

# Econometría II



## Introducción II

Carlos A. Yanes Guerra

2024-I

# Series de tiempo

## Características

- ✈ En **series** tenemos un "orden" temporal. No es como los datos de sección cruzada
- ✈ Tenemos entonces que alterar un poco los **supuestos** de MCO ya que no vamos a tener una **muestra aleatoria** de individuos.
- ✈ Vamos ahora a encontrarnos con una realización de un *proceso estocástico* (lo que se conoce como aleatorio).

Un modelo estático no es más que aquel que se conforma con:

$$Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t$$

# Series de tiempo

## Características

✚ Un modelo de **rezagos distribuidos** (FDL), muestra una o mas variables que afectan a  $(Y_t)$  con un rezago:

$$Y_t = \phi_0 + \phi_1 X_t + \phi_2 X_{t-1} + \phi_3 X_{t-2} + \varepsilon_t$$

✚ De forma mas general, un modelo de **rezagos finitos** de orden  $p$  que incluye  $p$  rezagos de la variable  $(X_t)$ .

- Podemos decir que  $\phi_0$  es la propensión de impacto que se refleja en un cambio inmediato de  $(Y_t)$ .
- Denotamos que  $(\phi_0 + \phi_1 + \phi_2 + \dots + \phi_p)$  refleja el cambio de **largo plazo** de los cambios de  $(Y_t)$

# Series de tiempo

## Supuestos del estimador para muestras finitas

🔹 Nuestro modelo sigue siendo lineal en parámetros.

$$Y_t = \beta_0 + \beta_1 X_{1t} + \dots + \beta_k X_{kt} + u_t$$

🔹 El supuesto de **media condicional** de los residuos también se mantiene p.e:  $E(u_t | X_t) = 0$ ,  $t = 1, 2, 3, 4, \dots, n$ .  
Acá se hace mas fuerte porque no queremos que en distintos periodos exista relación entre el *error* y las variables explicativas del modelo.

Lo anterior se conoce como (X's) estrictamente exógenas (hasta en el tiempo).

🔹 Nuestro/s control/es ( $X_t$ ) no son constantes y desde luego no hay perfecta **colinealidad**.

*Si los anteriores supuestos se cumplen, entonces estamos en condiciones de decir que nuestros parámetros son insesgados*

# Series de tiempo

## Otros supuestos

Necesitamos otros mas (repassando 🤔)

🔹 La varianza de los residuos  $Var(\varepsilon_t|X_t) = Var(\varepsilon_t) = 0$ , debe ser constante en el tiempo y ademas *independiente* de los movimientos o cambios de  $X_t$ .

🔹 Finalmente, la covarianza de los **residuos** es independiente en el tiempo, es decir, no existe **correlación serial**  $corr(\varepsilon_t, \varepsilon_j|X_t) = 0$ , para  $t \neq j$ .

*Ahora bajo todos los 5 supuestos podemos argumentar que los estimadores de regresión de serie de tiempo son (BLUE)*

# Componentes de una serie de tiempo

# Componentes

## Tendencia

$$Y_t = T_t + C_t + S_t + Irrr_t$$

La tendencia nos dice hacia donde va la serie de tiempo. Si esta es positiva, la serie diremos que tiene tendencia creciente. **que tanto?** Dependerá de su forma funcional.

- Si tenemos dos series de tiempo  $Y_t, X_t$  no podemos decir que ambas tengan una relación causal si la **dirección** es la misma. Existen múltiples factores no observables que van contenidos en la **tendencia** y por ende tenemos que eliminarla/tratarla, para que la relación sea ajustada a lo que podemos observar.


# Componentes

## Formas funcionales $f(X)$

Modelo	Significado
<i>Lineal</i> $Y_t = \delta_0 + \delta_1 T_t + u_t$	<i>Modelo lineal de tendencia</i>
<i>Lineal - orden =2</i> $Y_t = \delta_0 + \delta_1 T_t + \delta_2 T_t^2 + u_t$	<i>Modelo lineal pero con polinomio de orden 2</i>
<i>Lineal - orden = <math>\rho</math></i> $Y_t = \delta_0 + \delta_1 T_t + \dots + \delta_\rho T_t^\rho + u_t$	<i>Modelo Lineal pero con polinomio de orden <math>\rho</math></i>



# Componentes



# Componentes

## Otras formas (menos convencionales)

Modelo	Significado
<i>Logaritmico</i> $Y_t = \delta_0 + \delta_1 \text{Log}(T_t) + u_t$	<i>Modelo logaritmico en Tendencia</i>
<i>Doble logaritmo</i> $\text{Log}(Y_t) = \delta_0 + \delta_1 \text{Log}(T_t) + u_t$	<i>Modelo logaritmico en Tendencia y serie</i>
<i>Exponencial</i> $Y_t = e^{\delta_0 + \delta_1 \text{Log} T_t + u_t}$	<i>Modelo Exponencial en T</i>
<i>Reciproco en <math>T_t</math></i> $Y_t = \delta_0 + \delta_1 \frac{1}{T_t} + u_t$	<i>Modelo reciproco (inverso) en tendencia</i>
<i>Box-Cox I</i> $Y_t^\theta = \delta_0 + \delta_1 T_t^\lambda + u_t$	<i>Modelo restringido I cuando <math>\lambda = \theta \neq 0</math></i>
<i>Box-Cox II</i>	<i>Modelo restringido II cuando <math>\lambda \neq \theta \neq 0</math></i>

# Componentes

## Modelo Box Cox

Hay que tener cuidado con él. Tiene algo espectacular y es que puede asumir las otras formas **funcionales**. Dependerá de los valores óptimos de  $\lambda$  y  $\theta$ .




Note adicional que entonces hay que encontrar los valores específicos de esos **parámetros**.

$$Y_t^\theta = C_0 + \delta_t T_t^\lambda + u_t$$

Donde:

$$Y_t^\theta = \frac{Y_t^\theta - 1}{\theta} \quad T_t^\lambda = \frac{T_t^\lambda - 1}{\lambda}$$

# Componentes



# Componentes

## Ciclo

$$Y_t = T_t + C_t + S_t + Irrr_t$$




El ciclo nos dice la evolución de la serie. Recordemos que en economía ciclos positivos van en **auge** o negativos si estos son o van en **recesión**. Una de las tantas formas naturales de expresarlo es:

$$Y_t = 2 \cos \left( 2\pi \frac{t + 15}{50} \right)$$



$$Y_t = 2 \cos \left( 2\pi \frac{t + 15}{50} \right) + \epsilon_t$$

La parte de  $\epsilon_t$  que tiene que ver con el "ruido", puede impactar en la serie de acuerdo al nivel de varianza  $var(\epsilon_t)$  que esta contenga. Involucramos a  $(\pi)$  por el radio y a  $(t)$  como referencia a la tendencia de la serie. p.e:  $t \in \{1, \dots, n\}$ .

# Componentes



# Componentes



# Componentes



## Estacionalidad (Seasonality)

El componente **Estacional** corresponde a los **movimientos** de una variable sucedidos reiteradamente durante una frecuencia *homogénea* de **tiempo**. Para las series de tiempo siempre se presenta cuando existe una periodicidad diaria, semanal, mensual, trimestral o semestral. Este elemento se caracteriza por aparecer en un periodo y desvanecerse en el siguiente.

$$Y_t = T_t + C_t + S_t + Irr_t$$




# Componentes



# Componentes

En  Se puede hacer directamente con el comando de `decompose` del paquete `XTS`.

```
# library(xts) Es requerida!!  
x = window(hor, start=2002)  
plot(decompose(x))
```




# Componentes

## Irregular


El componente irregular hace referencia a  $(\varepsilon_t)$  conocido anteriormente como residuo de la regresión. Toda serie de tiempo lo tiene, ahonda todo lo que incide en el **comportamiento** de ella, pero es inobservable.

Es un componente impredecible, hace parte de factores de corto plazo (coyunturales), no recurrentes que de cierta manera afectan el comportamiento de la serie.

# Componentes



**Distribución de residuos  
Habitaciones Hawaii**



# Bibliografía

- 📖 Chatfield, C. (2000). *Time-series forecasting*. CRC press.
- 📖 Hyndman, R.J., & Athanasopoulos, G. (2021). *Forecasting: principles and practice*, 3rd edition, OTexts: Melbourne, Australia.
- 📖 Righetti, N., (2022). *Time Series Analysis With R*. Bookdown.
- 📖 Shumway, R., & Stoffer, D. (2019). *Time series: a data analysis approach using R*. CRC Press.

# ¡Gracias!

## Componentes

## Seguimos aprendiendo



 Syllabus/ Curso

 @keynes37

 [cayanes@uninorte.edu.co](mailto:cayanes@uninorte.edu.co)