

Caso de Éxito 1

Xavi Barber

Centro de Investigación Operativa
Universidad Miguel Hernández de Elche

martes, 06 de marzo de 2018



- 1 Suavizado Exponencial
- 2 Medidas del Error en la predicción
- 3 Modelos clásicos con R
- 4 Predicting Jute Yarn Demand

Valencia Bayesian Research group

Suavizado Exponencial

Valencia Bayesian Research group

Simple Moving Average Method (SMA)

Supongamos que deseamos estudiar unos datos que son la Demanda de cierto producto.

- La media móvil simple (SMA) o promedio móvil es la media aritmética de las observaciones del conjunto completo de datos y utiliza la media aritmética como el predictor del período futuro.
- Este método se utiliza para suavizar las desviaciones a corto plazo de los datos de series de tiempo e indicar tendencias o ciclos a largo plazo.
 - La ecuación de SMA es la siguiente:

$$F_t = MA_n = \frac{\sum_{i=1}^n D_i}{n}$$

donde F_t es la predicción para el periodo de tiempo t , y donde D_i es la demanda en el periodo t , y n es el número de periodo en la media móvil.

Single Exponential Smoothing (SES) Method

- Este método “sofisticado” es un tipo de promedio ponderado que estima el valor futuro en función del pronóstico anterior más un porcentaje del error pronosticado.
- Es fácil de implementar y calcular, ya que no es necesario mantener el historial de todos los datos anteriores.
- Se desvanece uniformemente el efecto de datos inusuales.
- La ecuación de SES es la siguiente:

$$F_t = F_{t-1} + \alpha(F_{t-1} - D_{t-1})$$

donde F_t es la predicción para el periodo de tiempo t , F_{t-1} es la predicción para el periodo previo, D_{t-1} es la actual demanda para el periodo previo, y α es la constante de suavizado ($0 \leq \alpha \leq 1$).

Double Exponential Smoothing (Holt's Method)

- El suavizado exponencial doble o el método de Holt (desarrollado por Holt en 1957) se usa para predecir datos con tendencia lineal.
- Es una extensión del suavizado exponencial simple.
- El método de Holt suaviza la tendencia y la pendiente en la serie temporal utilizando dos constantes de suavizado diferentes (α para el nivel y γ para la tendencia).

$$\text{Forest equation } y_{t+h} = l_t + hb_t$$

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

$$\text{Trend equation } b_t = \gamma(l_t - l_{t-1}) + (1 - \gamma)b_{t-1}$$

donde y_{t+h} es la predicción para h periodos futuros, l_t es el nivel estimado en el tiempo t , b_t es la tendencia (pendiente) estimada en el tiempo t , h son periodos a predecir (siempre a futuro), α es la constante de suavizado para el nivel ($0 \leq \alpha \leq 1$), y γ es la constante de suavizado para la tendencia ($0 \leq \gamma \leq 1$).

Winters Method

- Este procedimiento se puede usar cuando tanto la tendencia como la estacionalidad están presentes.
- Se utiliza para suavizar los datos que emplean una componente de nivel, una componente de tendencia y una componente estacional en cada período y proporciona una previsión de corto a medio plazo.
- Hay dos tipos de modelos: **multiplicativo** y **aditivo**.
- El modelo multiplicativo se usa cuando la magnitud del patrón estacional varía con el tamaño de los datos.
- El modelo aditivo es justo lo contrario al modelo multiplicativo.
- Las siguientes ecuaciones son ecuaciones de suavizado del método de Winters.

Las ecuaciones para el modelo multiplicativo son:

$$\text{Forest equation } \hat{y}_t = (L_{t-1} + T_{t-1})S_{t-p},$$

$$\text{Level equation } L_t = \alpha \left(\frac{y_t}{S_{t-p}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1})$$

$$\text{Trend equation } T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1}$$

$$\text{Seasonal equation } S_t = \delta \left(\frac{y_t}{L_t} \right) + (1 - \delta)S_{t-p}$$

donde \hat{y}_t es el valor ajustado o un periodo por encima del pronosticado en el tiempo t , L_t es la estimación del nivel en el tiempo t , T_t es la tendencia, S_t es la estacionalidad, y_t es el dato en el tiempo “t”, p es el periodo de estacionalidad y α , γ y δ son las constante de suavizado, tendencia y estacionalidad respectivamente y donde $0 \leq \alpha, \gamma, \delta \leq 1$.

Las ecuaciones para el modelo aditivo son:

$$\text{Forecast equation } \hat{y}_t = (L_{t-1} + T_{t-1})S_{t-p},$$

$$\text{Level equation } L_t = \alpha(y_t - S_{t-p}) + (1 - \alpha)(L_{t-1} + T_{t-1})$$

$$\text{Trend equation } T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1}$$

$$\text{Seasonal equation } S_t = \delta(y_t - L_t) + (1 - \delta)S_{t-p}$$

donde \hat{y}_t es el valor ajustado o un periodo por encima del pronosticado en el tiempo t , L_t es la estimación del nivel en el tiempo t , T_t es la tendencia, S_t es la estacionalidad, y_t es el dato en el tiempo t , p es el periodo de estacionalidad y α , γ y δ son las constantes de suavizado, tendencia y estacionalidad respectivamente y donde $0 \leq \alpha, \gamma, \delta \leq 1$.

Trend Analysis

- El análisis de la tendencia se ajusta a un modelo general de datos que tengan un patrón y proporciona una idea sobre lo que sucederá en el futuro en función de los datos históricos.
- La tendencia puede ser lineal, cuadrática o curva en S. Una ecuación de tendencia de tipo lineal general tiene la siguiente forma:

$$F_t = a + bt$$

$$b = \frac{n \sum ty - \sum t \sum y}{n \sum t^2 - (\sum t)^2}$$

$$a = \frac{\sum y - b \sum t}{n}$$

donde F_t es la predicción para el periodo t , t se especifica como el nombre de periodos de tiempo, a es el "intercepto" (punto de corte al eje 'x'), b es la pendiente de la línea, n es un número de periodos, y finalmente siendo y el valor de la serie temporal (datos).

¿A qué os suena esto? \Rightarrow Recta de regresión

Medidas del Error en la predicción

Valencia BAYesian Research group

Mean absolute deviation (MAD)

- MAD es la diferencia absoluta media entre el actual valor y el valor que hemos predicho para un periodo dado

$$MAD = \frac{\sum |D_t - F_t|}{n}$$

donde D_t es la actual ## Mean squared error (MSE)

- MSE es el error cuadrático medio

$$MSE = \frac{\sum (D_t - F_t)^2}{n - 1}$$

Mean Absolute Percentage Error (MAPE)

- MAPE es el porcentaje del error absoluto medio

$$MAPE = \frac{\sum |e_t / D_t|}{n} \times 100$$

Valencia Bayesian Research group

Modelos clásicos con R

Valencia Bayesian Research group

Media móvil

ma computes a simple moving average smoother of a given time series. Ejemplo:

```
library(forecast)
plot(wineind)
sm <- ma(wineind, order = 12)
lines(sm, col = "red")
```

Valencia Bayesian Research group




Figure 1

Suavizado Exponencial Simple

ses Returns forecasts and other information for exponential smoothing forecasts applied to *y*.

```
fcast <- ses(airmiles)
plot(fcast)
```

Valencia Bayesian Research group

Forecasts from Simple exponential smoothing




Figure 2

Doble suavizado o método Holt

holt Returns forecasts and other information for exponential smoothing forecasts applied to *y*.

```
fcast <- holt(airmiles)
plot(fcast)
```

Valencia Bayesian Research group

Forecasts from Holt's method




Figure 3


Método tendencia

Pues dependerá del tipo de pendiente que queramos estudiar, pero lo habitual será utilizar un modelo lineal (que no por ello deja de ser un modelo lineal).


Ejemplos de modelos lineales:

```
lm(Y ~ t ,data=serie)
lm(Y ~ t+ t^2, data=serie)
lm (Y ~ log(t), data=serie)
...
```


Pero así puede ser muy difícil captar la tendencia, y la forma.




$$y \sim t + t^2$$



$$y \sim t + t^2 + t^3$$



$y \sim \exp(t)$ 

Si utilizamos los comandos adecuados dentro del paquete *forecast* que son:

```
fit <- tslm(y ~ trend + season)
plot(forecast(fit, h = 20))
```

Valencia Bayesian Research group

Forecasts from Linear regression model




Figure 4

Método Holt-Winters

hw Returns forecasts and other information for exponential smoothing forecasts applied to y .

```
deaths.fcast1 <- hw(USAccDeaths,  
                    seasonal="multiplicative",  
                    h=48)  
plot(deaths.fcast1)
```

Valencia Bayesian Research group

Forecasts from Holt-Winters' multiplicative method




Figure 5

```
deaths.fcast2 <- hw(USAccDeaths,  
                    seasonal="additive",  
                    h=48)  
  
plot(deaths.fcast2)
```

Valencia Bayesian Research group

Forecasts from Holt-Winters' additive method




Figure 6

Calculando los errores de predicción

MAD, MSE y MAPE

accuracy: Returns range of summary measures of the forecast accuracy. The measures calculated are:

- **ME: Mean Error**
- **RMSE: Root Mean Squared Error**
- MAE: Mean Absolute Error
- MPE: Mean Percentage Error
- **MAPE: Mean Absolute Percentage Error**
- MASE: Mean Absolute Scaled Error
- ACF1: Autocorrelation of errors at lag 1.

Valencia Bayesian Research group


```
library(forecast)
fit1 <- ses(EuStockMarkets[1:200, 1], h = 100)
accuracy(fit1)
## si conocemos los datos reales para comparar
accuracy(fit1, EuStockMarkets[201:300, 1])
```

Valencia Bayesian Research group

Table 1: Incorporando la información real

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	0.4438718	15.80579	8.913465	0.0215229	0.5505189	0.9948454	0.0017072

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	0.4438718	15.80579	8.913465	0.0215229	0.5505189	0.9948454	0.0017072
Test set	0.8061599	78.18019	63.272633	-0.1725265	3.7876695	7.0619551	NA

```
fit2 <- holt(EuStockMarkets[1:200, 1], h = 100)
accuracy(fit2)
## si conocemos los datos reales
accuracy(fit2, EuStockMarkets[201:300, 1])
```

Valencia Bayesian Research group


	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	0.0223505	15.815	8.975217	-0.0043653	0.5544369	1.001738	0.0058492

```
##
## Training set 0.02235053 15.81500 8.975216 -0.00436527 0.5544369
## Test set -23.08052081 90.85252 62.531656 -1.59262812 3.8138285
## MASE ACF1
## Training set 1.001738 0.005849176
## Test set 6.979253 NA
```

Valencia Bayesian Research group

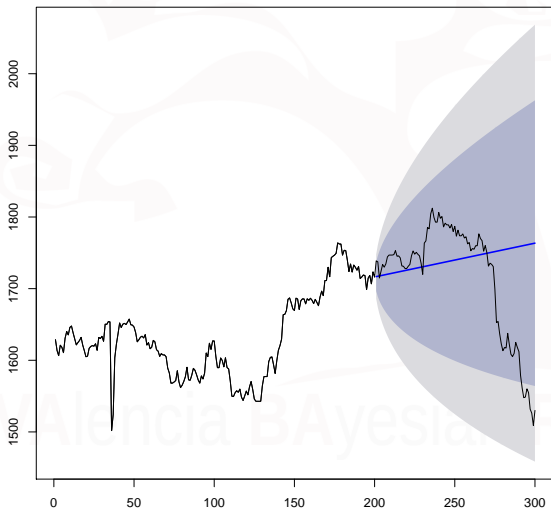
```
plot(fit1)  
lines(EuStockMarkets[1:300, 1]) #datos reales
```

Forecasts from Simple exponential smoothing



```
plot(fit2)  
lines(EuStockMarkets[1:300, 1]) #datos reales
```

Forecasts from Holt's method



Predicting Jute Yarn Demand

Valencia Bayesian Research group

A Study of Time Series Model for Predicting Jute Yarn Demand: Case Study

Journal of Industrial Engineering Volume 2017 (2017), Article ID 2061260, 8 pages
<https://doi.org/10.1155/2017/2061260>

A Study of Time Series Model for Predicting Jute Yarn Demand: Case Study

C. L. Karmaker, P. K. Halder, and E. Sarker

Valencia Bayesian Research group

Enunciado

- En el entorno competitivo actual, predecir las ventas para los próximos períodos en la cantidad correcta es muy crucial para garantizar la disponibilidad del producto y mejorar la satisfacción del cliente.
- Desarrollar un modelo para identificar el método más apropiado para la predicción basado en los valores mínimos de los errores de predicción.
- Los datos necesarios sobre ventas de hilo de yute se obtuvieron de una industria fabricante de productos de yute en Bangladesh, a saber, Akij Jute Mills, Akij Group Ltd., en Noapara, Jessore.

Meterial y métodos

- El objetivo principal de este estudio es determinar la mejor técnica de predicción apropiada para la próxima venta de hilo de yute para la industria de fabricación de productos de yute en Bangladesh.

El método de predicción se seleccionará sobre la base de errores de previsión, es decir, valores mínimos de MAPE, MAD, y MSD.

- Para esta predicción , se han realizado diferentes análisis de series temporales con la demanda demanda de 208 semanas y se han calculdon las medidas de precisión:
 - Media móvil
 - Suavizado exponencial simple
 - Suavizado doble o método de Holt
 - Estudio de la tendencia.
 - Método de Winters
 - Aditiva
 - Multiplicativa

La demanda

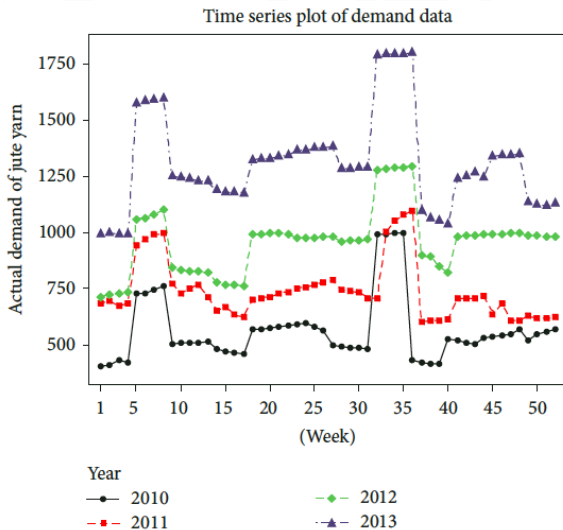


Figure 8

Media móvil

TABLE 1: Forecasting errors under SMA method.

Length of average in weeks (n)	MAPE	MAD	MSD
2MA	8.3	70.5	19431.2
3MA	10.8	91.4	24473.3
4MA	13.2	112.1	29783.9
5MA	14.1	121.9	32376.7
6MA	14.7	127.5	33504.7
7MA	15	131.1	33920.3
8MA	15.1	133.2	33976.4
9MA	15.3	135	33949.8
10MA	15.1	134.7	33797.7
11MA	15	133.5	33577.2
12MA	14.7	131.4	33334.6
13MA	14.4	129.6	33163.5
14MA	14.2	128.9	33243.4
15MA	14.3	129.8	33645.2

Figure 9

Media móvil

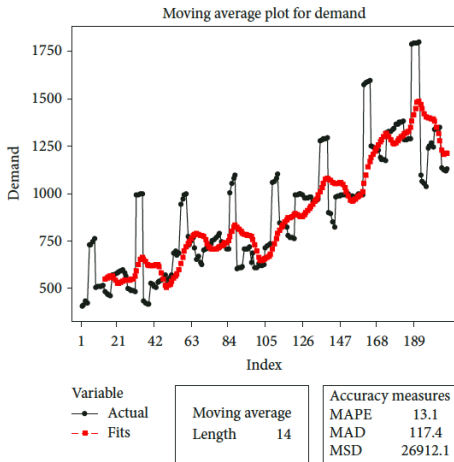


FIGURE 2: Comparison of actual sales with forecasted demand in SMA method.

Figure 10

Suavizado exponencial

TABLE 2: Forecasting errors under SES method.

Value of smoothing constant (α)	MAPE	MAD	MSD
0.1	13.1	116.8	29939.5
0.2	12.6	109.1	26144.4
0.3	11.8	101.1	23576.3
0.4	10.8	92.2	21390.4
0.5	9.8	82.7	19528.3
0.6	8.7	73.6	18003.7
0.7	7.8	65.7	16822.2
0.8	7.1	59.1	15977.1
0.9	6.5	53.6	15457

Figure 11

Suavizado exponencial

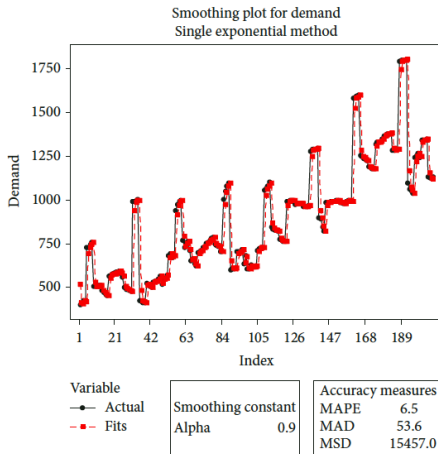


FIGURE 3: Comparison of actual sales with forecasted demand in SES method.

Figure 12

Caso de Éxito 1

Suavizado doble exponencial o Método Hold

TABLE 3: Forecasting errors under Holt's method.

Smoothing constant alpha (Level)	Smoothing constant gamma (Trend)	MAPE	MAD	MSD
0.1	0.1	15	128	32880.4
0.1	0.2	15.9	136.7	36354.1
0.1	0.3	18	152.1	42391.8
0.2	0.1	14.2	119.8	29969.1
0.2	0.2	16.3	135.5	34575.1
0.2	0.3	17.8	147	38415.1
0.3	0.1	13.2	110.6	27050.4
0.3	0.2	14.5	120.4	30592.1
0.3	0.3	15.1	125.9	33875.7

Figure 13

Suavizado doble exponencial o Método Hold




FIGURE 4: Comparison of actual sales with forecasted demand in Holt's method.

Figure 14

Método sólo tendencia

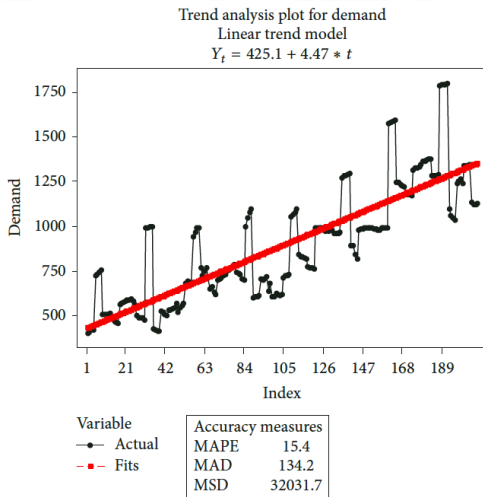


FIGURE 5: Linear trend line analysis of demand.

Figure 15

Método Winter

TABLE 4: Forecasting errors under Winters method.

Smoothing constant alpha (level)	Smoothing constant gamma (trend)	Smoothing constant delta (seasonal)	Winters additive model			Winters multiplicative model		
			MAPE	MAD	MSD	MAPE	MAD	MSD
0.1	0.1	0.1	6.08	48.51	5030.6	7.16	61.75	7560.57
0.1	0.1	0.2	6.21	49.99	5414.65	7.42	64.46	8376.62
0.1	0.1	0.3	6.36	51.73	5807.84	7.66	66.66	9235.14
0.1	0.2	0.1	6.21	49.55	5204.78	7.44	63.17	7537.56
0.1	0.2	0.2	6.38	51.38	5608.68	7.84	68.07	8643.47
0.1	0.2	0.3	6.57	53.43	6012.93	8.26	72.77	9873.75
0.1	0.3	0.1	6.48	51.77	5537.25	7.67	63.24	7413.21
0.1	0.3	0.2	6.61	53.44	5991.33	8.2	69.22	8616.98
0.1	0.3	0.3	6.79	55.46	6442.68	9	77.5	10167.7
0.2	0.1	0.1	5.35	43.04	4779.84	5.89	48.51	5563.59
0.2	0.1	0.2	5.45	44.28	5124.34	6.13	51.3	6212.32
0.2	0.1	0.3	5.56	45.63	5473.25	6.38	54.18	6908.63
0.2	0.2	0.1	5.59	45.14	5166.55	6.37	51.91	5863.92
0.2	0.2	0.2	5.68	46.48	5571.86	6.64	55.02	6609.84
0.2	0.2	0.3	5.83	48.21	5994.81	6.96	58.51	7481.55
0.2	0.3	0.1	5.93	48.24	5643.04	6.68	54.74	6380.57
0.2	0.3	0.2	6.07	50.14	6130.07	7.04	58.76	7246.09
0.2	0.3	0.3	6.28	52.5	6660.18	7.42	62.88	8305.83
0.3	0.1	0.1	5.06	40.58	4705.68	5.38	43.92	5089.33
0.3	0.1	0.2	5.11	41.38	5003.92	5.55	45.84	5624.94
0.3	0.1	0.3	5.19	42.43	5309.95	5.74	47.84	6204.97
0.3	0.2	0.1	5.39	43.47	5153.21	5.65	46.38	5550.05
0.3	0.2	0.2	5.47	44.51	5493.52	5.88	48.8	6141.81
0.3	0.2	0.3	5.56	45.74	5852.34	6.11	51.21	6803.38
0.3	0.3	0.1	5.7	46.13	5652.62	5.73	47.36	6066.61
0.3	0.3	0.2	5.78	47.21	6033.21	5.98	49.94	6723.87
0.3	0.3	0.3	5.89	48.56	6446.37	6.25	52.75	7472.54

Figure 16

Método Winter

TABLE 5: Summary of decomposition methods.

Measure	Decomposition			
	Multiplicative		Additive	
	Trend and seasonality	Only seasonality	Trend and seasonality	Only seasonal
MAPE	8.35	31.8	8.16	31.8
MAD	67.66	252.6	65.93	252.4
MSD	7573.78	86107.7	7467.41	86446

TABLE 6: Summary of all forecasting methods and error calculations.

Forecasting method	MAPE	MAD	MSD
Multiplicative decomposition model with trend and seasonality	8.35	67.66	7573.78
Additive decomposition model with trend and seasonality	8.16	65.93	7467.41
Moving average	14.2	128.9	33243.4
Single exponential smoothing	6.5	53.6	15457
Holt's method	13.2	110.6	27050.4
Trend analysis	15.39	134.16	32031.66
Winters multiplicative model	5.38	43.92	5089.33
Winters additive model	5.06	40.58	4705.68

Figure 17

Método Winter

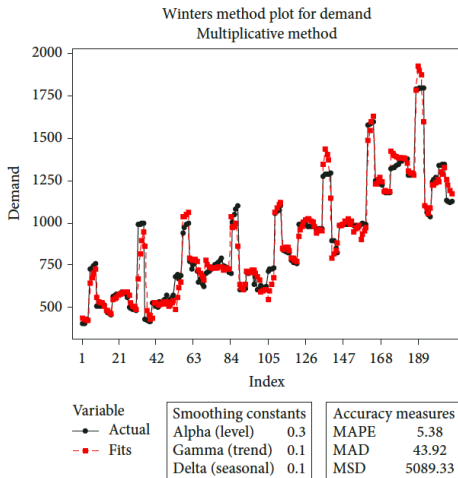


FIGURE 7: Comparison of actual sales with forecasted demand in Winters multiplicative method.

Figure 18

Conclusion

- Se han realizado diferentes métodos de predicción (ajustes de modelos) y tras su ajuste, los resultados muestran que cuando hacemos el método Holt-Winters con estacionalidad Aditiva se obtienen los mejores resultados, es decir los valores más pequeños para el *accuracy*.

Conclusiones reales del artículo:

- *This study can help the industry as well as others Bangladeshi manufacturers to reduce the deviation between actual and forecasted demand through the selection of the contingent forecasting method.*