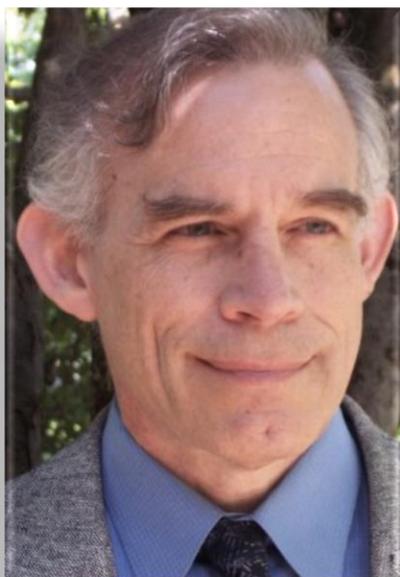


# CURSO: ECONOMETRÍA Y ANÁLISIS DE POLÍTICAS FISCALES

INSTRUCTOR: HORACIO CATALÁN ALONSO

## Especificación de los modelos VAR





# ECONOMETRICA

VOLUME 48

JANUARY, 1980

NUMBER 1

---

---

MACROECONOMICS AND REALITY<sup>1</sup>

BY CHRISTOPHER A. SIMS

CHRISTOPHER A. SIMS

*University of Minnesota*

*Policy Analysis with  
Econometric Models*

- 
- Modelos VAR es una extensión de un AR(p)
  - Permiten un mejor entendimiento de la relación que existe entre un conjunto de variables
  - No se imponen restricciones en los coeficientes del modelo. En este sentido su especificación es más flexible respecto a otro tipo de modelos
  - No incluyen la relación contemporánea lo que permite utilizar MCO
  - Muy pocas variables podrían ser genuinamente clasificadas como exógenas



Idea básica de Sims es especificar un modelo donde todas las variables son consideradas endógenas, sin restricciones y que equivale a un modelo en su forma reducida

Asumiendo que existe una relación entre dos variables:

$$y_{1t}, y_{2t}$$

$$y_{1t} = a_{11}y_{1t-1} + a_{12}y_{2t-1} + u_{1t}$$

$$y_{2t} = a_{21}y_{1t-1} + a_{22}y_{2t-1} + u_{2t}$$

En una representación matricial el modelo VAR(1):

$$\begin{bmatrix} y_{1t} \\ y_{2t} \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} y_{1t-1} \\ y_{2t-1} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix}$$

$$\mathbf{Y}_t = \mathbf{A}\mathbf{Y}_{t-1} + \mathbf{U}_t$$

$\mathbf{Y}_t$  Vector de variables consideradas en el modelo

$\mathbf{Y}_{t-1}$  variables rezagadas un periodo

$\mathbf{A}$  matriz de parámetros

$\mathbf{u}_t$  vector del término de error

---

El modelo VAR asume un conjunto de supuestos estadísticos que es permiten representarlo como una buena aproximación al proceso generador de datos

$$Y_t = A Y_{t-1} + U_t$$

Supuestos sobre el modelo

- $U_t \sim N[0, \Sigma_u]$  Normal
- $\text{Var}(U_t) = \Sigma_u$  Constante
- $\text{Cov}(U_t, U_{t-i}) = 0 \quad i=1,2,\dots$  No existe autocorrelación
- Parámetros lineales y constantes en el tiempo

## II. EJEMPLOS APLICADOS



Relación entre emisiones e ingreso. Modelo VAR de orden uno (un rezago)

Se especifica como un sistema. Una ecuación para cada variable

$$CO2_t = a_{11}CO2_{t-1} + a_{12}PIB_{t-1} + u_{1t}$$

$$PIB_t = a_{21}CO2_{t-1} + a_{22}PIB_{t-1} + u_{2t}$$

Su representación matricial

$$\begin{bmatrix} CO2_t \\ PIB_t \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} CO2_{t-1} \\ PIB_{t-1} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix}$$

$$\mathbf{Y}_t = \mathbf{A}\mathbf{Y}_{t-1} + \mathbf{U}_t$$

# Estimación en Stata

Nivel de significancia al 5%  
Valor Crítico Z = ±1.96

		Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
co2p	co2p L1.	.8313223	.0599623	13.86	0.000	.7137983	.9488463
	plib L1.	.000073	.0000239	3.05	0.002	.0000261	.0001198
plib	co2p L1.	-159.3993	152.7891	-1.04	0.297	-458.8604	140.0619
	plib L1.	1.075819	.0608828	17.67	0.000	.9564914	1.195148

$$CO2_t = 0.83CO2_{t-1} + 0.0007PIB_{t-1} + u_{1t}$$

$$PIB_t = -159.4CO2_{t-1} + 1.075PIB_{t-1} + u_{2t}$$

## Vector autoregression

Sample: 1966 - 2014

Log likelihood = -282.5872  
FPE = 412.3096  
Det(Sigma\_ml) = 350.1699

No. of obs = 49  
AIC = 11.69744  
HQIC = 11.75603  
SBIC = 11.85187

Equation	Parms	RMSE	R-sq	chi2	P>chi2
co2p	2	.104787	0.9989	45680.01	0.0000
pibp	2	267.005	0.9989	44181.94	0.0000

Se construye una matriz de varianzas y covarianzas de los errores

$$\hat{\Sigma} = \frac{1}{\tilde{T}} \hat{\mathbf{U}}' \hat{\mathbf{U}}$$

```
symmetric sig_var[2,2]
                co2p      pibp
co2p  .01053208  19.236281
pibp  19.236281  68381.996
```

$$\text{Var} \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix} = \begin{bmatrix} \sigma_{11}^2 & \sigma_{12}^2 \\ \sigma_{21}^2 & \sigma_{22}^2 \end{bmatrix} = \tilde{\Sigma}$$

```

symmetric sig_var[2,2]
                co2p                pibp
co2p    .01053208
pibp    19.236281    68381.996

```

$$|\tilde{\Sigma}| = \det \tilde{\Sigma} \quad \text{Det(Sigma_ml)} = 350.1699$$

```

. disp det_sigma
350.1699

```

Se calcula el log de máxima verosimilitud

$$LL = \left( \frac{T}{2} \right) \left\{ \ln(|\hat{\Sigma}^{-1}|) - K \ln(2\pi) - K \right\} \quad \ln(|\hat{\Sigma}^{-1}|) = -\ln(|\hat{\Sigma}|)$$

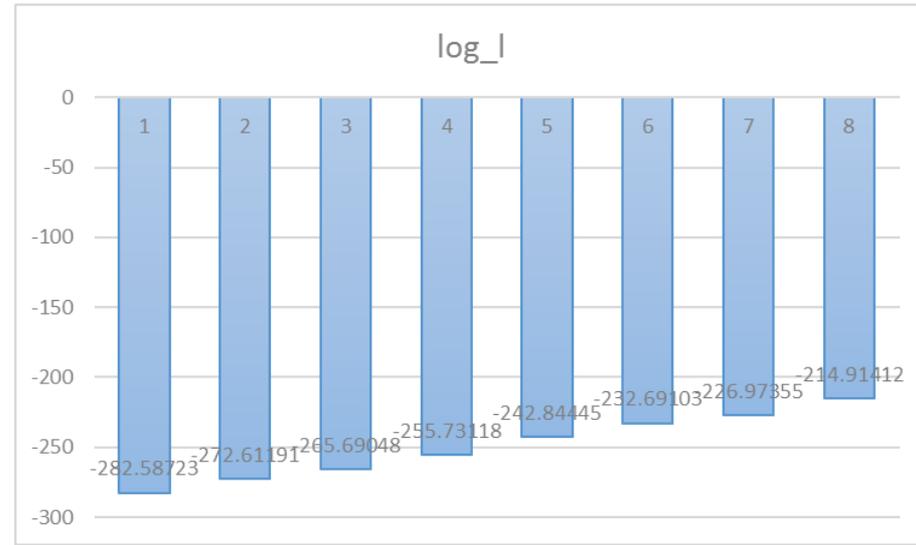
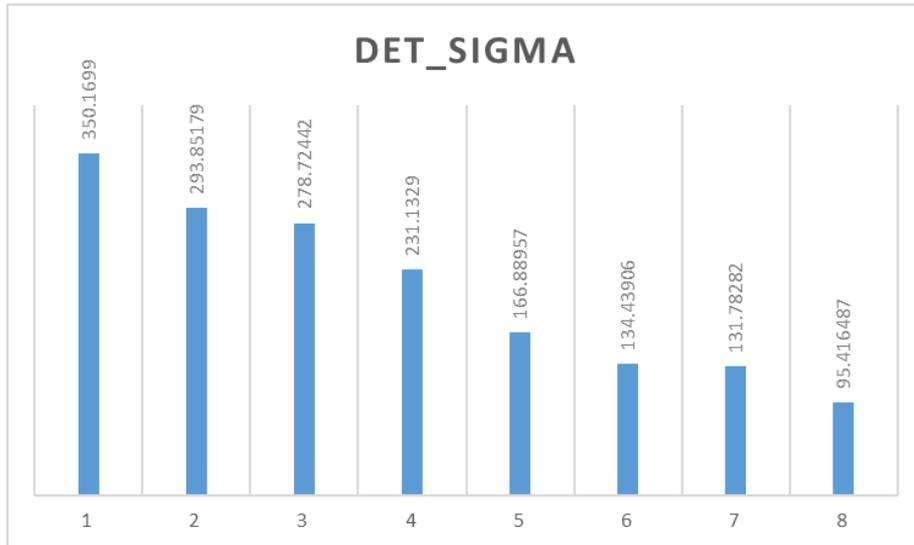
Donde K= número de ecuaciones en el modelo VAR, es decir número de variables endógenas

```

|Log likelihood = -282.5872

```

El determinante de la matriz de varianzas y covarianzas y el log de máxima verosimilitud, son indicadores de la información estadística en el modelo



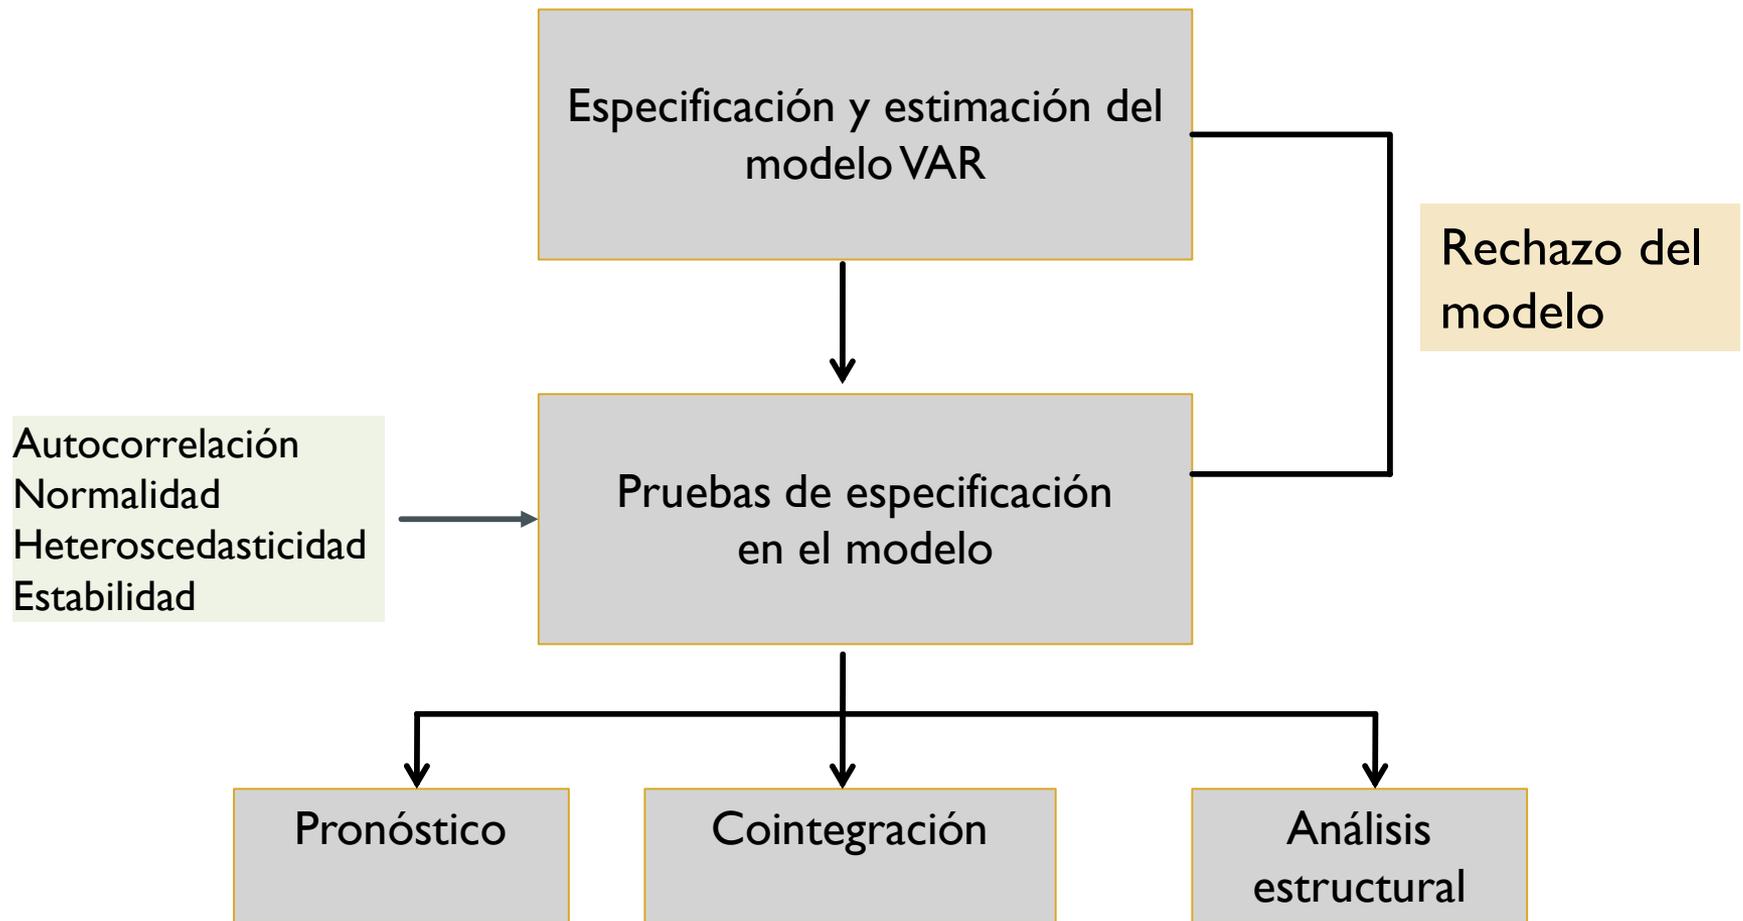
Cambian con el orden de los rezagos

La especificación del modelo VAR consiste en seleccionar el número de rezagos óptimo para el conjunto de variables

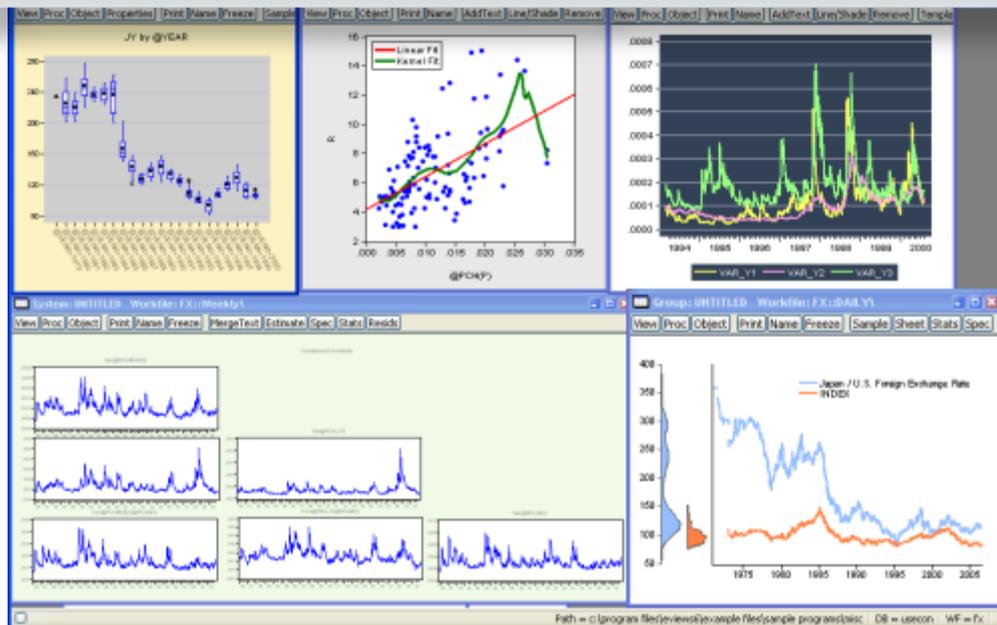
$$\mathbf{Y}_t = \mathbf{A}_0 + \mathbf{A}_1 \mathbf{Y}_{t-1} + \mathbf{A}_2 \mathbf{Y}_{t-2} + \dots + \mathbf{A}_k \mathbf{Y}_{t-k} + \mathbf{U}_t$$

$$\begin{aligned} \begin{bmatrix} CO2_t \\ PIB_t \end{bmatrix} &= \begin{bmatrix} c_{01} \\ c_{02} \end{bmatrix} + \begin{bmatrix} a_{11}^{(1)} & a_{12}^{(1)} \\ a_{21}^{(1)} & a_{22}^{(1)} \end{bmatrix} \begin{bmatrix} CO2_{t-1} \\ PIB_{t-1} \end{bmatrix} + \\ &+ \begin{bmatrix} a_{11}^{(2)} & a_{12}^{(2)} \\ a_{21}^{(2)} & a_{22}^{(2)} \end{bmatrix} \begin{bmatrix} CO2_{t-2} \\ PIB_{t-2} \end{bmatrix} + \dots + \begin{bmatrix} a_{11}^{(k)} & a_{12}^{(k)} \\ a_{21}^{(k)} & a_{22}^{(k)} \end{bmatrix} \begin{bmatrix} CO2_{t-k} \\ PIB_{t-k} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix} \end{aligned}$$

# Metodología de los modelos VAR



# Selección del número de rezagos y pruebas de especificación



En la especificación del VAR el número de parámetros crece al cuadrado del número de las variables

Benkwitz, Lutkepohl y Wolters (2000 y 2001) muestran que los métodos de bootstrap para construir intervalos de confianza puede estar seriamente distorsionados en el caso en que coeficientes que son cero so estimado sin restringir

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
<b>co2p</b>						
co2p						
L1.	.3111842	.1803993	1.72	0.085	-.0423919	.6647603
L2.	.5875177	.1728877	3.40	0.001	.248664	.9263714
pibp						
L1.	.0002167	.0000707	3.07	0.002	.0000782	.0003552
L2.	-.0001999	.0000723	-2.76	0.006	-.0003417	-.0000581
_cons	.2411325	.0865226	2.79	0.005	.0715513	.4107138
<b>pibp</b>						
co2p						
L1.	-527.4557	506.8895	-1.04	0.298	-1520.941	466.0295
L2.	553.7348	485.7833	1.14	0.254	-398.383	1505.853
pibp						
L1.	1.245822	.1985184	6.28	0.000	.8567326	1.634911
L2.	-.3006424	.2032738	-1.48	0.139	-.6990517	.0977669
_cons	445.0064	243.113	1.83	0.067	-31.48638	921.4992

Coeficientes NO significativos



Solución:

Utilizar métodos de reducción de parámetros basados en los datos

La teoría económica no es informativa respecto a la estructura rezagos

Utilizar teoría económica para reducir implica un sesgo a favor de una teoría particular que criticaba Sims

---

En la especificación correcta del modelo VAR se deben tomar en cuenta los siguientes aspectos:

- Criterios de información
- Pruebas sobre la selección de rezagos
- Pruebas de diagnóstico al modelo a fin de verificar que no existe información sistemática adicional
- Analizar las propiedades de estacionaridad del modelo

## Prueba de razón de máxima verosimilitud

$$\lambda_{LR} = 2 \left[ \ln \ell(\hat{\beta}) - \ln \ell(\hat{\beta}_r) \right]$$

$\ell(\hat{\beta})$  Parámetro de máxima verosimilitud sin restricción

$\ell(\hat{\beta}_r)$  Parámetro de máxima verosimilitud Con restricción

En la prueba se utiliza la función log de máximaverosimilitud

$$LL = \left( \frac{T}{2} \right) \left\{ \ln(|\hat{\Sigma}^{-1}|) - K \ln(2\pi) - K \right\}$$

Se desea probar la hipótesis nula que el conjunto de variables es generado por un VAR orden  $p_0$  respecto a una especificación alternativa  $p_1$ , donde  $p_1 > p_0$

$H_0: p_0$  VAR especificado en el rezago  $p_0$

$H_1: p_1$  el VAR especificad en el rezago  $p_1$

Asociado a cada rezago se tiene un valor de log de máximaverosimilitud

$$VAR(p_0) \rightarrow LL_0$$

$$VAR(p_1) \rightarrow LL_1$$

Se define un estadístico de prueba denominado LR, que es la diferencia entre ambos log de máxima verosimilitud:

$$LR(1) = 2 \times (LL_1 - LL_0)$$

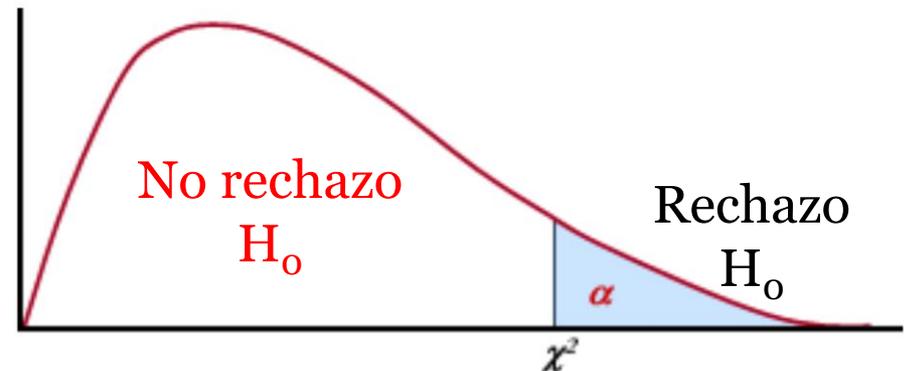
En general

$$LR(j) = 2 \times (LL_j - LL_0)$$

El estadístico LR se distribuye como una ji-cuadrada con T-m grados de libertad

$$LR \sim \chi^2(m)$$

m = diferencia en el número de parámetros



## Resultados de la prueba LR

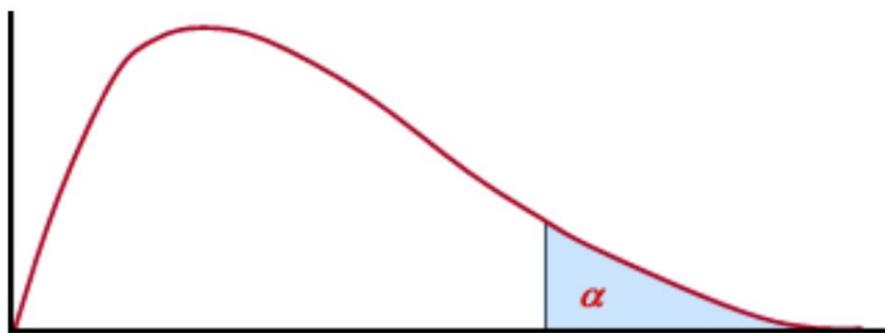
lag	LL	LR	df	p
0	-358.583			
1	-253.569	210.03	4	0.000
2	-244.315	18.507	4	0.001
3	-243.27	2.0902	4	0.719
4	-240.972	4.5957	4	0.331
5	-233.992	13.961*	4	0.007
6	-229.575	8.8333	4	0.065

Prob<0.05 Se rechaza  
la hipótesis nula  
El rezago "j" en el VAR  
es significativo

El máximo rezago donde No se rechaza la hipótesis nula es el número 5, es decir el VAR debe ser especificado con dos rezagos

# Estadístico LR

rezago	LL	Num parm	m = df	LR		VC 5%	Hipótesis	Conclusión
0	-358.583	2						
1	-253.569	6	(6-2)=4	$2*(-253.569-(-358.583))=$	210.03	9.4877	H0: VAR(0) H1:VAR(1)	Rechaza VAR(0)
2	-244.315	10	(10-6)=4	$2*(-244.315-(-253.569))=$	18.507	9.4877	H0: VAR(1) H1:VAR(2)	Rechaza VAR(1)
3	-243.270	14	(14-10)=4	$2*(-243.270-(-244.315))=$	2.0902	9.4877	H0: VAR(2) H1:VAR(3)	No Rechaza VAR(2)
4	-240.972	18	(18-14)=4	$2*(-240.972-(-243.270))=$	4.5957	9.4877	H0: VAR(3) H1:VAR(4)	No Rechaza VAR(3)
5	-233.992	22	(22-18)=4	$2*(-233.992-(-240.972))=$	13.961	9.4877	H0: VAR(4) H1:VAR(5)	Rechaza VAR(4)
6	-229.575	26	(26-22)=4	$2*(-229.575-(-233.992))=$	8.8333	9.4877	H0: VAR(5) H1:VAR(6)	No rechaza VAR(5)



$\chi^2$

9.4877 m=4

# Criterios Información

Akaike (Akaike, 1973; 1974)

$$\text{AIC} = -2 \left( \frac{\text{LL}}{T} \right) + \frac{2t_p}{T}$$

Schwarz (Rissanen 1978; Schwarz 1978)

$$\text{SBIC} = -2 \left( \frac{\text{LL}}{T} \right) + \frac{\ln(T)}{T} t_p$$

Hannan-Quinn (Hannan y Quinn (1979; Quinn 1980)

$$\text{HQIC} = -2 \left( \frac{\text{LL}}{T} \right) + \frac{2 \ln \{ \ln(T) \}}{T} t_p$$

$t_p$  = es el número de parámetros en el modelo VAR

$T$  = es el número de observaciones

$$\text{LL} = \left( \frac{T}{2} \right) \left\{ \ln(|\hat{\Sigma}^{-1}|) - K \ln(2\pi) - K \right\}$$

## Criterios de información en el modelo VAR STATA

lag	AIC	HQIC	SBIC
0	16.3901	16.4202	16.4712
1	11.7986	11.8888	12.0419
2	11.5598*	11.7102*	11.9653*
3	11.6941	11.9046	12.2618
4	11.7715	12.0421	12.5014
5	11.636	11.9668	12.5281
6	11.617	12.008	12.6713

El rezago óptimo es aquel donde el criterio de información reporta el valor mínimo en el rango de rezagos considerado

## Criterios Información modificados Lütkepohl (2005)

Akaike  $AIC(m) = \log \det(\hat{\Sigma}_m) + \frac{2}{T}mK^2$

Schwarz  $SC(m) = \log \det(\hat{\Sigma}_m) + \frac{\log T}{T}mK^2$

Hannan-Quinn  $HQ(m) = \log \det(\hat{\Sigma}_m) + \frac{2 \log \log T}{T}mK^2$

$m$  = el número de rezagos en el VAR

$T$  = número de observaciones

$K$  = número de variables endógenas

$$\hat{\Sigma} = \frac{1}{\tilde{T}} \hat{U}' \hat{U}$$

```
varsoc co2p pibp, maxlag(6) lutstats
```

Selection-order criteria (lutstats)

Sample: 1971 - 2014

Number of obs

=

44

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	-358.583				44998.8	10.6235	10.6235	10.6235
1	-253.569	210.03	4	0.000	456.348	6.03192	6.09207	6.19412
2	-244.315	18.507	4	0.001	359.962*	5.79312*	5.91342*	6.11752*
3	-243.27	2.0902	4	0.719	413.143	5.92743	6.10789	6.41403
4	-240.972	4.5957	4	0.331	449.177	6.0048	6.24541	6.6536
5	-233.992	13.961*	4	0.007	396.185	5.86932	6.17008	6.68032
6	-229.575	8.8333	4	0.065	394.494	5.85038	6.21129	6.82358

El rezago óptimo es aquel donde el criterio de información reporta el valor mínimo en el rango de rezagos considerado

Selección VAR(2)

- 
- Steward (2004), argumenta a favor Schwartz
  - Patterson (2000) Señala que Akaike sobre estima el número de rezagos
  - Lutkepohl (1991): Complementar con la prueba de autocorrelación
  - Paulsen (1984)

$$\hat{p}(\text{SC}) \leq \hat{p}(\text{HQ}) \leq \hat{p}(\text{AIC})$$

En muestras pequeñas AIC y FPE tienen mejores propiedades que SC y HQC

En muestras grandes AIC y FPE muestran errores en la selección de los rezagos

**Table 4.6.** Simulation results based on 1000 realizations of the bivariate VAR(2) process (4.2.1)

	FPE	AIC	HQ	SC	LR
VAR	$T = 30$				
order	frequency distributions of estimated VAR orders in %				
0	0.1	0.1	0.6	2.6	0.1
1	46.1	42.0	60.4	81.2	29.8
2	33.3	32.2	28.5	14.4	16.5
3	8.3	9.0	5.0	1.1	6.5
4	3.8	4.1	2.2	0.5	8.1
5	3.9	5.0	1.5	0.1	13.6
6	4.5	7.6	1.8	0.1	25.4

## FPE: Final Prediction Error

$$\text{FPE} = |\Sigma_u| \left( \frac{T + \bar{m}}{T - \bar{m}} \right)^K$$

$T$  = tamaño de la muestra

$K$  = número de variables en el VAR (número de ecuaciones)

$\bar{m}$  = promedio de parámetros en cada ecuación del VAR

$$|\Sigma_u| = \det \tilde{\Sigma}$$

lag	LL	LR	df	p	FPE
0	-358.583				44998.8
1	-253.569	210.03	4	0.000	456.348
2	-244.315	18.507	4	0.001	359.962*
3	-243.27	2.0902	4	0.719	413.143
4	-240.972	4.5957	4	0.331	449.177
5	-233.992	13.961*	4	0.007	396.185
6	-229.575	8.8333	4	0.065	394.494

$$FPE[\hat{p}(FPE)] = \min \{FPE(m) | m = 0, 1, \dots, M\}$$

Se selecciona el rezago donde FPE es mínimo, en este caso corresponde al segundo rezago

## Pruebas de exclusion (Wald lag-exclusion)

Prueba ji-cuadrada sobre los parámetros del modelo

$$\begin{bmatrix} y_{1t} \\ y_{2t} \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} y_{1t-1} \\ y_{2t-1} \end{bmatrix} + \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix} \begin{bmatrix} y_{1t-2} \\ y_{2t-2} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix}$$

$$H_0: b_{11} = 0, b_{12} = 0, b_{21} = 0, b_{22} = 0$$

$H_1$ : los estimadores diferentes de cero

Rechazar  $H_0$  implica que el rezago 2 no aporta información

Equation: All

lag	chi2	df	Prob > chi2
1	67.63201	4	0.000
2	15.66449	4	0.004
3	4.648129	4	0.325
4	12.99716	4	0.011
5	10.51378	4	0.033
6	9.354535	4	0.053

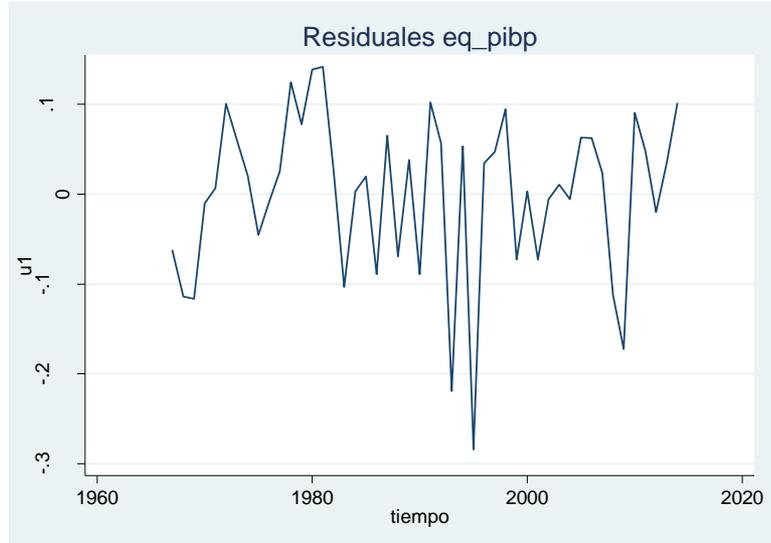
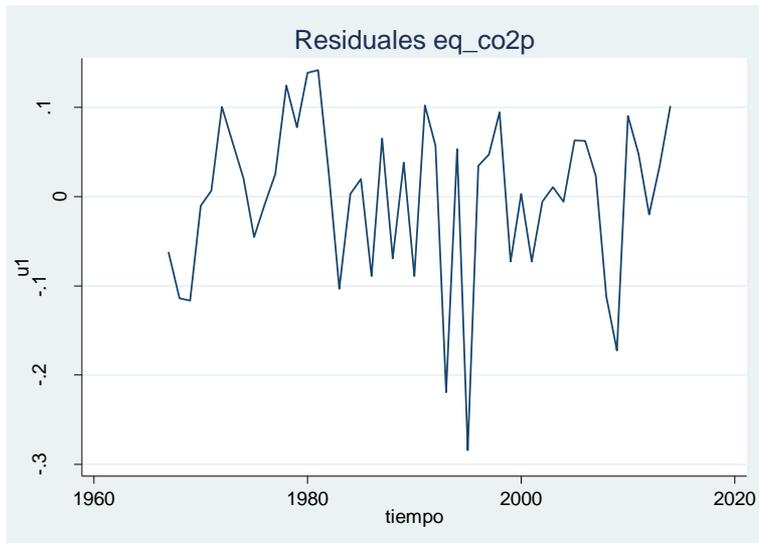
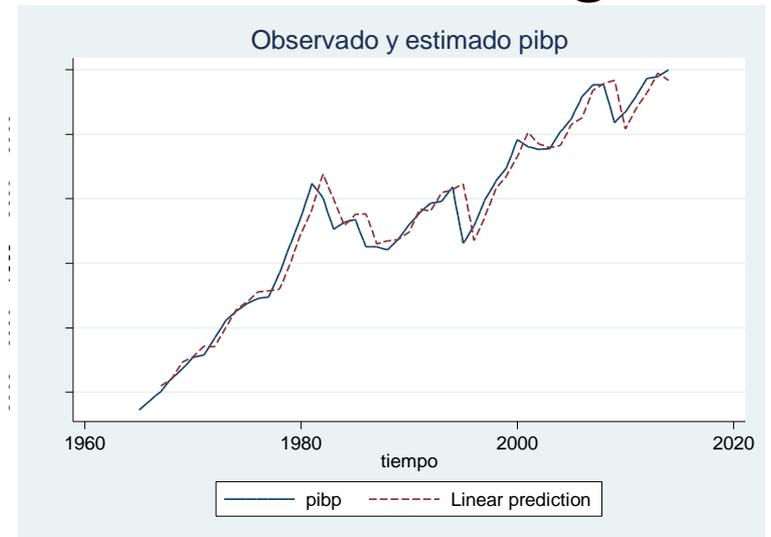
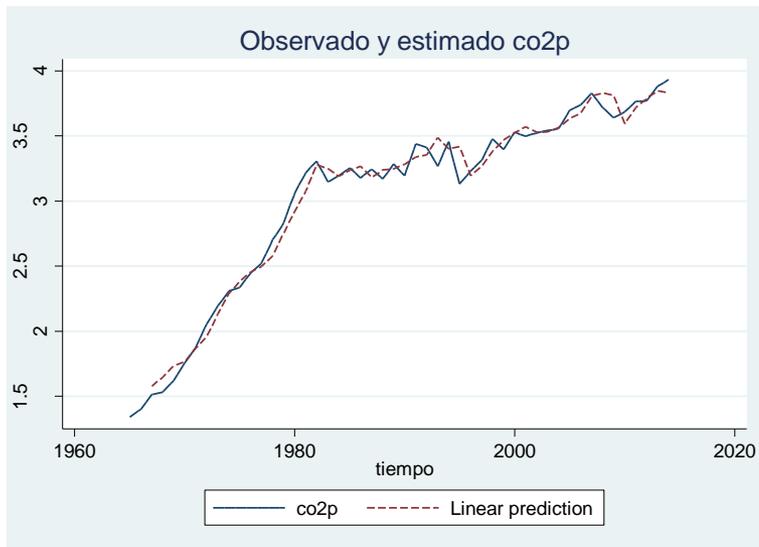
No  
significant

Una posible especificación es solo incluir los rezagos que son estadísticamente significativos

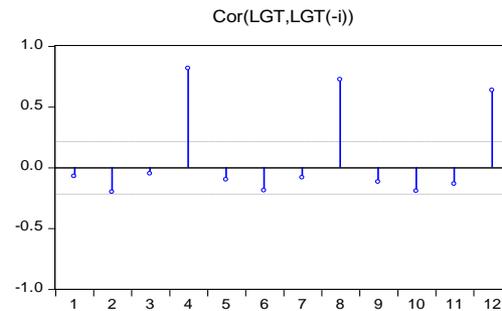
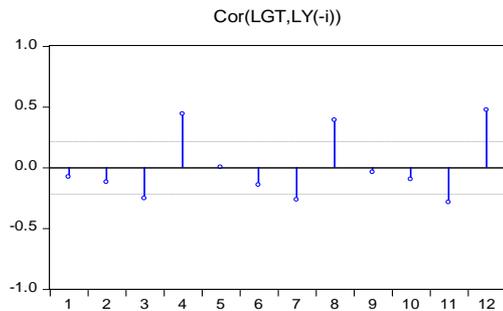
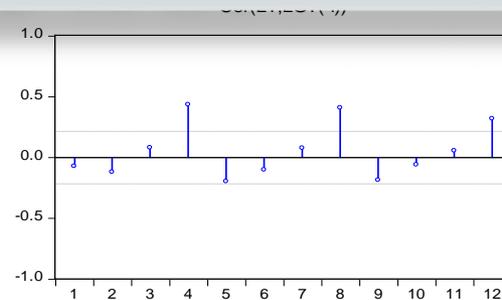
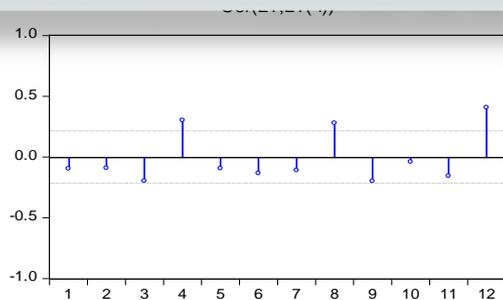
$$\begin{bmatrix} CO2_t \\ PIB_t \end{bmatrix} = \begin{bmatrix} c_{01} \\ c_{02} \end{bmatrix} + \begin{bmatrix} a_{11}^{(1)} & a_{12}^{(1)} \\ a_{21}^{(1)} & a_{22}^{(1)} \end{bmatrix} \begin{bmatrix} CO2_{t-1} \\ PIB_{t-1} \end{bmatrix} + \begin{bmatrix} a_{11}^{(2)} & a_{12}^{(2)} \\ a_{21}^{(2)} & a_{22}^{(2)} \end{bmatrix} \begin{bmatrix} CO2_{t-2} \\ PIB_{t-2} \end{bmatrix} + \\ + \begin{bmatrix} a_{11}^{(4)} & a_{12}^{(4)} \\ a_{21}^{(4)} & a_{22}^{(4)} \end{bmatrix} \begin{bmatrix} CO2_{t-4} \\ PIB_{t-4} \end{bmatrix} + \begin{bmatrix} a_{11}^{(5)} & a_{12}^{(5)} \\ a_{21}^{(5)} & a_{22}^{(5)} \end{bmatrix} \begin{bmatrix} CO2_{t-5} \\ PIB_{t-5} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix}$$

var co2p pibp, lags(1/3 4/5)

# El modelo VAR debe ser especificado con 2 rezagos



# Pruebas de Diagnóstico en el modelo VAR



---

El modelo VAR debe cumplir los supuestos estadísticos de un modelo econométrico

$$\mathbf{Y}_t = \mathbf{A}_0 + \mathbf{A}_1 \mathbf{Y}_{t-1} + \mathbf{A}_2 \mathbf{Y}_{t-2} + \cdots + \mathbf{A}_k \mathbf{Y}_{t-k} + \mathbf{U}_t$$

- $U_t \sim N[0, \Sigma_u]$  Normal
- $\text{Var}(U_t) = \Sigma_u$  Constante
- $\text{Cov}(U_t, U_{t-i}) = 0 \quad i=1,2,\dots$  No existe autocorrelación
- Parámetros lineales y constantes en el tiempo

Es necesario aplicar pruebas estadísticas

## PRUEBAS DE AUTOCORRELACIÓN

La prueba autocorrelación es particularmente importante para los modelos VAR. Permite mejorar la especificación del modelo en términos del número de rezago óptimo

La prueba utilizada se denomina LM y se basa en el siguiente procedimiento:

Estimar el modelo VAR original

$$Y_t = A_0 + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_k Y_{t-k} + U_t$$

Obtener el vector de errores para cada ecuación

Con los vectores de errores como nuevas variables se estima el siguiente modelo auxiliar

$$\hat{U}_t = A_0 + A_1 Y_{t-1} + \dots + A_k Y_{t-k} + D_1 \hat{U}_{t-1} + D_2 \hat{U}_{t-2} + \dots + D_h \hat{U}_{t-h} + \varepsilon_t$$

$H_0 : D_1 = \dots = D_h = 0$  **Hipótesis nula No hay autocorrelación**

$H_1 : D_j \neq 0$  **Hipótesis alternativa Problemas de autocorrelación**

## El estadístico de la prueba

$$LM_s = (T - d - .5) \ln \left( \frac{|\hat{\Sigma}|}{|\tilde{\Sigma}_s|} \right)$$

$|\hat{\Sigma}|$  = Determinante de la matriz de varianzas y covarianzas del VAR original

$|\tilde{\Sigma}_s|$  = Determinante de la matriz de varianzas y covarianzas del modelo auxiliar

$s$  = el orden de rezago en la prueba

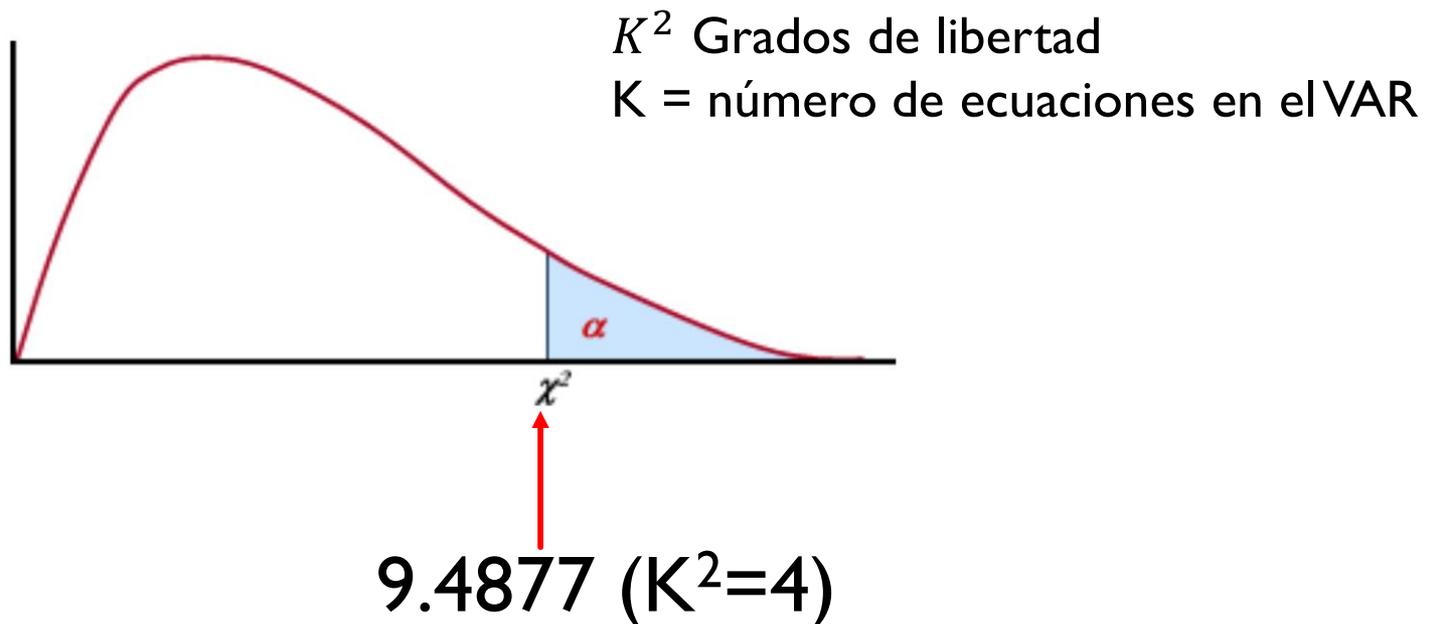
$d$  = número de coeficientes en el modelo auxiliar

Bajo la hipótesis nula (no existe autocorrelación) el estadístico  $LM_s$  se distribuye como una ji-cuadrada con  $K^2$  grados de libertad

## Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	1.1508	4	0.88612
2	2.5748	4	0.63129

H0: no autocorrelation at lag order



## PRUEBAS DE NORMALIDAD

Si los errores del VAR no se distribuyen como una normal indicarían que no es una buena representación del proceso generador de los datos

Debe ser una prueba sobre el vector de los errores del VAR

Considerar las desviaciones respecto a cada variable

$$y_t - \mu = A_1(y_{t-1} - \mu) + \dots + A_p(y_{t-p} - \mu) + u_t$$

Obtener los errores

$$\hat{u}_t := (y_t - \bar{y}) - \hat{A}_1(y_{t-1} - \bar{y}) - \dots - \hat{A}_p(y_{t-p} - \bar{y})$$

Se define la matriz de varianzas y covarianzas

$$\hat{\Sigma}_u := \frac{1}{T - Kp - 1} \sum_{t=1}^T \hat{u}_t \hat{u}_t'$$

Se utiliza un método de ortogonalización, para calcular el tercer y cuarto momento de la distribución

Descomposición de Cholesky

Matriz  $\hat{P}$  tal que  $\hat{P}\hat{P}' = \hat{\Sigma}_u$

Que permite definir un vector de errores (que son ortogonales)

$$\hat{w}_t = (\hat{w}_{1t}, \dots, \hat{w}_{Kt})' := \hat{P}^{-1} \hat{u}_t,$$

Cada columna de la matriz  $w_t$  representa a los errores de cada ecuación del VAR, respectivamente

$$\hat{\mathbf{b}}_1 = (\hat{b}_{11}, \dots, \hat{b}_{K1})'; \quad \hat{b}_{k1} = \frac{1}{T} \sum_{i=1}^T \hat{w}_{kt}^3 \quad \text{mide el sesgo}$$

$$\hat{\mathbf{b}}_2 = (\hat{b}_{12}, \dots, \hat{b}_{K2})'; \quad \hat{b}_{k2} = \frac{1}{T} \sum_{i=1}^T \hat{w}_{kt}^4 \quad \text{mide la curtosis}$$

Se define la siguiente prueba de hipótesis sobre los coeficientes de sesgo y curtosis

$$H_0 : \hat{\mathbf{b}}_1 = \mathbf{0} \quad \text{y} \quad \hat{\mathbf{b}}_2 = \mathbf{3}$$

Los estadísticos de prueba para cada sesgo y curtosis para cada ecuación

$$\hat{\lambda}_{1k} = \frac{T \hat{b}_{k1}^2}{6} \xrightarrow{d} \chi^2(1) \text{ Sesgo}$$

$$\hat{\lambda}_{2k} = \frac{T (\hat{b}_{k2}^2 - 3)^2}{24} \xrightarrow{d} \chi^2(1) \text{ Curtosis}$$

$$\hat{\lambda}_{3k} = \hat{\lambda}_{1k} + \hat{\lambda}_{2k} \xrightarrow{d} \chi^2(2) \text{ Normalidad}$$

Normalidad conjunta estadístico

$$\hat{\lambda}_3 = \hat{\lambda}_1 + \hat{\lambda}_2 \xrightarrow{d} \chi^2(2K)$$

### Jarque-Bera test

Equation	chi2	df	Prob > chi2
co2p	8.656	2	0.01319
pibp	0.848	2	0.65447
ALL	9.504	4	0.04966

No pasa la prueba

### Skewness test

Equation	Skewness	chi2	df	Prob > chi2
co2p	-.94012	7.071	1	0.00784
pibp	-.25038	0.502	1	0.47884
ALL		7.572	2	0.02268

Problemas de sesgo en los errores de la eq co2p

### Kurtosis test

Equation	Kurtosis	chi2	df	Prob > chi2
co2p	3.8904	1.586	1	0.20794
pibp	2.5838	0.346	1	0.55618
ALL		1.932	2	0.38058

No hay exceso de curtosis



tiempo	u1
1990	-.0889355
1991	.1019697
1992	.0569133
1993	-.2193569
1994	.0532744
1995	-.2844393
1996	.0344505
1997	.0472736
1998	.0942471
1999	-.0728777
2000	.0031545

Valores extremos

Se debe generar una variable dummy

# CURSO: ECONOMETRÍA Y ANÁLISIS DE POLÍTICAS FISCALES

INSTRUCTOR: HORACIO CATALÁN ALONSO

## Especificación de los modelos VAR

