



## Application Chapitre 8 (corrigé)

### Techniques d'estimation

Dans ce document, je propose une correction de l'application du Chapitre 8 de mon manuel de Macroéconomie quantitative (p.112). Les fonctions et les données utiles sont disponibles sur mon site <sup>a</sup>. Un ou plusieurs scripts Octave/Matlab accompagnent également ce document, dont une partie des éléments qui sont repris et commentés ici, apparaissent sous une police à chasse fixe.

a. [www.christophecahn.fr/macroquant](http://www.christophecahn.fr/macroquant)

### Estimation d'un modèle néo-keynésien

Les séries contenues dans le fichier `data.txt` ont été engendrées par une économie artificielle. Les séries correspondent à l'écart de production (différence entre la production et son niveau naturel), l'inflation et le taux d'intérêt nominal, présentés en colonne. Nous allons tenter dans ce problème de déterminer le processus générateur des données (PGD), c.-à-d. le modèle qui a engendré ces données.

### Estimation par maximum de vraisemblance

On envisage d'estimer le modèle suivant

$$\pi_t = \beta \mathbb{E}_t \{\pi_{t+1}\} + \kappa \tilde{y}_t + v_{p,t}$$

$$\tilde{y}_t = \mathbb{E}_t \{\tilde{y}_{t+1}\} - (i_t - \pi_{t+1} - v_{n,t})$$

$$i_t = \phi_\pi \pi_t + \phi_y \tilde{y}_t + v_{i,t}$$

où les chocs  $v_{x,t}$ ,  $x \in \{p, n, i\}$  sont des processus AR(1)

$$v_{x,t} = \rho_x v_{x,t-1} + \epsilon_{x,t}, \quad \epsilon_{x,t} \sim \text{i.i.d. } N(0, \sigma_x^2)$$

**1a** Écrire le fichier `dynare` correspondant au modèle de l'énoncé. On utilisera les valeurs suivantes :  $\beta = 0.98$ ,  $\kappa = 0.01$ ,  $\phi_\pi = 1.2$ ,  $\phi_y = 0.1$ ,  $\rho_x = 0.8$  et  $\sigma_x = 0.01$  pour  $x \in \{p, n, i\}$ .

```
// Application 8 : question 1b
```

```
var y p i nu_i nu_p nu_n ;
varexo en ei ep ;
```

```
parameters k b ap ay rho_p rho_i rho_n ;
b = .98 ;
k = .01 ;
ap = 1.2 ;
ay = .1 ;
```

```

rho_n = 0.8 ;
rho_i = 0.8 ;
rho_p = 0.8 ;

model;

    b*p(+1) + k*y + nu_p - p ;
    y = y(+1) - (i - p(+1) - nu_n) ;
    i = ap*p + ay*y + nu_i ;

    nu_n = rho_n*nu_n(-1) + en ;
    nu_i = rho_i*nu_i(-1) + ei ;
    nu_p = rho_p*nu_p(-1) + ep ;
end;

shocks;
var en; stderr .01 ;
var ei; stderr .01 ;
var ep; stderr .01 ;
end;

stoch_simul(irf=80,graph_format=pdf);

```

**1b** Simuler le modèle et commenter les IRF.

```
stoch_simul(irf=80);
```

**1c** Estimer par maximum de vraisemblance les paramètres du modèle à l'exception de  $\beta$ . On trouvera les valeurs estimées dans la structure `M_.params`, dans l'ordre de la déclaration des paramètres dans le fichier `mod`. Les variances des chocs sont dans la structure `M_.Sigma_e`.

```

estimated_params;
k , .01;
ap , 1.2 ;
ay , .1 ;
rho_n, .8 ;
rho_i, .8 ;
rho_p, .8 ;
stderr en, .01 ;
stderr ei, .01 ;
stderr ep, .01 ;
end ;

varobs y p i ;

estimation(datafile='data',graph_format=pdf);

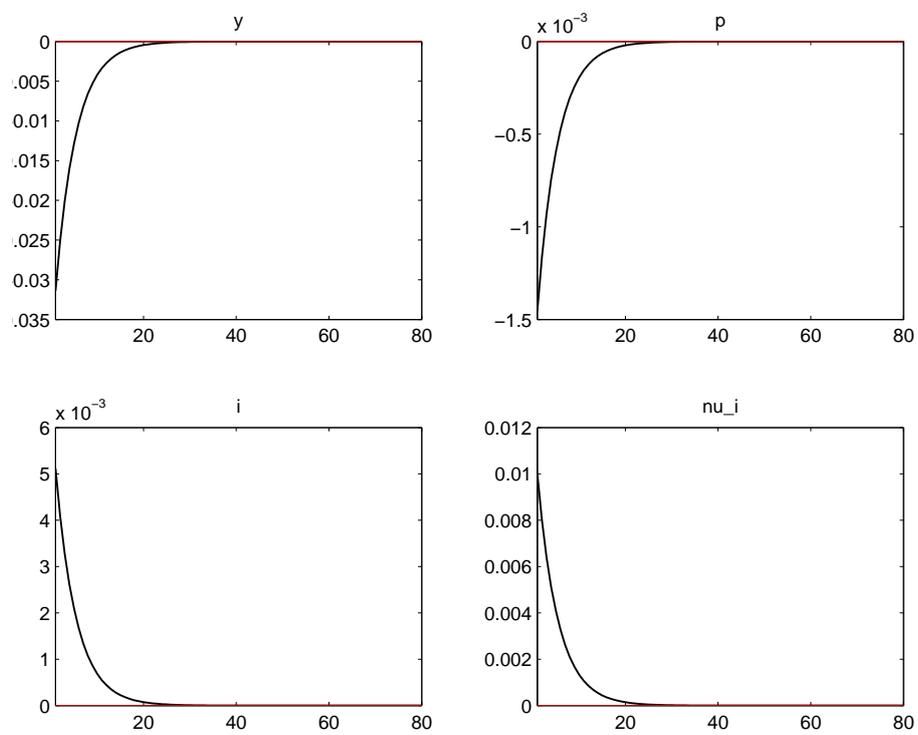
```

```

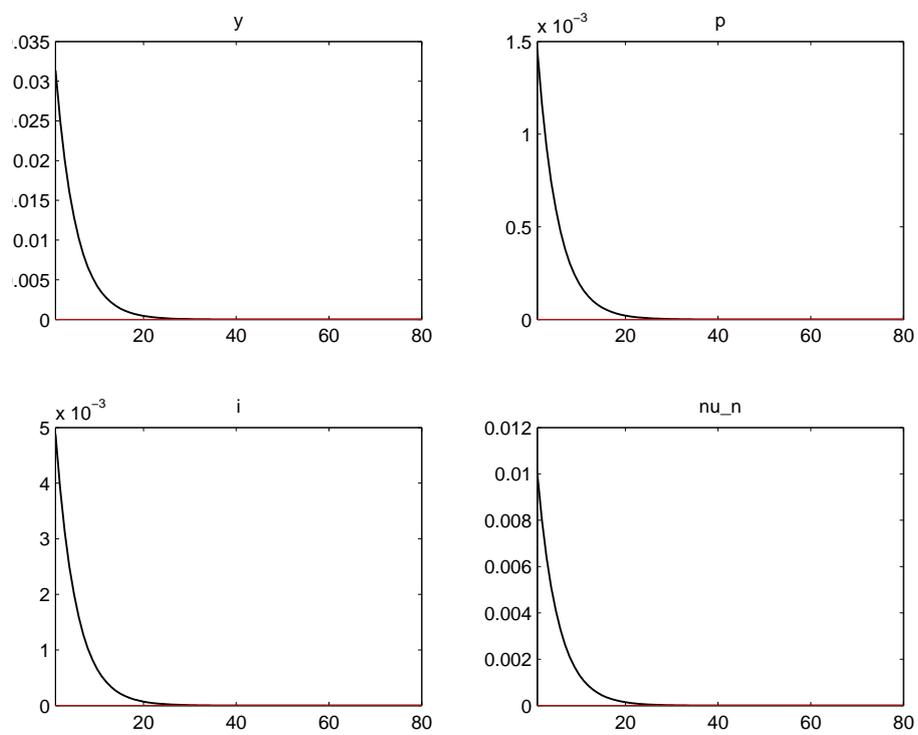
RESULTS FROM MAXIMUM LIKELIHOOD ESTIMATION
parameters
    Estimate    s.d. t-stat

```

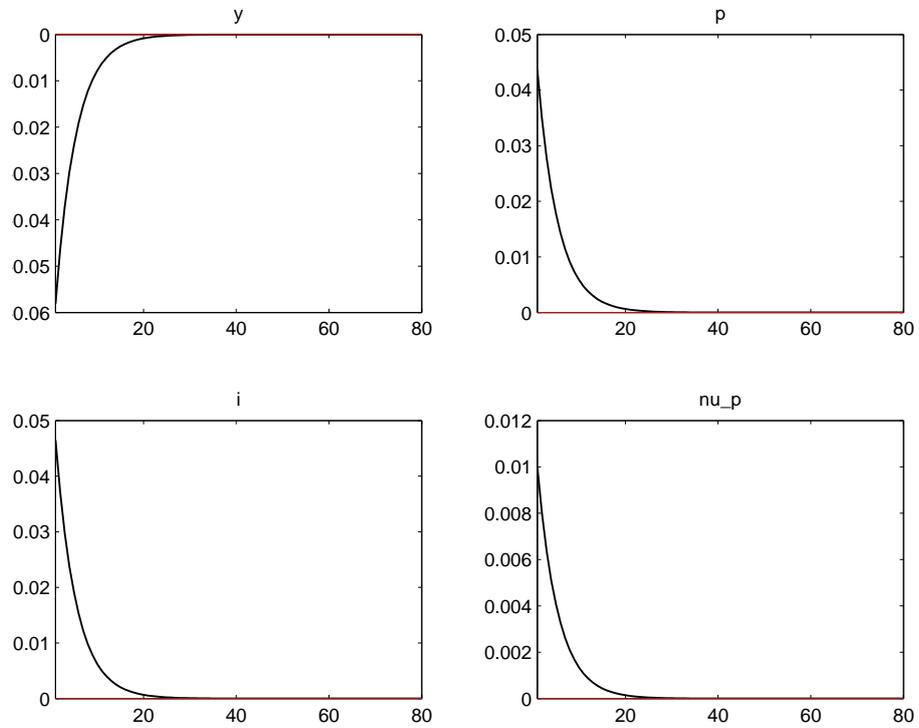
**Figure 1** – Réponses dynamiques à un choc de politique monétaire



**Figure 2** – Réponses dynamiques à un choc de préférence



**Figure 3** – Réponses dynamiques à un cost-push shock



```

k      0.0204  0.0092  2.2042
ap     1.3351  0.0320  41.6907
ay     0.1136  0.0208  5.4579
rho_n  0.7678  0.0281  27.3117
rho_i  0.9152  0.0149  61.4091
rho_p  0.6934  0.0280  24.8041

```

standard deviation of shocks

```

      Estimate      s.d. t-stat
en    0.0108  0.0010  10.9669
ei    0.0076  0.0008  9.9346
ep    0.0131  0.0010  13.0694

```

**1d** Estimer le modèle par méthode bayésienne en utilisant dynare.

```

estimated_params;
k , normal_pdf, 0.01, 0.02;
ap , normal_pdf, 1.2, 2;
ay , normal_pdf, .1, .2;
rho_n, beta_pdf, .8, .1 ;
rho_i, beta_pdf, .8, .1 ;
rho_p, beta_pdf, .8, .1 ;
stderr en, inv_gamma_pdf, 0.01, inf;
stderr ei, inv_gamma_pdf, 0.01, inf;
stderr ep, inv_gamma_pdf, 0.01, inf;
end ;

varobs y i p ;

estimation(order=1,mh_replic=2000,mh_nblocks=2,
  mode_compute=4,datafile='data',mh_jscale = .75,graph_format=pdf);

```

ESTIMATION RESULTS

Log data density is 3661.043255.

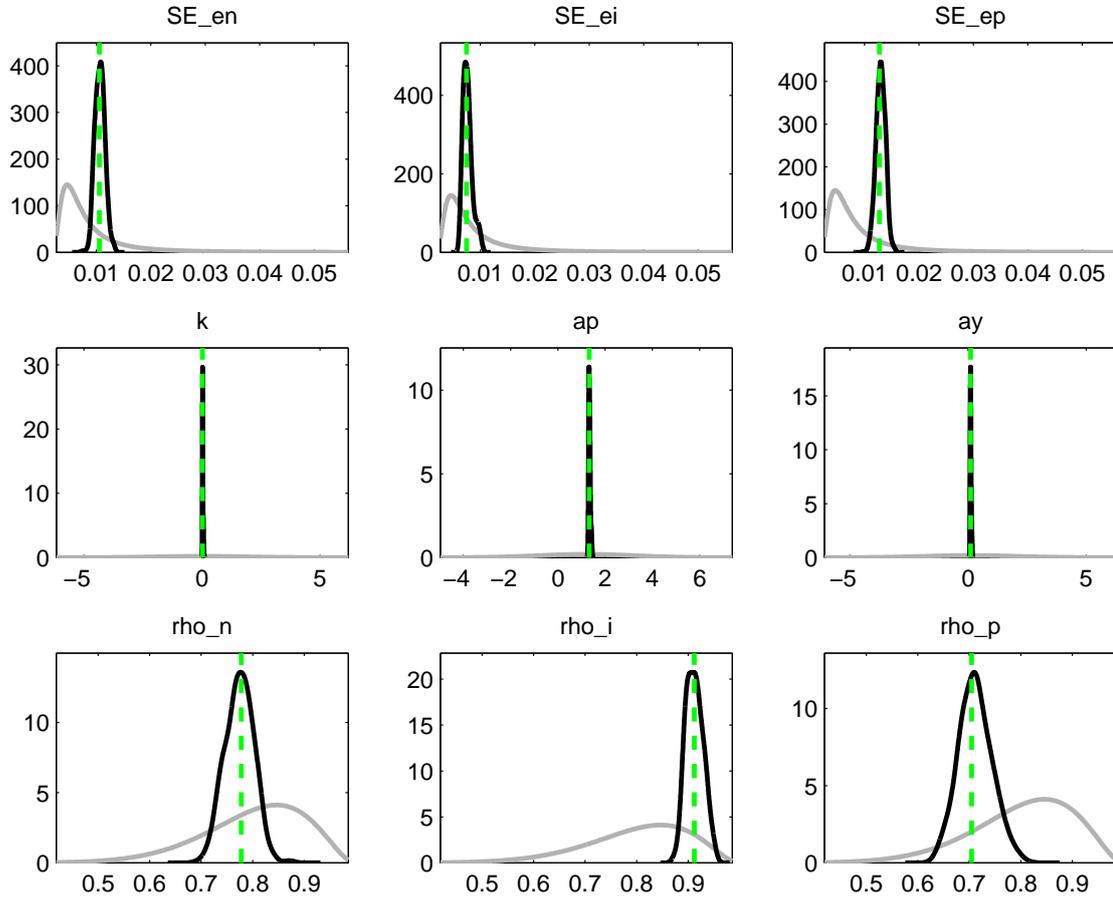
```

parameters
  prior mean  post. mean      90% HPD interval  prior  pstdev
k           0.010      0.0268      0.0087      0.0460  norm    2.0000
ap          1.200      1.3319      1.2862      1.3873  norm    2.0000
ay          0.100      0.1102      0.0796      0.1475  norm    2.0000
rho_n       0.800      0.7760      0.7231      0.8135  beta    0.1000
rho_i       0.800      0.9098      0.8896      0.9376  beta    0.1000
rho_p       0.800      0.7077      0.6626      0.7570  beta    0.1000

standard deviation of shocks
  prior mean  post. mean      90% HPD interval  prior  pstdev
en           0.010      0.0106      0.0090      0.0121  invg    Inf

```

Figure 4 – Densités a priori et a posteriori.



ei	0.010	0.0076	0.0063	0.0087	invg	Inf
ep	0.010	0.0130	0.0116	0.0147	invg	Inf

### Estimation par la méthode des moments simulés

2a Représenter le modèle sous forme matricielle.

Le modèle peut se mettre sous la forme

$$E_t\{Fx_{t+1} + Gx_t + Hx_{t-1} + Lz_{t+1} + Mz_t\} = 0, z_{t+1} = Nz_t + u_{t+1}$$

avec  $x_t = (y_t, \pi_t, i_t)'$ ,  $z_t = (v_{p,t}, v_{n,t}, v_{i,t})'$ ,  $u_t = (\epsilon_{p,t}, \epsilon_{n,t}, \epsilon_{i,t})'$  et

$$F = \begin{pmatrix} 0 & \beta & 0 \\ 1 & 1 & 0 \\ 0 & 0 & 0 \end{pmatrix}, G = \begin{pmatrix} \kappa & -1 & 0 \\ -1 & 0 & -1 \\ \phi_y & \phi_\pi & -1 \end{pmatrix}, H = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix}, L = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix},$$

$$M = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}, N = \begin{pmatrix} \rho_p & 0 & 0 \\ 0 & \rho_n & 0 \\ 0 & 0 & \rho_i \end{pmatrix}.$$

**2b** Proposer un algorithme permettant d'estimer par la méthode de moments simulés les paramètres du modèle. Proposer un ensemble de moments pour l'estimation.

- engendrer une série de vecteurs de chocs  $\epsilon \equiv \{(\epsilon_{p,t}, \epsilon_{n,t}, \epsilon_{i,t})'\}_{t=1}^T$
- pour un jeu de paramètres  $\Theta = (\kappa, \phi_y, \phi_\pi, \rho_p, \rho_n, \rho_i, \sigma_p, \sigma_n, \sigma_i)$ , simuler des séries  $\{x_t(\Theta) = (y_t, \pi_t, i_t)\}_{t=1}^T$  et calculer des moments  $\mu(\Theta, \epsilon)$
- Trouver  $\Theta$  tel que  $\mu(\Theta, \epsilon)$  soit très proche de  $\mu^o$ , les moments calculés sur les observations, par exemple

$$\Theta^* = \arg \max_{\Theta} (\mu(\Theta, \epsilon) - \mu^o)^2.$$

On peut prendre par exemple comme moments les éléments de la matrice de variance covariance de  $x_t$ .

**2c** Estimer le modèle par la méthode des moments simulés.

On commence donc par calculer et stocker les moments des variables observées

```
load data ;
moments = mom([y p i]);
```

Ensuite, on crée une fonction objectif `funobj(x, ee, moments, T, burn, nsim)` dont l'objet est de donner une mesure de la distance entre les moments calculés sur données observées `moments` et des moments calculés sur des données simulées à partir d'un modèle dont les paramètres sont donnés par `x`. Ces données simulées sont engendrées à partir d'une série de chocs gaussiens iid stockée dans la matrice `ee`. La taille de l'échantillon initial est `T`, mais nous allons simuler le modèle `burn` périodes avant afin d'atteindre par approximation la distribution ergodique. Par ailleurs, les moments obtenus à partir de la simulation du modèle dépendent du tirage de chocs gaussiens. Afin de limiter cette dépendance, nous allons itérer `nsim` fois la procédure puis calculer la moyenne sur ces `nsim` simulations. Enfin, nous prendrons la distance euclidienne pour caractériser l'écart entre les moments observés et les moments simulés.

Un telle fonction peut s'écrire ainsi

```
function [res] = funobj(x, ee, moments, T, burn, nsim)

moms = [];

for ii=1:nsim
    [y_sim, p_sim, i_sim] = modsim(x, ee(:, 1 + (nsim-1)*(burn+T) : nsim*(burn+T)));
    y_sim = y_sim(burn+1:burn+T, :);
    p_sim = p_sim(burn+1:burn+T, :);
    i_sim = i_sim(burn+1:burn+T, :);
    moms = [moms vec(mom([y_sim, p_sim, i_sim]))];
end
w = mean(moms, 2) - moments(:) ;
res = w'*w;
```

où `modsim` est une fonction qui simule le modèle à partir de sa forme matricielle trouvée plus haut.

La suite de la procédure consiste à minimiser cette fonction objectif. Pour ce faire, on peut utiliser la commande `fminsearch`. Il se peut néanmoins qu'au cours du processus de minimisation, l'algorithme s'en aille visiter des régions dans lesquelles certains paramètres prennent des valeurs interdites par le modèle économique. Par exemple, il se peut que la valeur attribuée à un des paramètres de persistance soit négative ou plus grande que 1, ou la valeur attribuée à  $\phi_\pi$  soit telle

que le principe de Taylor vu au Chapitre 7 ne soit plus respecté. Dans ce cas, on peut être amené à opérer une transformation sur les paramètres afin de modifier leur domaine de définition. Dans le cas présent, la fonction `invtrans` permet d'opérer cette transformation :

```
function res = invtrans(x)

res = zeros(size(x));
res(1) = exp(x(1));
res(2) = exp(x(2));
res(3) = 1+exp(x(3));
res(4) = .5+.5*tanh(x(4));
res(5) = .5+.5*tanh(x(5));
res(6) = .5+.5*tanh(x(6));
res(7) = exp(x(7));
res(8) = exp(x(8));
res(9) = exp(x(9));

end
```

Dans ce cas, en posant  $x = \text{invtrans}(xx)$ , on voit que si la première composante de  $xx$  peut prendre toutes les valeurs de la droite réelle, la première composante de  $x$  sera nécessairement strictement positive (ce qui doit être le cas pour le paramètre  $\kappa$ ). De la même manière, le paramètre  $\rho_p$  qui correspond à la quatrième composante de  $x$  est bien compris entre 0 et 1 alors que la quatrième composante de  $xx$  balaye à nouveau la droite réelle.

En définitive, la procédure de minimisation peut s'écrire simplement :

```
xsol = fminsearch(@(xx) funobj(invtrans(xx), ee, moments, T, burn, nsim), xinit)
```

En appliquant cette procédure, on trouve

```
invtrans(xsol) =

    0.0315    0.0241    1.1351    0.7337    0.8123    0.7389    0.0118    0.0107    0.0071
```

en rappelant l'ordre des paramètres

```
1:k 2:ay 3:ap 4:rp 5:rn 6:ri 7:sp 8:sn 9:si
```

### Estimation par inférence indirecte

On se propose cette fois d'estimer les paramètres du modèle par inférence indirecte. À cet effet, on utilisera un modèle VAR en guise de modèle auxiliaire.

**3a** Estimer un modèle VAR(4) sur les données.

On peut utiliser la fonction de Sims vue au chapitre 4. On peut également utiliser la fonction `estimVar` qui calcule directement les matrices de coefficients et la matrice de variance covariance

```
function [B,S] = estimVAR(Yobs,nlag)
```

```
T = size(Yobs,1);
Y = Yobs(nlag+1:T,:);
```



avec pondération une matrice diagonale par block contenant l'inverse de la matrice de variance-covariance de l'estimateur de  $B$  et l'inverse de la matrice de variance-covariance de l'estimateur de  $S$ .

En appliquant cette procédure (avec  $nsim=100$  et  $seed=33$ ), on trouve

```
invtrans(xsolVAR) =  
0.0439 0.1170 1.3537 0.6806 0.7909 0.9384 0.0147 0.0069 0.0053
```

en rappelant à nouveau l'ordre des paramètres

```
1:k 2:ay 3:ap 4:rp 5:rn 6:ri 7:sp 8:sn 9:si
```