



CURSOS DE VERANO 2014

Aproximación práctica a la ciencia de los datos
y Big Data

Introducción a las series temporales

José Manuel Benítez Sánchez

Contenido

- ❑ Predicción
- ❑ Herramientas para predicción
- ❑ Regresión sencilla
- ❑ Regresión múltiple
- ❑ Descomposición de series temporales
- ❑ Alisado exponencial
- ❑ ARIMA
- ❑ Modelos avanzados

Predicción

Predicción

Predicción

- La predicción ha fascinado al ser humano a lo largo de su historia
- Algunas referencias históricas:
 - Profetas bíblicos
 - Sacerdotes babilónicos
 - Los griegos que acudían a Delfos a consultar el oráculo
 - “Adivinos”



Predicción

¿Qué se puede predecir?

- La predecibilidad de un evento o cantidad depende de varios factores:
 - ¿Cómo de bien entendemos los factores que intervienen?
 - ¿Cuántos datos hay disponibles?
 - ¿Influye la predicción en lo que se quiere predecir?

Predicción

Ejemplos

- ❑ Predicción de la demanda eléctrica: muy precisa
- ❑ Predicción de tasas de cambio monetarias: más o menos
- ❑ Combinación ganadora de Euromillones: no



Predicción

Factores a considerar

- Horizonte temporal
- Tipos de patrones en los datos

Predicción

Elección del método de predicción

- Depende de la disponibilidad de datos y de lo predecible que sea la magnitud
- Cada método tiene sus propias características, precisión, coste

Predicción

Definición

- **Predicción:** Elaborar una afirmación sobre el futuro tan precisa como sea posible, basándose en la información disponible incluyendo datos históricos y conocimiento de eventos futuros que puedan influir
- Habitualmente, es una parte esencial en la toma de decisiones

Predicción

Clasificación según el horizonte

- Predicción a corto plazo
- Predicción a medio plazo
- Predicción a largo plazo

Predicción

Estableciendo lo que hay que predecir

- ¿Qué predecir?
 - Una cantidad simple
 - Un resumen (agregado)
- Horizonte de predicción
- Frecuencia de predicción

Predicción

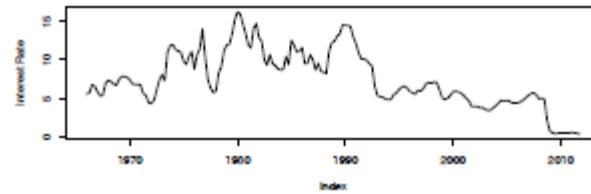
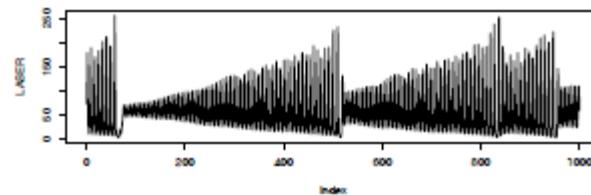
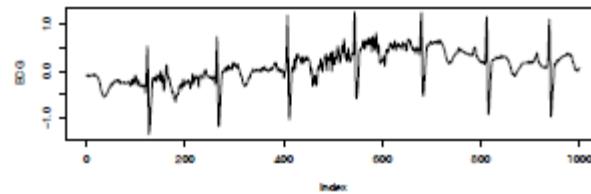
Predicción cuantitativa

- Se puede aplicar cuando:
 - Hay datos numéricos del pasado disponibles
 - Es razonable asumir que algunos aspectos del comportamiento de los datos (patrones) en el pasado continuarán en el futuro

Series temporales

Serie temporal

- Cualquier magnitud observada a lo largo del tiempo es una serie temporal
- Es habitual que se realicen observaciones en intervalos regulares (minutos, horas, días, semanas, ...)

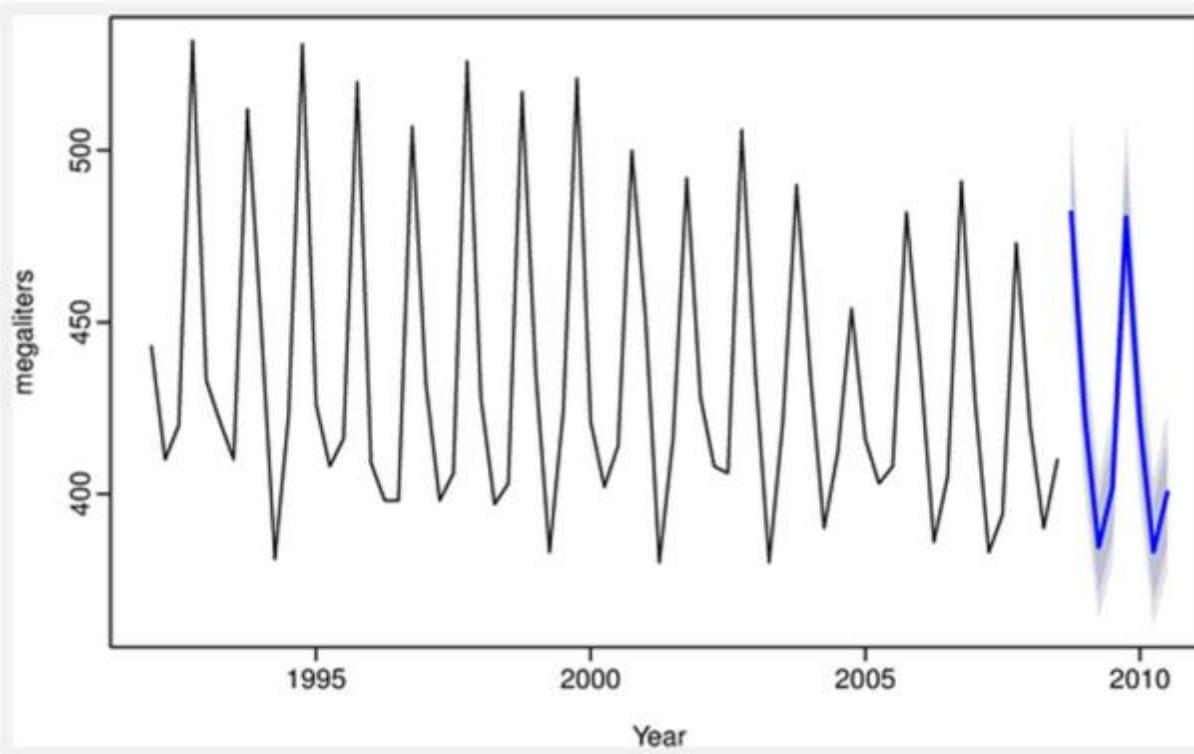


Predicción de series temporales

- Los datos de una serie temporal son útiles cuando se quiere predecir algo que cambia a lo largo del tiempo (precios de acciones, ventas, beneficios, ...)
- La predicción de la serie pretende averiguar cómo continuará la serie de observaciones en el futuro

Series temporales

Producción de cerveza



VARIABLES PREDICTIVAS

- Demanda de electricidad (DE)
- $DE = f(\text{temperatura actual, fortaleza económica, población, hora del día, día de la semana, error})$

Pasos en una tarea de predicción

1. Definición del problema
2. Recabar información
3. Análisis exploratorio de datos
4. Elegir y ajustar un modelo adecuado
5. Evaluar el modelo
6. Explotación del modelo

Prespectiva estadística de la predicción

- La magnitud a predecir se puede ver como una variable aleatoria
- Cuanto más se aleja el horizonte de predicción, mayor incertidumbre
- Predecir: calcular la esperanza de la variable aleatoria

Herramientas para la predicción

Herramientas para la predicción

- Gráficos
- Medidas de tendencia central
- Transformaciones y ajustes
- Evaluación de la precisión de la predicción
- Análisis de residuos
- Intervalos de predicción

Gráficos

Diagrama temporal

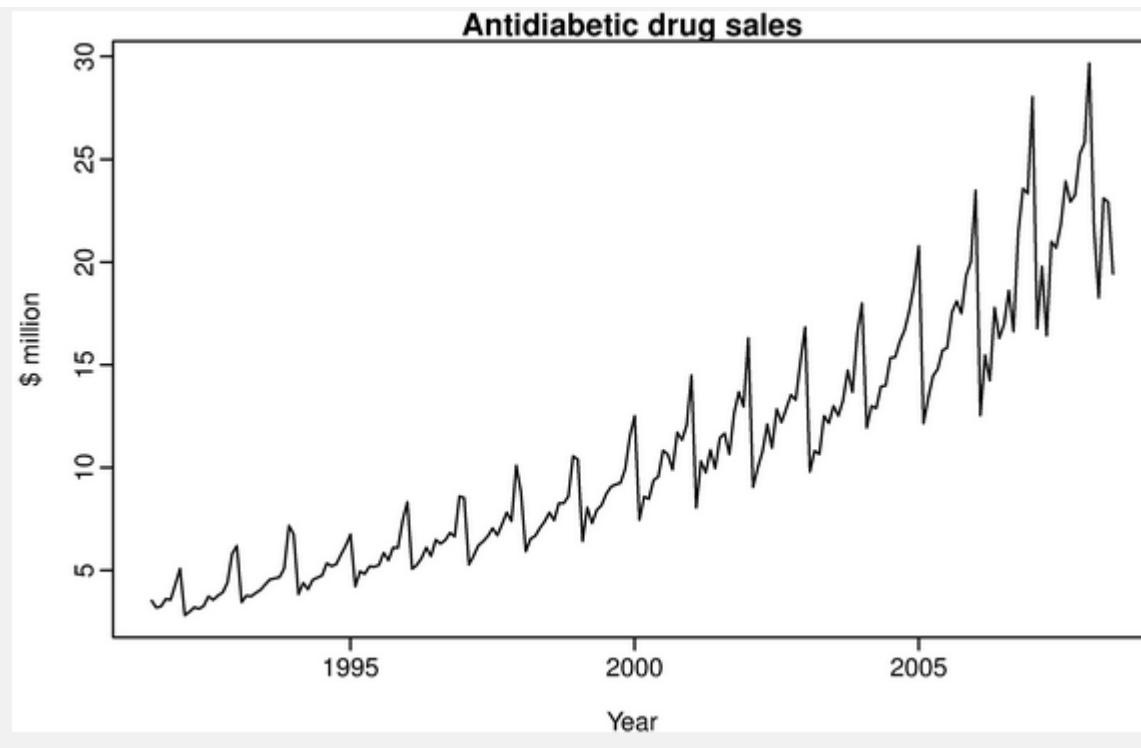


Para generar el gráfico

```
library(fpp)  
data(melsyd)  
  
plot(melsyd[, "Economy.class"] ,  
      main = "Economy class passengers: Melbourne-  
Sydney" ,  
      xlab = "Year" , ylab = "Thousands")
```

Gráficos

Diagrama temporal

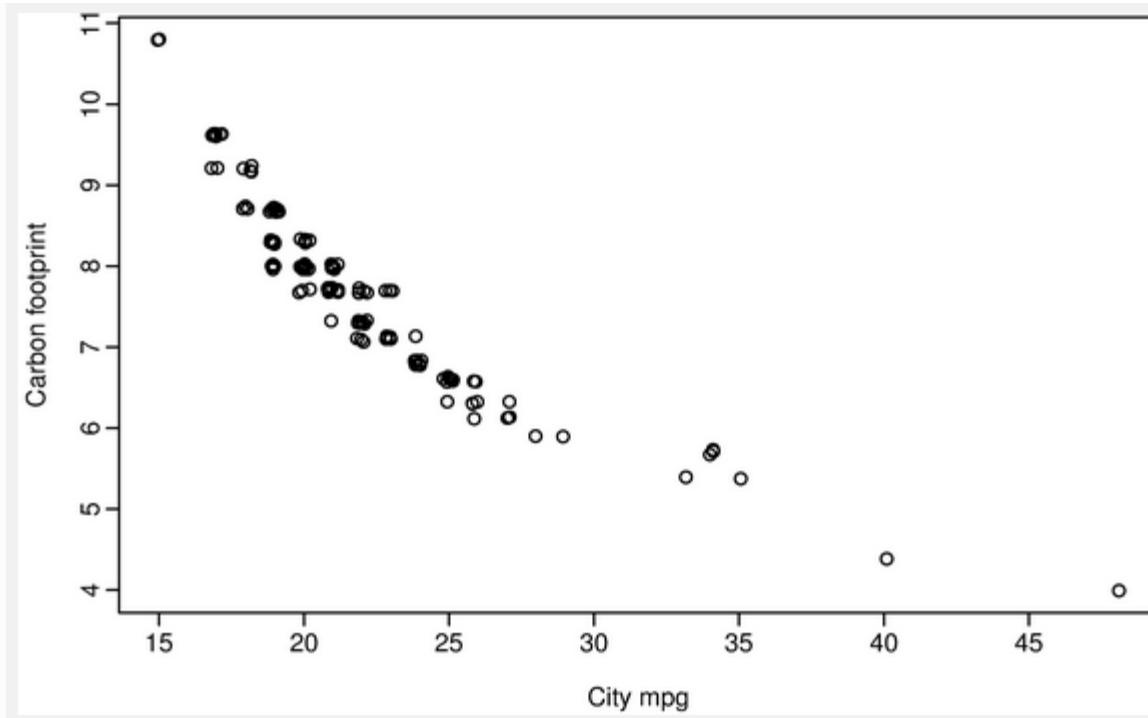


Para generar el gráfico

```
data(a10)  
  
plot(a10, ylab="$ million", xlab="Year",  
main="Antidiabetic drug sales")
```

Gráficos

Diagrama de puntos

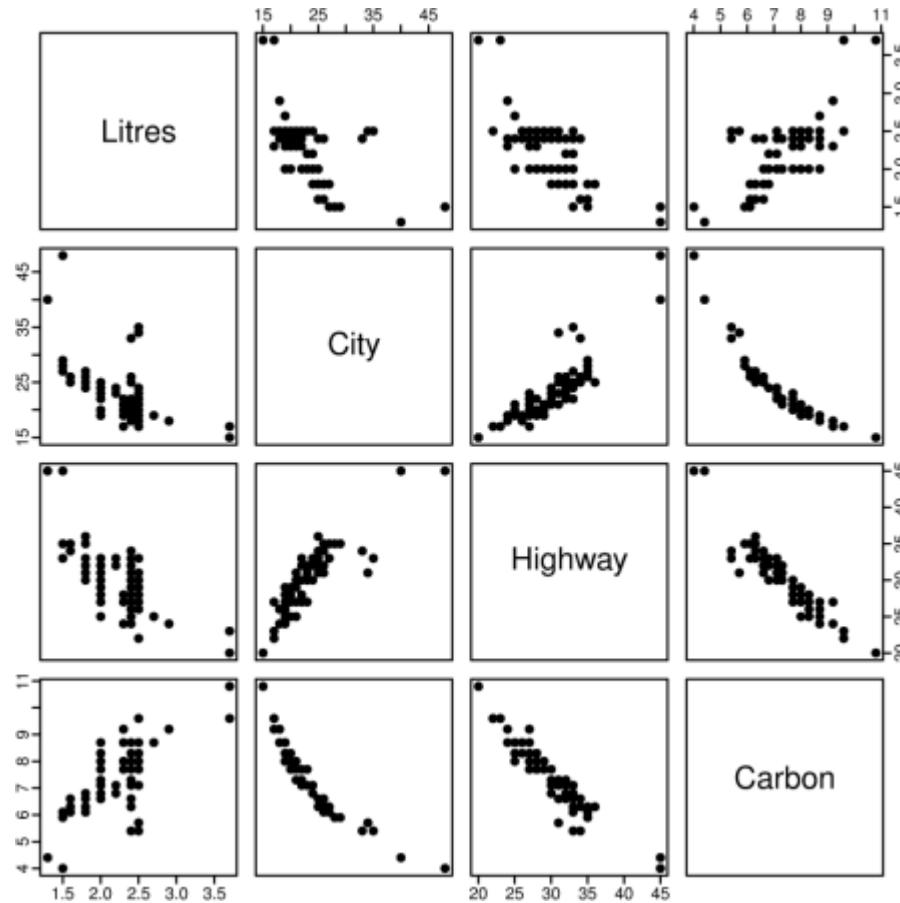


Para generar el gráfico

```
data(jitter)  
  
plot(jitter(fuel[,5]), jitter(fuel[,8]),  
xlab="City mpg", ylab="Carbon footprint")
```

Gráficos

Matriz de diagramas



Para generar el gráfico

```
data(fuel)  
pairs(fuel[,-c(1:2,4,7)], pch=19)
```

Patrones en series temporales

- **Tendencia:** incremento o decremento a largo plazo
- **Estacionalidad:** efectos estacionales (momento del año, día, semana)
- **Ciclos:** los datos muestran subidas o caídas que no se tienen un periodo fijo, son variables y de longitud desconocida

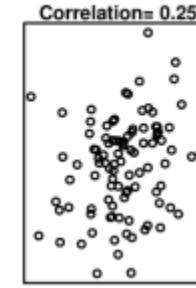
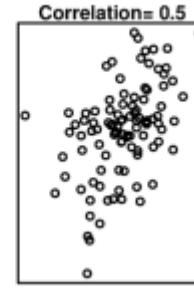
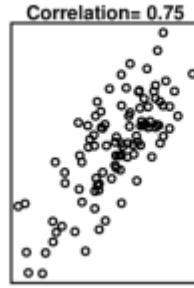
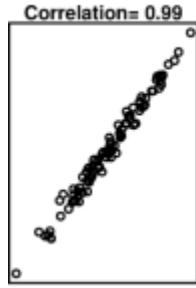
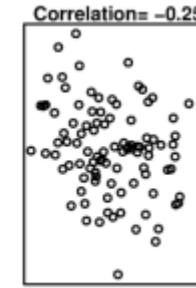
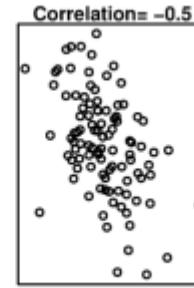
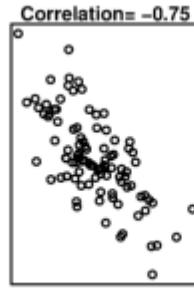
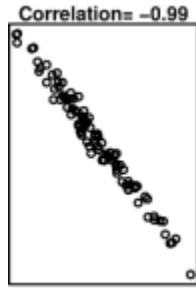
Medidas de tendencia central: univariadas

- Mediar aritmética
- Mediana
- Percentiles
- Rango intercuartílico
- Desviación estándar

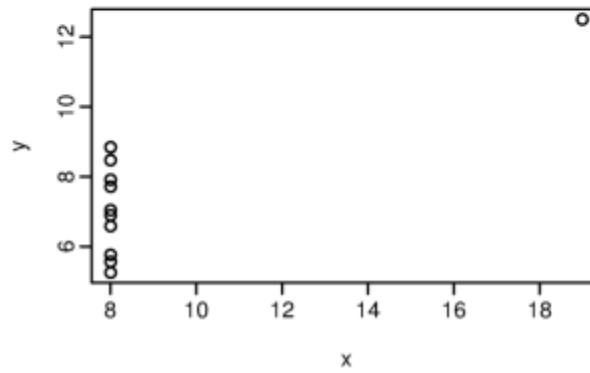
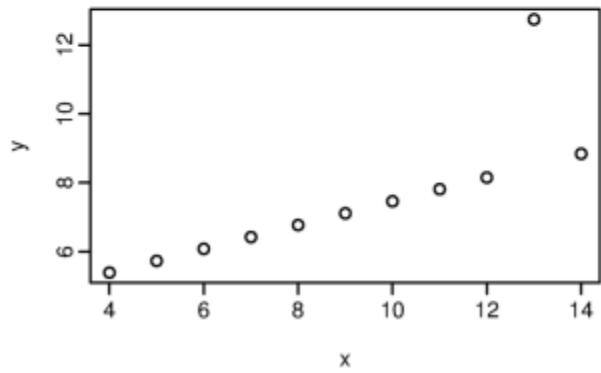
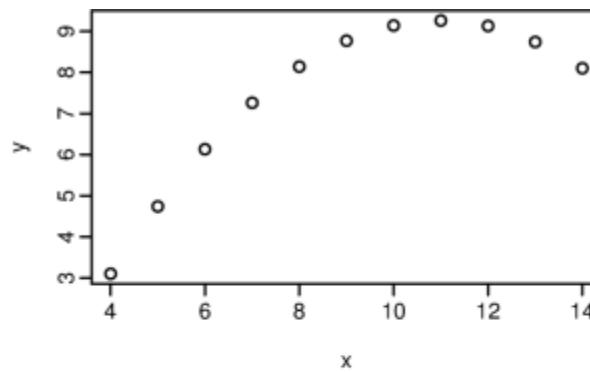
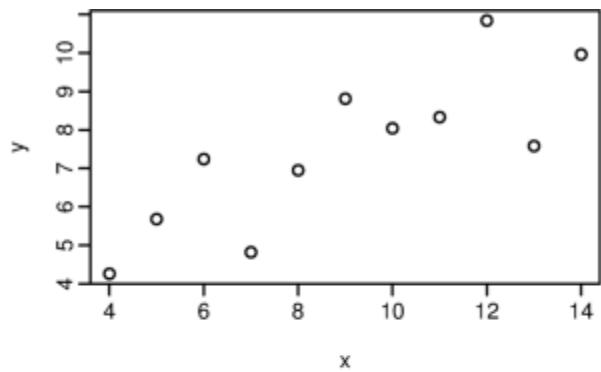
Coeficiente de correlación

■ Fuerza de la relación lineal

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2} \sqrt{\sum(y_i - \bar{y})^2}},$$



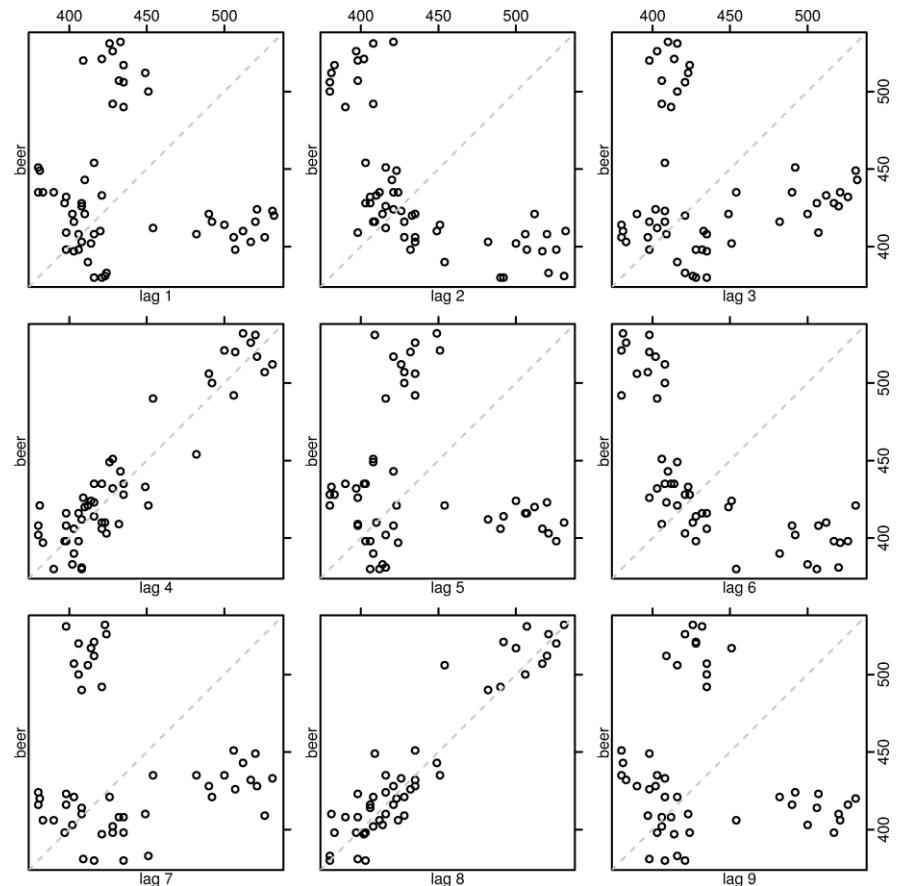
Coeficiente de correlación: 0,82



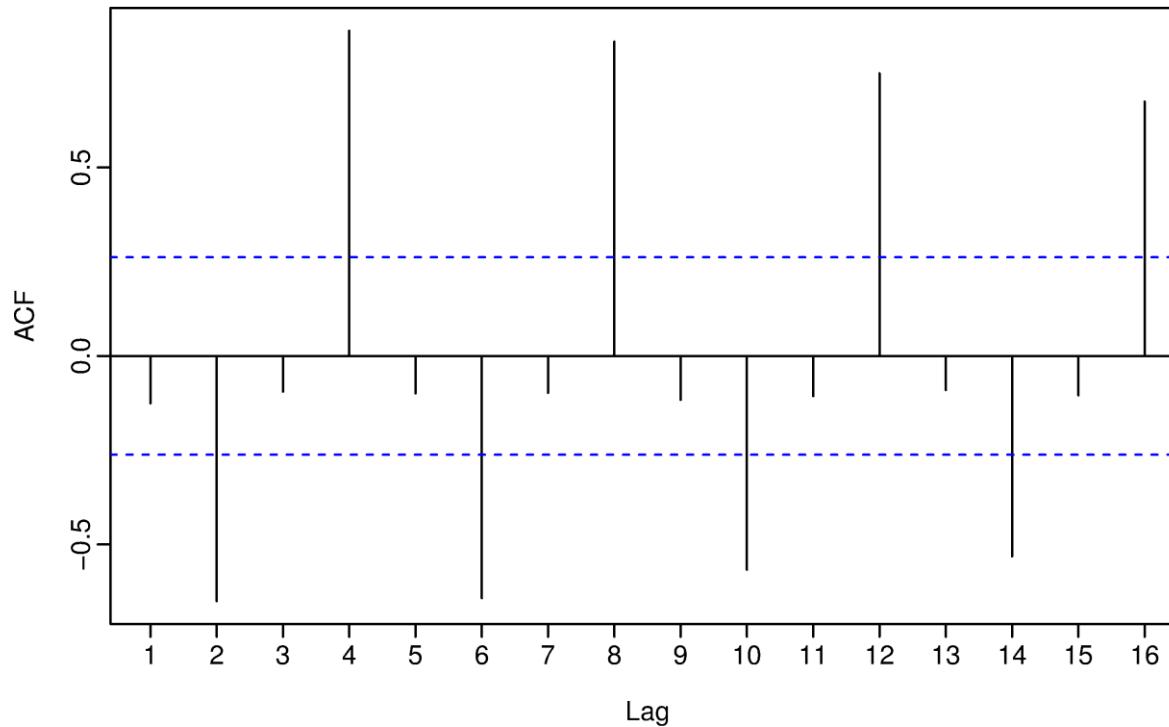
Autocorrelación

- Relación entre valores retrasados de una serie

$$r_k = \frac{\sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2},$$



Función de autocorrelación (ACF)



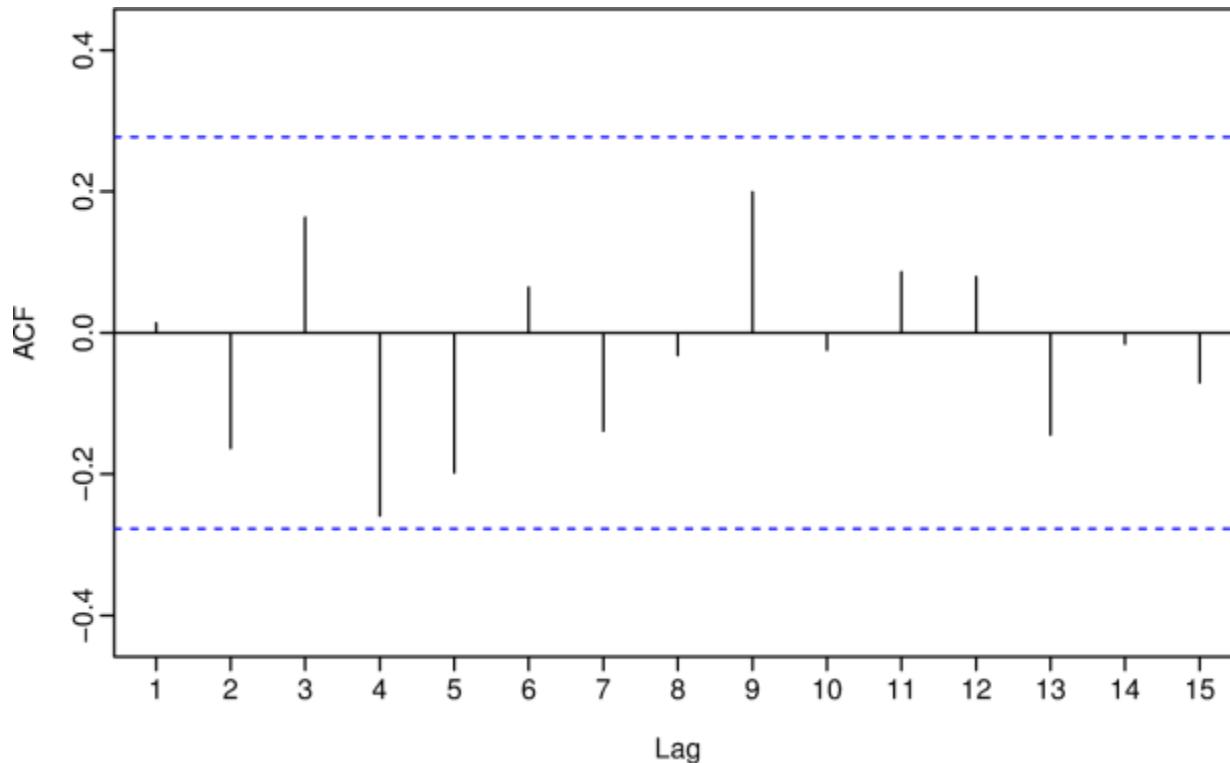
Para generar el gráfico

```
data(ausbeer)
```

```
beer2 <- window(ausbeer, start=1992, end=2006-.1)
```

```
Acf(beer2)
```

Ruido blanco



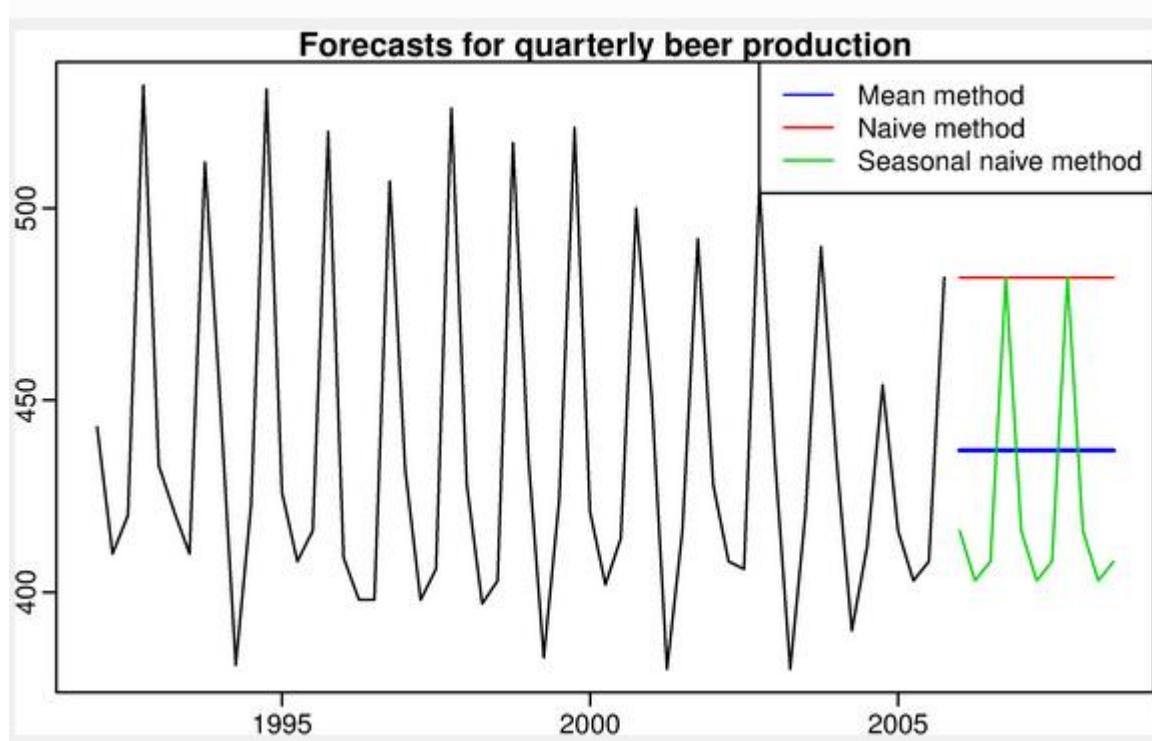
Para generar el gráfico

```
set.seed(30)  
x <- ts(rnorm(50))  
Acf(x)
```

Métodos de predicción simples

- Promedio $\hat{y}_{T+h|T} = \bar{y} = (y_1 + \dots + y_T)/T.$
- Ingenuo: el último valor
- Ingenuo estacional
- Método deriva
 - La predicción se incrementa o decremente a lo largo del tiempo en base a la media histórica

Métodos de predicción sencillos



Para generar el gráfico

```
beer2 <- window(ausbeer,start=1992,end=2006-.1)
beerfit1 <- meanf(beer2, h=11)
beerfit2 <- naive(beer2, h=11)
beerfit3 <- snaive(beer2, h=11)

plot(beerfit1, plot.conf=FALSE,
      main="Forecasts for quarterly beer production")
lines(beerfit2$mean,col=2)
lines(beerfit3$mean,col=3)
legend("topright",lty=1,col=c(4,2,3),
      legend=c("Mean method","Naïve method","Seasonal
naïve method"))
```

Transformaciones

- Ajustar los datos históricos puede permitir obtener un modelo de predicción más sencillo
- Transformaciones matemáticas
- Ajustes de calendario
- Ajustes de población
- Ajustes de inflación

Evaluar la precisión

- Error de predicción

$$e_i = y_i - \hat{y}_i$$

- Errores dependientes de la escala

$$\text{MAE} = \text{mean}(|e_i|),$$

$$\text{RMSE} = \sqrt{\text{mean}(e_i^2)}.$$

- Error en porcentaje

$$p_i = 100e_i/y_i$$

- Errores escalados

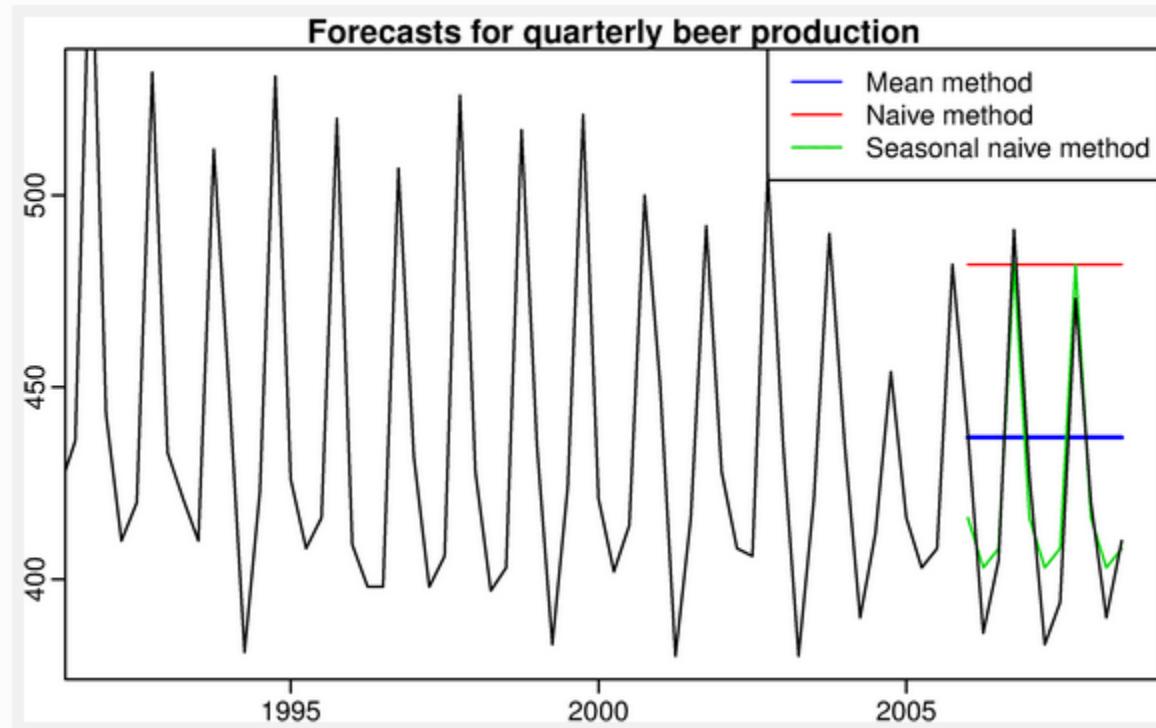
$$\text{MAPE} = \text{mean}(|p_i|).$$

$$\text{sMAPE} = \text{mean} (200|y_i - \hat{y}_i|/(y_i + \hat{y}_i))$$

$$q_j = \frac{e_j}{\frac{1}{T-1} \sum_{t=2}^T |y_t - y_{t-1}|}.$$

$$\text{MASE} = \text{mean}(|q_j|).$$

Series temporales estacionales

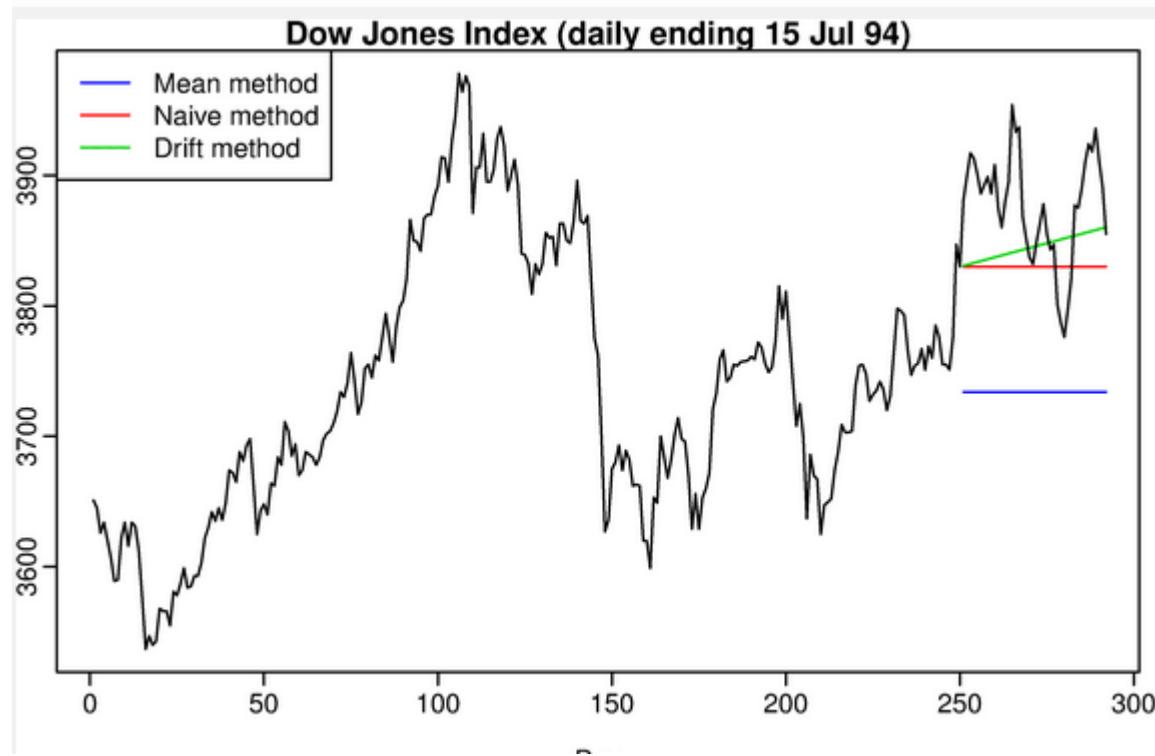


Method	RMSE	MAE	MAPE	MASE
Mean method	38.01	33.78	8.17	0.61
Naïve method	70.91	63.91	15.88	1.15
Seasonal naïve method	12.97	11.27	2.73	0.20

Para generar el gráfico

```
data(dj)
dj2 <- window(dj, end=250)
plot(dj2, main="Dow Jones Index (daily ending 15
Jul 94)",
     ylab="", xlab="Day", xlim=c(2,290))
lines(meanf(dj2, h=42)$mean, col=4)
lines(rwf(dj2, h=42)$mean, col=2)
lines(rwf(dj2, drift=TRUE, h=42)$mean, col=3)
legend("topleft", lty=1, col=c(4,2,3),
       legend=c("Mean method", "Naive method", "Drift
method"))
```

Series temporales no estacionales

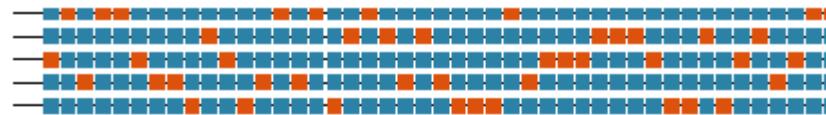


Method	RMSE	MAE	MAPE	MASE
Mean method	148.24	142.42	3.66	8.70
Naïve method	62.03	54.44	1.40	3.32
Drift method	53.70	45.73	1.18	2.79

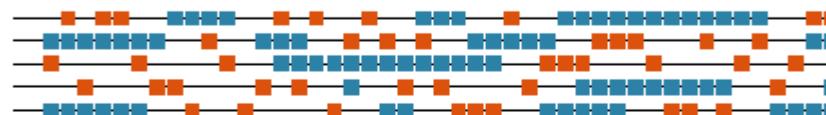
Metodología

- Como en cualquier otra tarea de análisis y modelado de datos, es esencial realizar una evaluación correcta
- Los datos deben dividirse en entrenamiento y prueba
- Se puede mejorar con validación cruzada
- O validación-cruzada por bloques

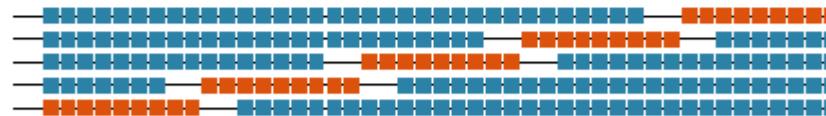
Procedimientos de selección de modelos



cross-validation



non-dep. cross-validation



blocked cross-validation



last block

Análisis de residuos

- Residuo: diferencia entre el valor observado y la predicción
- Un buen método de predicción producirá residuos que:
 - No esté correlados
 - Tengan media cero
- Cualquier método que no verifique esas propiedades puede ser mejorado
- Además, es interesante observar si:
 - Los residuos tienen varianza constante
 - Los residuos tienen distribución normal

Intervalos de predicción

- Un intervalo de predicción da un intervalo dentro del cual está el valor esperado con una probabilidad determinada (dependen de la probabilidad)
- Cuando la predicción se hace para el siguiente valor, la desviación estándar de la distribución de predicción es casi la misma que la desviación estándar de los residuos

Predicción de series temporales con R

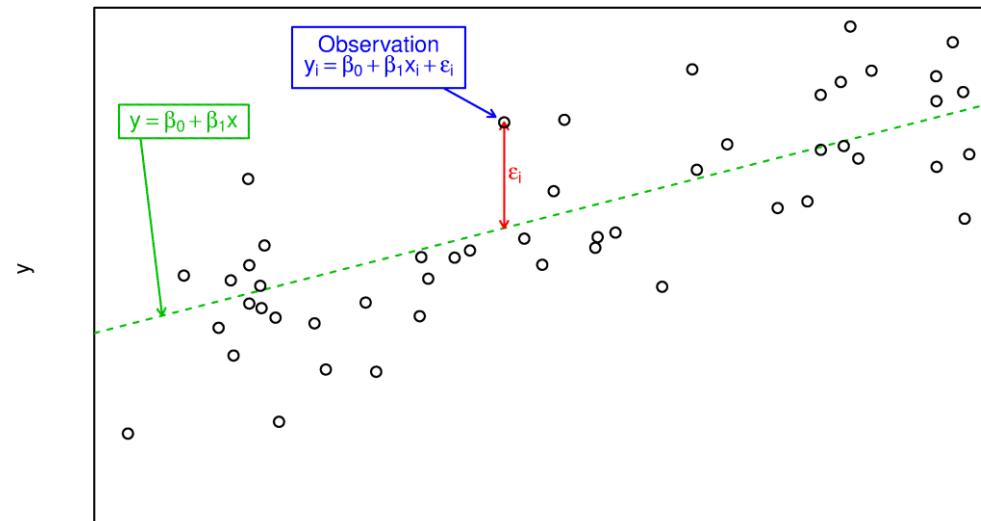
- R es un plataforma muy potente para el análisis y predicción de series temporales
- CRAN Task View: Time Series Analysis
- Principales paquetes:
 - forecast
 - zoo
 - ts
 - tseries
 - tsDyn

Regresión simple

Regresión lineal simple

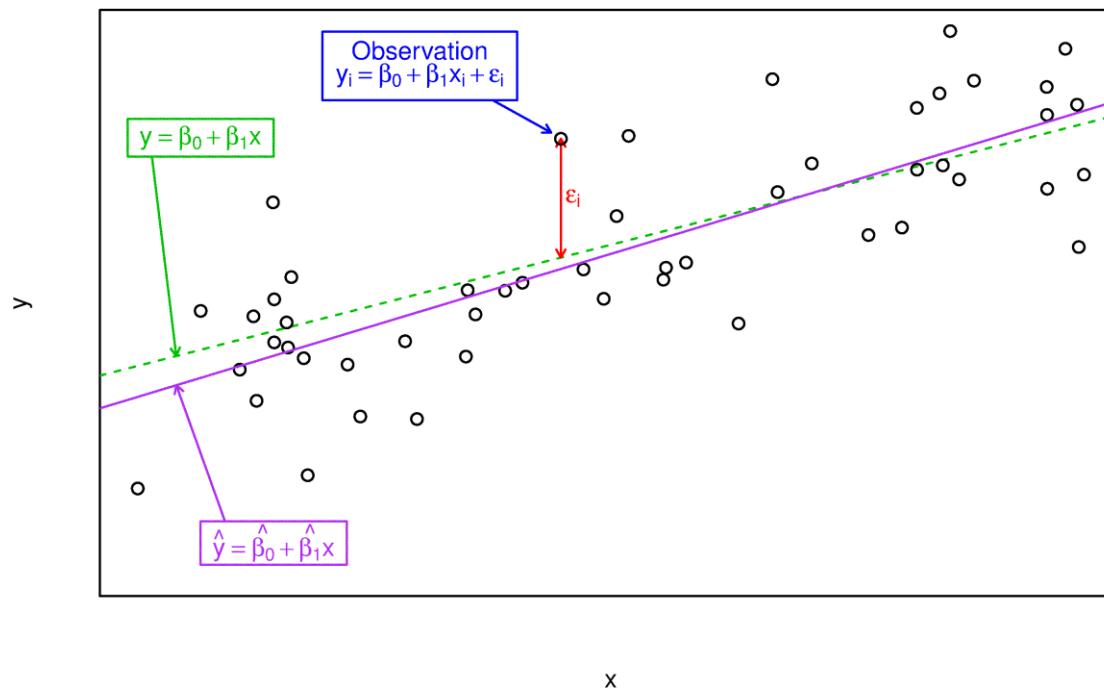
- Asumamos que la variable predicha y las predictivas tienen una relación lineal

$$y = \beta_0 + \beta_1 x + \varepsilon$$



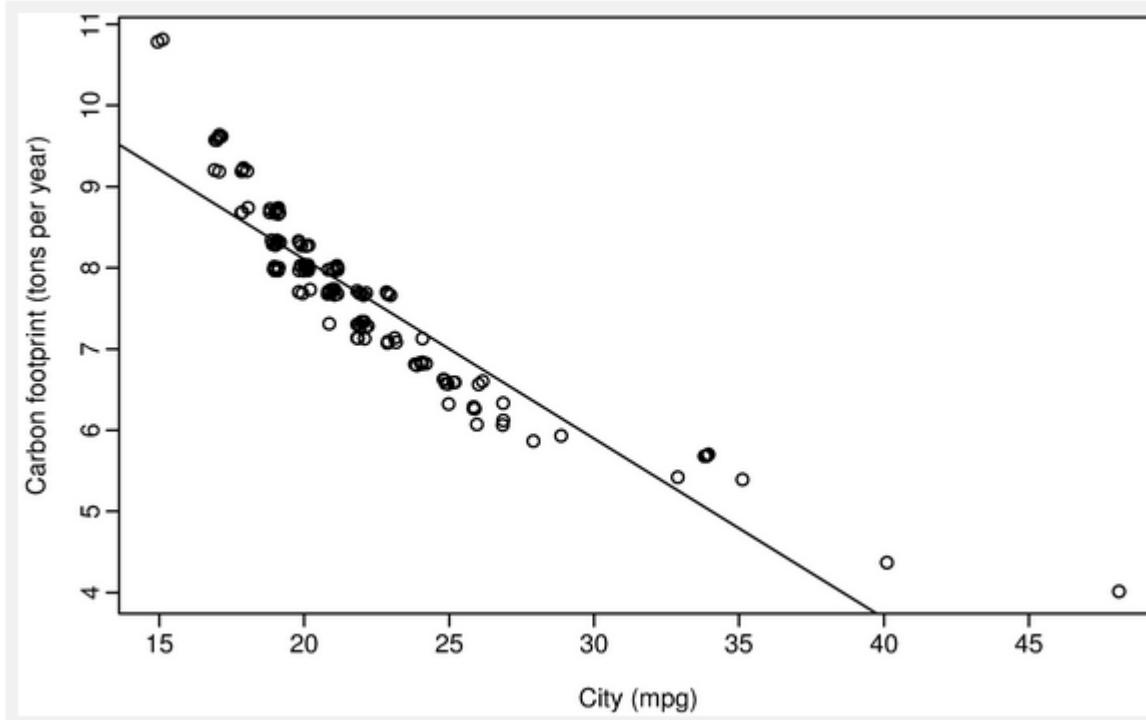
Aproximación por mínimos cuadrados

$$\sum_{i=1}^N \epsilon_i^2 = \sum_{i=1}^N (y_i - \beta_0 - \beta_1 x_i)^2$$



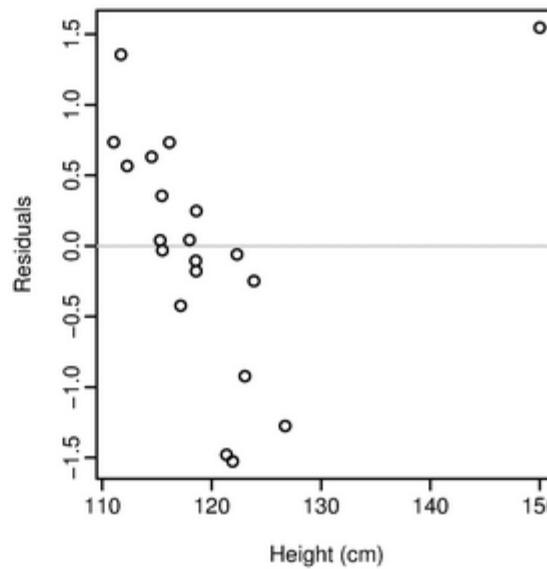
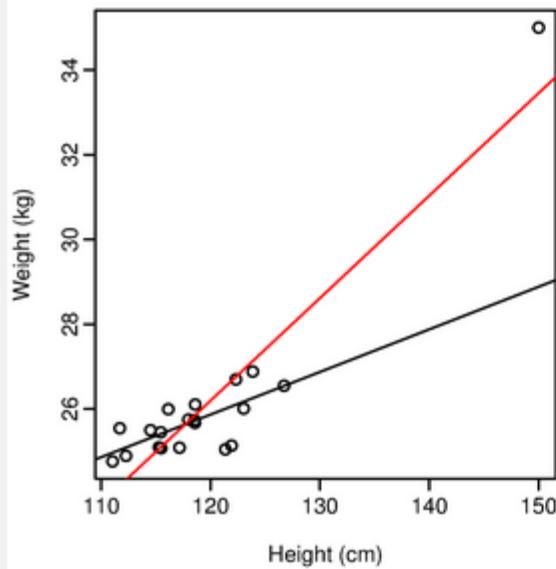
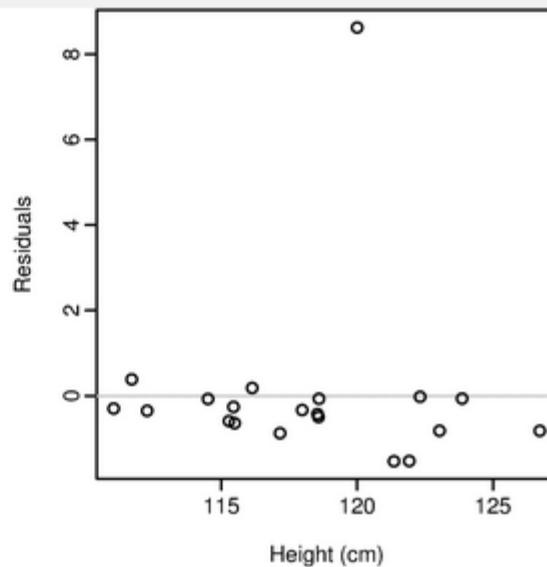
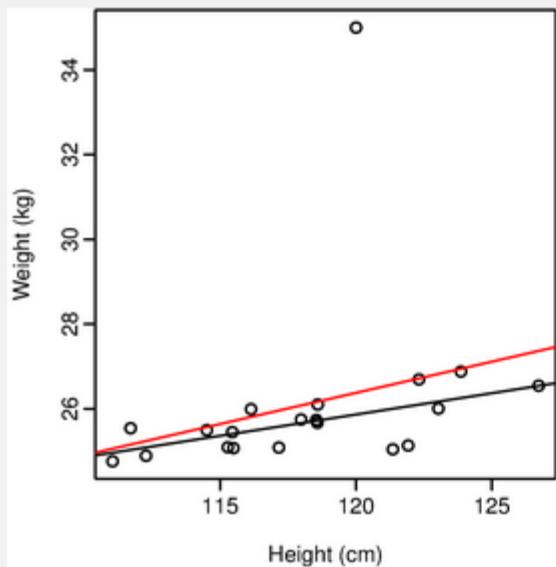
Regresión y correlación

$$\hat{\beta}_1 = r \frac{s_y}{s_x}$$



Ajuste del modelo

```
data(jitter)
plot(jitter(Carbon) ~ jitter(city),xlab="city
(mpq)",
      ylab="Carbon footprint (tons per
year)",data=fuel)
fit <- lm(Carbon ~ city, data=fuel)
abline(fit)
```



Calidad del ajuste

- Coeficiente de determinación, R^2 :

$$R^2 = \frac{\sum(\hat{y}_i - \bar{y})^2}{\sum(y_i - \bar{y})^2},$$

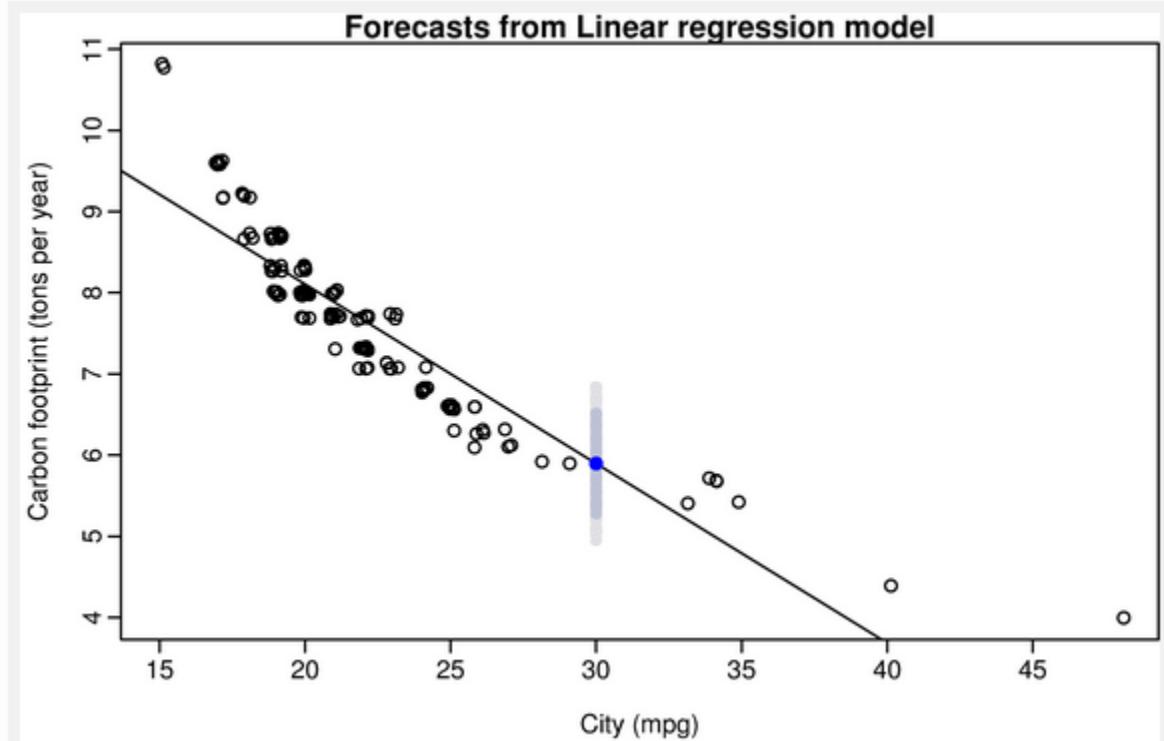
- Error estándar de la regresión

$$s_e = \sqrt{\frac{1}{N-2} \sum_{i=1}^N e_i^2}.$$

Predicción con regresión

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$$

$$\hat{y} \pm 1.96 s_e \sqrt{1 + \frac{1}{N} + \frac{(x - \bar{x})^2}{(N - 1)s_x^2}}$$



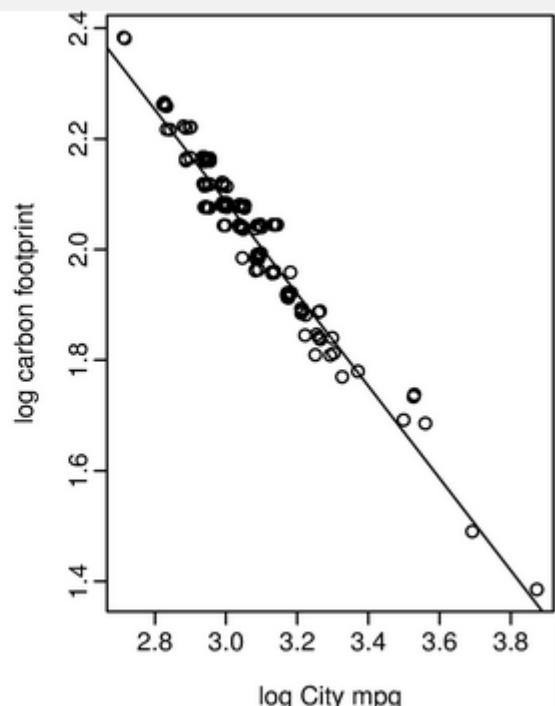
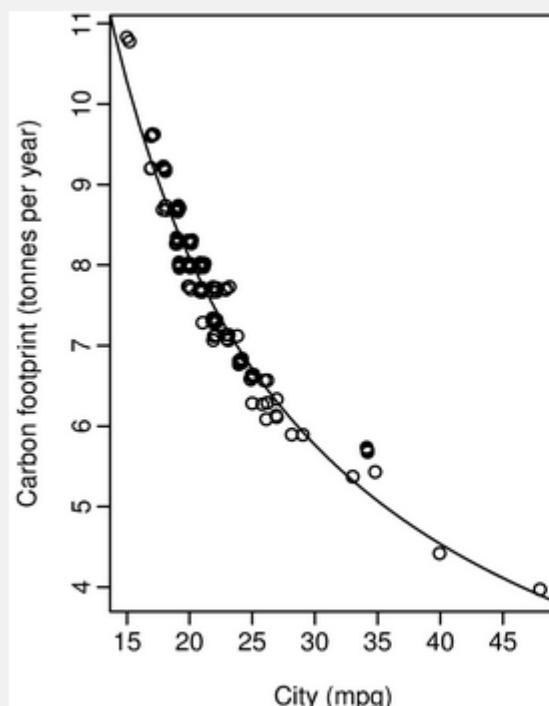
Para generar el gráfico

```
fitted(fit)[1]  
  
fcast <- forecast(fit,  
newdata=data.frame(city=30))  
  
plot(fcast, xlab="City (mpg)", ylab="Carbon  
footprint (tons per year)")
```

Regresión no lineal

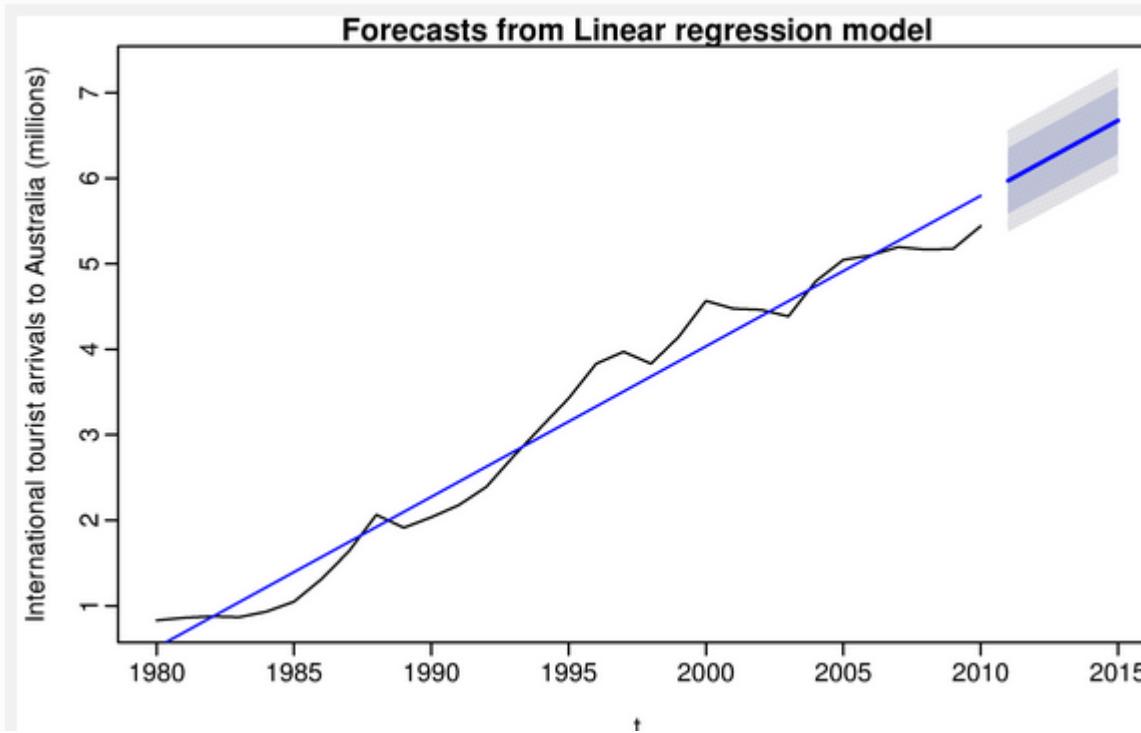
- Puede ocurrir que una función no lineal sea más adecuada para el problema que una función lineal
- Se puede conseguir transformando x o y

$$\log y_i = \beta_0 + \beta_1 \log x_i + \varepsilon_i.$$



Regresión con datos de series temporales

$$y_t = \beta_0 + \beta_1 t + \varepsilon_t.$$



Para generar el gráfico

```
fit.ex4 <- tslm(austa ~ trend)

f <- forecast(fit.ex4, h=5, level=c(80,95))

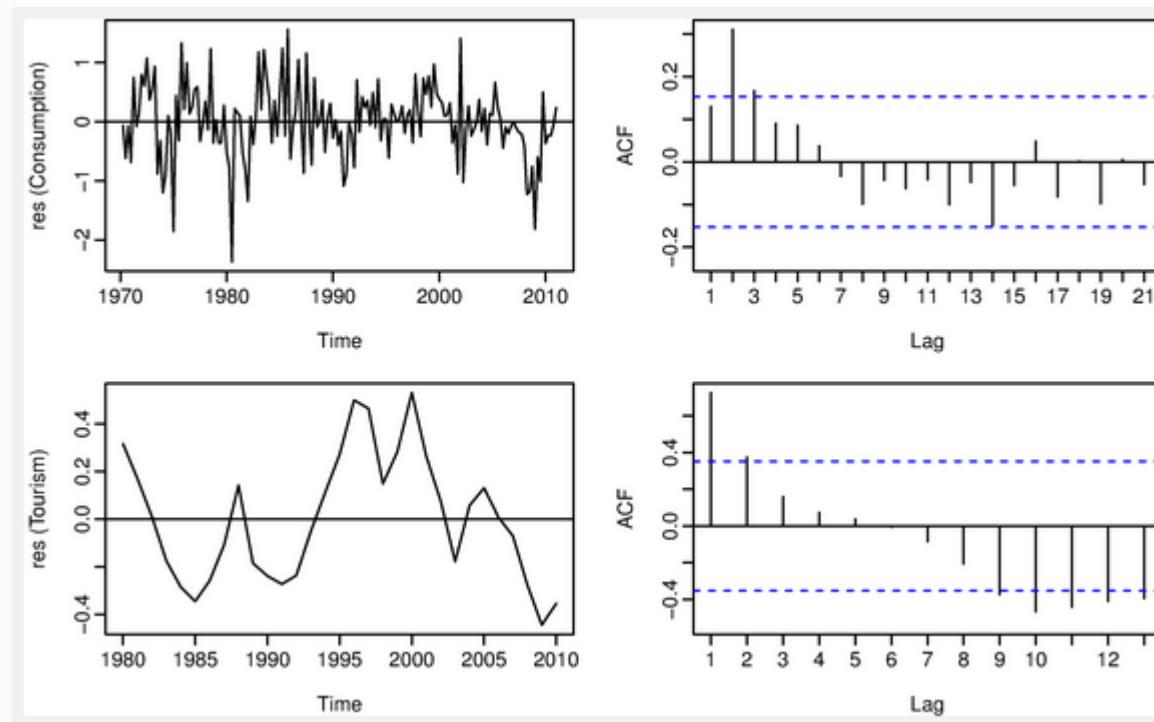
plot(f, ylab="International tourist arrivals to
Australia (millions)",

      xlab="t")

lines(fitted(fit.ex4), col="blue")

summary(fit.ex4)
```

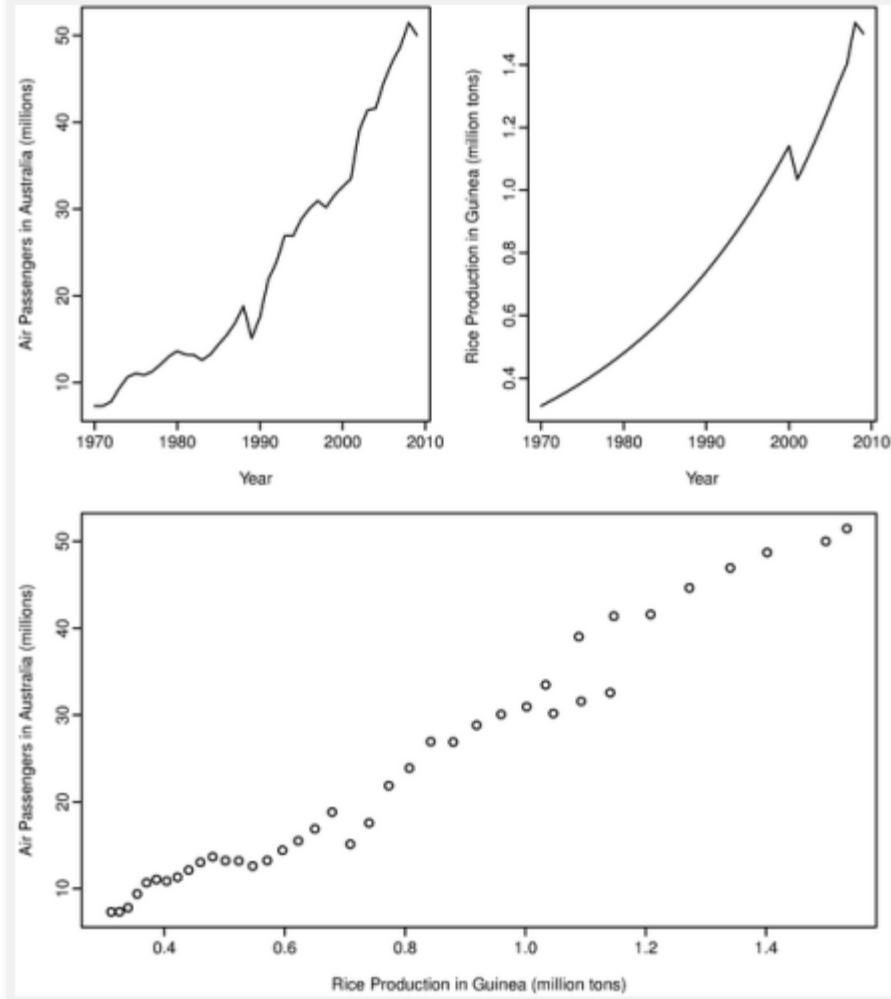
Autocorrelación de residuos



Para generar el gráfico

```
par(mfrow=c(2,2))
res3 <- ts(resid(fit.ex3),s=1970.25,f=4)
plot.ts(res3,ylab="res (Consumption)")
abline(0,0)
Acf(res3)
res4 <- resid(fit.ex4)
plot(res4,ylab="res (Tourism)")
abline(0,0)
Acf(res4)
```

Regresión espúrea



Regresión multivariable

Regresión multivariable

Se puede construir una predicción con base en varias variables predictivas

$$y_i = \beta_0 + \beta_1 x_{1,i} + \beta_2 x_{2,i} + \cdots + \beta_k x_{k,i} + e_i.$$

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{1,i} - \cdots - \beta_k x_{k,i})^2.$$

Selección de variables predictivas

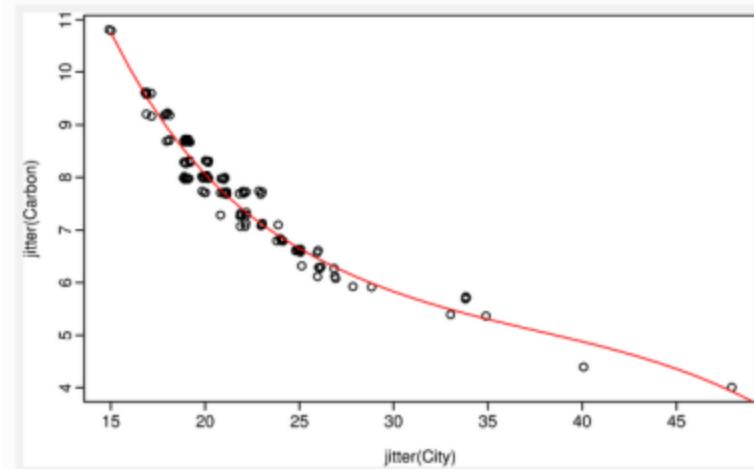
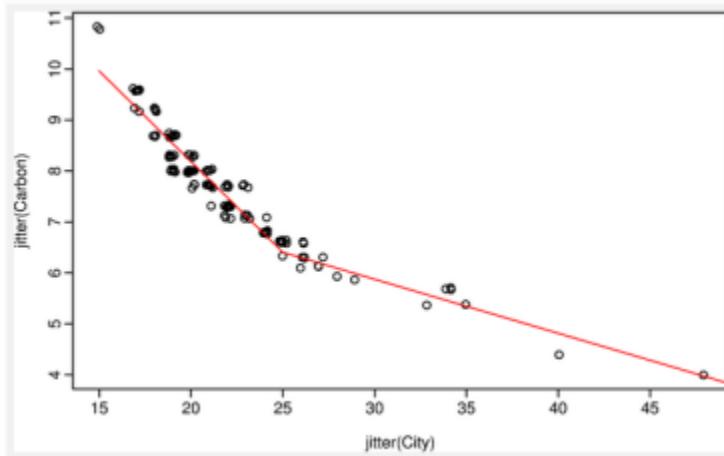
- ❑ R2 ajustado
- ❑ Validación cruzada
- ❑ Akaike's Information Criterion
- ❑ Corrected Akaike's Information Criterion
- ❑ Schwarz Bayesian Information Criterion
- ❑ Mejor subconjunto para la regresión
- ❑ Regresión por pasos

Análisis de residuos: gráficos

- Gráficos de puntos: residuo frente a predictivas
- Gráfico de puntos: residuos frente a valores predichos
- Autocorrelación en los residuos
- Histograma de residuos

Regresión no lineal

$$y = f(x) + e,$$



Para generar los dos gráficos

```
cityp <- pmax(fuel$city-25,0)
fit2 <- lm(Carbon ~ City + Cityp, data=fuel)
x <- 15:50; z <- pmax(x-25,0)
fcast2 <- forecast(fit2,
newdata=data.frame(City=x,Cityp=z))
plot(jitter(Carbon) ~ jitter(City), data=fuel)
lines(x, fcast2$mean,col="red")

fit3 <- lm(Carbon ~ City + I(City^2) + I(City^3) +
I(Cityp^3), data=fuel)
fcast3 <-
forecast(fit3,newdata=data.frame(City=x,Cityp=z))
plot(jitter(Carbon) ~ jitter(City), data=fuel)
lines(x, fcast3$mean,col="red")
```

Correlación NO es causalidad

- Una variable x puede ser útil para predecir una variable y , pero eso no significa que x cause y
- Las correlaciones son útiles para predecir aunque no exista relación causal entre las variables

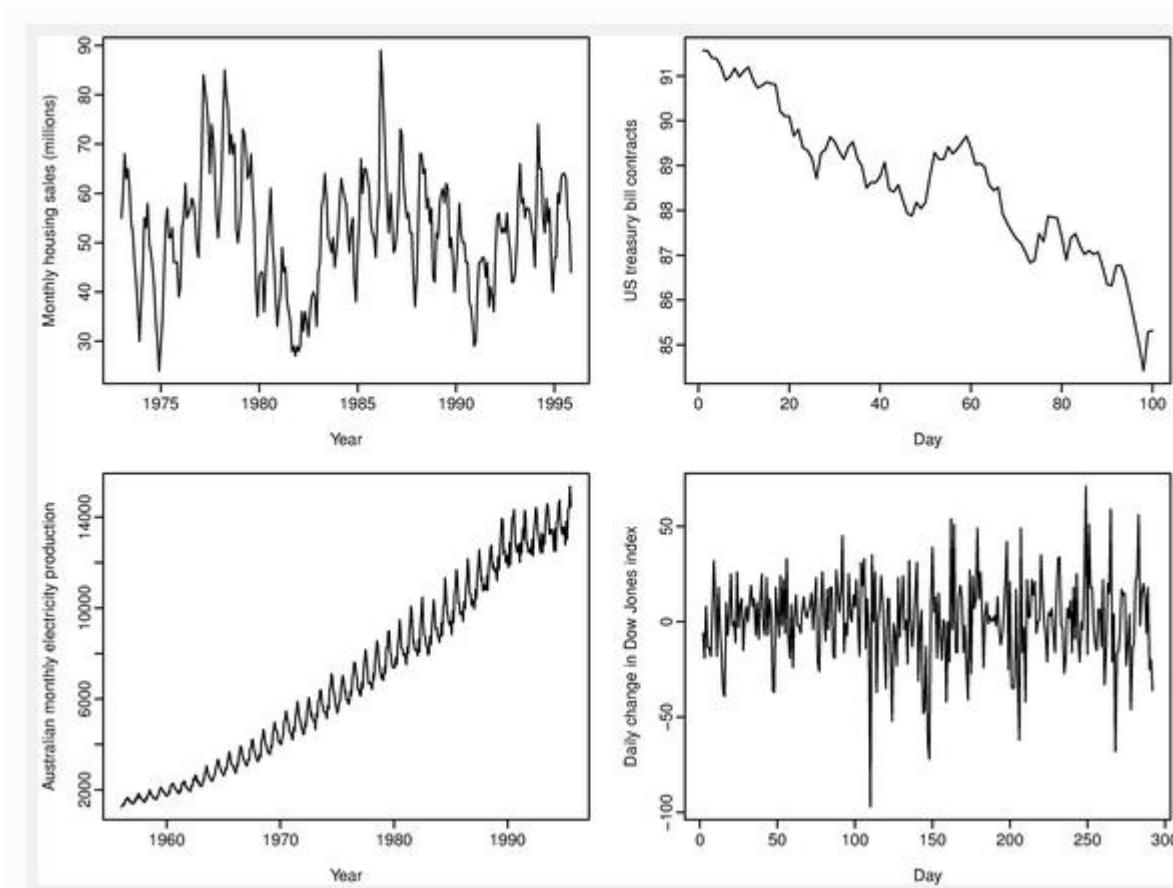
Descomposición de series temporales

Descomposición de series temporales

- Las series temporales pueden mostrar una gran variedad de patrones. Es beneficioso categorizar algunos patrones y comportamientos que pueden verse
- A veces, es muy útil descomponer una serie en varias partes, cada una de las cuales representa una parte del comportamiento

Componentes de las series temporales

Tendencia, estacionalidad y ciclos



Para generar el gráfico

```
data(hsales)
data(ustreas)
data(elec)
par(mfrow=c(2,2))
plot(hsales,xlab="Year",ylab="Monthly housing
sales (millions)")
plot(ustreas,xlab="Day",ylab="US treasury bill
contracts")
plot(elec,xlab="Year",ylab="Australian monthly
electricity production")
plot(diff(dj),xlab="Day",ylab="Daily change in
Dow Jones index")
```

Time series decomposition

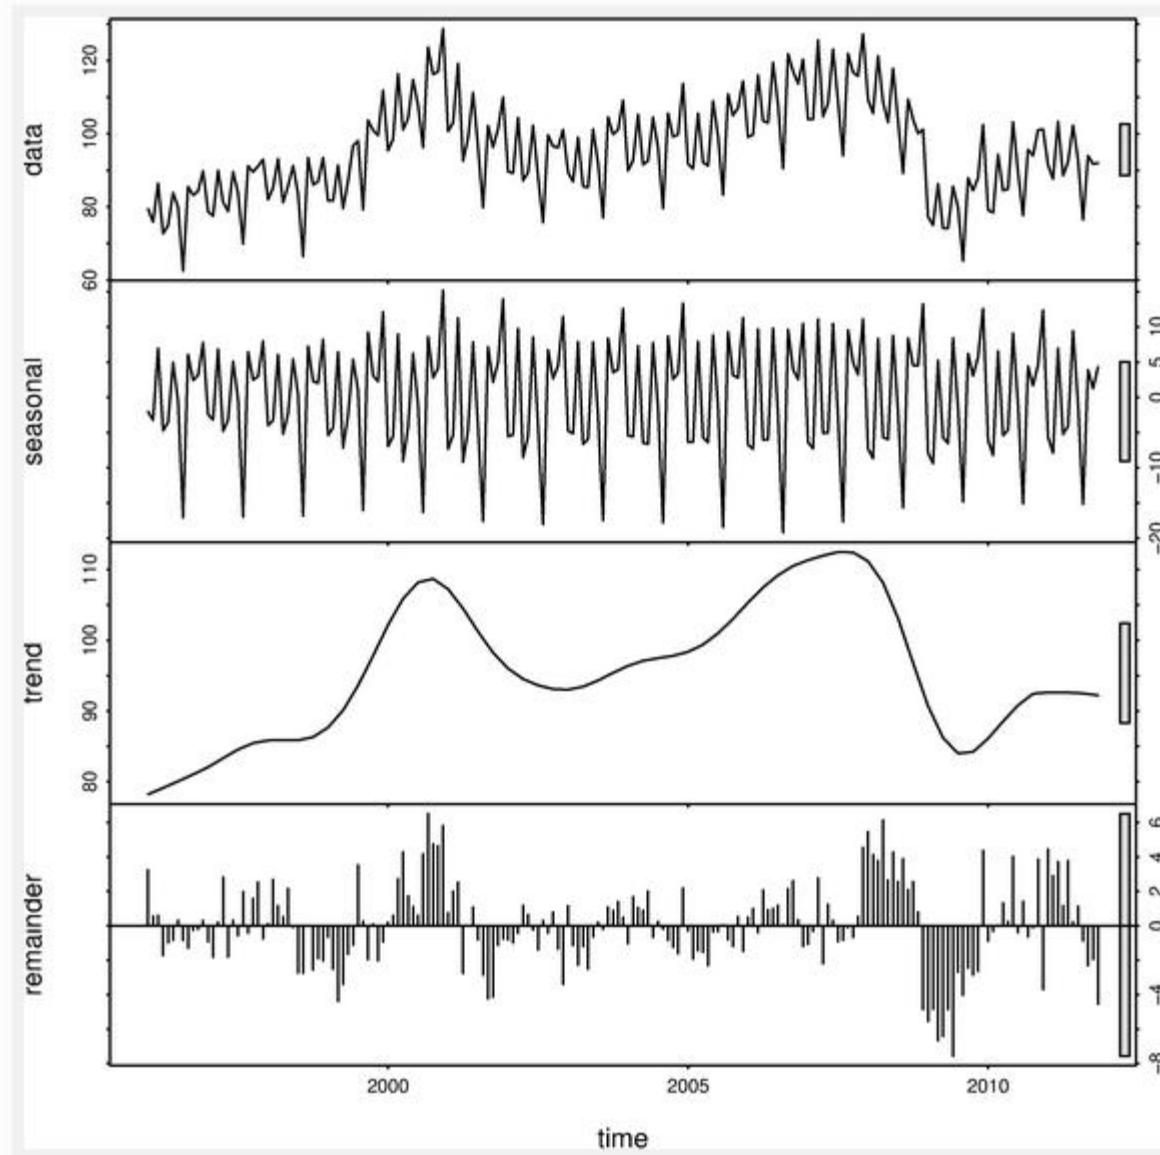
Descomposición aditiva

$$y_t = S_t + T_t + E_t$$

Adecuada cuando la magnitud de las fluctuaciones estacionales o la varación entorno a la tendencia no varía con el nivel de la serie temporal

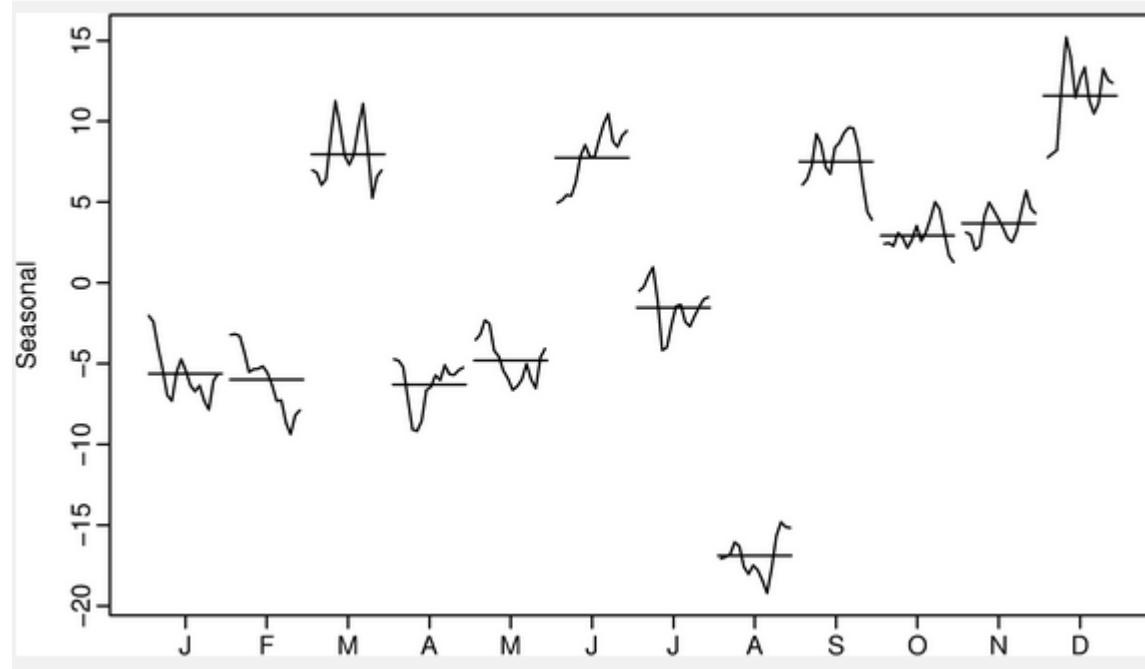
Descomposición multiplicativa

$$y_t = S_t \times T_t \times E_t$$



Para generar el gráfico

```
data(elecequip)  
fit <- stl(elecequip, s.window=5)  
plot(fit)
```

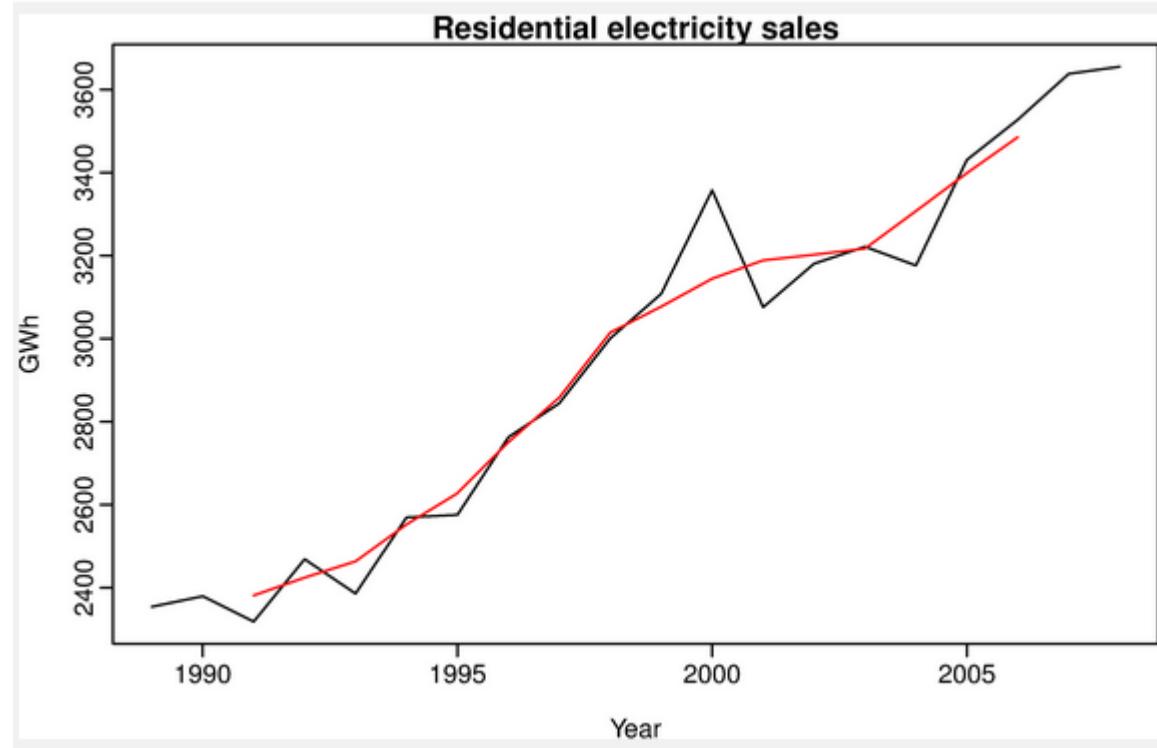


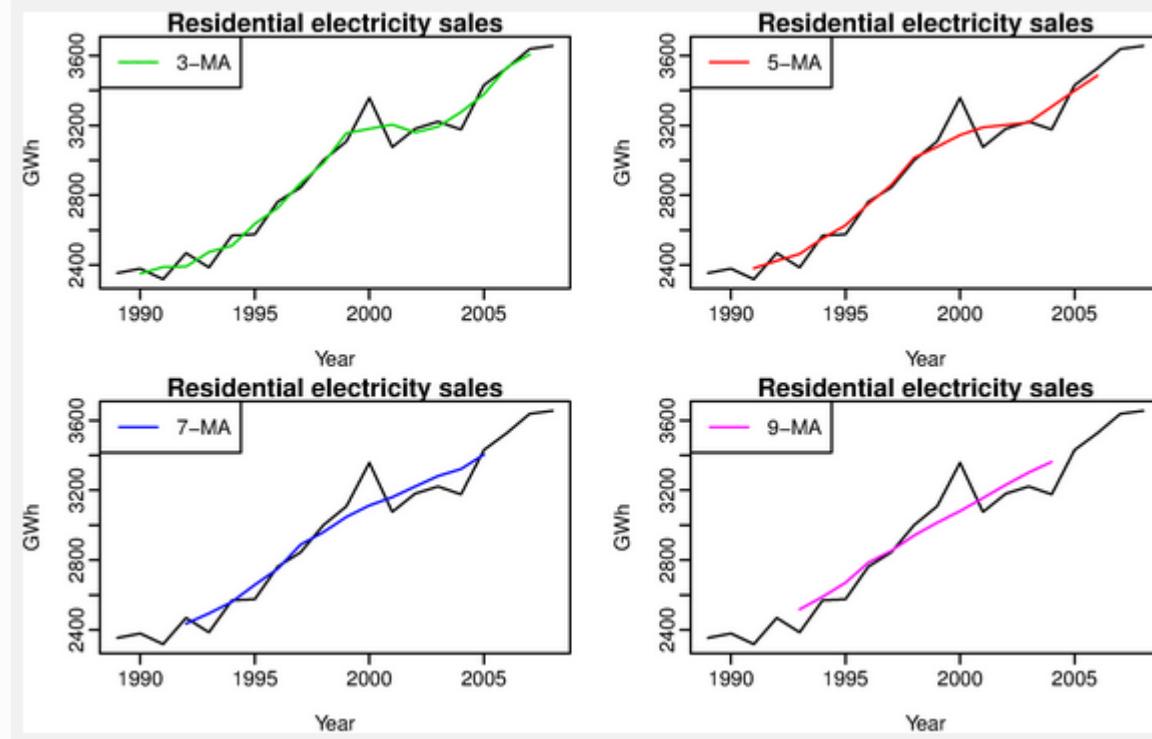
Para generar el gráfico

```
monthplot(fit$time.series[, "seasonal"], main="",  
ylab="Seasonal")
```

Medias móviles

$$\hat{T}_t = \frac{1}{m} \sum_{j=-k}^k y_{t+j}$$





Utilizadas frecuentemente para calcular la tendencia a partir de datos estacionales

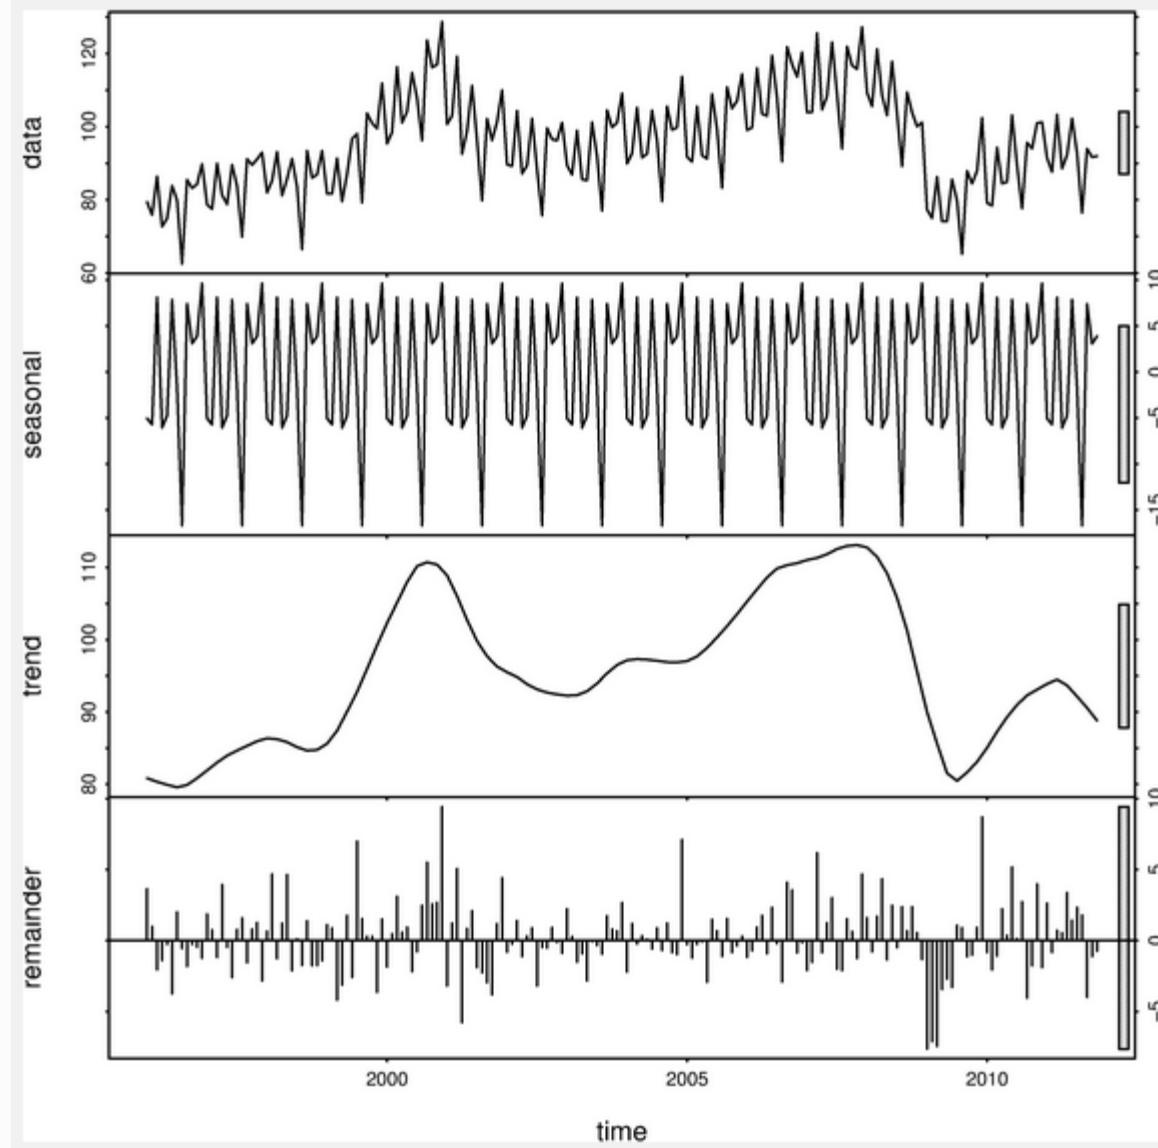
Medias móviles ponderadas

$$\hat{T}_t = \sum_{j=-k}^k a_j y_{t+j}$$

Su principal ventaja es que ofrecen una aproximación más suave de la tendencia

Descomposición STL

- STL es un método de descomposición robusto y versátil:
Seasonal and Trend decomposition using Loess.
 - Puede manejar cualquier tipo de estacionalidad
 - Los componentes estacionales pueden cambiar con el tiempo, dentro de un rango controlable por el usuario
 - Es robusto frente a puntos extremos



Predicción con descomposición

- Para predecir una serie descompuesta, se predicen los componentes individuales y después se calcula el valor predicho

$$y_t = \hat{S}_t + \hat{A}_t$$

$$y_t = \hat{S}_t \hat{A}_t,$$

Alisado exponencial

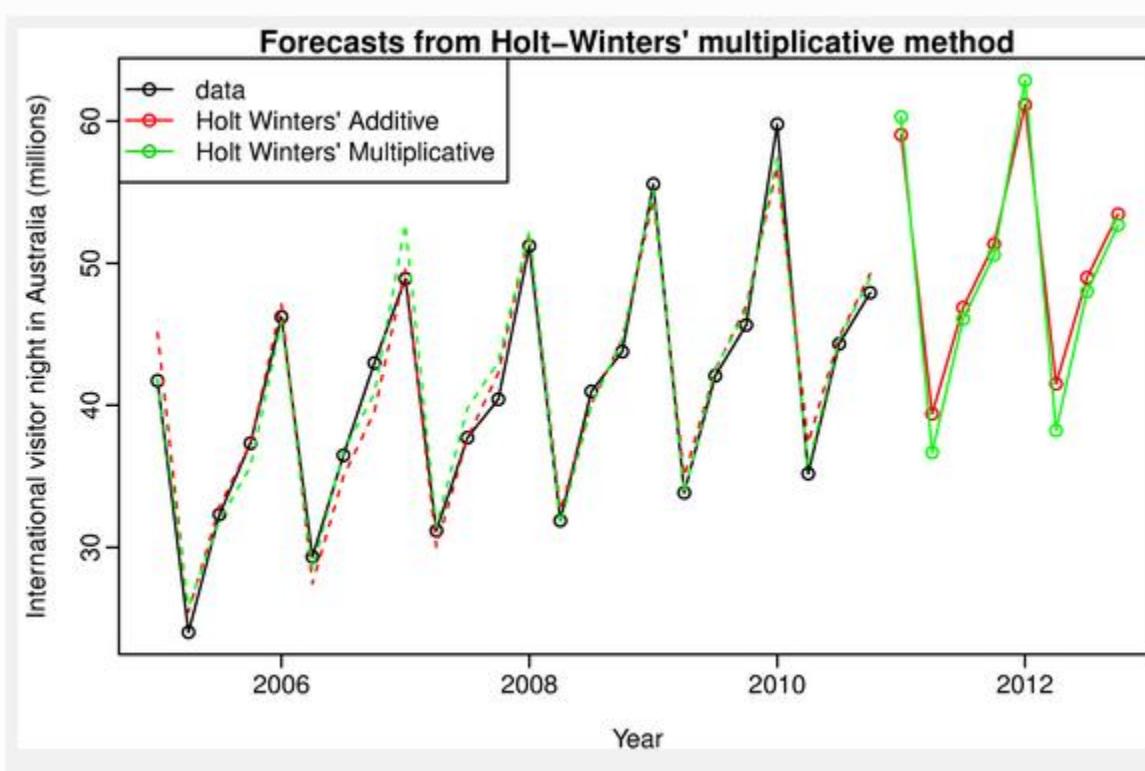
Alisado exponencial

- Sus predicciones son medias móviles ponderadas de observaciones pasadas con pesos que decaen exponencialmente conforme la observación es más antigua

Método estacional de Holt-Winters

- Método combinado que incluye una expresión para la predicción y tres ecuaciones para el alisado de las componentes: nivel, tendencia, estacionalidad
- Variaciones:
 - Método aditivo. Para variaciones estacionales que son relativamente constantes a lo largo de la serie
 - Método multiplicativo. Para variaciones estacionales proporcionales al nivel (valor) de la serie.

International visitor nights in Australia

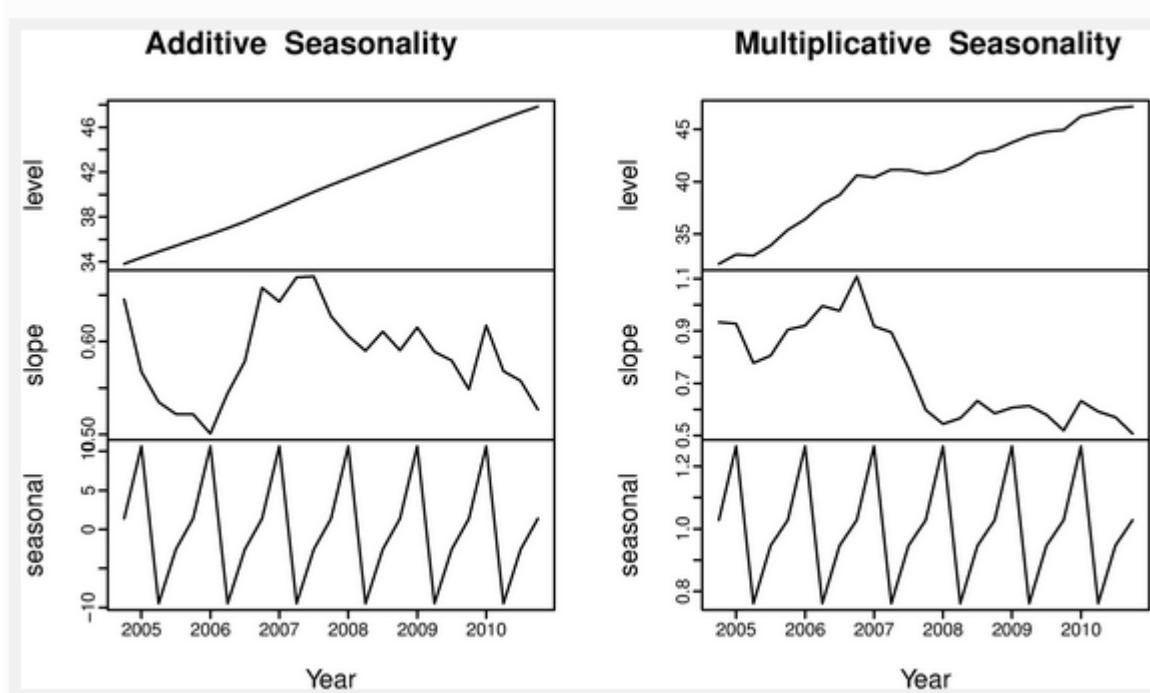


Para generar el gráfico

```
aust <- window(austourists,start=2005)
fit1 <- hw(aust,seasonal="additive")
fit2 <- hw(aust,seasonal="multiplicative")

plot(fit2,ylab="International visitor night in Australia
(millions)",
      plot.conf=FALSE, type="o", fcol="white",
      xlab="Year")
lines(fitted(fit1), col="red", lty=2)
lines(fitted(fit2), col="green", lty=2)
lines(fit1$mean, type="o", col="red")
lines(fit2$mean, type="o", col="green")
legend("topleft",lty=1, pch=1, col=1:3,
      c("data","Holt Winters' Additive","Holt Winters'
      Multiplicative"))
```

International visitor nights in Australia



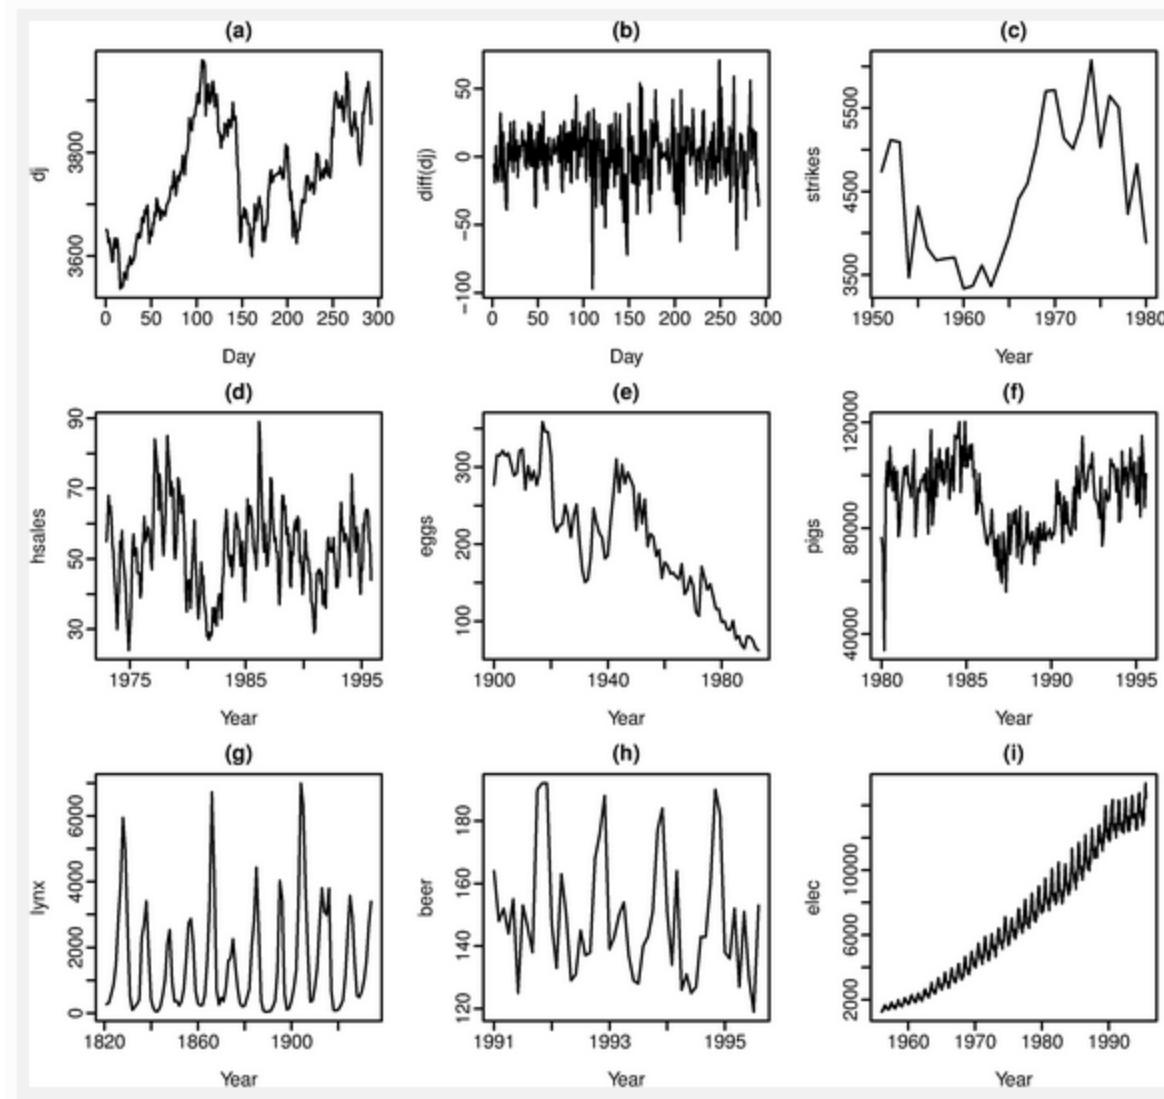
Para generar el gráfico

```
states <-  
cbind(fit1$model$states[,1:3],fit2$model$states[,1:3])  
  
colnames(states) <-  
c("level","slope","seasonal","level","slope","seasonal")  
  
plot(states, xlab="Year")  
  
fit1$model$state[,1:3]  
  
fitted(fit1)  
  
fit1$mean
```

Modelos ARIMA

Estacionariedad

- Una serie temporal es estacionaria si sus propiedades no dependen del momento en que se observa la serie
- La gráfica de la ACF es útil para identificar series no estacionarias. Para las series estacionarias, la función se acercará a cero relativamente rápido, mientras que para las series no estacionarias lo hará más lentamente



Diferenciación

- Calcular las diferencias entre valores sucesivos
- Transformaciones como el logaritmo pueden ayudar a estabilizar la varianza de una serie. La diferenciación puede ayudar a estabilizar la media de una serie eliminando cambios en el valor a lo largo del tiempo y, por tanto, eliminando la tendencia y la estacionalidad

Modelo de paseo aleatorio

- Una serie temporal construida añadiendo el error a cada nuevo término:

$$y_t = y_{t-1} + e_t$$

donde la media de e_t es cero y su desviación es constante

- Los paseos aleatorios típicamente tienen:
 - Largos periodos de tendencias aparentes ascendentes o descendentes
 - Cambios de dirección repentinos e impredecibles

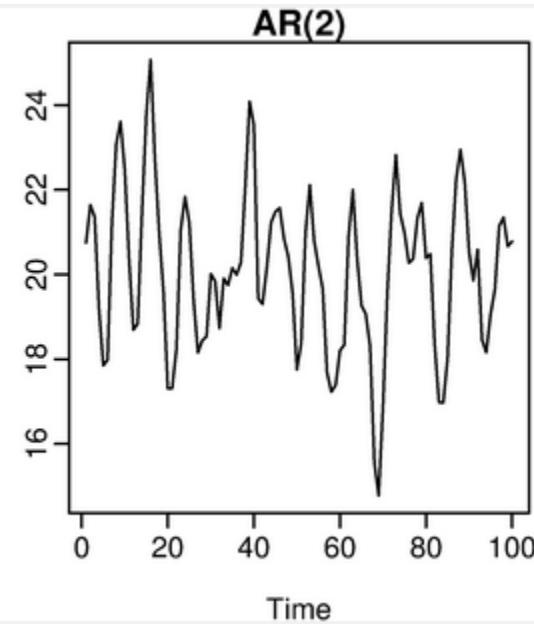
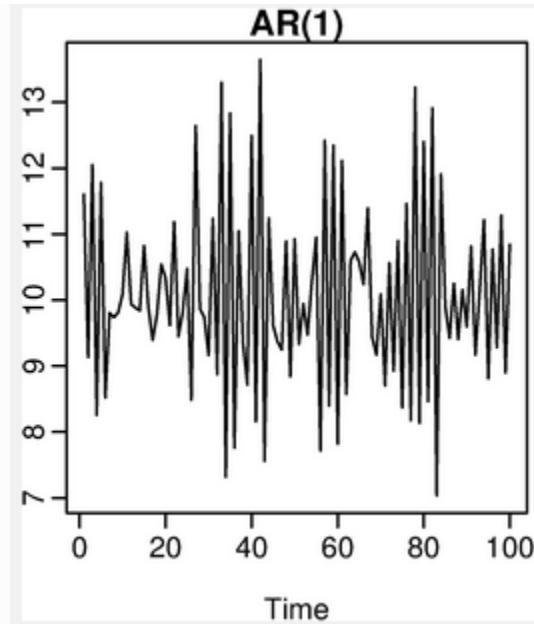
Test de raíz unidad

- Test de hipótesis de estacionariedad para determinar si es necesario diferenciar
- Test Augmented Dickey-Fuller

$$y'_t = \phi y_{t-1} + \beta_1 y'_{t-1} + \beta_2 y'_{t-2} + \cdots + \beta_k y'_{t-k},$$

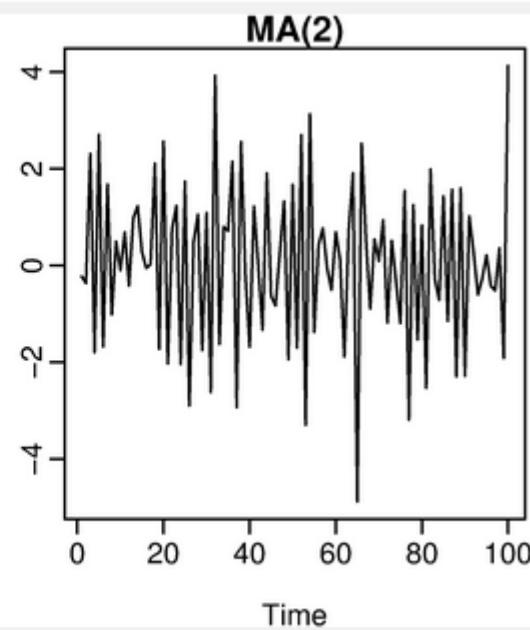
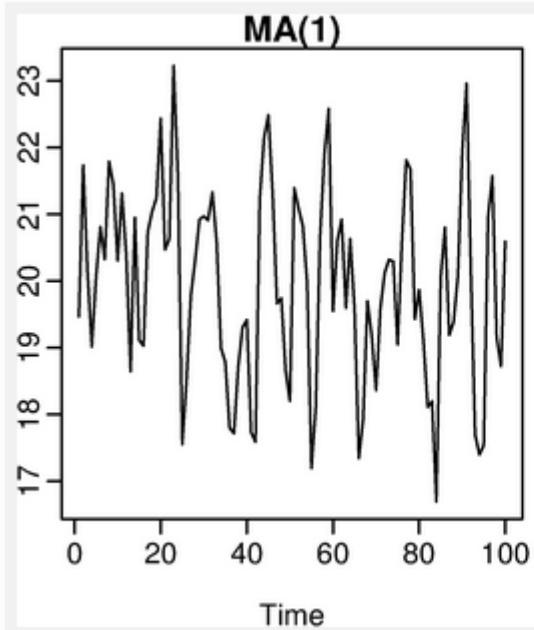
Modelos autoregresivos

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + e_t$$



Modelos de medias móviles

$$y_t = c + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \cdots + \theta_q e_{t-q}$$



Modelo ARIMA no estacional

$$y'_t = c + \phi_1 y'_{t-1} + \cdots + \phi_p y'_{t-p} + \theta_1 e_{t-1} + \cdots + \theta_q e_{t-q} + e_t$$

■ ARIMA(p,d,q)

- p: orden parte autoregresiva
- d: grado de la diferenciación
- q: grado del componente de medias móviles

White noise	ARIMA(0,0,0)
Random walk	ARIMA(0,1,0) with no constant
Random walk with drift	ARIMA(0,1,0) with a constant
Autoregression	ARIMA($p, 0, 0$)
Moving average	ARIMA($0, 0, q$)

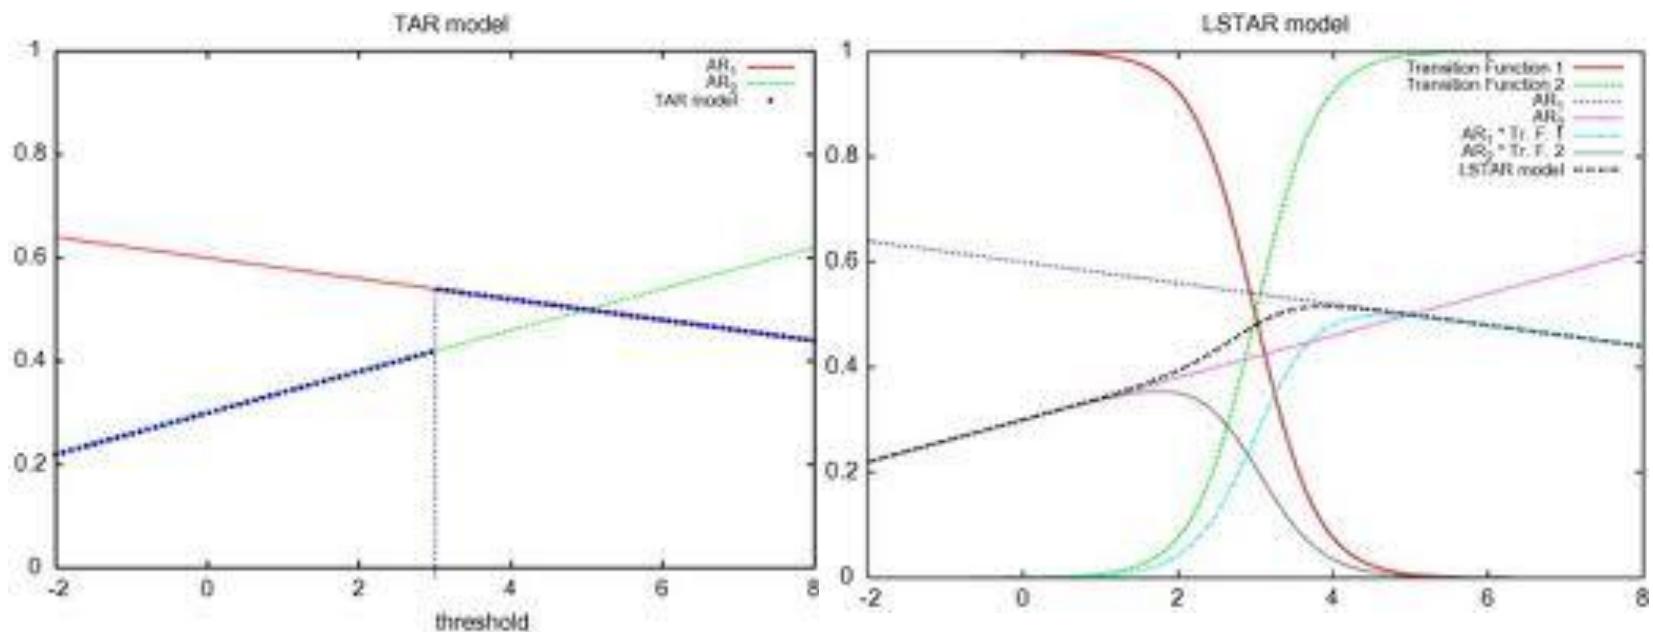
Modelos ARIMA en R

```
fit <- Arima(usconsumption[,1], order=c(0,0,3))
```

Función: auto.arima()

Modelos predictivos avanzados

Modelos autoregresivos de umbral (TAR)



Familia de modelos TAR

- ❑ TAR: Threshold AR
- ❑ STAR: Smooth TAR
- ❑ LSTAR: Logistic TAR
- ❑ NCSTAR: Neural Coefficient STAR

Conexiones entre familias de modelos

- Muchas familias son en realidad distintas caras de la misma idea
- Existen relaciones estrechas que permiten un intercambio de procedimientos y propiedades
- ANN = FRBS
- TAR = FRBS
- SVR = FRBS

Encrustamiento de series temporales

lag4	lag3	lag2	lag1	target
		
14	10	26	11	-13
10	26	11	-13	-15
26	11	-13	-15	-8
11	-13	-15	-8	35
-13	-15	-8	35	40
-15	-8	35	40	-8
-8	35	40	-8	-16
35	40	-8	-16	7
40	-8	-16	7	17
		

Redes neuronales

- Perceptrón multicapa
- Redes de función de base radial (RBF)
- Redes recurrentes
- ...

Pasos para la aplicación de una red

- ❑ Definición del problema: entradas y salidas
- ❑ Aplicar posibles transformaciones
- ❑ Definir la arquitectura de la red:
 - ❑ Número de capas; de unidades por capa, funciones de activación
- ❑ Definir el algoritmo de aprendizaje y sus parámetros
- ❑ Ajustar el modelo
- ❑ Evaluar y validar el modelo
- ❑ Usar el modelo

Otras técnicas

- ❑ SVR
- ❑ FRBS
- ❑ Modelos neuro-difusos
- ❑ Wavelets
- ❑ Spectral Analysis
- ❑ State-space models
- ❑ Hidden Markov models
- ❑ MARS
- ❑ Functional analysis
- ❑ ...

Conclusiones

- Las series temporales constituyen un tipo de dato de enorme interés en la industria y la ciencia. Constituyen una parte esencial de la Ciencia de los Datos
- Existen muchos métodos estadísticos para su análisis y predicción
- La Inteligencia Computacional aporta métodos avanzados de predicción
- R es una plataforma muy potente para su análisis y modelado

Referencias

- R. Hyndman, G. Athanasopoulos, «Forecasting and time series» 2013 (<https://www.otexts.org/fpp>)
- C. Chatfield, «The analysis of time series: An Introduction», 2003
- J.D. Hamilton, «Time Series Analysis», Princeton University Press, 1994
- P.J. Brockwell, R.A. Davis, «Time Series: Theory and Methods», 2nd Ed., Springer, 1991
- J.S. Armstrong (ed), «Principles of Forecasting: A Handbook for Researchers and Practitioners», Springer, 2001

Referencias (2)

- S.G. Makridakis, S.C. Wheelwright, R.J. Hyndman, «Forecasting», 3rd Ed., Wiley & Sons, 1998
- P.J. Brockwell, R.A. Davis, «Introduction to Time Series and Forecasting», 2nd ed., Springer, 2002
- A.K. Palit, D. Popovic, «Computational Intelligence in Time Series Forecasting: Theory and Engineering Applications», Springer, 2005
- R.H. Shumway, D.S. Stoffer, «Time Series Analysis and Its Applications», Springer, 2nd Ed., 2006

