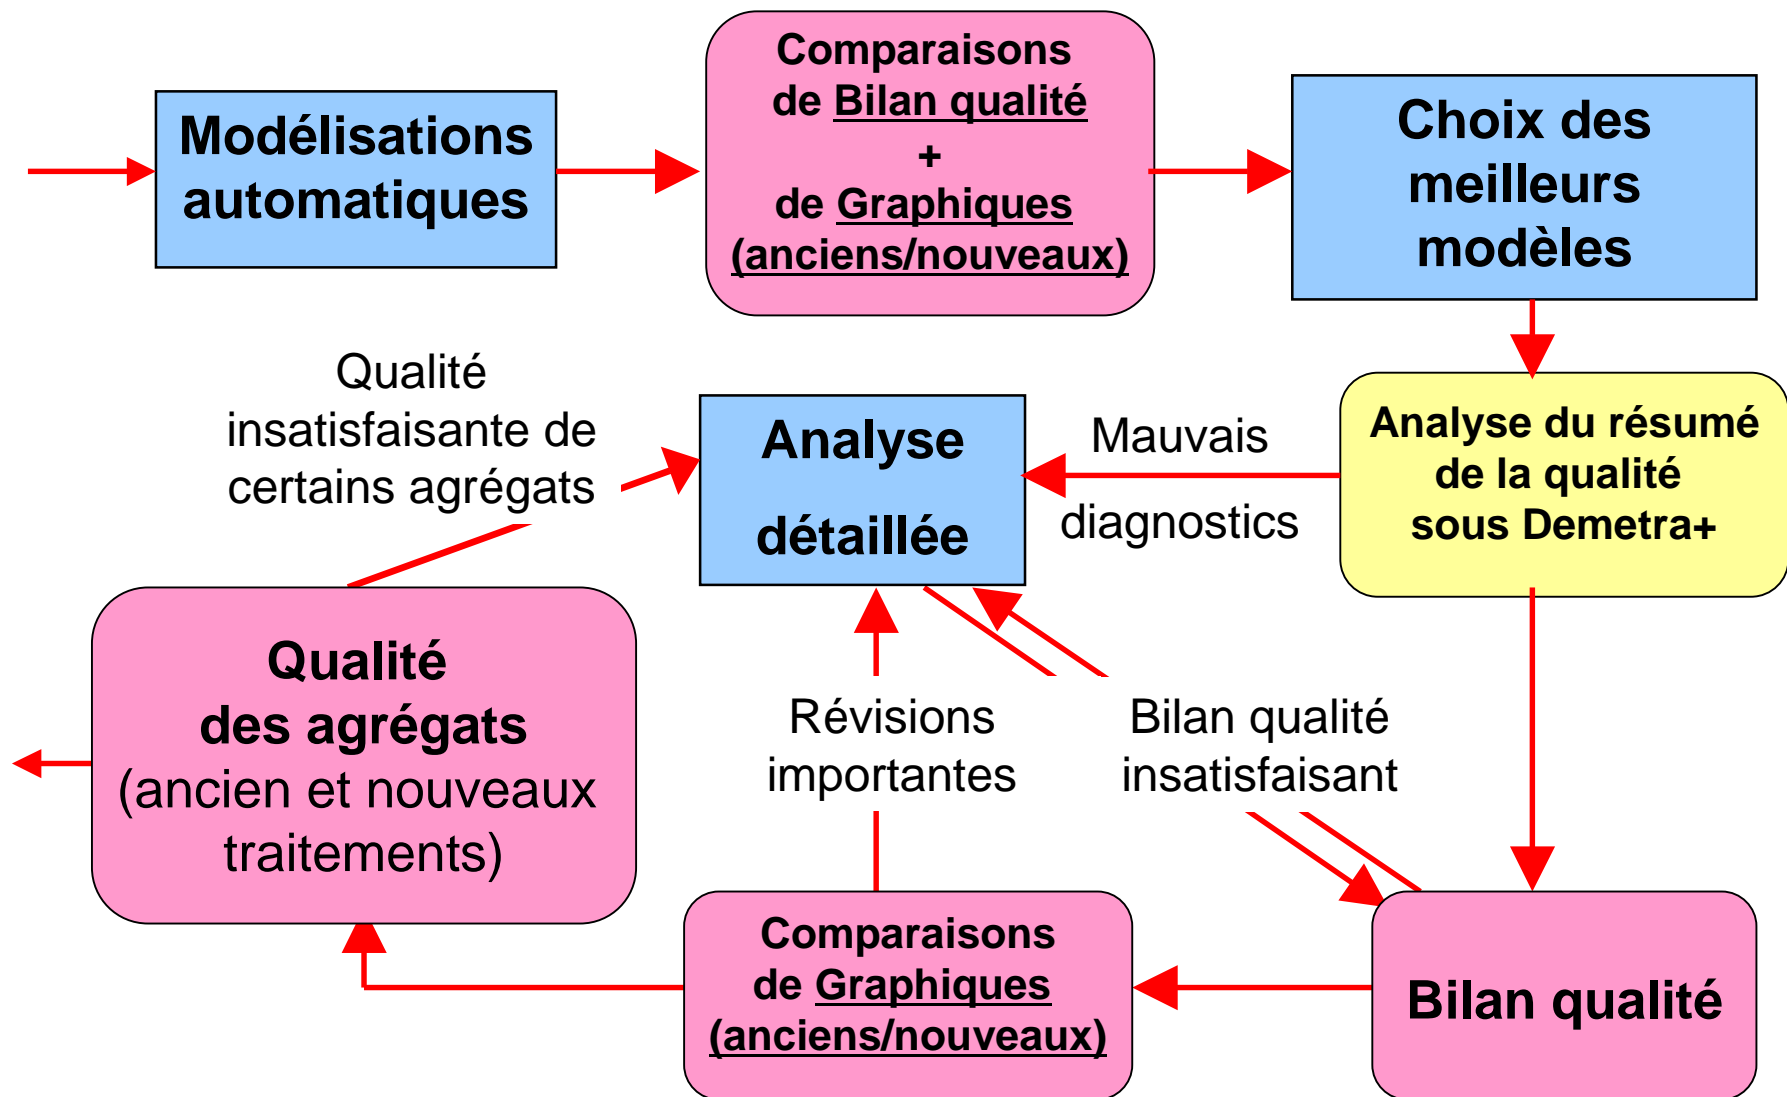
Graphiques superposés des courbes obtenues avec les deux jeux de spécifications

Ascenseur permettant de faire défiler les résultats

Barres représentant les différences entre les deux courbes

Janvier 2012

Schéma de la campagne annuelle



Merci de votre attention !

Contact

M.Himpens Stéphanie

Tél. 01 41 17 64 54

Courriel : stephanie.himpens@insee.fr

Insee

18 bd Adolphe-Pinard
75675 Paris Cedex 14

www.insee.fr  

Informations statistiques :

www.insee.fr / Contacter l'Insee

09 72 72 4000

(coût d'un appel local)

du lundi au vendredi de 9h00 à 17h00



Journées de Méthodologie Statistique 2012

**Janvier
2012**