

# Tema 06: El modelo de regresión lineal con residuos autocorrelados

## Análisis estadístico de series económicas

Xavier Barber

Departamento de Estadística, Matemáticas e Informática  
Centro de Investigación Operativa  
Universitas Miguel Hernández de Elche

07/May/2019



# Ajuste por mínimos cuadrados y la tendencia

# Serie temporal $Y_t$ como modelo lineal

- El modelo lineal ha sido la herramienta predominante en el contexto de la estadística clásica.
- La primera idea se basa en estudiar el “crecimiento” de la serie y su tendencia, es decir, expresar la relación de  $Y_t$  para  $t = 1, 2, \dots, q$ .


## Modelo Lineal

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_q + Y_t e_t$$

donde  $\beta_1, \beta_2, \dots, \beta_q$  son los coeficientes fijos de la regresión, y siendo  $e_t \stackrel{iid}{\sim} \mathcal{N}(0, \sigma_e^2)$  el error aleatorio o proceso de ruido.

# Ejemplo: Gasto en consumo en USA

- Porcentaje de cambio trimestral (tasa de crecimiento) del gasto personal real en consumo y su disponibilidad de ingresos en USA desde 1970 a 2016.



# Ejemplo: Gasto en consumo en USA

```
tslm(Consumo ~ Ingresos, data = uschange) %>% summary
```

Call:

```
tslm(formula = Consumo ~ Ingresos, data = uschange)
```

Residuals:

Min	1Q	Median	3Q	Max
-2.40845	-0.31816	0.02558	0.29978	1.45157

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )		
(Intercept)	0.54510	0.05569	9.789	< 2e-16 ***		
Ingresos	0.28060	0.04744	5.915	1.58e-08 ***		
---						
Signif. codes:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.'	0.1 ' '	1

Residual standard error: 0.6026 on 185 degrees of freedom


Multiple R-squared: 0.159, Adjusted R-squared: 0.1545

F-statistic: 34.98 on 1 and 185 DF, p-value: 1.577e-08

# Ajuste modelo lineal

- ¿Cuál es la relación entre Consumo e ingresos?

$$\text{Consumo} = 0.55 + 0.28 * \text{Ingresos}$$




Por cada cambio de un 1% en los ingresos hay un cambio de 0.28 en el Consumo

# Ajuste modelo lineal > 2 variables

```
autoplot(uschange[,3:5], facets = TRUE,  
        colour=TRUE) +  
  ylab("") + xlab("Años") +  
  guides(colour="none")
```


# Ajuste modelo lineal > 2 variables



# Ajuste modelo lineal > 2 variables

```
uschange %>%  
  as.data.frame %>%  
  GGally::ggpairs()
```

# Ajuste modelo lineal > 2 variables



# Ajuste modelo lineal > 2 variables

```
fit.consMR<-tslm(Consumo~Ingresos+Tasa_produc+Desempleo+Ahorros,
summary(fit.consMR)
```

Call:

```
tslm(formula = Consumo ~ Ingresos + Tasa_produc + Desempleo +
    Ahorros, data = uschange)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.88296	-0.17638	-0.03679	0.15251	1.20553

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	0.26729	0.03721	7.184	1.68e-11 ***
Ingresos	0.71449	0.04219	16.934	< 2e-16 ***
Tasa_produc	0.04589	0.02588	1.773	0.0778 .
Desempleo	-0.20477	0.10550	-1.941	0.0538 .
Ahorros	-0.04527	0.00278	-16.287	< 2e-16 ***

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.3286 on 182 degrees of freedom

Multiple R-squared: 0.754, Adjusted R-squared: 0.7486

F-statistic: 139.5 on 4 and 182 DF, p-value: < 2.2e-16

# Ejemplo: Gasto en consumo de USA


- ¿Cómo ajusta este modelo?

```
autoplot(uschange[, 'Consumo'], series="Datos originales") +  
  autolayer(fitted(fit.consMR), series="Datos Ajustados") +  
  xlab("año") + ylab("") +  
  ggtitle("Porcentaje de cambio en el gasto en Consumo en USA") +  
  guides(colour=guide_legend(title=" "))+  
  theme(legend.position = "bottom")
```

# Ejemplo: Gasto en consumo de USA

- ¿Cómo ajusta este modelo?

Porcentaje de cambio en el gasto en Consumo en USA



# Ejemplo: Gasto en consumo de USA


- ¿Cómo ajusta este modelo?

```
cbind(Data=uschange[, "Consumo"], Fitted=fitted(fit.consMR)) %>%
  as.data.frame %>%
  ggplot(aes(x=Data, y=Fitted)) +
  geom_point() +
  xlab("Ajustados (valores predichos)") +
  ylab("Datos (valores actuales)") +
  ggtitle("Porcentaje de cambio en el gasto en Consumo en USA") +
  geom_abline(intercept=0, slope=1)
```

# Ejemplo: Gasto en consumo de USA

- ¿Cómo ajusta este modelo?



Porcentaje de cambio en el gasto en Consumo en USA



# Ejemplo: Gasto en consumo de USA

- ¿Es válido este modelo?

Residuals from Linear regression model



# Autocorrelación serial

# Introducción

- En el entorno de las series temporales la principal asunción que no suele cumplirse en la independencia de los residuos.
- La correlación en los residuos representa una estructura en los datos, y el modelo de regresión lineal “inicialmente” no lo tiene en cuenta.
- Cuando las observaciones tienen un orden secuencial, y como resultado una estructura de correlación relacionada con ese orden, esta correlación se le llama **autocorrelación**.

# Residuos autocorrelados

- ¿Y si al mirar la validez del modelo tenemos autocorelación? (gráfico ACF)
- Este es un caso habitual cuando se estudian series temporales mediante modelos de regresión
- Hay situaciones en las que es relativamente sencillo solucionarlo introduciendo alguna variable más en el modelo
- En otras ocasiones se necesitan de métodos de ajuste alternativos a los mínimos cuadrados ordinarios.

# Efectos de la autocorrelación

- La autocorrelación puede tener varios efectos sobre el ajuste del modelo:
- Ajuste insesgado, pero no eficiente, en el sentido de no tener la mínima varianza posible. Un proceso **autorregresivo de orden uno**, AR(1), puede ser suficiente

Modelos lineal con residuos  $\sim AR(1)$

$$Y_t = \beta_0 + \beta_1 \times X_1 + \dots + \beta_p \times X_p + w_t$$
$$w_t = \rho e_{t-1} + z_i, \quad |\rho| < 1$$

# Efectos de la autocorrelación

La autocorrelación puede tener varios efectos sobre el ajuste del modelo:

- ② Las estimaciones de los errores estándar de los coeficientes de la regresión y de  $\sigma_e^2$  son sesgados. Esto ocurre muy a menudo en los datos de series económicas, donde la correlación es positiva y el coeficiente de dicho AR(1) también es positivo.
  
- ③ Como resultado de ese sesgo, los intervalos de confianza, los contrastes de hipótesis y los intervalos de predicción no son válidos (muy anchos).

# Identificando la autocorrelación

Una forma habitual de identificar la autocorrelación,  $\rho_k \equiv \text{corr}(e_t, e_{t-1}) = \rho^k$ , es mediante el estadístico de **Durbin-Watson**.

$$H_0 : \rho = 0 ; H_a : \rho > 0$$

$$d = \frac{\sum_{t=2} n(e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2}$$

- **Región de rechazo:**

- Si  $d < d_L$ , se rechaza  $H_0$ .
- Si  $d > d_U$ , no se rechaza  $H_0$ .
- Si  $d \in (d_U, d_L)$ , el test no puede concluir nada.

# Identificando la autocorrelación

- En el caso de R:

```
dwtest(formula, order.by = NULL,  
       alternative = c("greater", "less",  
                      "two.sided"),  
       iterations = 15, exact = NULL,  
       tol = 1e-10, data = list())
```

# Test de autocorrelación serial

- Otra alternativa para el estudio de la autocorrelación: *rank von Neumann ratio test*, que es una aproximación a la normal basada en las ecuaciones de Yule-Walker que se vieron en temas anteriores.

**Nota:** Muchos de los paquetes estadísticos del mercado utilizan por defecto los residuos estudentizados para eliminar el efecto de la magnitud de las variables a estudio:

$$e^{\star_t} = \frac{e_t - \bar{e}_t}{\sigma_e}$$

Lógicamente estos residuos estandarizados siempre tendrán media cero, pero tienen numerosas ventajas para tratarlos en otros tipos de contrastes.

# Test de autocorrelación serial

- Rank von Neumann ratio test

$$H_0 : \rho_1 = 0$$

$$H_a : \rho_1 > 0; \quad H_a : \rho_1 < 0; \quad H_a : \rho_1 \neq 0$$

donde  $\rho_1$  denota la verdadera autocorrelación con retardo-1.

El test se basa en la aproximación a la normal de las ecuaciones de Yule-Walker (`test="AR1.yw"`) que viene dada por:

$$\hat{\rho}_1 = \frac{\hat{\gamma}_1}{\hat{\gamma}_0} \hat{\gamma}_k = \frac{1}{n} \sum_{t=1}^{n-k} (x_t - \bar{x})(x_{t+k} - \bar{x})$$

donde  $\hat{\gamma}_k$  es la estimación de la autocovarianza de retardo- $k$

# Test de autocorrelación serial

Bajo la hipótesis nula:

- El valor estimado de retardo-1 se distribuye como una variable aleatoria Gaussiana<sup>1</sup> con media 0 y varianza dada por

$$Var(\hat{\rho}_1) \approx \frac{1}{n}.$$

- Entonces, la hipótesis nula puede contrastarse con el estadístico:

$$z = \sqrt{n}\hat{\rho}_1$$

*El cual se distribuye aproximadamente como una normal estándar bajo la hipótesis nula, esto es, que la autocorrelación de retardo-1 es 0.*

---

<sup>1</sup> Box and Jenkins, 1976, pp.34-35

# Breusch-Godfrey test

- El contraste de Godfrey-Breusch para la autocorrelación serial es un contraste basado en los multiplicadores de Lagrange, cuya hipótesis de trabajo son:


$$H_0 : \rho = 0$$

$$H_a : e_t \sim AR(p); \quad H_a : e_t \sim MA(q)$$

- En *R* se utiliza el comando:

```
# del paquete lmtest
bgtest(formula, order = 1, order.by = NULL,
       type = c("Chisq", "F"), data = list(), fill = 0)
# o del paquete EnvStats el comando
checkresiduals(object, lag, df = NULL, test, plot = TRUE, ...)
```

# Ejemplo: Gasto.farmacia~Temp.+Conta.



# Ejemplo: Gasto en farmacia

- Diferentes modelos y estudiar cuál se aadecua mejor a los datos a estudio.

$$GF_t = \beta_0 + \beta_1 t + e_t \quad (1)$$

$$GF_t = \beta_0 + \beta_1 t + \beta_2(T_t - \bar{T}) + e_t \quad (2)$$

$$GF_t = \beta_0 + \beta_1 t + \beta_2(T_t - \bar{T}) + \beta_3(T_t - \hat{T})^2 + e_t \quad (3)$$

$$GF_t = \beta_0 + \beta_1 t + \beta_2(T_t - \bar{T}) + \beta_3(T_t - \bar{T})^2 + \beta_4 C_t + e_t \quad (4)$$

# Ejemplo: Gasto en farmacia

```
##Creación de las variables centradas y temepratura al cuadrado
temp = temp-mean(temp)
temp2 = temp^2
trend = time(gasto)           # tiempo como tendencia ( != beta_0)

## ajuste del modelo con tendencia ; temp. ; temp^2 y cont.
regre1 = lm(gasto~ trend, na.action=NULL)
regre2 = lm(gasto~ trend + temp, na.action=NULL)
regre3 = lm(gasto~ trend + temp + temp2 , na.action=NULL)
regre4 = lm(gasto~ trend + temp + temp2 + part, na.action=NULL)
```

# Ejemplo: Gasto en farmacia

	Modelo-1	Modelo-2	Modelo-3	Modelo-4
$\beta_0$	3356.10*** (281.35)	3181.12*** (249.96)	3091.59*** (236.43)	2881.74*** (203.19)
Tendencia	-1.62*** (0.14)	-1.54*** (0.12)	-1.49*** (0.12)	-1.40*** (0.10)
Temperatura		-0.46*** (0.04)	-0.48*** (0.04)	-0.47*** (0.03)
Temperatura <sup>2</sup>			0.03*** (0.00)	0.02*** (0.00)
Contaminación				0.26*** (0.02)
R <sup>2</sup>	0.21	0.38	0.45	0.60
Adj. R <sup>2</sup>	0.21	0.38	0.44	0.59
Num. obs.	508	508	508	508
RMSE	8.89	7.89	7.45	6.39


\*\*\* $p < 0.001$ , \*\* $p < 0.01$ , \* $p < 0.05$

# Ejemplo: Gasto en farmacia

- El modelo más bondadoso:

$$\text{Gasto} = \beta_0 - 1.40 \times t - 0.47 \times \text{Temp.} + 0.02 \times \text{Temp.}^2 + 0.26 \times \text{Cont.} + e_t$$


Gasto en farmacia asociado a Temp. y Cont.



— Datos Ajustados — Datos originales

# Ejemplo: Gasto en farmacia

¿Es válido el modelo?



# Ejemplo: Gasto en farmacia

¿Es válido el modelo?

Results of Hypothesis Test

Alternative Hypothesis:

Test Name: Breusch-Godfrey test for serial correlation of order up to 101

Data: Residuals

Test Statistic: LM test = 198.3097

Test Statistic Parameter: df = 101

P-value: 2.599885e-08

# Ejemplo: Gasto en farmacia

- ¿Existe autocorrelación en los residuos

Durbin-Watson test

```
data: regre4
DW = 1.3109, p-value = 1.523e-15
alternative hypothesis: true autocorrelation is greater than 0
```

*Estos modelos van a producir estimaciones sesgadas y no es un modelo válido.*

*Se deben probar diferentes alternativas para analizar la relación existente entre el gasto en farmacia y las temperaturas.*


# Ejemplo: Gasto en farmacia

- Para el *Rank von Neumann ratio test*:


z-Test for Lag-1 Autocorrelation (Normal Approximation)

```
data: Residuals
z = 7.76, p-value = 8.438e-15
alternative hypothesis: true rho is not equal to 0
sample estimates:
rho
0.344296
```

# Ejemplo: Tiempo entre “caidas” en bolsa



# Ejemplo: Tiempo entre “caidas” en bolsa



# Ejemplo: Tiempo entre “caidas” en bolsa

- Los modelos que se van a probar son:

$$Tiempo.entre_t = \beta_0 + \beta_1 \times Dura_t + e_t$$

$$Tiempo.entre_t = \beta_0 + \beta_1 \times Dura_t + e_t$$

$$Tiempo.entre_t = \beta_0 + \beta_1 \times Dura_t + \beta_2 \times Dura_t^2 + e_t$$

$$Tiempo.entre_t = \beta_0 + \beta_1 \times Dura_t + \beta_2 \times Dura_t^2 + \beta_3 \times Dura_t^3 + e_t$$

- Para realizar estos ajustes en *R* es recomendable utilizar el comando *poly(variable, grado)*.

```
regreBolsa3b <- lm(tiempo.entre ~ poly(Duracion, 3))
```


# Ejemplo: Tiempo entre “caidas” en bolsa

	Mod.Lineal	Mod.Cuadrático	Mod.Cúbico
(Intercept)	34.98*** (1.35)	20.88*** (4.83)	54.80*** (12.74)
Duracion	10.67*** (0.37)	20.89*** (3.39)	-14.41 (12.75)
dura2		-1.58** (0.52)	9.61* (3.93)
dura3			-1.11** (0.39)
R <sup>2</sup>	0.79	0.80	0.80
Adj. R <sup>2</sup>	0.79	0.80	0.80
Num. obs.	229	229	229
RMSE	6.74	6.62	6.52

\*\*\* $p < 0.001$ , \*\* $p < 0.01$ , \* $p < 0.05$

- Dados los valores del  $Adj.R^2$  y del  $RMSE$ , el Modelo 1 sería el más parsimonioso (mínimo número de variables en el modelo)

# Ejemplo: Tiempo entre “caidas” en bolsa



# Ejemplo: Tiempo entre “caidas” en bolsa

Results of Hypothesis Test

---

Alternative Hypothesis:

Test Name: Breusch-Godfrey test for serial correlation of order up to 10

Data: Residuals



Test Statistic: LM test = 28.89081

Test Statistic Parameter: df = 10

P-value: 0.001297776

# Ejemplo: Tiempo entre “caidas” en bolsa

- A la vista del gráfico anterior, creemos que es necesario profundizar en el estudio de la autocorrelación



# Procedimiento de Cochrane-Orcutt

# Procedimiento de Cochrane-Orcutt

- El procedimiento indica que los residuos debe de seguir una proceso AR(1):

$$y_t = \beta_0 + \beta_1 x_t + e_t, \quad e_t = \rho e_{t-1} + w_t$$

*ahora consideraremos la trasnformación:*

$$y_t^* = y_t - \rho y_{t-1}$$

# Procedimiento de Cochrane-Orcutt

$$\begin{aligned}y_t^* &= y_t - \rho y_{t-1} \\&= \beta_0 + \beta_1 x_t + e_t - \rho(\beta_0 + \beta_1 x_{t-1} + e_{t-1}) \\&= \beta_0(1 - \rho) + \beta_1(x_t - \rho x_{t-1}) + e_t - \rho e_{t-1} \\&= \beta_0(1 - \rho) + \beta_1(x_t - \rho x_{t-1}) + w_t \\&\equiv \beta_0^* + \beta_1 x_t^* + w_t\end{aligned}$$

donde  $\beta_0^* = \beta_0(1 - \rho)$  y  $x_t^* = x_t - \rho x_{t-1}$ . Estas transformaciones harán que la regresión sobre  $y_t^*$  cumpla las asunciones y los nuevos errores  $w_t$  sean independientes e identicamente distribuidos.

# Procedimiento de Cochrane-Orcutt

- ① Determinar una estimación para  $\rho$  (retardo 1 del ACF)
- ② Trasnformar en  $y_t^* = y_t - \rho y_{t-1}$  y  $x_t^* = x_t - \rho x_{t-1}$ .
- ③ Ajustar la regresión de  $y_t^*$  en  $x_t^*$  usando OLS. El intervalo de predicción vendrá dado por  $y_t^* \pm 2\tilde{\sigma}$ , donde  $\tilde{\sigma} = \hat{\sigma}/\sqrt{1 - \hat{\rho}}$  y  $\hat{\sigma}$  es el error standar de la estimación en el ajuste de Cochrane-Orcutt.

# Cochrane-Orcutt en R

- Existe un paquete que se llama *orcutt*,
- Resuelve los problemas de autocorrelación de primer orden de forma iterativa.

```
cochrane.orcutt(reg, convergence = 8)
```

# Ejemplo: Gasto en farmacia

Call:

```
lm(formula = gasto ~ trend + temp + temp2 + part, na.action = NULL)
```

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	3.1613e+03	5.6946e+02	5.551	4.599e-08	***
trend	-1.5323e+00	2.8316e-01	-5.411	9.709e-08	***
temp	-1.6203e-02	4.2458e-02	-0.382	0.7029	
temp2	1.4833e-02	2.1747e-03	6.821	2.612e-11	***
part	1.5587e-01	2.4082e-02	6.472	2.300e-10	***
---					

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 5.6905 on 502 degrees of freedom  
 Multiple R-squared: 0.2194 , Adjusted R-squared: 0.2132  
 F-statistic: 35.3 on 4 and 502 DF, p-value: < 5.571e-26

Durbin-Watson statistic

(original): 1.31088 , p-value: 1.523e-15  
 (transformed): 2.58152 , p-value: 1e+00

# Ajuste por mínimos cuadrados generalizados (GLS)

# Introducción a los GLS

- Del inglés *Generalized Least Squares* que no debe confundirse con los modelos lineales generalizados (GLM).
- Se trata de una corrección al algoritmo de los *OLS* propuesta por Cochrane-Orcutt (1949) que es óptima para cuando los errores tienen una estructura AR(1).
- La estimación vía GLS puede ser una de las soluciones al problema de la autocorrelación.

# Estimación de los parámetros

- Usa una matriz diagonal para ayudar a corregir la varianza no constante. Sin embargo, en un modelo con errores correlacionados, los errores tienen una estructura de varianza-covarianza más complicada.
- Por lo tanto, la matriz de ponderación para la estructura de varianza-covarianza más complicada no es diagonal y utiliza el método de **mínimos cuadrados generalizados**, de los cuales los mínimos cuadrados ponderados son casos especiales.

# Estimación de los parámetros

- Dado el modelo lineal en forma matricial

$$\mathbf{Y} = \boldsymbol{\beta} \mathbf{X} + \mathbf{e} \quad E[\mathbf{e}] = 0 \quad Var[\mathbf{e}] = \sigma^2 \mathbf{I} \quad (5)$$

- Los cuadrados mínimos ordinarios (OLS) se estimaban minimizando la suma del cuadrado de los errores.

$$RSS = \sum_{t=1}^n (y_t - \boldsymbol{\beta} \mathbf{x}_t)^2,$$

y se obtiene

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}' \mathbf{X})^{-1} \mathbf{y}$$

# Modelo con GLS

- Dado el modelo lineal en forma matricial, los cuadrados mínimos generalizados

$$\mathbf{Y} = \boldsymbol{\beta} \mathbf{X} + \mathbf{e} \quad E[\mathbf{e}] = 0 \quad Var[\mathbf{e}] = \sigma^2 \mathbf{V}$$

donde  $\mathbf{V}$  es una matriz desconocida de orden  $n \times n$ .

Si  $\mathbf{V}$  es diagonal pero con elementos distintos, las observaciones y están incorreladas pero tienen varianza desigual.

Si  $\mathbf{V}$  tiene elementos distintos de cero fuera de la diagonal, las observaciones están correladas.

# Estimación por GLS

- Se descompone la matriz de la varianza en  $\mathbf{V} = \mathbf{K}'\mathbf{K}$   
*donde  $\mathbf{K}$  se conoce como la raíz cuadrada de  $\mathbf{V}$*
- Se define pues

$$\mathbf{g} = \mathbf{K}^{-1}\mathbf{e} \Rightarrow \mathbf{z} = \mathbf{B}\beta + g$$

*con lo que se obtiene, utilizando resultados de álgebra matricial*

$$E[\mathbf{g}] = \mathbf{K}^{-1}E[\mathbf{e}] = 0$$

$$Var[\mathbf{g}] = Var[\mathbf{K}^{-1}\mathbf{e}] = \sigma^2\mathbf{I}$$

# Estimación por GLS

- Y entonces bajo las asunciones de los cuadrados mínimos ordinarios, las estimaciones aquí de los cuadrados mínimos generalizados serán:

$$\hat{\beta} = (\mathbf{X}'\mathbf{V}^{-1}\mathbf{X})^{-1} \mathbf{X}\mathbf{V}^{-1}\mathbf{y}$$

*que es insesgado y con*

$$Var(\hat{\beta}) = \sigma^2 (\mathbf{X}'\mathbf{V}^{-1}\mathbf{X})^{-1}$$

*y su verosimilitud vendrá dada por*

$$L \propto -\ln(\sigma^2) - \frac{1}{2}\ln|\mathbf{V}| - \frac{1}{2\sigma^2}(\mathbf{y} - \mathbf{X}\beta)' \mathbf{V}^{-1} (\mathbf{y} - \mathbf{X}\beta)$$

# Desempleo en USA (1947-1962)

- Se dispone para el periodo 1947-1962 de 7 variables económicas:
  - **GNP**: Producto interior bruto (PIB)
  - **GNP.deflator**: PIB con deflación de precio (1954=100)
  - **Unemployed**: Numeros desempleados
  - **Armed.Forces**: Número de personas en el ejercito
  - **Population**: población en edad laboral
  - **Year**: año
  - **Employed**: número de gente empleada

# Desempleo en USA (1947-1962)

- Este ejemplo se utiliza en diversos libros de texto para mostrar un claro ejemplo de colinealidad y de autocorrelación. Sólo se utilizarán: *GNP*, *Population* y *Employed*.

Call:

```
lm(formula = Employed ~ GNP + Population, data = longley)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-0.80899	-0.33282	-0.02329	0.25895	1.08800

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	88.93880	13.78503	6.452	2.16e-05 ***
GNP	-0.06317	0.01065	-5.933	4.96e-05 ***
Population	-8.40974	8.15214	-1.02693	0.0184 *

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.5459 on 13 degrees of freedom

Multiple R-squared: 0.9791, Adjusted R-squared: 0.9758





F-statistic: 303.9 on 2 and 13 DF, p-value: 1.221e-11

Correlation of Coefficients:

	(Intercept)	GNP
GNP	0.98	
Population	-1.00	-0.99

# Desempleo en USA (1947-1962)

$\text{Im}(\text{Employed} \sim \text{GNP} + \text{Population})$



# Desempleo en USA (1947-1962)

- Habitualmente cuando los datos proviene de una serie temporal, los errores suelen tomar forma autorregresiva:

$$e_{t+1} = \rho e_t + w_t, \quad w_t \sim \mathcal{N}(0, \tau^2)$$

*se puede estimar  $\rho$  utilizando la correlación muestral de los residuos:*

[1] 0.3104092

# Desempleo en USA (1947-1962)

- Un modelo con errores autorregresivos tiene la matriz de covarianza de la siguiente forma

$$\mathbf{V}_{ij} = \rho^{|i-j|}$$

- Asumiendo que  $\rho$  es conocido e igual a 0.3104092. Entonces,  $\mathbf{V}$  se calcula como

# Desempleo en USA (1947-1962)

- Y la estimación por mínimos cuadrados generalizados será pues

$$\hat{\beta} = (\mathbf{X}'\mathbf{V}^{-1}\mathbf{X})^{-1} \mathbf{X}\mathbf{V}^{-1}\mathbf{y}$$

[,1]

(Intercept)	94.89887752
GNP	0.06738948
Population	-0.47427391

# Desempleo en USA (1947-1962)

- El error estandar de  $\hat{\beta}$  es ,

$$\sqrt{Var(\hat{\beta})} = \sqrt{\sigma^2(\mathbf{X}'\mathbf{V}^{-1}\mathbf{X})^{-1}\mathbf{X}\mathbf{V}^{-1}\mathbf{y}}$$

```
## B(Intercept)          BGNP   BPopulation  
##  94.89887752    0.06738948 -0.47427391
```

# Desempleo en USA (1947-1962)

- El modelo GLS en *R* se escribe como parte del paquete de los modelos no-lineales:

```
library(nlme)
g<-gls(Employed~GNP+Population,
        correlation=corAR1(form=~Year),
        data=longley)
```

# Desempleo en USA (1947-1962)

- Donde *correlation*= es la autocorrelación que le queremos dar a los errores:
  - **corAR1** : autoregressive process of order 1.
  - **corARMA**: autoregressive moving average process, with arbitrary orders for the autoregressive and moving average components.
  - **corCAR1**: continuous autoregressive process (AR(1) process for a continuous time covariate).
  - **corCompSymm**: compound symmetry structure corresponding to a constant correlation.
  - **corSymm**: general correlation matrix, with no additional structure.

# Desempleo en USA (1947-1962)

Generalized least squares fit by REML

Model: Employed ~ GNP + Population

Data: longley

AIC	BIC	logLik
44.66377	47.48852	-17.33188

Correlation Structure: AR(1)

Formula: ~Year

Parameter estimate(s):

Phi
0.6441692

Coefficients:

	Value	Std. Error	t-value	p-value
(Intercept)	101.85813	14.198932	7.173647	0.0000
GNP	0.07207	0.010606	6.795485	0.0000
Population	-0.54851	0.154130	-3.558778	0.0035

Correlation:

	(Intr)	GNP
GNP	0.943	
Population	-0.997	-0.966

Standardized residuals:

Min	Q1	Med	Q3	Max
-1.5924564	-0.5447822	-0.1055401	0.3639202	1.3281898

Residual standard error: 0.689207

Degrees of freedom: 16 total; 13 residual

# Desempleo en USA (1947-1962)

Durbin-Watson test

```
data: fit.lm.as.gls
DW = 1.6152, p-value = 0.1198
alternative hypothesis: true autocorrelation is greater than 0
```

Breusch-Godfrey test for serial correlation of order up to 6

```
data: Residuals
LM test = 5.7272, df = 6, p-value = 0.4544
```

# Ejemplo: Gasto en farmacia

Durbin-Watson test

```
data: regre4
DW = 1.3109, p-value = 1.523e-15
alternative hypothesis: true autocorrelation is greater than 0
```

Breusch-Godfrey test for serial correlation of order up to 101

```
data: Residuals
LM test = 198.31, df = 101, p-value = 2.6e-08
```

# Ejemplo: Gasto en farmacia

- El modelo GLS en R se escribe como parte del paquete de los modelos no-lineales:

```
library(nlme)
regre4.gls<-gls(gasto~ trend + temp + temp2 + part,
                  na.action=NULL ,
                  correlation = corAR1(form = ~ 1))
```

Frente al modelo anterior (OLS)

```
regre4<-lm(gasto~ trend + temp + temp2 + part, na.action=NULL)
```

# Ejemplo: Gasto en farmacia

Generalized least squares fit by REML

Model: gasto ~ trend + temp + temp2 + part

Data: NULL

AIC	BIC	logLik
3237.099	3266.643	-1611.55

Correlation Structure: AR(1)

Formula: ~1

Parameter estimate(s):

Phi  
0.6959633

Coefficients:

	Value	Std.Error	t-value	p-value
(Intercept)	3155.9776	584.6619	5.397953	0.0000
trend	-1.5295	0.2907	-5.260982	0.0000
temp	-0.0028	0.0426	-0.065110	0.9481
temp2	0.0148	0.0022	6.833991	0.0000
part	0.1498	0.0241	6.214143	0.0000

Correlation:

	(Intr)	trend	temp	temp2
trend	-1.000			
temp	0.049	-0.047		
temp2	-0.013	0.013	-0.070	
part	-0.053	0.051	-0.571	0.005

Standardized residuals:

Min	Q1	Med	Q3	Max
-2.1195215	-0.7008765	-0.1425260	0.5490998	4.1999770

Residual standard error: 7.917382

Degrees of freedom: 508 total; 503 residual

# Ejemplo: Gasto en farmacia

	OLS	GLS
(Intercept)	2881.743*** (203.193)	3155.978*** (584.662)
trend	-1.396*** (0.101)	-1.529*** (0.291)
temp	-0.472*** (0.032)	-0.003 (0.043)
temp2	0.023*** (0.003)	0.015*** (0.002)
part	0.255*** (0.019)	0.150*** (0.024)
R <sup>2</sup>	0.595	
Adj. R <sup>2</sup>	0.592	
Num. obs.	508	508
RMSE	6.385	
AIC		3237.099
BIC		3266.643
Log Likelihood		-1611.550

\*\*\*  $p < 0.001$ , \*\*  $p < 0.01$ , \*  $p < 0.05$

# Ejemplo: tpo. entre “caidas” en bolsa

```
regreBolsa1.gls<-gls( tiempo.entre ~ Duracion, data=bolsa,  
                      na.action=na.omit ,  
                      correlation = corAR1(form = ~ 1))
```

Frente al modelo anterior (OLS)

```
regre4<-lm(tiempo.entre~ Duracion, data=bolsa, na.action=na.omit )
```

# Ejemplo: tpo. entre “caidas” en bolsa

Generalized least squares fit by REML

Model: tiempo.entre ~ Duracion

Data: bolsa

AIC	BIC	logLik
1505.775	1519.475	-748.8876

Correlation Structure: AR(1)

Formula: ~1

Parameter estimate(s):

Phi  
-0.3550814

Coefficients:

	Value	Std.Error	t-value	p-value
(Intercept)	38.33386	1.5372250	24.93706	0
Duracion	9.70735	0.4315217	22.49563	0

Correlation:

(Intr)

Duracion -0.979

Standardized residuals:

Min	Q1	Med	Q3	Max
-1.8737852	-0.8196553	-0.1180854	0.5827529	4.5116691

Residual standard error: 6.834881

Degrees of freedom: 229 total; 227 residual

# Ejemplo: tpo. entre “caidas” en bolsa

	OLS	GLS
(Intercept)	34.978*** (1.352)	38.334*** (1.537)
Duracion	10.669*** (0.366)	9.707*** (0.432)
R <sup>2</sup>	0.789	
Adj. R <sup>2</sup>	0.788	
Num. obs.	229	229
RMSE	6.740	
AIC		1505.775
BIC		1519.475
Log Likelihood		-748.888

\*\*\*  $p < 0.001$ , \*\*  $p < 0.01$ , \*  $p < 0.05$

# Modelos ARIMA incluyendo covariables

# Utilizando *xreg* dentro de ARIMA



```
#All data sets required for the examples and
# exercises in the book
# "Forecasting: principles and practice" by
# Rob J Hyndman and George Athanasopoulos

library(fpp) # Forecasting: principles and practice
library(fpp2) # Forecasting: principles and practice

plot(usconsumption, xlab="Year",
      main="Quarterly changes in US
            consumption and personal income")
```

# Utilizando *xreg* dentro de ARIMA



Quarterly changes in US  
consumption and personal income



# Correlogramas

```
par(mfrow = c(1, 2))
Acf(uschange[, 1], main = "")  
Pacf(uschange[, 1], main = "")
```

# Correlogramas



¿Podría ser un  $AR(2)$  o  $AR(3)$ , o un  $ARMA(1,1)$ ?

# Ejemplo: US Personal Consumption and Income

## Los datos

Consumo	Ingresos	Tasa_produc	Ahorros	Desempleo
0.6159862	0.9722610	-2.4527003	4.8103115	0.9
0.4603757	1.1690847	-0.5515251	7.2879923	0.5
0.8767914	1.5532705	-0.3587079	7.2890131	0.5
-0.2742451	-0.2552724	-2.1854549	0.9852296	0.7
1.8973708	1.9871536	1.9097341	3.6577706	-0.1
0.9119929	1.4473342	0.9015358	6.0513418	-0.1

# US Consumption: ajuste del modelo

```
fit <- auto.arima(uschange[, "Consumo"], # Serie Y_t  
                    xreg=uschange[, "Ingresos"]) # covariable X
```

```
fit
```

```
Series: uschange[, "Consumo"]  
Regression with ARIMA(1,0,2) errors
```

Coefficients:

	ar1	ma1	ma2	intercept	xreg
	0.6922	-0.5758	0.1984	0.5990	0.2028
s.e.	0.1159	0.1301	0.0756	0.0884	0.0461

```
sigma^2 estimated as 0.3219: log likelihood=-156.95  
AIC=325.91 AICc=326.37 BIC=345.29
```




# US Consumption: ajuste del modelo

$$\begin{aligned}y_t &= 0.599 + 0.203x_t + \eta_t, \\ \eta_t &= 0.692\eta_{t-1} + \varepsilon_t - 0.576\varepsilon_{t-1} + 0.198\varepsilon_{t-2}, \\ \varepsilon_t &\sim \text{NID}(0, 0.322).\end{aligned}$$

]

# US Consumption: los residuos

Errores tras ajuste



# US Consumption: ¿residuos autocorrelados?

```
Box.test(residuals(fit), fitdf=5, lag=10,  
         type="Ljung-Box")  
  
##  
## Box-Ljung test  
##  
## data: residuals(fit)  
## X-squared = 6.0465, df = 5, p-value = 0.3017
```

If the p value is greater than 0.05 then the residuals are independent which we want for the model to be correct.


**¿Podemos predecir?**

# US Consumption: predicción

```
fcast <- forecast(fit,
                    xreg=rep(mean(usconsumption[,2]),8), h=8)
#h= periodos a predecir
plot(fcast,
      main="Predicción: modelo con errores ARIMA(1,0,2) y xreg")
```

# US Consumption: predicción

Predicción: modelo con errores ARIMA(1,0,2) y xreg




# US Consumption: predicción

```
fcast <- forecast(fit,
                    xreg=c(0.5,0.8,0.2,1,1.5,2,1.5,1), h=8)
#h= periodos a predecir
plot(fcast,
      main="Predicción: modelo con errores ARIMA(1,0,2) y xreg")
```

# US Consumption: predicción

Predicción: modelo con errores ARIMA(1,0,2) y xreg



# Covariables “no continuas”

# Datos: Compras de navidad

	Customer_Visit	Weekday	Christmas	Day
1	3000	1	0	1
2	2985	2	0	2
3	3112	3	0	3
4	3001	4	0	4
5	3003	5	0	5
6	2978	6	0	6
7	2904	7	0	7
8	3062	1	0	8
9	2964	2	0	9
10	3048	3	0	10
11	3096	4	0	11
12	3026	5	0	12
13	2950	6	0	13
14	2976	7	0	14
15	...	...	...	...
40	3042	5	0	40
41	2998	6	1	41
42	3037	7	0	42
43	3084	1	0	43
44	2928	2	0	44
45	2903	3	0	45
46	2885	4	0	46
47	2973	5	0	47

# Datos: Compras de navidad

- Como podéis ver, hay una variable que es “Navidad”, otra variable que es día de la semana pero en números de 1 a 7.
- Por lo que habrá que decirle al comando que tenga en cuenta que estas variables son factores.
- ¿cómo se hace esto?

Nosotros queremos ajustar el siguiente modelo:

$$Y_t = \beta_0 + \beta_1 \text{Weekday} + \beta_2 \text{Day} + \beta_3 \text{Christmas} + ARMA(p, q)$$

# model.matrix

Debemos pasar nuestras variables factor a variables “dummies”. Una variable dummie es una variable que se crea a partir de una variable nominal y que identifica sólo a una de sus categorías. Es decir, tenemos que crear diferentes variables dummie para identificar los 7 días de la semana.

```
diaSemana <- model.matrix(~as.factor(modelfitsample$Weekday))
diaSemana <- diaSemana[, -1]
colnames(diaSemana) <- c("Mon", "Tue", "Wed", "Thu", "Fri", "Sat")
kable(head(diaSemana, n = 10))
```

# model.matrix

```
diaSemana <- model.matrix(~as.factor(modelfitsample$Weekday))  
diaSemana <- diaSemana[, -1]  
colnames(diaSemana) <- c("Mon", "Tue", "Wed", "Thu", "Fri", "Sat")
```

Como podeis ver, hemos generado **6** variables donde antes sólo había una. Falta el Domingo, pero el sistema toma como Domingo cuando no es ninguno de los otros días, es decir, cuando Mon ... Sat valen cero.

# Ajuste del modelo

# Creamos las variables del modelo lineal

```
Variables.xreg <- cbind(Weekday=diaSemana,
                         Day=modelfitsample$Day,
                         Christmas=modelfitsample$Christmas)
```

# Le decimos a R cual es nuestra varia de "Time Series"

```
visits <- ts(modelfitsample$Customer_Visit, frequency=7)
```

# Ajustamos el modelo ARIMAX (ARMA(2,0) a modo de ejemplo)




```
modArima <- Arima(visits, xreg=Variables.xreg, order=c(2,0,0))
```

# Ajuste del modelo

Los resultados del ajuste (parámetros y error):

```
## Series: visits
## Regression with ARIMA(2,0,0) errors
##
## Coefficients:
##             ar1      ar2  intercept      Mon      Tue      Wed      Thu
##             0.0162  0.0637  3014.8611   9.8830  15.7114   7.8297  6.3939
## s.e.     0.1453  0.1485    24.0485  28.2263  27.5547  28.4301  28.4642
##             Fri      Sat      Day Christmas
##            -20.3970 -4.5479 -0.4230   12.7212
## s.e.     29.0857  28.4466   0.5908   62.3499
##
## sigma^2 estimated as 3640: log likelihood=-264.19
## AIC=552.39   AICc=561.06   BIC=575.09
##
## Training set error measures:
##               ME      RMSE      MAE      MPE      MAPE      MASE
## Training set 0.07679988 53.12831 41.33195 -0.02859856 1.373526 0.722105
##             ACF1
## Training set 0.0074646
```

# Ajuste del modelo: checkresiduals




# Ajuste del modelo: checkresiduals

```
library("portes")
testresid<-LjungBox(fit)
plot(testresid[,4],
      ylim = c(0.001,max(testresid[,4])),
      xlab="", ylab="p-values",
      xaxt='n', ann=FALSE)
abline(h=0.05)
title("Ljung-Box test")
```

# Ajuste del modelo: checkresiduals

## Ljung-Box test



```
## [1] "Ho: Los residuos son independientes"  
  
##  
##   Box-Ljung test  
##  
## data: residuals(fit)  
## X-squared = 6.0465, df = 5, p-value = 0.3017
```

# Predictión del modelo

El modelo es mejorable, pero esto es simplemente un ejemplo.

y como resultado, tambien podemos predecir

```
# hay que darle valores "X" para que haga la predicción
# voy a predecir un valor para el lunes sin ser Navidad del día 43
# por que tengo Mon=1 Tue=0 Wed Thu Fri Sat=0 Day=43 Xmas=0
variables.prediccion<-data.frame(1,0,0,0,0,0,43,0)
colnames(variables.prediccion)<- colnames(Variables.xreg)
prediccion<-forecast(modArima,
                      xreg=as.matrix(cbind(variables.prediccion)) )
```

# Predictión del modelo

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
8	3006.449	2929.133	3083.765	2888.205	3124.693

# Predicción del modelo

Y dibujamos la predicción

## Opción 1


```
plot(prediccion)
```

## Opción 2

```
library(ggfortify)
autoplot(prediccion) + xlab("Día")+
    ylab("Visitantes")
```


# Predicción del modelo

Forecasted ratio Regressivariante ARIMA(2,0,0) errors



# Predicción del modelo

Predicciones con variables categóricas




# Más predicciones

Vamos a pedir más predicciones, según valores de "X"


```
## hay que darle valores "X" para que haga la predicción  
  
#voy a predecir tres valores lunes, martes y miércoles  
# y alguno que sea Navidad (el miércoles día 44).  
dia1<-c(1,0,0,0,0,0,43,0)  
dia2<-c(0,1,0,0,0,0,44,0)  
dia3<-c(0,0,1,0,0,0,44,1) #Navidad  
covar.pred<-as.matrix(rbind(dia1, dia2, dia3 ))  
colnames(covar.pred)<- colnames(Variables.xreg)  
  
variables.prediccion<-data.frame(rbind(dia1,dia2,dia3))  
  
prediccion2<-forecast(modArima,  
                      xreg=covar.pred)
```

# Predicción del modelo



# Predicción del modelo

Forecasts from Regression with ARIMA(2,0,0) errors



# Escenarios

- Una vez visto esto, podemos estar interesados en generar escenarios Pesimistas, neutros y Optimistas.
- Para ello lo que debemos de hacer es darle valores las **covariables** según deseemos crear esos escenarios (más altos o más bajos según el coeficiente que acompañe en el modelo).