


Leçon 3 : Modélisation VAR

Prof KEHO

Table des matières



I - Spécification et estimation d'un modèle VAR	3
II - Tests de causalité de Granger	6
III - Simulation dans un modèle VAR	8

Spécification et estimation d'un modèle VAR



Spécification d'un modèle VAR

Un modèle vectoriel autorégressif (VAR) est un modèle à équations simultanées particulier dans lequel la valeur contemporaine d'une variable dépend de ses propres valeurs passées et des valeurs passées des autres variables. La modélisation VAR est souvent critiquée d'être athéorique dans le sens où elle ne fait pas appel à la théorie économique pour spécifier les relations entre les variables. Elle repose sur la proposition générale selon laquelle les variables économiques ont tendance à varier les unes avec les autres au cours du temps et aussi à être autocorrélées. Toutes les variables d'un modèle VAR sont donc supposées endogènes. Considérons deux variables X et Y. L'écriture sous la forme d'un VAR à p retards est :

$$Y_t = \alpha_0 + \sum_{i=1}^p \phi_{1i} X_{t-i} + \sum_{i=1}^p \phi_{1i} Y_{t-i} + \mu_{1t} \quad (13.1)$$

$$X_t = \eta_0 + \sum_{i=1}^p \phi_{2i} X_{t-i} + \sum_{i=1}^p \phi_{2i} Y_{t-i} + \mu_{2t} \quad (13.2)$$

On voit clairement qu'un modèle VAR est un type particulier de modèle à équations simultanées : chaque équation est un modèle autorégressif à p décalages temporels et toutes les équations comportent les mêmes variables explicatives. Soulignons que les équations du VAR peuvent inclure des tendances, des variables indicatrices ou d'autres variables exogènes stationnaires.

Estimation d'un modèle VAR

Un modèle VAR peut être estimé par les méthodes présentées dans le chapitre précédent. Toutefois, il est possible de recourir à la méthode des moindres carrés ordinaires

Considérons le vecteur constitué des deux variables suivantes : *LPibr* et *LConsg*. Etant donné que ces deux variables ne sont pas stationnaires en niveau, nous allons considérer les différences premières. On génère les différences premières des séries à partir du menu Quick/Generate Series. Après cette opération, sélectionnez les deux variables différenciées dans le workfile et faites un clic droit puis sélectionnez **Open/as VAR...**

On peut aussi procéder par le menu principal en sélectionnant **Quick/Estimate VAR...** puis on entre la liste des variables. La constante est ici la seule variable exogène. Cliquez sur **OK** pour valider. On obtient le tableau de résultats suivant:

Tableau 13.1 : Estimation du modèle VAR

Vector Autoregression Estimates
Sample(adjusted): 1967 2002

	DLCONSG	DLPIBR
DLCONSG(-1)	-0.09121 (-0.51540)	-0.07550 (-1.85118)
DLPIBR(-1)	-0.04586 (-0.07486)	0.48188 (3.41269)
C	0.05533 (1.42978)	0.01855 (2.08037)
R-squared	0.00807	0.32067
Adj. R-squared	-0.05204	0.27950
Sum sq. resids	1.10787	0.05884
S.E. equation	0.18322	0.04222
F-statistic	0.13434	7.78883
Log likelihood	11.5775	64.4125
Akaike AIC	-0.47652	-3.41180
Schwarz SC	-0.34456	-3.27984
Mean dependent	0.04943	0.03233
S.D. dependent	0.17863	0.04974
Determinant Residual Covariance		5.81E-05
Log Likelihood (d.f. adjusted)		73.38502
Akaike Information Criteria		-3.74361
Schwarz Criteria		-3.47969

Nous venons d'estimer un VAR bivarié avec un seul retard, ce qu'on note VAR(1). Rappelons que l'estimation du VAR est équivalente à la régression par MCO équation par équation. Ainsi les résultats présentés dans ce tableau peuvent être considérés comme une compilation de deux régressions par moindres carrés ordinaires.

L'estimation d'un VAR ne présente pas les *p-values* pour le test de significativité des coefficients. Cependant, sur la base des t-statistiques, on peut aisément conduire ce test, en utilisant la valeur critique de 1,96 ou 2.

Exemple

Par exemple, si la valeur absolue du t-stat est supérieure à 1,96 ou 2, alors on conclut que le coefficient est significativement différent de zéro. Le coefficient de DLPIBR(-1) dans la première équation a un t-stat de -0.07486 indiquant que ce coefficient n'est pas significatif. Il en est de même pour la constante de la première équation. Puisque certains coefficients ne sont pas significatifs, on peut les supprimer du modèle de sorte à avoir un modèle réduit. Mais cela n'est pas possible à partir de l'option VAR, puisque toutes les équations d'un modèle VAR devraient avoir exactement le même nombre de retards et donc le même nombre de variables explicatives. Si l'on veut obtenir un modèle réduit du VAR, on devra utiliser l'option system utilisée pour estimer les modèles à équations simultanées (voir TP). En outre, l'option system permet de faire des tests sur les coefficients des équations.

Détermination du nombre de retards

La détermination du nombre de retards est une étape préalable à l'estimation d'un VAR. Cette étape est particulièrement délicate puisqu'elle n'est pas neutre au regard des résultats numériques qui en découlent. L'estimation d'un VAR(p) à k variables nécessite au total l'estimation de $k+pk^2$ paramètres (y compris les termes constants). Ce nombre augmente de k^2 avec chaque niveau de retards. Un nombre trop élevé de retards risque donc d'épuiser rapidement les degrés de libertés et d'affaiblir la puissance des tests statistiques. Par exemple, un VAR(4) à 5 variables nécessite l'estimation d'au moins 20 coefficients dans chacune des

équations. Si le nombre d'observations dont on dispose est faible, il aura une perte de degrés de liberté qui appauvrira l'estimation puisqu'elle réduira le nombre de données disponibles.

Pour déterminer le nombre de retards, on utilise les critères d'information : on calcule ces critères pour des ordres différents et on retient le retard qui minimise ces critères. EViews offre la possibilité de réaliser plus aisément cette opération en sélectionnant lui-même la solution. Sélectionnez **View/Lag Structure/Lag Length Criteria...**, puis indiquez le retard maximal.

Pour un retard maximal égal à 4, on obtient le tableau suivant :

Tableau 13.2 : Critères d'information pour le VAR

Lag	LogL	LR	FPE	AIC	SC	HQ
0	65.2435	NA	7.42E-05	-3.8329	-3.7422	-3.8024
1	72.3436	12.9093*	6.16E-05	-4.0208	-3.7487*	-3.9292*
2	76.2785	6.6774	6.20E-05	-4.0168	-3.5633	-3.8643
3	81.9412	8.9229	5.66E-05*	-4.1176*	-3.4827	-3.9040
4	82.9206	1.4245	6.90E-05	-3.9345	-3.1183	-3.6599

LR: sequential modified LR test statistic (each test at 5% level)

FPE: Final prediction error

AIC: Akaike information criterion

SC: Schwarz information criterion

HQ: Hannan-Quinn information criterion

Pour chaque critère le signe (*) indique le retard optimal retenu. Selon la statistique du rapport de vraisemblance et les critères SC et HQ, un retard suffit pour modéliser les interrelations dynamiques entre le taux de croissance du PIB et celui des dépenses publiques. Cependant les critères FPE et AIC sélectionnent trois retards. Notons qu'il est possible de déterminer l'ordre du VAR à partir des propriétés statistiques des résidus. On estime le VAR pour différents retards successifs et on retient le nombre de retard p pour lequel les résidus sont des bruits blancs.

Tests de causalité de Granger



D'une façon générale, les coefficients d'un modèle VAR ne peuvent être directement interprétés. Les retards d'une même variable peuvent se voir attribuer des signes différents. On s'intéresse, en général, à la significativité globale des coefficients associés à une variable spécifique ou à un groupe de variables. C'est l'idée du test de causalité de Granger (1969). La causalité au sens de Granger (1969) est une approche de la causalité qui renvoie non pas au caractère théorique de la causalité (cause-effet) mais au caractère prédictif de l'éventuelle cause sur l'effet. En effet, selon Granger (1969), une variable X cause une autre variable Y, si la connaissance des valeurs passées de X rend meilleure la prévision de Y. En d'autres termes, on dira que la variable X cause au sens de Granger la variable Y si les valeurs passées de X influencent significativement la valeur contemporaine de Y. Sur le plan statistique, le test de causalité au sens de Granger revient à faire un test de significativité globale des coefficients associés aux valeurs passées de la variable causale dans l'équation de la variable causée.

Considérons le modèle *VAR* bivarié défini de la façon suivante :

$$Y_t = c_1 + \sum_{i=1}^p \phi_{1i} X_{t-i} + \sum_{i=1}^p \varphi_{1i} Y_{t-i} + \mu_{1t} \quad (13.3)$$

$$X_t = c_2 + \sum_{i=1}^p \phi_{2i} X_{t-i} + \sum_{i=1}^p \varphi_{2i} Y_{t-i} + \mu_{2t} \quad (13.4)$$

On teste les hypothèses suivantes :

$$X_t = c_2 + \sum_{i=1}^p \phi_{2i} X_{t-i} + \sum_{i=1}^p \varphi_{2i} Y_{t-i} + \mu_{2t} \quad (13.4)$$

$$H_0: \phi_{11} = \phi_{12} = \dots = \phi_{1p} = 0 \Leftrightarrow X \text{ ne cause pas } Y.$$

Ces hypothèses peuvent être testées à l'aide du test de Fisher. On peut aussi utiliser un test du rapport de vraisemblance par comparaison du modèle *VAR* non contraint et du modèle *VAR* contraint. Le rejet des deux hypothèses implique une causalité réciproque entre X et Y. On parle également de boucle rétroactive. Rappelons que le cadre statistique de ce test suppose la stationnarité des variables.

Pour réaliser le test de causalité de Granger, sélectionnez **View/Lag Structure/Pairwise Granger Causality Tests**.

On obtient les résultats consignés dans le tableau suivant.

Tableau 13.3 : Résultats du test de causalité de Granger (p=1)

VAR Pairwise Granger Causality/Block Exogeneity Wald Tests

Sample: 1965 2002

Included observations: 36

Dependent variable: DLCONSG

Exclude	Chi-sq	df	Prob.
DLPIBR	0.00560	1	0.9403
All	0.00560	1	0.9403

Dependent variable: DLPIBR

Exclude	Chi-sq	df	Prob.
DLCONSG	3.42685	1	0.0641
All	3.42685	1	0.0641

Pour une variable dépendante donnée, le tableau donne la statistique de Wald du test de nullité simultanée des coefficients associés aux retards de la variable dépendante. Par exemple, pour la variable DLCONSG, la statistique de test donne une valeur de 0.0056 et une probabilité égale à 0.94. Cette probabilité étant supérieure à 5%, l'hypothèse de non causalité de DLCONSG par DLPIBR ne peut être rejetée au seuil de 5%. En d'autres termes, le PIB réel ne cause pas la consommation publique au seuil de 5%. En revanche, quand on considère l'équation du PIB réel, on constate que la consommation publique cause (négativement) le PIB réel au seuil de 7%.

Nous allons refaire le test de Granger en considérant 3 retards. Les résultats sont donnés dans le tableau suivant :

Tableau 13.4 : Résultats du test de causalité de Granger ($p=3$)

VAR Pairwise Granger Causality/Block Exogeneity Wald Tests

Sample: 1965 2002

Included observations: 36

Dependent variable: DLCONSG

Exclude	Chi-sq	df	Prob.
DLPIBR	6.10416	3	0.1067
All	6.10416	3	0.1067

Dependent variable: DLPIBR

Exclude	Chi-sq	df	Prob.
DLCONSG	5.40822	3	0.1442
All	5.40822	3	0.1442

On voit bien qu'aucune causalité ne peut être mise ici en évidence avec ces résultats. Le test de Granger est donc sensible au nombre de décalages pris en compte dans la modélisation.

Simulation dans un modèle VAR



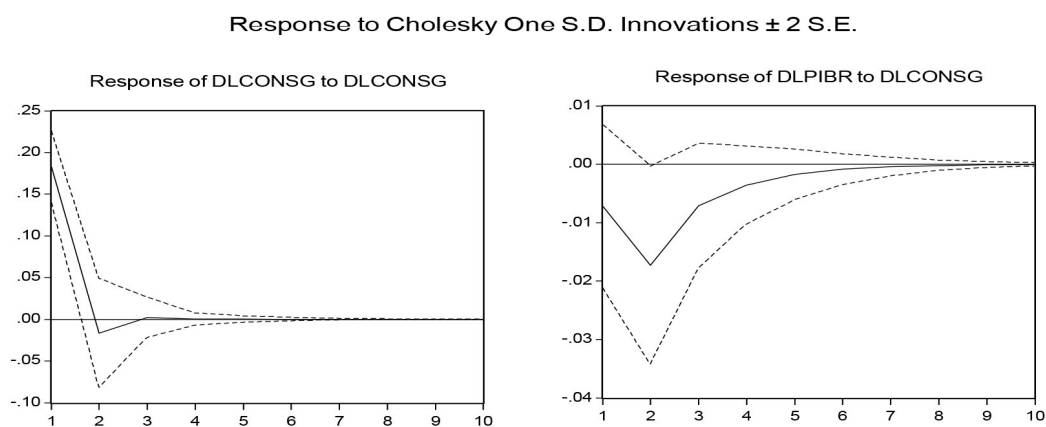
Simulation dans un modèle VAR

L'une des principales applications des modèles VAR est d'analyser les effets de politiques économiques au travers de simulations de chocs. Un modèle VAR modélise les relations dynamiques entre un groupe de variables choisies pour caractériser un phénomène économique particulier. L'analyse impulsionnelle permet d'analyser comment un choc à la date T sur une variable affecte l'ensemble des variables du système pour les périodes T , $T+1$, $T+2, \dots$

Pour faire l'analyse impulsionnelle, sélectionnez **View/Impulse Response...**

On peut aussi directement cliquer sur l'onglet impulse dans le tableau des estimations. Le graphique suivant représente les réponses de la politique budgétaire aux chocs de demande publique. Le deuxième graphique représente la réponse du PIB aux chocs de demande publique. Nous allons nous intéresser particulièrement au second graphique.

Figure 13.1 : Fonctions de réponse de DLCONSG et DLPIBR



On observe qu'un choc positif sur les dépenses publiques (augmentation des dépenses publiques) conduit dans un premier temps à une baisse transitoire du taux de croissance de l'économie. L'effet sur l'activité s'estompe progressivement. Il décroît fortement dès la deuxième année et tend à se résorber au bout de 8 années. Le fait que la réponse tend vers zéro est en cohérence avec la propriété de stationnarité des séries.

Décomposition de la variance

L'analyse des variances fournit des informations quant à l'importance relative des innovations dans les variations de chacune des variables. Elle permet de déterminer dans quelle direction un choc a le plus d'impact. Il existe une relation entre la décomposition de la variance de l'erreur de prévision et la non causalité au sens de Granger. Si ne cause pas dans un système

bivarié, alors la variance de l'erreur de prévision de sera entièrement due aux innovations de et aucunement à celles de . Cette propriété n'est cependant vérifiée que si la matrice de variance-covariance des innovations est diagonale , c'est-à-dire s'il n'y a pas de causalité instantanée entre les deux variables et .

Pour obtenir la décomposition de la variance, sélectionnez, à partir du menu, **View/Variance Decomposition....** On obtient deux tableaux qui indiquent chacun la proportion de la variance expliquée par chaque variable.

Tableau 13.5: Décomposition de la variance de DLPIBR

Variance Decomposition of DLPIBR:			
Period	S.E.	DLCONSG	DLPIBR
1	0.04222	2.88732	97.11267
2	0.04984	14.10783	85.89217
3	0.05129	15.23580	84.76420
4	0.05164	15.51525	84.48475
5	0.05172	15.57927	84.42073
6	0.05174	15.59451	84.40549
7	0.05174	15.59813	84.40187
8	0.05174	15.59899	84.40101
9	0.05174	15.59920	84.40080
10	0.05174	15.59924	84.40076

Cholesky Ordering: DLCONSG DLPIBR			
-----------------------------------	--	--	--

Tableau 13.6 : Décomposition de la variance de DLCONSG

Variance Decomposition of DLCONSG:			
Period	S.E.	DLCONSG	DLPIBR
1	0.18322	100.0000	0.00000
2	0.18396	99.98923	0.01076
3	0.18398	99.98759	0.01240
4	0.18398	99.98716	0.01283
5	0.18398	99.98706	0.01293
6	0.18398	99.98704	0.01296
7	0.18398	99.98703	0.01296
8	0.18398	99.98703	0.01296
9	0.18398	99.98703	0.01296
10	0.18398	99.98703	0.01296

Le premier tableau indique que le choc d'offre explique une très grande part de la dynamique du PIB. De façon instantanée, le choc d'offre contribue à 97,11% de la variance de l'erreur de prévision du PIB, contre seulement 2,88% pour le choc de demande publique. A moyen et long terme, la variance de l'erreur de prévision du taux de croissance est expliquée à 84,4% par ses propres innovations et à 15,6% par les dépenses publiques. La décomposition de la variance de l'erreur de prévision des dépenses publiques (cf. tableau 7.8) indique que moins de 0,1% de l'erreur de prévision de celles-ci est dû aux impulsions provenant des chocs d'offre. Nous

pouvons conclure que les chocs de politique budgétaire en matière de consommation publique ont plus d'impact sur l'activité économique que l'impact d'un choc d'offre en a sur la politique budgétaire.

