

VARMA Based Impulse Response Estimation: A Simulation Study

Jairo Flores

Encuentro de Economistas 2025

Versión Preliminar

October 22, 2025

Outline

- 1 Idea Principal
- 2 Contribución
- 3 Revisión de la Literatura
- 4 Modelos
- 5 Simulación
- 6 Resultados
- 7 Agenda Futura

Outline

- 1 Idea Principal
- 2 Contribución
- 3 Revisión de la Literatura
- 4 Modelos
- 5 Simulación
- 6 Resultados
- 7 Agenda Futura

Idea Principal

- Ha habido un creciente interés en el uso de **modelos VARMA** para analizar datos de series de tiempo multivariadas, dado que estos modelos se han mostrado como candidatos prometedores para combinar los enfoques LP y VAR en el análisis de las funciones de impulso-respuesta (IRFs).
- El objetivo del presente estudio es realizar un **análisis de simulación** para comparar el desempeño de la estimación de las IRFs a partir de un modelo VARMA con el desempeño de las estimaciones obtenidas mediante los modelos SVAR y LP.
- La evaluación de cada método se basa en cuantificar **el sesgo y la varianza a lo largo de las replicaciones de Monte Carlo**. El diseño de simulación se basa en el trabajo de Li, Plagborg-Møller y Wolf (2022).

Outline

- 1 Idea Principal
- 2 Contribución**
- 3 Revisión de la Literatura
- 4 Modelos
- 5 Simulación
- 6 Resultados
- 7 Agenda Futura

- Encuentro evidencia de que el modelo VARMA presenta **trade-off entre sesgo y varianza más balanceado que los modelos VAR y LPs**. Esto significa que, en horizontes intermedios, el modelo VARMA muestra un menor (mayor) sesgo que el modelo VAR (LP), pero una mayor (menor) varianza en esos mismos horizontes.
- Estos resultados sugieren que el modelo VARMA puede ser un estimador útil en ciertos contextos donde se desea un trade-off más balanceado entre sesgo y varianza.

Outline

- 1 Idea Principal
- 2 Contribución
- 3 Revisión de la Literatura**
- 4 Modelos
- 5 Simulación
- 6 Resultados
- 7 Agenda Futura

Revisión de la literatura (1/2)

- La estimación de funciones de impulso-respuesta (IRFs) ha sido abordada desde:
 - ▶ Modelos VAR tradicionales (Sims, 1980).
 - ▶ Proyecciones Locales (LP) de Jordà (2005).
- Estudios recientes:
 - ▶ Plagborg-Møller y Wolf (2021): equivalencia asintótica entre VAR y LP.
 - ▶ Li, Plagborg-Møller y Wolf (2022): LP muestra menor sesgo pero mayor varianza que VAR.
- Surgen los modelos VARMA como alternativa teórica más flexible:
 - ▶ Capaces de representar mejor la dinámica de series temporales.
 - ▶ Incorporan componentes MA presentes en modelos DSGE.

Revisión de la literatura (2/2)

- Principales contribuciones teóricas:
 - ▶ Athanasopoulos y Vahid (2008a), Poskitt (2016), Chan y Eisenstat (2017).
- Aplicaciones empíricas:
 - ▶ Raghavan et al. (2009): política monetaria en Malasia.
 - ▶ Das (2003): respuestas ante shocks estructurales.
- Potencial en predicción:
 - ▶ Estudios de Athanasopoulos, Dufour, Dias, Kascha y otros muestran superioridad predictiva de VARMA.
- Desafíos:
 - ▶ Identificación y estimación complejas.
 - ▶ Modelos VARMA poco usados por ser difíciles de implementar en práctica.

Outline

- 1 Idea Principal
- 2 Contribución
- 3 Revisión de la Literatura
- 4 Modelos**
- 5 Simulación
- 6 Resultados
- 7 Agenda Futura

Modelos VARMA (1/2)

- Un modelo VARMA(p, q) general para una serie vectorial $Y_t \in \mathbb{R}^K$ se escribe como:

$$Y_t = \sum_{i=1}^p \Phi_i Y_{t-i} + U_t - \sum_{j=1}^q \Theta_j U_{t-j}$$

- Donde U_t es un proceso de ruido blanco con media cero y matriz de covarianza Σ_u .
- Representación en operadores de rezago:

$$\Phi(L)Y_t = \Theta(L)U_t$$

- Si la inversa existe, podemos escribir:

$$Y_t = \Psi(L)U_t, \quad \text{con} \quad \Psi(L) = \Phi(L)^{-1}\Theta(L)$$

Modelos VARMA (2/2)

- El modelo puede reescribirse en su forma más general como:

$$\Phi_0 Y_t = \sum_{i=1}^p \Phi_i Y_{t-i} + \Theta_0 U_t - \sum_{j=1}^q \Theta_j U_{t-j}$$

- Es posible obtener las funciones de respuesta al impulso (IRFs) a partir de:

$$Y_t = \sum_{j=0}^{\infty} \Psi_j U_{t-j}$$

- Este modelo es más parsimonioso que un VAR tradicional, pero su estimación requiere métodos como máxima verosimilitud o técnicas bayesianas, debido a problemas de identificación.

- **Proyecciones Locales (LP)** estiman IRFs directamente a partir de regresiones por horizonte:

$$Y_{t+h} = \alpha_h + \beta_h \varepsilon_t + \sum_{i=1}^p \Gamma_{hi} Y_{t-i} + e_{t+h}$$

- β_h es el coeficiente que representa la respuesta del sistema a un shock en t en el horizonte h .
- Estimación separada para cada h : robusta, pero con mayor varianza.

Comparación metodológica: SVAR

- En un **SVAR estructural**, se parte de un modelo reducido:

$$Y_t = A_1 Y_{t-1} + \dots + A_p Y_{t-p} + u_t, \quad u_t = B \varepsilon_t$$

- Donde B es una matriz de identificación que relaciona los errores estructurales ε_t con los residuales del VAR reducido.
- Se requiere una matriz de restricciones (recursiva, sign-restrictions, IV, etc.) para identificar B .

$$IRF(h) = \Psi_h B, \quad \text{con} \quad \Psi_h = \text{coeficientes del MA}(\infty)$$

Outline

- 1 Idea Principal
- 2 Contribución
- 3 Revisión de la Literatura
- 4 Modelos
- 5 Simulación**
- 6 Resultados
- 7 Agenda Futura

Diseño de Simulación

- Realicé un estudio de simulación Monte Carlo basado en una versión a pequeña escala del diseño de simulación presentado en Li et al. (2022), en el cual los autores seleccionan aleatoriamente miles de DGPs (procesos generadores de datos) a partir de un modelo de factor dinámico (DFM) a gran escala de Stock y Watson (2016) para EUA.
- Para cada DGP, se implementan los métodos SVAR, VARMA y LP para estimar las IRFs estructurales bajo tres esquemas de identificación comunes: shocks observados, identificación recursiva y esquema de identificación IV/proxy.
- Específicamente, para cada replicación Monte Carlo, se selecciona aleatoriamente un DGP que contiene tres variables con un tamaño muestral de $T = 250$, a partir de las 207 series de tiempo generadas por el DFM.
- Los procedimientos de estimación se implementan como un SVAR(2) y un LP con dos rezagos como variables de control. Para el modelo VARMA, considero una especificación VARMA(2,1) por su parsimonia y su potencial para capturar dinámicas subyacentes entre las variables.


Outline

- 1 Idea Principal
- 2 Contribución
- 3 Revisión de la Literatura
- 4 Modelos
- 5 Simulación
- 6 Resultados**
- 7 Agenda Futura


Resultados

- Exploro dos conjuntos de DGPs y examino cómo se desempeñan los distintos métodos de estimación cuando se aplican a cada uno de estos conjuntos bajo tres esquemas de identificación diferentes. Esto implica que se realizan un total de seis experimentos.
 - ▶ El primer conjunto de DGPs incluye una variable de gasto público y se utiliza para estudiar los efectos de los shocks de política fiscal. Este conjunto se denomina “G”.
 - ▶ El segundo conjunto de DGPs incluye la tasa de fondos federales y se utiliza para estudiar los efectos de los shocks de política monetaria. Este conjunto se denomina “MP”.
- Las variables restantes en cada conjunto se seleccionan aleatoriamente de un conjunto de 207 series de tiempo generadas mediante un modelo DFM. Para cada experimento, realizo 1000 simulaciones Monte Carlo.

Recursive G: Sesgo Medio de los Estimadores



Recursive G: Desviación Estándar de los Estimadores



Outline

- 1 Idea Principal
- 2 Contribución
- 3 Revisión de la Literatura
- 4 Modelos
- 5 Simulación
- 6 Resultados
- 7 Agenda Futura**

Agenda Futura

- Agregar algunos modelos más: BVAR, TVP-VAR, etc.
- Extender a un estudio sobre la construcción de intervalos de confianza.
- Proponer una herramienta donde se evidencie el trad-off de sesgo y varianza del método utilizado para los investigadores que empleas estas herramientas.
- **Cualquier sugerencia adicional es bienvenida.**