

Análisis clásico de las series temporales

Análisis estadístico de series económicas

Xavier Barber

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

09/Feb/2019



Índice de contenidos

- 1 Series Temporales
- 2 Ajuste Estacional
- 3 Descomposición STL
- 4 Predicción y Descomposición
- 5 Suavizado exponencial simple (SES)
- 6 Métodos de tendencia
- 7 Métodos estacionales
- 8 ETS con R

Series Temporales

Valencia Bayesian Research group

Patrones en las series temporales

Recordatorio (Modelo ETS: *Error, Trend and Seasonality*)

Tendencia: patrón existente cuando hay un incremento o decremento a largo plazo en los datos

Ciclo: patrón existente cuando los datos muestran subidas y bajadas *que no son de período fijo* (duración generalmente ≥ 2 años).

Estacionalidad: patrón existente cuando una serie está influenciada por un factor estacional (trimestres, mes, día de la semana)

Descomposición de una serie temporal

$$y_t = f(S_t, T_t, R_t)$$

donde $y_t =$ data en el periodo t

$T_t =$ componente tendencia-ciclo en el periodo t

$S_t =$ componente estacional en el periodo t

$R_t =$ componente "restante" en el periodo t

Descomposición Aditiva: $y_t = S_t + T_t + R_t.$

Descomposición Multiplicativa: $y_t = S_t \times T_t \times R_t.$

Descomposición de una serie temporal

$$y_t = f(S_t, T_t, R_t)$$

donde $y_t =$ data en el periodo t

$T_t =$ componente tendencia-ciclo en el periodo t

$S_t =$ componente estacional en el periodo t

$R_t =$ componente "restante" en el periodo t

Descomposición Aditiva: $y_t = S_t + T_t + R_t.$

Descomposición Multiplicativa: $y_t = S_t \times T_t \times R_t.$


Descomposición de una serie temporal

- El **modelo Aditivo** apropiado si la magnitud de las fluctuaciones estacionales no varía con el nivel.
- Si la estacionalidad es proporcional al nivel de la serie, el **modelo Multiplicativo** es más apropiado. Muy habitual en las series económicas.
 - Trasformar los datos (Box-Cox) y usar un modelo aditivo.
 - Tomar logaritmos convierte una relación multiplicativa en aditiva.

$$y_t = S_t \times T_t \times E_t \quad \Rightarrow \quad \log y_t = \log S_t + \log T_t + \log R_t.$$


Euro-equipamiento eléctrico

```
fit <- stl(elecequip, s.window = 7)  
autoplot(fit) + xlab("Año")
```



Euro-equipamiento eléctrico

```
autoplot(elecequip, series="Datos") +  
  autolayer(trendcycle(fit), series="Tend.-ciclo")
```



Funciones a recordar

- `seasonal()` extrae la componente estacional.
- `trendcycle()` componente tendencia-ciclo.
- `remainder()` componente “restante”.
- `seasadj()` ajusta componente estacional.

Ajuste Estacional

Valencia Bayesian Research group

Ajuste estacional

- Descomposición aditiva: datos estacionales ajustados por

$$y_t - S_t = T_t + R_t$$


- Estacionalidad multiplicativa: datos estacionales ajustados por

$$y_t/S_t = T_t \times R_t$$

Euro-equipamiento eléctrico

```
fit <- stl(elecequip, s.window=7)
autoplot(elecequip, series="Datos") +
  autolayer(seasadj(fit), series="Estacion. ajustada")
```

Manufacturación de equipos eléctricos (Euro area)



Ajuste de la estacionalidad

- Se usan las estimaciones de S_t basadas en valores pasados para ajustar la estacionalidad de un valor actual.
- Las series ajustadas estacionalmente reflejan **Restos** y también **tendencia**. Por lo tanto, no son series “suaves” y puede haber “subidas” y “bajadas” engañosas.
- Es mejor utilizar la componente Tendencia-ciclo para mirar los puntos de inflexión.

La estacionalidad en la vida real

Información.es » Alicante » Noticias de Alicante

Noticias de Alicante

Turismo se centra en los congresos para acabar con la estacionalización

Alicante ha recibido en tres años más de cien mil congresistas, con una media de 33.000 visitantes al año, cerca del doble que los 19.163 que visitaron la ciudad en 2014

R.J. Benito | 03.05.2016 | 20:16

Elche, que cuenta con un centro específico para reuniones, atiende a unos 40.000 participantes al año.

La Agencia Valenciana de Turismo ha puesto en marcha una nueva línea estratégica dirigida a



La Opinión de Málaga » Turismo

Noticias de Cullera

El programa para combatir la estacionalidad tiene en marcha el 28% de las acciones

Los empresarios solicitan trabajar ya los mercados para el invierno de 2016

L. O. | 01.05.2015 | 09:00

El Plan contra la Estacionalidad Litoral tiene ejecutadas el 28% de las acciones que se programaron, según explicó ayer el consejero de Turismo y Comercio en funciones, Luciano Alonso, quien garantizó la ejecución de esta iniciativa, puesta en marcha a finales del pasado año. Este plan es clave para la industria turística de la Costa del Sol, que ha visto como en los últimos años pese a los buenos resultados la brecha entre temporada alta y baja se mantiene, lo que provoca que cada invierno más del 38% de las plazas



Alonso, director de Sertur Turismo, la CEA y Turismo Costa del Sol. L. O.

Diario DEE | 22.08.2018 | 18:50

hosteltur

HOJES Y ALIMENTOS | INNOVACIÓN | ECONOMÍA | TRANSPORTE | EDUCACIÓN

OPINIÓN | NOTICIAS | PREMIOS | CONTACTO

POR JOSÉ CANTERO GÓMEZ, EN INNOVACIÓN

La estacionalidad en turismo ni se crea ni se destruye, solo se transforma

7 COMENTARIOS

La estacionalidad en turismo ni se crea ni se destruye, solo se transforma

Uno de los temas más recurrentes en turismo, es sin duda la mencionada estacionalidad de esta industria. Si bien no es un aspecto único de la industria turística, pensemos en cualquier industria y observaremos que en mayor o menor medida existe estacionalidad en las ventas. Ahora sin ir más lejos, en plena Navidad, se produce un estacionalidad en las ventas de juguetes: que para algunas marcas representa casi el 70% de su facturación anual.

Levante-EMV » La Ribera » Noticias de Cullera

Noticias de Cullera

Creciente oferta para combatir la estacionalidad

Juan Gimeno Cullera | 11.12.2017 | 22:42


«En general, los locales que han estado abiertos han trabajado bien», reflexionó ayer el edil de Turismo, Javier Cantos. En esta época del año «muchos empresarios lo toman como período de descanso por lo que la oferta es más limitada». El hecho de que la tendencia en los últimos años sea a recibir más visitantes durante períodos vacacionales fuera de la temporada alta «ha de servir al sector para realizar una reflexión profunda sobre una estrategia de ciudad en la que amplíemos los servicios turísticos privados a todo el año», valoró el edil. El municipio trabaja ya en el «Plan 52» en el que se programan eventos todos los fines de semana de 2018 para la dinamización del sector. «Los eventos son un paso más en la



El edil Javier Cantos. Levante-EMV


Empleos en el sector turístico (afiliación)

Total empleados




Empleos desde 2009

Total empleados




Empleo (turismo) 2009-2018

```
ggseasonplot(window(x,start=c(2009,1)),
              year.labels=TRUE) +
ggtitle("Total empleados") + ylab("Miles")
```




Empleos en el sector turístico 2009-

```
x %>% window(start=2009) %>%
  stl(s.window=11, robust=TRUE) -> fit
autoplot(fit)
```




Empleos: ajuste estacional 2014-2016

Componente estacional



Empleos en el sector turístico 2009-2017

```
autoplot(seasadj(fit))
```



Descomposición STL

Valencia Bayesian Research group

Descomposición STL

STL: “Seasonal and Trend decomposition using Loess”.

- Muy versátil y robusto.
- STL se maneja bien con la estacionalidad.
- La componente estacional puede cambiar en el tiempo, y el ratio de cambio puede contralarla el usuario.
- El suavizado de la tendencia-ciclo también la controla el usuario.
- Robusto con los outliers.

Valencia Bayesian Research group

Descomposición STL


STL: “Seasonal and Trend decomposition using Loess”.

- No tiene periodo-calendario.
- Solo método aditivos.
- Tomando *log* si es multiplicativa.
- Usas la transformación Box-Cox para otro tipo de descomposiciones.

Descomposición STL

```
fit <- stl(elecequip, s.window=5, robust=TRUE)
autoplot(fit) +
  ggtitle("Descomp. STL para el índice de Equip. Eléctric.")
```


Descomp. STL para el índice de Equip. Eléctric.



Descomposición STL

```
fit <- stl(elecequip, s.window="periodic", robust=TRUE)
autoplot(fit) +
  ggtitle("Descomp. STL para el índice de Equip. Eléctric.")
```

Descomp. STL para el índice de Equip. Eléctric.




Descomposición STL

```
stl(elecequip, s.window=5)
stl(elecequip, t.window=15,
    s.window="periodic", robust=TRUE)
```

- *t.window* controla la ondulación de la componente de la tendencia
- *s.window* controla la variación de la componente de la estacionalidad

Descomposición STL

```
elecequip %>% mstl() %>% autoplot()
```



- `mstl()` elije `s.window=13`
- Puede incluirse un argumento `lambda` (Box-Cox).

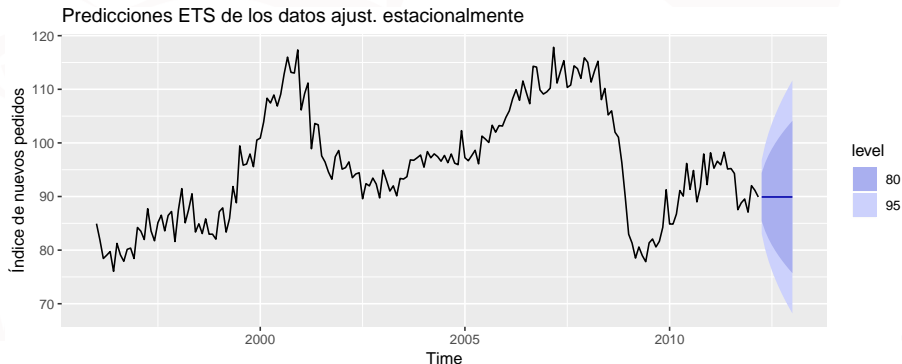
Predicción y Descomposición

Predicción y Descomposición

- Predicción de la componente estacional repitiendo la del año anterior
- Predecir con la componentes estacional ajustada usando métodos de series no estacionales
- Combinando el ajuste estacional con los datos de la estacionalidad ajustada para obtener predicciones de los datos originales
- Algunas veces la descomposición es útil solo para entender los datos antes de crear las predicciones.

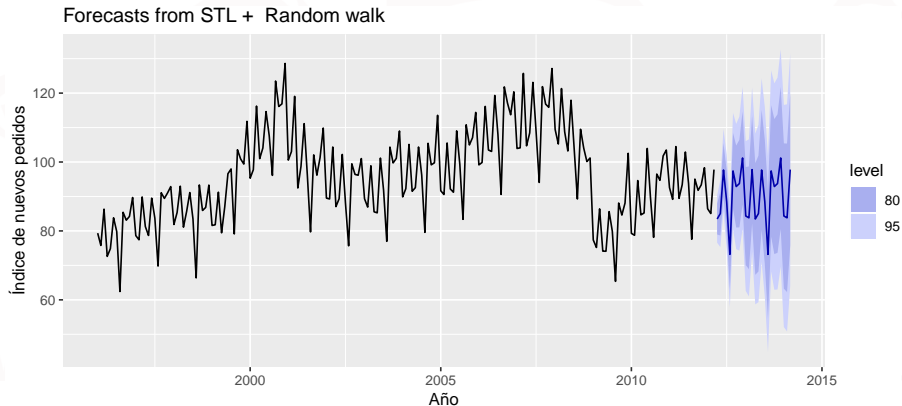
Equipamiento eléctrico

```
fit <- stl(elecequip, t.window=13, s.window="periodic")
fit %>% seasadj() %>% naive() %>%
  autoplot() + ylab("Índice de nuevos pedidos") +
  ggtitle("Predicciones ETS de los datos ajust. estacionalmente")
```



Equipamiento eléctrico

```
fit %>% forecast(method='naive') %>%
  autoplot() + ylab("Índice de nuevos pedidos") +
  xlab("Año")
```




Predicción y Descomposición

```

elecequip %>% stlf(method='naive') %>%
  autoplot() + ylab("Índice de nuevos pedidos") +
  xlab("Año")

```

Forecasts from STL + Random walk



Descomposición e intervalos de predicción

- Es común tomar los intervalos de predicción de las predicciones desestacionalizados y modificarlos con la componente estacional.
- Esto ignora la incertidumbre en la estimación del componente estacional.
- También ignora la incertidumbre en el futuro patrón estacional.

Suavizado exponencial simple (SES)

Métodos sencillos

Sea la serie temporal y_1, y_2, \dots, y_T .

Predicciones **Random Walk**

$$\hat{y}_{T+h|T} = y_T$$

Predicciones medias

$$\hat{y}_{|T+h|T} = \frac{1}{T} \sum_{t=1}^T y_t$$

- Se desea algo intermedio, que le de más peso a los datos más recientes.
- El SES utiliza una media móvil con pesos que decrecen exponencialmente.

Métodos sencillos

Sea la serie temporal y_1, y_2, \dots, y_T .

Predicciones **Random Walk**

$$\hat{y}_{T+h|T} = y_T$$

Predicciones medias

$$\hat{y}_{T+h|T} = \frac{1}{T} \sum_{t=1}^T y_t$$

- Se desea algo intermedio, que le de más peso a los datos más recientes.
- El SES utiliza una media móvil con pesos de decrecen exponencialmente.

Métodos sencillos

Sea la serie temporal y_1, y_2, \dots, y_T .

Predicciones **Random Walk**

$$\hat{y}_{T+h|T} = y_T$$

Predicciones medias

$$\hat{y}_{T+h|T} = \frac{1}{T} \sum_{t=1}^T y_t$$

- Se desea algo intermedio, que le de más peso a los datos más recientes.
- El SES utiliza una media móvil con pesos de decrecen exponencialmente.

Suavizado exponencial simple

Ecuación de predicción

$$\hat{y}_{T+1|T} = \alpha y_T + \alpha(1 - \alpha)y_{T-1} + \alpha(1 - \alpha)^2 y_{T-2} + \dots \quad 0 \leq \alpha \leq 1$$

Pesos asignados a las observaciones:

Observación	$\alpha = 0.2$	$\alpha = 0.4$	$\alpha = 0.6$	$\alpha = 0.8$
y_T	0.2	0.4	0.6	0.8
y_{T-1}	0.16	0.24	0.24	0.16
y_{T-2}	0.128	0.144	0.096	0.032
y_{T-3}	0.1024	0.0864	0.0384	0.0064
y_{T-4}	$(0.2)(0.8)^4$	$(0.4)(0.6)^4$	$(0.6)(0.4)^4$	$(0.8)(0.2)^4$
y_{T-5}	$(0.2)(0.8)^5$	$(0.4)(0.6)^5$	$(0.6)(0.4)^5$	$(0.8)(0.2)^5$

Suavizado exponencial simple

Ecuación de predicción

$$\hat{y}_{T+1|T} = \alpha y_T + \alpha(1 - \alpha)y_{T-1} + \alpha(1 - \alpha)^2 y_{T-2} + \dots \quad 0 \leq \alpha \leq 1$$

Pesos asignados a las observaciones:

Observación	$\alpha = 0.2$	$\alpha = 0.4$	$\alpha = 0.6$	$\alpha = 0.8$
y_T	0.2	0.4	0.6	0.8
y_{T-1}	0.16	0.24	0.24	0.16
y_{T-2}	0.128	0.144	0.096	0.032
y_{T-3}	0.1024	0.0864	0.0384	0.0064
y_{T-4}	$(0.2)(0.8)^4$	$(0.4)(0.6)^4$	$(0.6)(0.4)^4$	$(0.8)(0.2)^4$
y_{T-5}	$(0.2)(0.8)^5$	$(0.4)(0.6)^5$	$(0.6)(0.4)^5$	$(0.8)(0.2)^5$

Suavizado exponencial simple

Forma de las componentes

Ecuación de predicción $\hat{y}_{t+h|t} = \ell_t$

Ecuación de suavizado $\ell_t = \alpha y_t + (1 - \alpha)\ell_{t-1}$

- ℓ_t es el nivel (o valor de suavizado) de la serie en t .
- $\hat{y}_{t+1|t} = \alpha y_t + (1 - \alpha)\hat{y}_{t|t-1}$
Se itera para obtener la forma de la media móvil ponderada exponencialmente.

Forma de la media ponderada

$$\hat{y}_{T+1|T} = \sum_{j=0}^{T-1} \alpha(1 - \alpha)^j y_{T-j} + (1 - \alpha)^T \ell_0$$

Optimización

- Se necesitan valores para α y ℓ_0
- Similar a la regresión — se elije α y ℓ_0 minimizando SSE:

$$\text{SSE} = \sum_{t=1}^T (y_t - \hat{y}_{t|t-1})^2.$$

- Como en la regresión la solución no tiene una forma cerrada — se usa la optimización numérica.

Ejemplo: Producción petrolífera

```
fc <- ses(oildata, h = 5)
```

Simple exponential smoothing

Call:

```
ses(y = oildata, h = 5)
```

Smoothing parameters:

alpha = 0.8339

Initial states:

l = 446.5868

sigma: 29.8282

AIC	AICc	BIC
178.1430	179.8573	180.8141

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2014	542.7	504.5	580.9	484.2	601.1
2015	542.7	492.9	592.5	466.6	618.8
2016	542.7	483.6	601.8	452.3	633.1
2017	542.7	475.5	609.8	440.0	645.4
2018	542.7	468.3	617.0	429.0	656.4

Valencia Bayesian Research group


Ejemplo: Producción petrolífera

Year	Time	Observation	Level	Forecast
	t	y_t	ℓ_t	$\hat{y}_{t+1 t}$
1995	0		446.59	
1996	1	445.36	445.57	446.59
1997	2	453.20	451.93	445.57
1998	3	454.41	454.00	451.93
1999	4	422.38	427.63	454.00
2000	5	456.04	451.32	427.63
2001	6	440.39	442.20	451.32
2002	7	425.19	428.02	442.20
2003	8	486.21	476.54	428.02
2004	9	500.43	496.46	476.54
2005	10	521.28	517.15	496.46
2006	11	508.95	510.31	517.15
2007	12	488.89	492.45	510.31
2008	13	509.87	506.98	492.45
2009	14	456.72	465.07	506.98
2010	15	473.82	472.36	465.07
2011	16	525.95	517.05	472.36
2012	17	549.83	544.39	517.05
2013	18	542.34	542.68	544.39
	h			$\hat{y}_{T+h T}$
2014	1			542.68
2015	2			542.68
2016	3			542.68

Ejemplo: Producción petrolífera

```
autoplot(fc) +
  autolayer(fitted(fc), series="Fitted") +
  ylab("Petróleo (mollones de toneladas)") +
  xlab("Año")
```

Forecasts from Simple exponential smoothing



Métodos de tendencia

Valencia Bayesian Research group

Método de tendencia lineal de Holt

Las componentes

Predicción	$\hat{y}_{t+h t} = \ell_t + hb_t$
Nivel	$\ell_t = \alpha y_t + (1 - \alpha)(\ell_{t-1} + b_{t-1})$
Tendencia	$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1},$

- Dos parámetros de suavizado α y β^* ($0 \leq \alpha, \beta^* \leq 1$).
- Nivel ℓ_t : media ponderada entre y_t y y la predicción para el tiempo t , ($\ell_{t-1} + b_{t-1} = \hat{y}_{t|t-1}$)
- La pendiente b_t : media ponderada de $(\ell_t - \ell_{t-1})$ and b_{t-1} , estimación actual y previa para la pendiente.
- Elegir $\alpha, \beta^*, \ell_0, b_0$ que minimice SSE.

Método de tendencia lineal de Holt

Las componentes


Predicción	$\hat{y}_{t+h t} = \ell_t + hb_t$
Nivel	$\ell_t = \alpha y_t + (1 - \alpha)(\ell_{t-1} + b_{t-1})$
Tendencia	$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1},$

- Dos parámetros de suavizado α y β^* ($0 \leq \alpha, \beta^* \leq 1$).
- Nivel ℓ_t : media ponderada entre y_t y la predicción para el tiempo t , ($\ell_{t-1} + b_{t-1} = \hat{y}_{t|t-1}$)
- La pendiente b_t : media ponderada de $(\ell_t - \ell_{t-1})$ and b_{t-1} , estimación actual y previa para la pendiente.
- Elegir $\alpha, \beta^*, \ell_0, b_0$ que minimice SSE.

Método de Holt en R

```
window(ausair, start=1990, end=2004) %>%  
  holt(h=5, PI=FALSE) %>%  
  autoplot()
```

Forecasts from Holt's method



Método de tendencia “amortiguado”

Componentes

$$\hat{y}_{t+h|t} = l_t + (\phi + \phi^2 + \dots + \phi^h)b_t$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + \phi b_{t-1})$$

$$b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)\phi b_{t-1}.$$

- parámetro de amortiguado $0 < \phi < 1$.
- Si $\phi = 1$, coincide con el método lineal de Holt.
- Como $h \rightarrow \infty$, $\hat{y}_{T+h|T} \rightarrow l_T + \phi b_T / (1 - \phi)$.
- Predicciones a corto plazo con
tendencia, predicciones a largo plazo son constantes.

Método de tendencia “amortiguado”

Componentes

$$\hat{y}_{t+h|t} = l_t + (\phi + \phi^2 + \dots + \phi^h)b_t$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + \phi b_{t-1})$$


$$b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)\phi b_{t-1}.$$

- parámetro de amortiguado $0 < \phi < 1$.
- Si $\phi = 1$, coincide con el método lineal de Holt.
- Como $h \rightarrow \infty$, $\hat{y}_{T+h|T} \rightarrow l_T + \phi b_T / (1 - \phi)$.
- Predicciones a corto plazo con tendencia, predicciones a largo plazo son constantes.

Ejemplo: Pasajeros aéreos

```
window(ausair, start=1990, end=2004) %>%  
  holt(damped=TRUE, h=5, PI=FALSE) %>%  
  autoplot()
```

Forecasts from Damped Holt's method



Ejemplo: Ovejas en Asia


```
# Ajustamo los tres modelos  
livestock2 <- window(livestock, start = 1970, end = 2013)  
fit1 <- ses(livestock2)  
fit2 <- holt(livestock2)  
fit3 <- holt(livestock2, damped = TRUE)
```

```
#Comporbamos cual es el mejor (*training RMSE*)  
accuracy(fit1, livestock)  
accuracy(fit2, livestock)  
accuracy(fit3, livestock)
```

Ejemplo: Ovejas en Asia

	SES	Tend. lineal	Tend. amort.
α	1.00	0.98	0.97
β^*		0.00	0.00
ϕ			0.98
ℓ_0	263.90	251.46	251.89
b_0		4.99	6.29
Training RMSE	14.77	13.98	14.00
Test RMSE	25.46	11.88	14.73
Test MAE	20.38	10.71	13.30
Test MAPE	4.60	2.54	3.07
Test MASE	2.26	1.19	1.48

Ejemplo: Ovejas en Asia



Te toca

eggs contiene el precio de la docena de huevos en USA en el periodo 1900–1993

- 1 Una SES y el método de Holt (con y sin amortiguación) para predecir precios “futuros”.
[Truco: utiliza $h=100$ así podrás ver mejor las diferencias al dibujar las predicciones.]
- 2 ¿Qué método da el mejor “training RMSE”?
- 3 ¿Son los valores del RMSE comparables?
- 4 Haz los residuos del mejor ajuste y comprueba si son un ruido blanco

Métodos estacionales

Valencia Bayesian Research group

Método aditivo de Holt-Winters

Holt y Winters extendieron el método de Holt para capturar la estacionalidad.

Componentes

$$\hat{y}_{t+h|t} = \ell_t + hb_t + s_{t+h-m(k+1)}$$

$$\ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} + b_{t-1})$$

$$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1}$$

$$s_t = \gamma(y_t - \ell_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m},$$

- $k =$ la parte entera de $(h - 1)/m$. Garantiza que las estimaciones del último año se utilizan para la predicción.
- Parámetros: $0 \leq \alpha \leq 1$, $0 \leq \beta^* \leq 1$, $0 \leq \gamma \leq 1 - \alpha$ y $m =$ periodo de estacionalidad (i.e. $m = 4$ para datos trimestrales).

Método aditivo de Holt-Winters

- La componente estacional se suele expresar como

$$s_t = \gamma^*(y_t - \ell_t) + (1 - \gamma^*)s_{t-m}.$$

- Substituidad dentro por ℓ_t :

$$s_t = \gamma^*(1 - \alpha)(y_t - \ell_{t-1} - b_{t-1}) + [1 - \gamma^*(1 - \alpha)]s_{t-m}$$

- Se obtiene $\gamma = \gamma^*(1 - \alpha)$.

- La restricción del parámetro habitual es $0 \leq \gamma^* \leq 1$, que se traduce en $0 \leq \gamma \leq (1 - \alpha)$.

Holt-Winters multiplicative method

Si las variaciones estacionales cambian proporcionalmente al nivel de la serie.

Componentes

$$\hat{y}_{t+h|t} = (\ell_t + hb_t)s_{t+h-m(k+1)}.$$

$$\ell_t = \alpha \frac{y_t}{s_{t-m}} + (1 - \alpha)(\ell_{t-1} + b_{t-1})$$

$$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1}$$

$$s_t = \gamma \frac{y_t}{(\ell_{t-1} + b_{t-1})} + (1 - \gamma)s_{t-m}$$

Si las variaciones estacionales cambian proporcionalmente al nivel de la serie.

- k es la parte entera de $(h - 1)/m$.
- Con el método aditivo s_t está en términos absolutos: dentro de cada año $\sum_i s_i \approx 0$.
- Con el método multiplicativos s_t está en términos absolutos: dentro de cada año $\sum_i s_i \approx m$.


Ejemplo: Pernoctaciones hoteleras

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

```
tmp <- cbind(Datos=aust,
  "Predicciones HW aditivo" = fit1[["mean"]],
  "Predicciones HW multiplicativo" = fit2[["mean"]])
```

```
autoplot(tmp) + xlab("Year") +
  ylab("Pernoctaciones hoteleras (millones)") +
  scale_color_manual(name="",
  values=c('#000000', '#1b9e77', '#d95f02'),
  breaks=c("Datos", "Predicciones HW aditivo",
    "Predicciones HW multiplicativo"))
```

Ejemplo: Pernoctaciones hoteleras




Componentes estimados


```
addstates <- fit1$model$states[,1:3]
multstates <- fit2$model$states[,1:3]
colnames(addstates) <- colnames(multstates) <-
  c("nivel", "pendiente", "estacionalidad")
p1 <- autoplot(addstates, facets=TRUE) +
  xlab("Año") + ylab("") +
  ggtitle("Estados aditivos")
p2 <- autoplot(multstates, facets=TRUE) +
  xlab("Año") + ylab("") +
  ggtitle("Estados multiplicativos")
gridExtra::grid.arrange(p1, p2, ncol=2)
```

Componentes estimados

Estados aditivos



Estados multiplicativos



Método de Holt-Winters amortiguado

A menudo el método de predicción más preciso para datos estacionales.

$$\hat{y}_{t+h|t} = [\ell_t + (\phi + \phi^2 + \dots + \phi^h)b_t]s_{t+h-m(k+1)}$$

$$\ell_t = \alpha(y_t/s_{t-m}) + (1 - \alpha)(\ell_{t-1} + \phi b_{t-1})$$

$$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)\phi b_{t-1}$$

$$s_t = \gamma \frac{y_t}{(\ell_{t-1} + \phi b_{t-1})} + (1 - \gamma)s_{t-m}$$

Tu turno

Aplica el método multiplicativo de $H-W$ a la serie *gas*.


- 1 ¿Por qué es necesaria la estacionalidad multiplicativa aquí?
- 2 Experimenta haciendo que la tendencia se amortigüe.
- 3 Compruebe que los residuos del mejor método se parezcan a un ruido blanco.

ETS con R

Valencia Bayesian Research group

Ejemplo: Venta de medicamentos

```
autoplot(h02) + xlab("Años") + ylab("Venta de medicamentos")
```



Ejemplo: Venta de medicamentos

```
ets(h02)
```

```
ETS(M,Ad,M)
```

```
Call:
```

```
ets(y = h02)
```

```
Smoothing parameters:
```

```
alpha = 0.1953
```

```
beta = 1e-04
```

```
gamma = 1e-04
```

```
phi = 0.9798
```

```
Initial states:
```

```
l = 0.3945
```

```
b = 0.0085
```

```
s = 0.874 0.8197 0.7644 0.7693 0.6941 1.2838
```

```
1.326 1.1765 1.1621 1.0955 1.0422 0.9924
```

```
sigma: 0.0676
```

AIC	AICc	BIC
-122.90601	-119.20871	-63.17985

Ejemplo: Venta de medicamentos

```
ets(h02, model = "AAA", damped = FALSE)
```

```
ETS(A,A,A)
```

```
Call:
```

```
ets(y = h02, model = "AAA", damped = FALSE)
```

```
Smoothing parameters:
```

```
alpha = 0.1672
```

```
beta = 0.0084
```

```
gamma = 1e-04
```

```
Initial states:
```

```
l = 0.3895
```

```
b = 0.0116
```

```
s = -0.1058 -0.1359 -0.1875 -0.1803 -0.2414 0.2097  
      0.2493 0.1426 0.1411 0.0823 0.0293 -0.0033
```

```
sigma: 0.0642
```

AIC	AICc	BIC
-18.26446	-14.97413	38.14358

La función *ets()*

- Elige automáticamente un modelo por defecto usando el AIC, AICc o BIC.
- Puede manejar cualquier combinación de tendencia, estacionalidad y amortiguación
- Asegura que los parámetros sean admisibles (equivalente a invertir)
- Produce un objeto de clase “ets”.

Los objetos *ets*

- **Métodos:**


coef(), *autoplot()*, *plot()*, *summary()*,
residuals(), *fitted()*, *simulate()* y
forecast()

autoplot(): para graficar la serie temporal, así
como extraer las componentes *S*, *T* y *R*

Ejemplo: Venta de medicamentos


```
h02 %>% ets() %>% autoplot()
```

Components of ETS(M,Ad,M) method



Ejemplo: Venta de medicamentos

```
h02 %>% ets() %>% forecast() %>% autoplot()
```



Ejemplo: Venta de medicamentos

```
h02 %>% ets() %>% accuracy()
```

	ME	RMSE	MAE	MPE
Training set	0.003872706	0.05096923	0.03903608	0.1125149
	MAPE	MASE	ACF1	
Training set	5.046201	0.6439654	0.00612504	

```
h02 %>% ets(model = "AAA", damped = FALSE) %>% accuracy()
```

	ME	RMSE	MAE	MPE
Training set	-0.006446776	0.06159595	0.0494885	-1.25778
	MAPE	MASE	ACF1	
Training set	7.141675	0.8163955	0.2612275	

La función *ets()*

La función *ets()* permite volver a ajustar el modelo al nuevo conjunto de datos.

```
train <- window(h02, end = c(2004, 12)) # datos 'calentamiento'  
test  <- window(h02, start = 2005)    # ajuste con modelo 'train'  
fit1  <- ets(train)  
fit2  <- ets(test, model = fit1)
```

Model is being refit with current smoothing parameters but initial states are being re-estimated.

Set 'use.initial.values=TRUE' if you want to re-use existing initial values.

Valencia Bayesian Research group

La función `ets()`

```
accuracy(fit2)
```

	ME	RMSE	MAE	MPE
Training set	0.001439752	0.0540574	0.04313607	-0.4332393
	MAPE	MASE	ACF1	
Training set	5.217966	0.6785027	-0.4120618	

```
accuracy(forecast(fit1, 10), test)
```

	ME	RMSE	MAE	MPE
Training set	0.003427223	0.04453419	0.03290053	0.158854
Test set	-0.077245307	0.09158286	0.07954666	-10.041291
	MAPE	MASE	ACF1	Theil's U
Training set	4.364239	0.5579938	0.02235938	NA
Test set	10.251511	1.3491135	-0.04360835	0.63331

La función `ets()` en R

```
ets(y, model = "ZZZ", damped = NULL,  
    additive.only = FALSE,  
    lambda = NULL, biasadj = FALSE,  
    lower = c(rep(1e-04, 3), 0.8),  
    upper = c(rep(0.9999, 3), 0.98),  
    opt.crit = c("lik", "amse", "mse", "sigma", "mae"),  
    nmse = 3,  
    bounds = c("both", "usual", "admissible"),  
    ic = c("aicc", "aic", "bic"),  
    restrict = TRUE,  
    allow.multiplicative.trend = FALSE, ...)
```

La función `ets()` en R

y: La serie temporal a predecir.

model: usa la clasificación y notación ETS: “N” para nada, “A” para aditivo y “M” para para multiplicativo, o “Z” para la selección automática. Por defecto `ZZZ` se seleccionan todos los componentes utilizando algún criterio de información

damped: Si `damped=TRUE`, entonces se amortigua la tendencia (puede utilizarse `A\damped\` o `M\damped`).
`damped=FALSE`, entonces no se amortigua la tendencia.
 Si `damped=NULL` (default), Según el mejor criterio de información el sistema elije el mejor método.

La función `ets()` en R

additive.only: Solo se considerarán modelos con componentes aditivos si `additive.only=TRUE`. De lo contrario, todos los modelos serán considerados.

lambda: El parámetro de la transformación de *Box-Cox*. Se ignora si `lambda=NULL` (por defecto). De lo contrario, la serie temporal será transformada antes que el modelo se estime. Cuando `lambda` no es `NULL`, `additive.only` se convierte en ***TRUE***.

biadj: Utiliza un ajuste del sesgo cuando se desahce la transformación de *Box-Cox* para los valores ajustados.

La función `ets()` en R

`lower, upper`: límites para la estimación de los parámetros α , β^* , γ^* and ϕ .

`opt.crit=lik`: (Por defecto) Criterio de optimización utilizado en la estimación de los parámetros. **`bounds`**:

Restricciones en los parámetros. * *habitual* región –

"`bounds=usual`"; * *admissible* región –

"`bounds=admissible`"; * "`bounds=both`" (por defecto) necesita los parámetros para satisfacer ambos conjuntos de restricciones.

`ic=aicc`: (por defecto) Criterio de optimización utilizado en la selección de los modelos.

`restrict=TRUE`: (por defecto) modelos que causan problemas numéricos no serán considerados en la selección del mejor modelo.

`allow.multiplicative.trend`: permite modelos con tendencia multiplicativa.

La función `forecast()` en `textsl{R}`

```
forecast(object,
  h=ifelse(object$m>1, 2*object$m, 10),
  level=c(80,95), fan=FALSE,
  simulate=FALSE, bootstrap=FALSE,
  npaths=5000, PI=TRUE,
  lambda=object$lambda, biasadj=FALSE,...)
```

- *object*: el objeto que devuelve la función `ets()`.
- *h*: el número de periodos a predecir.
- *level*: el intervalo de confianza para la predicción.
- *fan*: if `fan=TRUE`, para obtener los *fan plots*.

La función `forecast()` en `textsf{R}`

- *simulate*: si TRUE, el intervalo de predicción generado vía simulación `prediction intervals generated via simulation` en lugar de las fórmulas analíticas. Incluso si FALSE se usará la simulación si no existen fórmulas algebraicas.
- *bootstrap*: si `bootstrap=TRUE` y `simulate=TRUE`, entonces los intervalos de predicción simulados usarán errores re-muestreados incluso si se distribuyen los errores de forma Gaussiana.
- *npaths*: El número de muestras usadas en la simulación.
- *PI*: Si `PI=TRUE`, entonces los intervalos se calcularán: de otra manera sólo se obtendrán

La función `forecast()` en `textsl{R}`

- ***lambda***: el parámetro de la transformación de The *Box-Cox*. Si `lambda=NULL` se ignorará. De otra manera, las predicciones serán re-trasformadas vía la inversa de la transformación de *Box-Cox*
- ***biasadj***: ¿Se aplica la corrección de sesgo tras la transformación de *Box-Cox*?

Tu turno

- Usa `ets()` en las siguientes series :

bicoal, chicken, dole, usdeaths, bricksq, lynx, ibmclose, eggs, bricksq, ausbeer

- ¿Se obtienen siempre buenas predicciones?
- Encuentra un ejemplo que no funcione bien.
¿Sabrías explicar lo que le ocurre a esa serie temporal?