

Econometría II



Performance

Carlos A. Yanes Guerra

2024-I

Performance de Pronosticos

Modelos de series y testeo

- Las **series** de tiempo deben aparte de cumplir con una serie de supuestos (sobre todo de consistencia de estimadores). Sus **predicciones** también deben ser sometidas a ciertas reglas y **test** con el objeto de ser muy técnicos con esto.

La parte residual

✈ Los errores son contemplados como:

$$\epsilon_t = y_t - \hat{y}_{t+1}$$

Performance de Pronosticos

Mean Absolute Error (MAE)

La media del valor absoluto del error se contempla como:

$$\text{MAE} = \left| \frac{\sum \epsilon_t}{n} \right|$$

Cuando se comparan métodos de **pronósticos** aplicados a una sola serie temporal, o a varias series temporales con las mismas unidades, el indicador de MAE es popular porque es fácil de entender y de calcular. Un método de **pronósticos** que minimice el MAE conducirá a previsiones de la mediana de la serie.

Performance de Pronosticos

Root Mean Square Error (RMSE)

La raíz del error cuadrático medio se establece como:

$$\text{RMSE} = \sqrt{\frac{\sum \epsilon_t^2}{n}}$$

Tiende a ser un poco más compleja la interpretación. Sin embargo cuando se tienen varios niveles de pronóstico lo mejor es tener el menor de todos ellos. El **principio** de minimización del error sigue permanente en estas estimaciones.

Performance de Pronosticos

Mean Absolute Percentage Error

Esta dado por el error porcentual esto es $p_t = 100 \times \frac{\epsilon_t}{y_t}$ y su medida singular se da por:

$$\text{MAPE} = \frac{\sum |p_t|}{n}$$

Tiene algunas desventajas sobre todo cuando $y_t = 0$, o inclusive en un caso particular va a ser infinito o tener valores de la serie muy cerca de cero. Por eso se hace una corrección propuesta por Armstrong (1978) y se establece

$$sMAPE = \text{promedio} \left[\frac{200 \times |y_t - \hat{y}_t|}{(y_t + \hat{y}_t)} \right]$$

Aunque tambien tiene sus desventajas. Se vuelve útil en algunas ocasiones.

Performance de Pronosticos

Scaled Errors

Es alternativo al test de sMAPE fue propuesto por Hyndman y Koehler (2006). Intenta comparar la precisión del pronóstico incluso en series que tienen distintas unidades. Para series no estacionales se propone:

$$q_j = \frac{\epsilon_j}{\frac{1}{T-1} \sum |y_t - y_{t-1}|}$$

De tal manera que si desea mirar la parte estacional es simplemente:


$$q_j = \frac{\epsilon_j}{\frac{1}{T-m} \sum_{t=m+1} |y_t - y_{t-m}|}$$

Finalmente, el test queda como:

$$MASE = \text{Promedio} (|q_j|)$$

Performance de Pronosticos

Producción trimestral de cervezas en Australia



Performance de Pronosticos

Performance de modelos

```
#>           ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
#> Training set  0.000 43.62858 35.23438 -0.9365102 7.886776 2.463942 -0.10915105
#> Test set     -13.775 38.44724 34.82500 -3.9698659 8.283390 2.435315 -0.06905715
#>           Theil's U
#> Training set      NA
#> Test set         0.801254
```

```
#>           ME      RMSE      MAE      MPE      MAPE      MASE
#> Training set  0.4761905 65.31511 54.73016 -0.9162496 12.16415 3.827284
#> Test set     -51.4000000 62.69290 57.40000 -12.9549160 14.18442 4.013986
#>           ACF1 Theil's U
#> Training set -0.24098292      NA
#> Test set     -0.06905715  1.254009
```

```
#>           ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
#> Training set -2.133333 16.78193 14.3 -0.5537713 3.313685 1.0000000 -0.2876333
#> Test set      5.200000 14.31084 13.4  1.1475536 3.168503 0.9370629  0.1318407
#>           Theil's U
#> Training set      NA
#> Test set         0.298728
```

Performance de Pronosticos## Performance de modelos

```
beer3 <- window(ausbeer, start=2008)
accuracy(beerfit1, beer3) # Modelo Promedio
accuracy(beerfit2, beer3) # Naive
accuracy(beerfit3, beer3) # Naive Estacional
```

La función **accuracy** nos muestra el resumen de cada uno de los modelos utilizando los criterios anteriores.

Performance de Pronosticos

Coeficiente de Theil

Así como es funcional para desigualdad, también lo es para métodos de pronósticos. Queremos que si la serie original se comporta de cierta manera, la serie predicha también haga lo mismo. Su estipulación va con raíces de medias.

$$\text{Coeficiente Theil} = \frac{\sqrt{\text{promedio } \epsilon_t^2}}{\sqrt{\text{promedio } y_t} + \sqrt{\text{promedio } \hat{y}_t}}$$

Como en desigualdad, si Theil se hace (1) es lo peor en distribución. Queremos que nuestro modelo de estimación sea cercano a (0) para tener un muy buen **ajuste**.

Modelos univariados autoregresivos

Modelos univariados

Redefiniendo lo del operador **Rezago** o "Lag" es representado por la letra (L).

$$Ly_t = y_{t-1}$$

$$L^n y_t = y_{t-n}$$

$$L^2 y_t = y_{t-2}$$

$$L^{-1}(Ly_t) = Ly_{t-1} = y_t$$

$$Lc = c$$

$$L^0 y_t = y_t$$

$$L^k L^j = L^{k+j}$$

¿Cómo sería un modelo de $y_t = \phi y_{t-1} + \epsilon_t$, expresado en términos de rezago?

R./

$$y_t = \phi Ly_t + \epsilon_t$$

Ahora uno como $y_t = \phi y_{t-1} + \phi y_{t-7} + \epsilon_t$

R./

$$y_t = \phi_1 Ly_t + \phi_7 L^7 y_t + \epsilon_t$$

Modelos univariados

Operador rezago en AR(1)

$$y_t = \phi y_{t-1} + \epsilon_t$$

$$y_t - \phi y_{t-1} = \epsilon_t$$

$$y_t - \phi L y_t = \epsilon_t$$

esto nos da que:

$$\boxed{y_t - \phi L y_t = \epsilon_t}$$

Recuerde por un momento la formula de Taylor

$$1 + \rho + \rho^2 + \rho^3 + \dots = \sum_{i=1}^{\infty} \rho^i = \frac{1}{1 - \rho}$$

Modelos univariados

Regresando al caso

$$y_t - \phi L y_t = \epsilon_t$$
$$y_t = \frac{1}{1 - \phi L} \epsilon_t$$

Acá tenemos un par de condiciones y son:

Si $|\phi| < 1$, entonces $(1 - \phi L)^{-1}$ existe por eso de:

$$(1 - \phi L)^{-1} = \frac{1}{(1 - \phi L)} = 1 + \phi L + \phi^2 L^2 + \phi^3 L^3 = \sum_{i=1}^{\infty} \phi^i L^i$$

$$y_t - \phi L y_t = \epsilon_t$$

$$y_t(1 - \phi L) = \epsilon_t$$

$$y_t = (1 - \phi L)^{-1} \epsilon_t$$

$$y_t = (1 + \phi L + \phi^2 L^2 + \phi^3 L^3 + \dots) \epsilon_t$$


$$y_t = \epsilon_t + \phi \epsilon_{t-1} + \phi^2 \epsilon_{t-2} + \phi^3 \epsilon_{t-3} + \dots$$

Modelos univariados

Ruido blanco

Un proceso **estocástico** (lo mas independiente) se considera aleatorio, posee una característica o estructura no discernible, su proceso cambia a través del tiempo. Ejemplo: El Baloto electrónico.

Ruido Blanco



Modelos univariados

Ruido blanco

$Y_t = \epsilon_t, t = 1, 2, 3 \dots T$, es ruido blanco si y solo si:


- Media cero: $E(Y_t) = 0 \forall t$.
- Varianza constante: $Var(Y_t) = \sigma^2$ y este es $< \infty$.
- Covarianza cero: $Cov(Y_i, Y_j) = 0 \forall i \neq j$.

Cuando hace lanzamientos con un dado. La media es de 3.5 (21/6), La probabilidad de que salga un valor es de 1/6 y el evento (i) que ocurre al lanzarlo es independiente de (j), es decir, el nuevo lanzamiento no depende del anterior ni tampoco de su futuro.

Con respecto a Máxima verosimilitud

Máxima verosimilitud

El método de máxima verosimilitud (Maximum Likelihood Estimation) es un enfoque estadístico utilizado para estimar los **parámetros** de un modelo probabilístico a partir de un conjunto de observaciones o datos. El objetivo del método es encontrar los valores de los parámetros que maximizan la probabilidad de observar los datos que tenemos, asumiendo que los datos siguen una cierta distribución de probabilidad.



Máxima verosimilitud

Se debe empezar desde la composición de un vector de característica aleatoria y con una distribución que depende de un parámetro desconocido como (Θ) , por tanto se tiene que $\mathbf{X} \in \{x_1, x_2, x_3, \dots, x_n\}$. Por tanto la función de verosimilitud de este vector vendrá a ser dada como:

$$L(\Theta) = (f_{x_1}, f_{x_2}, f_{x_3}, \dots, f_{x_n})(x_1, x_2, x_3, \dots, x_n | \Theta)$$

Cuando las variables sean independientes (explicativas) entonces se procede a establecer la función de verosimilitud como:

$$L(\Theta) = f_{x_1}(x_1; \Theta), f_{x_2}(x_2; \Theta), f_{x_3}(x_3; \Theta) \dots, f_{x_n}(x_n; \Theta)$$

Si dado el caso, estas variables resultan ser idénticamente distribuidas, entonces se tendrá:

$$L(\Theta) = f(x_1; \Theta), f(x_2; \Theta), f(x_3; \Theta) \dots, f(x_n; \Theta)$$

Que sería el caso de una **muestra aleatoria**.

Máxima verosimilitud

Entonces, para obtener el valor de (Θ) que maximiza a la función de verosimilitud se debe establecer la estimación de $L(\Theta)$ o estimador verosímil. La razón principal de calculo, debe ser encontrar un valor numérico observable $(x_1, x_2, x_3, \dots, x_n)$, de la muestra aleatoria tenga probabilidad máxima.

Sea una muestra aleatoria (m.a), con valores $X_1, \dots, X_n \sim f(X|\theta)$, se debe encontrar el estimador $\theta = ?$ que **maximiza** la función.

- **Primer paso:** es plantear la función de máxima verosimilitud:

$$L(\theta|x) = \prod_{i=1}^n f(x_i|\theta)$$

- **Segundo paso:** es tratar de encontrar la referencia del estimador que es:

$$L(\theta_1|x) > L(\theta_2|x)$$

Si lo anterior ocurre $\Rightarrow \theta_1 = \theta$ y será mas **verosímil** que $\theta_2 = \theta$

- **Tercer paso:** es escoger ese mejor estimador (mas creíble), es decir, $\hat{\theta} \in \Theta$.

Máxima verosimilitud

Entender lo anterior no es tan trivial, se hace necesario conocer que la estimación máxima verosimilitud (E.M.V) este en función de los valores provistos:

$$\hat{\theta} = E.M.V(\theta|X_1, \dots, X_n) = f(X_1, \dots, X_n)$$

Lo que en mejores términos vendría a ser:

$$L = \left(\hat{\theta} | X_1, \dots, X_n \right) = \max_{\{\theta \in \Theta\}} L(\theta | X_1, \dots, X_n)$$

Veamos un ejemplo 🧐

Ejemplo: Máxima Verosimilitud

Sea la siguiente función definida como:

$$f(x, \theta) = \frac{1}{\theta} e^{-\frac{x}{\theta}} ; x > 0 ; \theta > 0$$

Halle el estimador θ

Debemos plantear la **función de densidad** de cada una de las variables de una m.a y esto es: Tenemos que las variables son (x_1, \dots, x_n) y la función de cada una de ellas vendrá a ser:

$$f(x_1, \theta) = \frac{1}{\theta} e^{-\frac{x_1}{\theta}} ; f(x_2, \theta) = \frac{1}{\theta} e^{-\frac{x_2}{\theta}} ; f(x_n, \theta) = \frac{1}{\theta} e^{-\frac{x_n}{\theta}}$$

La idea es resolver el **producto** o multiplicación de las funciones usando la formula del **logaritmo de verosimilitud** y esto resulta:

$$L(\hat{\theta} | X_1, \dots, X_n) = \frac{1}{\theta} e^{-\frac{x_1}{\theta}} * \frac{1}{\theta} e^{-\frac{x_2}{\theta}} * \dots * \frac{1}{\theta} e^{-\frac{x_n}{\theta}}$$

Ejemplo: Máxima Verosimilitud

Para lo cual, simplificamos la expresión (lo mas que se pueda\footnote{Acá es útil utilizar todas las herramientas de calculo básico y álgebra.})

$$L(\hat{\theta} | X_1, \dots, X_n) = \frac{1}{\theta^n} e^{\left\{ \frac{-x_1}{\theta} + \frac{-x_2}{\theta} + \dots + \frac{-x_n}{\theta} \right\}}$$

Obteniendo de forma mas simple:

$$L(\hat{\theta} | X_1, \dots, X_n) = \frac{1}{\theta^n} e^{-\frac{1}{\theta} \{x_1 + x_2 + \dots + x_n\}}$$

Que haciendo mas simple la ecuación puede ser reemplazada usando el termino de la sumatoria:

$$L(\hat{\theta} | X_1, \dots, X_n) = \frac{1}{\theta^n} e^{-\frac{1}{\theta} \sum x_i}$$

El siguiente proceso será derivar.

Ejemplo: Máxima Verosimilitud

Toda la expresión que ha quedado simplificada y de ahí aplicar el despeje como tal, resultando:

Estableciendo la condición de primer orden:

$$\frac{\partial L(x_1, \dots, x_n, \theta)}{\partial \theta} = 0$$

Tomar la expresión tal cual se encuentra situada seria algo complejo. Una forma de linearizar es aplicando logaritmos a la expresión de M.V y de ahí si derivar.

$$\ln L = \ln \left(\frac{1}{\theta^n} \right) + L n e^{-\frac{1}{\theta} \sum x_i}$$

Se aplican todas las propiedades de Logaritmo.

$$\ln L = \ln(1) - n \ln \theta - \frac{1}{\theta} \sum x_i \ln(e)$$

Ejemplo: Máxima Verosimilitud

Conocemos que el logaritmo de (1) es cero y que el Ln de (e) es 1, por ende ahora nos encontramos con:

$$\ln L = -n \ln \theta - \frac{1}{\theta} \sum x_i$$

Derivando la expresión con respecto a $\theta \Rightarrow$

$$\frac{\partial \ln L}{\partial \theta} = -\frac{n}{\theta} + \frac{\sum x_i}{\theta^2} = 0$$

Despejando θ :

$$\frac{\sum x_i}{\theta^2} = \frac{n}{\theta}$$

Dando como resultado:

$$\theta = \frac{\sum x_i}{n}$$

Para este caso el estimador $\theta = \bar{X}$.

Bibliografía

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

¡Gracias!

Del contorno de series

Seguimos aprendiendo



 Syllabus/ Curso

 @keynes37

 cayanes@uninorte.edu.co