




# Pasajeros de avión

# Datos

- ▶ Datos mensuales de enero de 1949 a diciembre de 1960



# Observaciones

- ▶ No es estacionaria
- ▶ Tiene una tendencia creciente
- ▶ Tiene un componente estacional
- ▶ Varianza crece (efecto multiplicativo)

# Descomposición clásica

- ▶ El modelo se puede expresar como


$$X_t = m_t + s_t + Y_t$$

donde

- $m_t$  - es el componente de tendencia
  - $s_t$  - es el componente estacional
  - $Y_t$  - es un componente de ruido aleatorio estacionario
- ▶ No necesariamente aparecerán los dos componentes
  - ▶ El objetivo es estimar  $m_t$  y  $s_t$  (no se consideran aleatorios)

# Datos

- ▶ Tendencia creciente y ciclos anuales



# Estimación de $m_t$ sin componente estacional

# Método 1: Suavizamientos

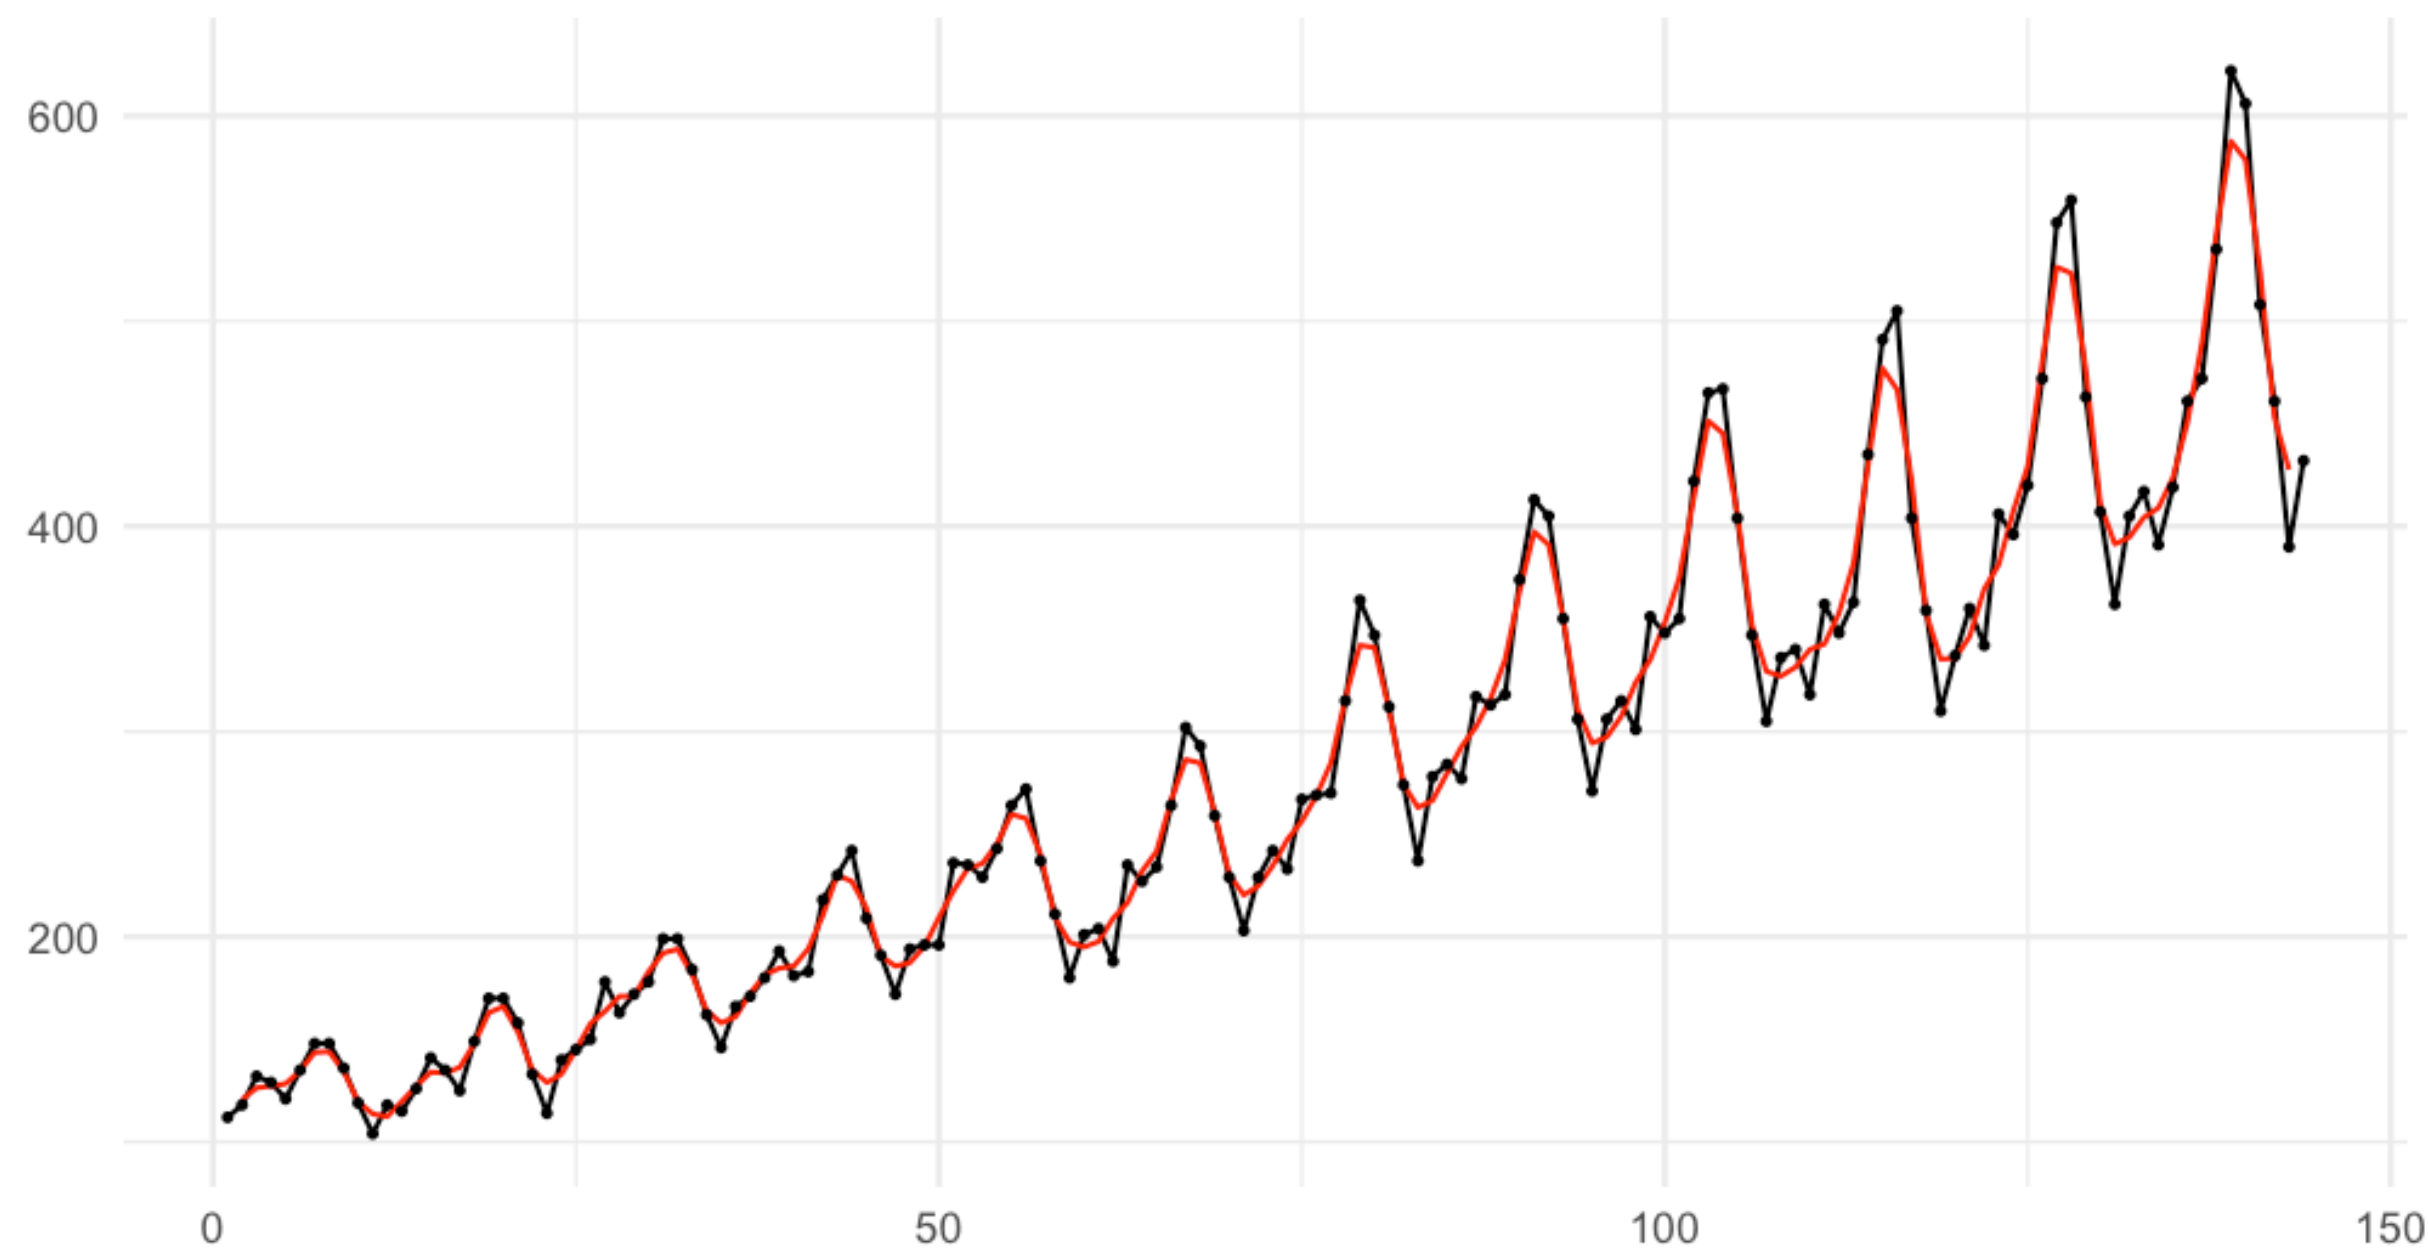
Suavizamiento mediante promedios móviles

$$\widehat{m}_t = (2q + 1)^{-1} \sum_{j=-q}^q X_{t-j}, \quad q + 1 \leq t \leq n - q$$


- ▶ Asumiendo observaciones  $X_1, \dots, X_n$ , no se puede calcular para  $t \leq q$  ni para  $t \geq n - q$
- ▶ Bajo ciertas condiciones puede remover la variación estacional

# Promedio móvil $q = 1$

Valores ajustados




Residuales




- ▶ Sigue sin ser estacionario

# Promedio móvil $q = 6$

Valores ajustados



Residuales



- ▶ Sigue sin ser estacionario

# Método 1: Suavizamientos

Suavizamiento exponencial para  $\alpha \in [0,1]$

$$\widehat{m}_t = \alpha X_t + (1 - \alpha) \widehat{m}_{t-1}, \quad t = 2, \dots, n$$

$$\widehat{m}_1 = X_1$$


- ▶ Equivalentemente para  $t \geq 2$

$$\widehat{m}_t = \sum_{j=0}^{t-2} \alpha(1 - \alpha)^j X_{t-j} + (1 - \alpha)^{t-1} X_1$$


- ▶ Versiones más generales para eliminar tendencia, estacionalidad, modelos aditivos y multiplicativos (en R: paquetería **forecast** y la función es **ets**)
- ▶ Eficiente para hacer predicciones a corto plazo pero no siempre es adecuado

# Suavizamiento exponencial

Valores ajustados



Residuales



- ▶ Ya parece ser un ruido blanco

# Método 2: Operador de diferencias

Diferencia de lag 1

$$\nabla X_t = X_t - X_{t-1} = (1 - B)X_t$$

donde  $BX_t = X_{t-1}$

▶ Álgebra de  $\nabla$  y  $B$


- $B^j X_t = X_{t-j}$
- $\nabla^j X_t = \nabla(\nabla^{j-1} X_t)$  con  $\nabla^0 X_t = X_t$

▶ Por ejemplo:

$$\nabla^2 X_t = (1 - B)(1 - B)X_t = X_t - 2BX_t + B^2 X_t = X_t - 2X_{t-1} + X_{t-2}$$


# Diferencia de lag 1

- ▶ No parece ser estacionario



# Diferencias mejoradas

- ▶ Se puede mejorar estabilizando la varianza con logaritmo y combinando operadores



Estimación de  $m_t$  con  
componente estacional  $s_t$

# Método 1: Suavizamientos

- ▶ Método 'clásico' (función **decompose** en R)
  1. Estimar  $m_t$  con un filtro de promedios móviles
  2. Construir serie sin tendencia,  $d_t = X_t - m_t$
  3. Estimar la estacionalidad de  $d_t$  promediando por año en cada punto estacional
  4. Construir la serie  $y_t = x_t - \hat{m}_t - \hat{s}_t$
- ▶ Brockwell y Davis (no hay función en R que lo haga)
  1. Estimar  $s_t$  mediante los promedios por punto estacional
  2. Construir serie sin estacionalidad,  $d_t = X_t - s_t$
  3. Estimar la tendencia de  $d_t$
  4. Construir la serie  $y_t = x_t - \hat{m}_t - \hat{s}_t$

# Método 1: Suavizamientos

Opciones más avanzadas y modernas

- ▶ Suavizamiento exponencial mediante modelos de espacio de estados
  - Función **ets** de R
  - Hyndman (2008). Forecasting with exponential smoothing: The state space approach.
- ▶ Suavizamiento Loess (Locally Estimated Scatterplot Smoothing)
  - Función **stl** de R
  - Cleveland et al. (1990). STL: A Seasonal-Trend Decomposition Procedure Based on Loess.

# Método 2: Operador diferencias


- ▶ Para remover estacionalidad utilizar el operado:

$$\nabla_d X_t = (1 - B^d)X_t = X_t - X_{t-d} = m_t - m_{t-d} + Y_t - Y_{t-d}$$

- ▶ Eliminar el nuevo componente de tendencia  $m_t - m_{t-d}$  con algún operador  $\nabla^k$

# Diferencias mejoradas


- ▶ Aplicar logaritmo a la serie y utilizar  $\nabla_{12}$  para el componente estacional y  $\nabla$  para el componente de tendencia




# Análisis de residuales

# ACF

- ▶ Para  $n$  suficientemente grande las autocorrelaciones muestrales  $\hat{\rho}(j)$  de los residuales deben ser  $\mathcal{N}(0, n^{-1})$
- ▶ Graficar el acf y checar que no haya muchos valores fuera de las bandas ( $\pm 1.96/\sqrt{n}$ ) o un valor extremadamente grande



Suavizamiento exponencial



Operador diferencias

# Prueba de Portmanteau

- ▶ Para  $n$  suficientemente grande las autocorrelaciones muestrales  $\hat{\rho}(j)$  de los residuales deben ser  $\mathcal{N}(0, n^{-1})$

- ▶ Bajo la hipótesis nula

$$Q = n \sum_{j=1}^h \hat{\rho}(j)^2 \sim \chi_h^2$$

- ▶ Rechazamos para valores grandes de  $Q$
- ▶ No es muy utilizada en la práctica

# Prueba de Ljung-Box

- ▶ Modificación de la prueba de Portmanteau, donde bajo la hipótesis nula

$$Q_{LB} = n(n + 2) \sum_{j=1}^h \frac{\hat{\rho}(j)^2}{n - j} \sim \chi_h^2$$

- ▶ Rechazamos para valores grandes de  $Q_{LB}$


<b>Residuales</b>	$Q_{LB}$	<b>p-valor</b>
Suavizamiento Exponencial	0.34999	0.5541
Operador Diferencias	15.596	7.843E-05

- ▶ Los residuales del suavizamiento ya son ruido estacionario pero los del operador de diferencias no

# Modelos ARMA

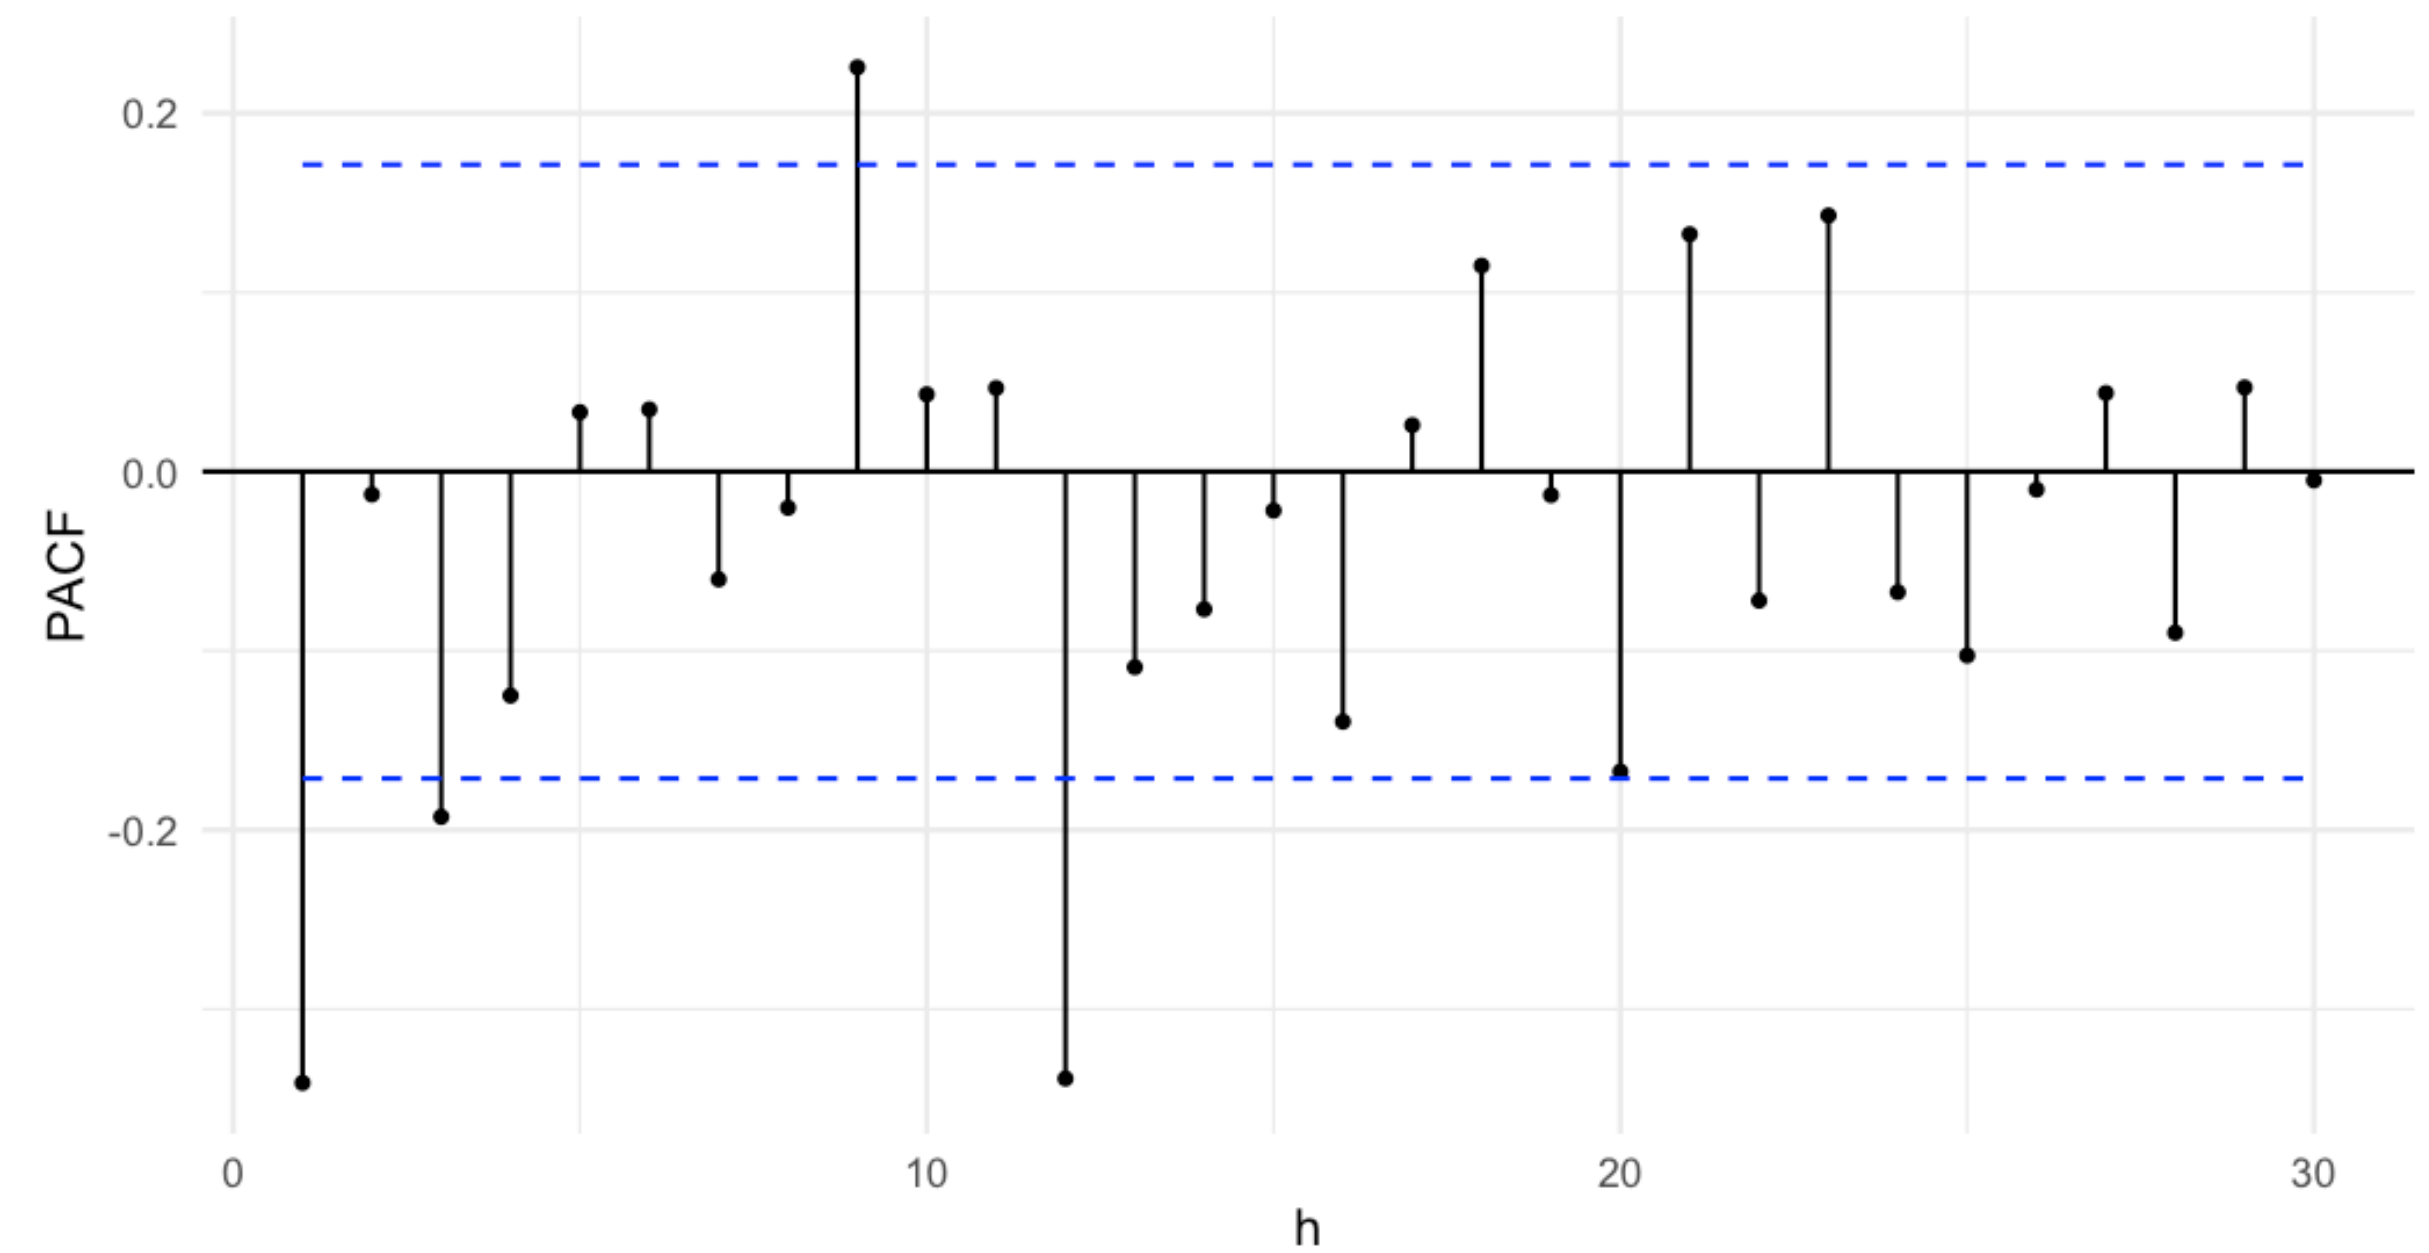
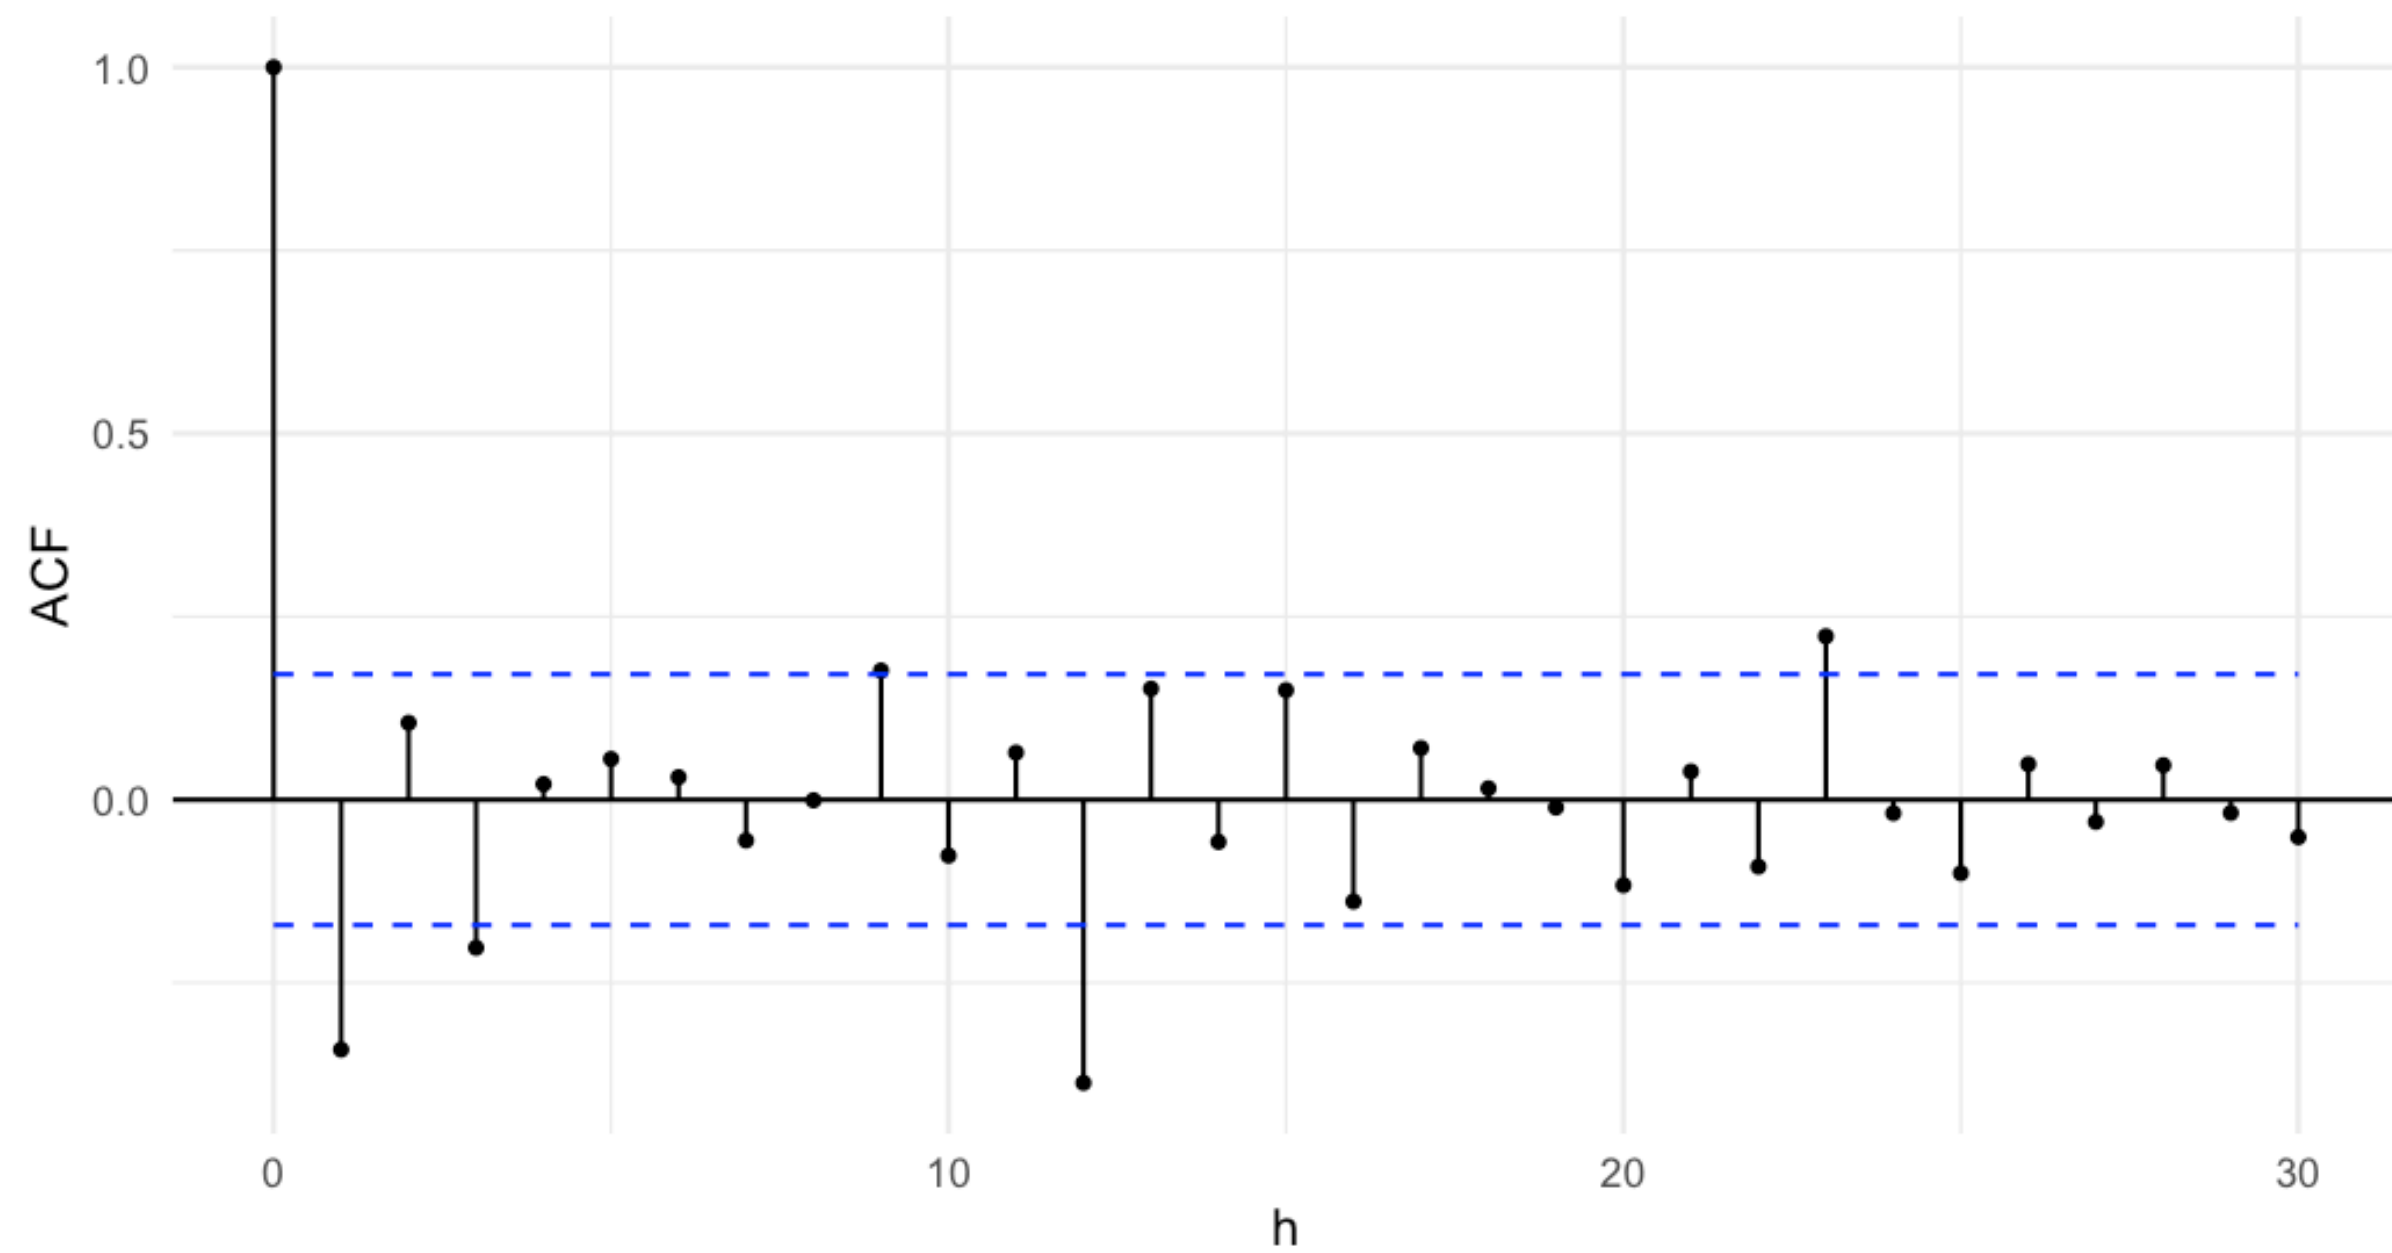
# Diferencias mejoradas

- ▶ Aplicar logaritmo a la serie y utilizar  $\nabla_{12}$  para el componente estacional y  $\nabla$  para el componente de tendencia



# Modelos ARMA

- ▶ A partir del ACF y PACF, ¿qué modelos ARMA se pueden ajustar?



# Modelos ARMA

- ▶ ARMA(12,12)
- ▶ ARMA(1,1)
- ▶ AR(12)
- ▶ AR(1)
- ▶ MA(12)
- ▶ MA(1)



# ARMA(1,1)

- ▶ Los parámetros estimados son

$$\phi = 0.1448$$


$$\theta = -0.5190$$

$$\sigma^2 = 0.001824$$

- ▶ AIC de -446.27

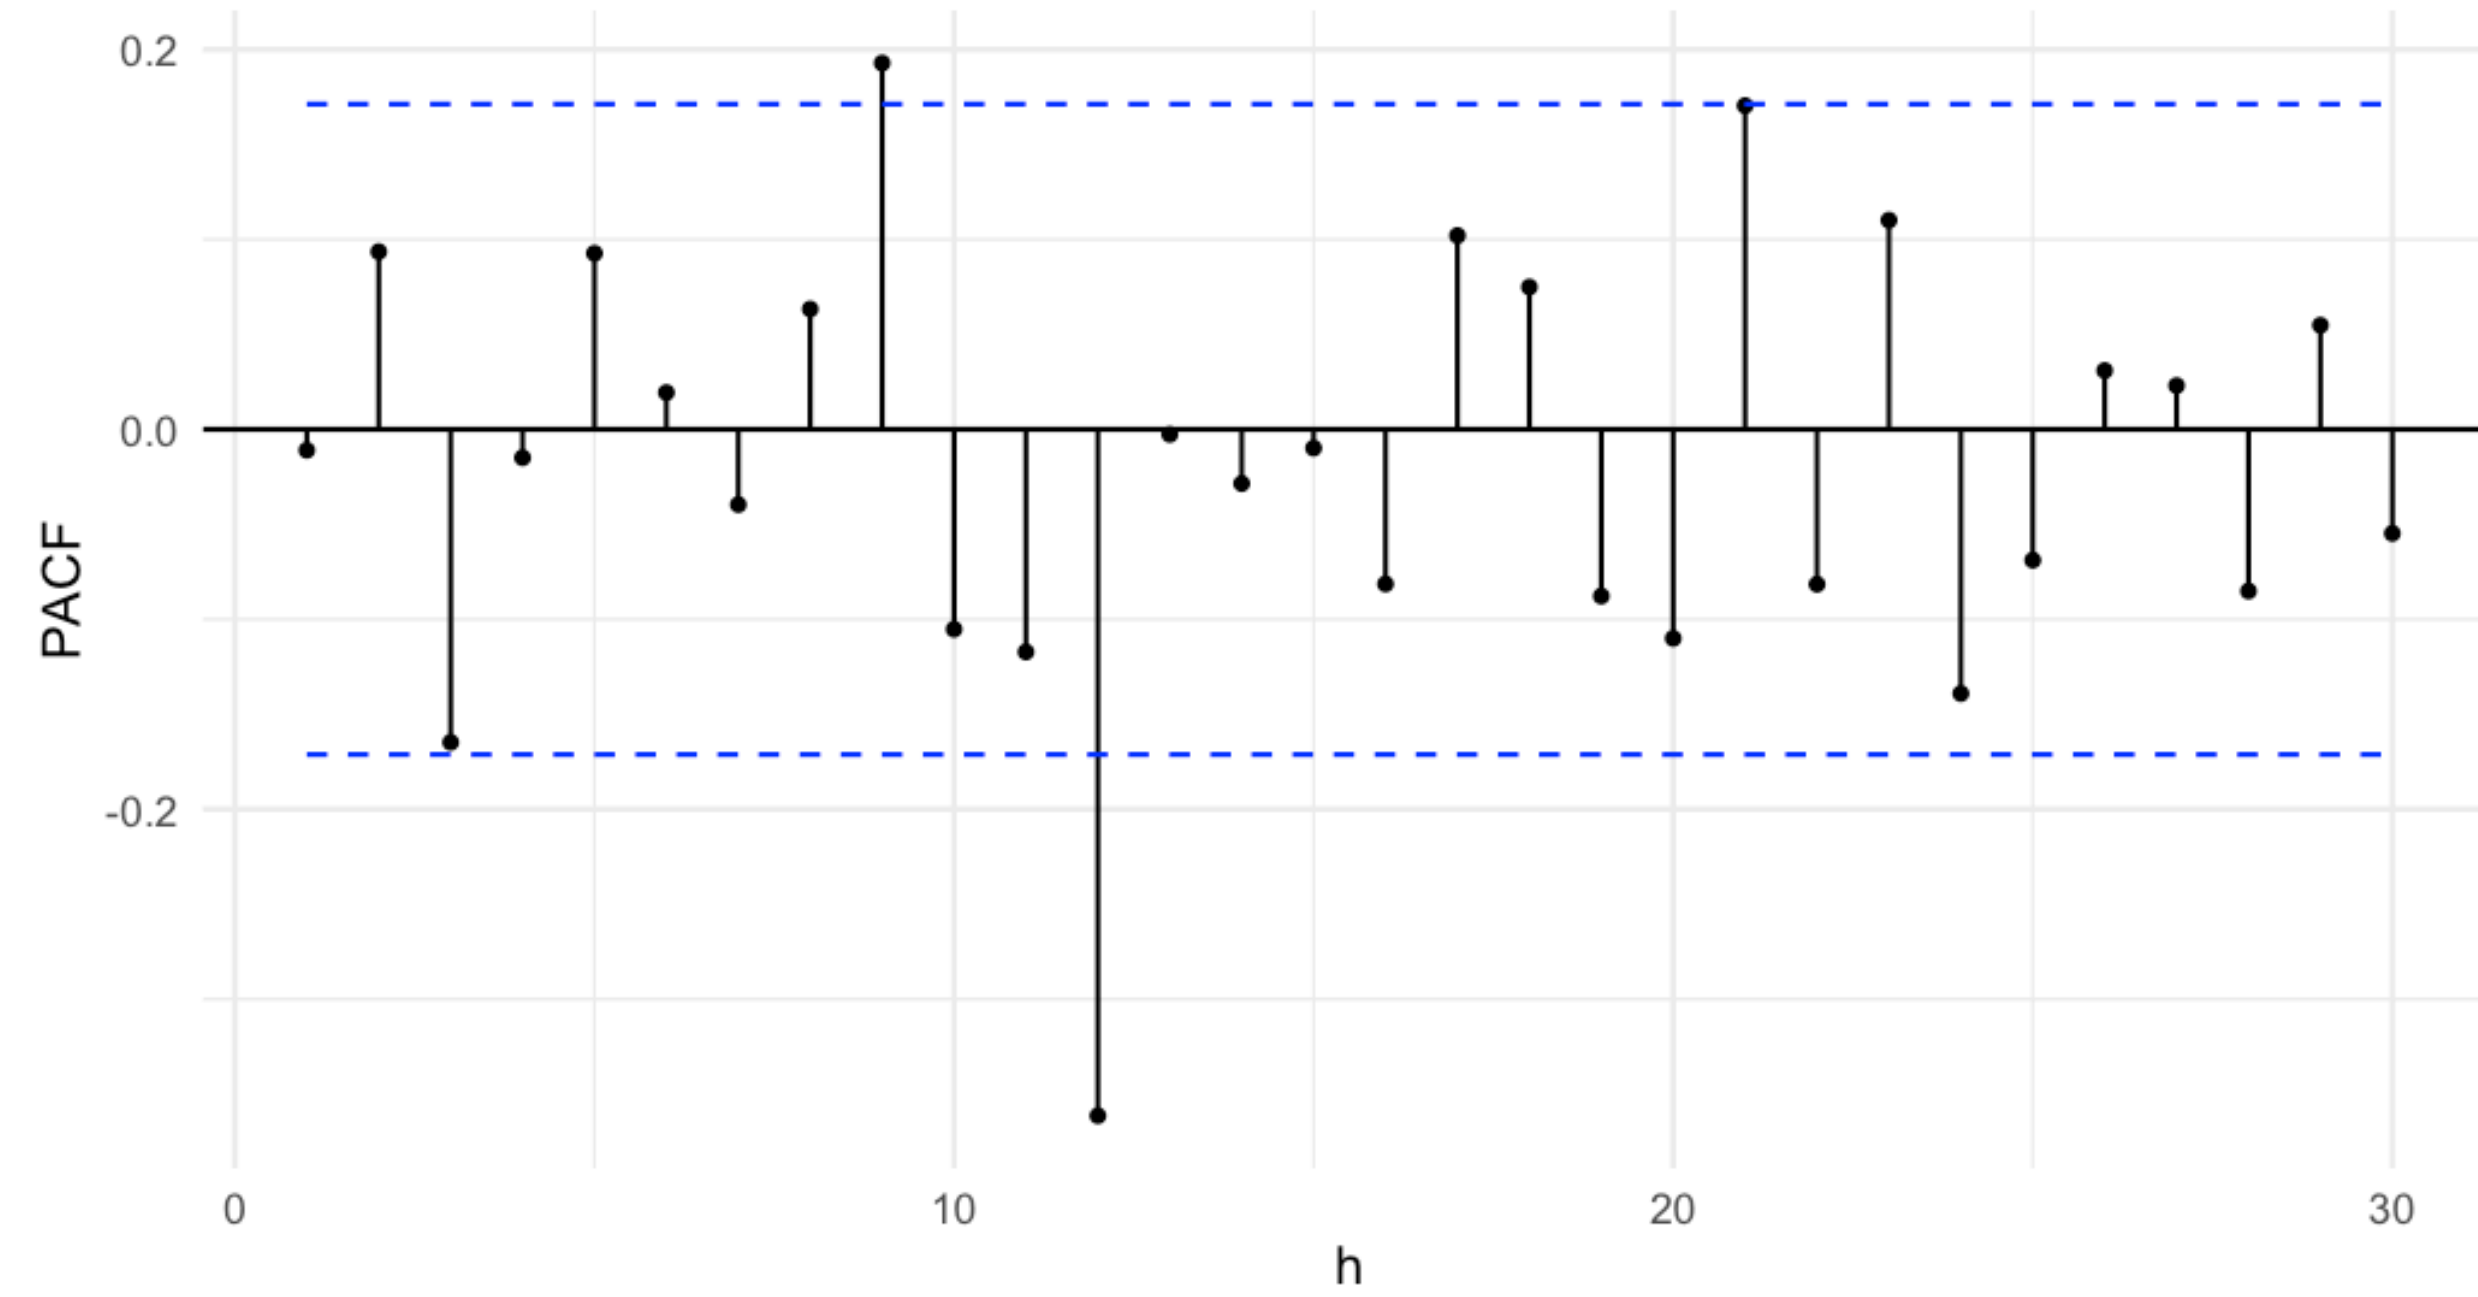

# ARMA(1,1)

- Residuales



# ARMA(1,1)


- Residuales



- p-value de Ljung-Box de 0.8985

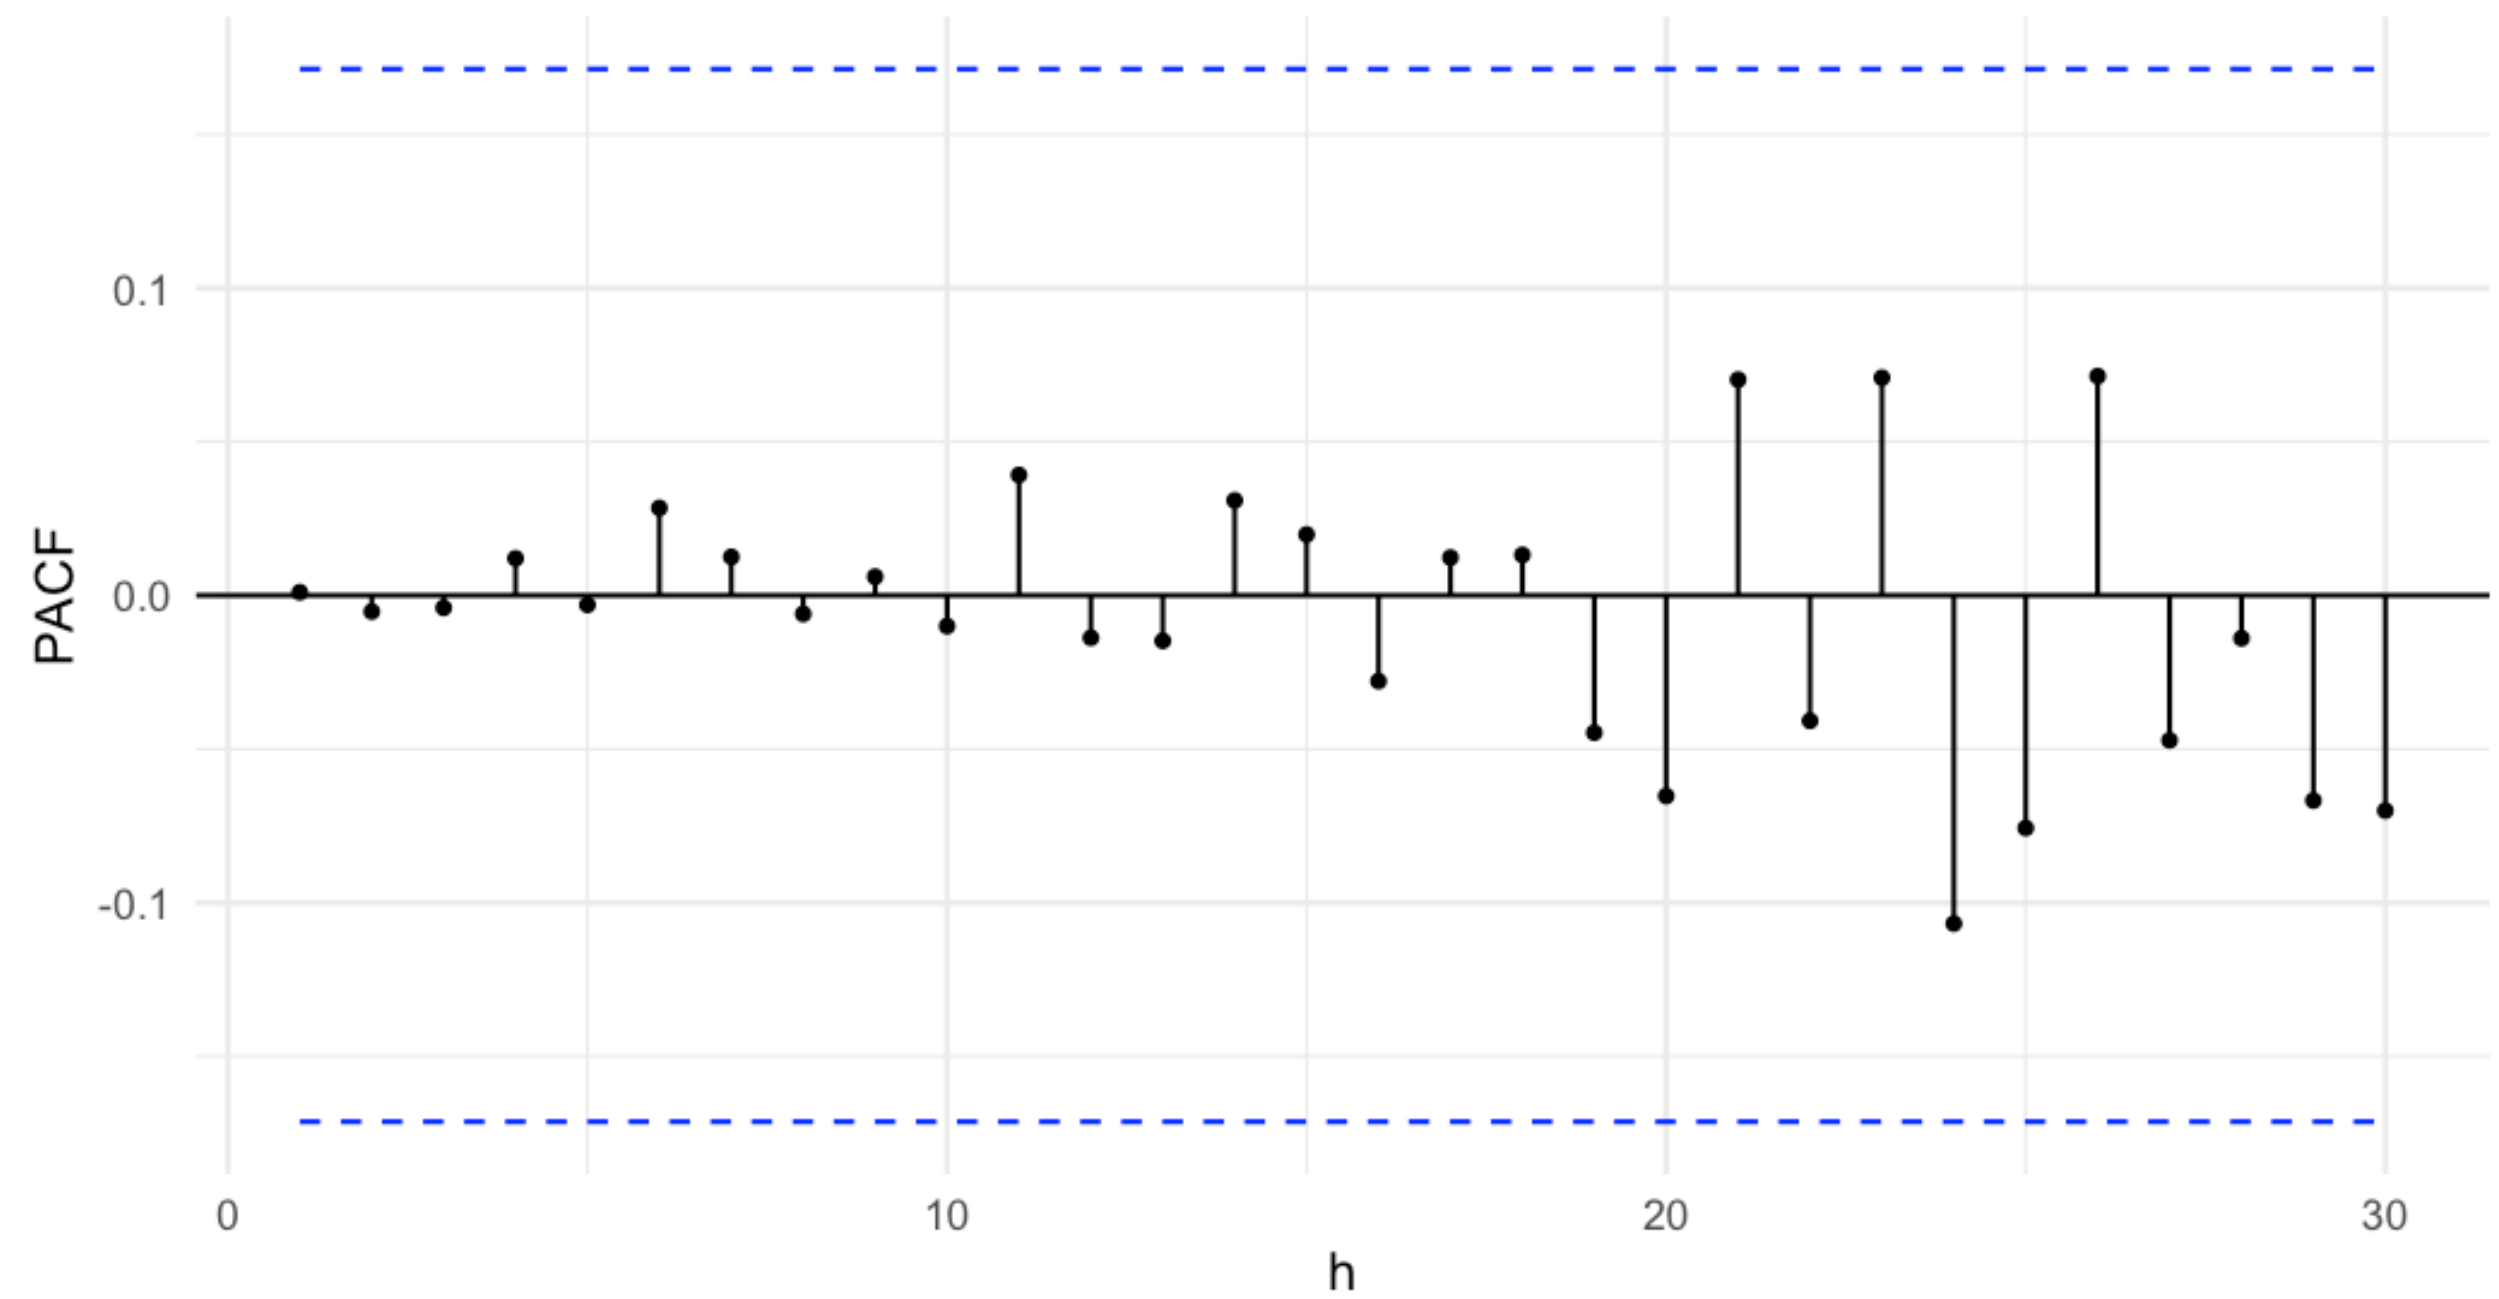

# ARMA(12,12)

- ▶ ¡Muchos parámetros (posiblemente innecesarios)!
- ▶ AIC de -467.34
- ▶ Residuales



# ARMA(12,12)


- ACF y PACF



- p-value de Ljung-Box de 0.9907

# ARMA(12,12)

- Predicción




- ¡Se tienen que revertir todas las transformaciones! (Proceso tedioso)

# Modelos SARIMA

# Periodograma

- ▶ Se calcula el periodograma para evaluar el ciclo de la serie



# Periodograma


- ▶ Las 4 frecuencias dominantes están en las posiciones 1,2,12,3

Posición	Frecuencia	Ciclo
1	0.006944444	144
2	0.01388889	72
12	0.08333333	12
3	0.02083333	48

- ▶ Tiene picos en frecuencias bajas (se puede deber a la tendencia)


# Diferenciando

- ▶ Generamos el proceso  $Y_t = (1 - B)(1 - B^{12})X_t$




# ACF

- ¿Qué valores para  $q$  y  $Q$ ? (Sol:  $q = Q = 1$ )



# PACF

- ¿Qué valores para  $p$  y  $P$ ? (Sol:  $p = P = 1$ )



# Modelo

▸  $X_t$  es un proceso SARIMA  $(1,1,1) \times (1,1,1)_{12}$

▸  $Y_t = (1 - B)(1 - B^{12})X_t$  es un proceso ARMA causal tal que


$$(1 - \phi B)(1 - \Phi B^{12})Y_t = (1 + \theta B)(1 + \Theta B^{12})Z_t$$

$\phi$	$\Phi$	$\theta$	$\Theta$	$\sigma$
0.1666	-0.099	-0.5615	-0.4973	0.03714835

▸ AICc de -479.83 y BIC -465.93

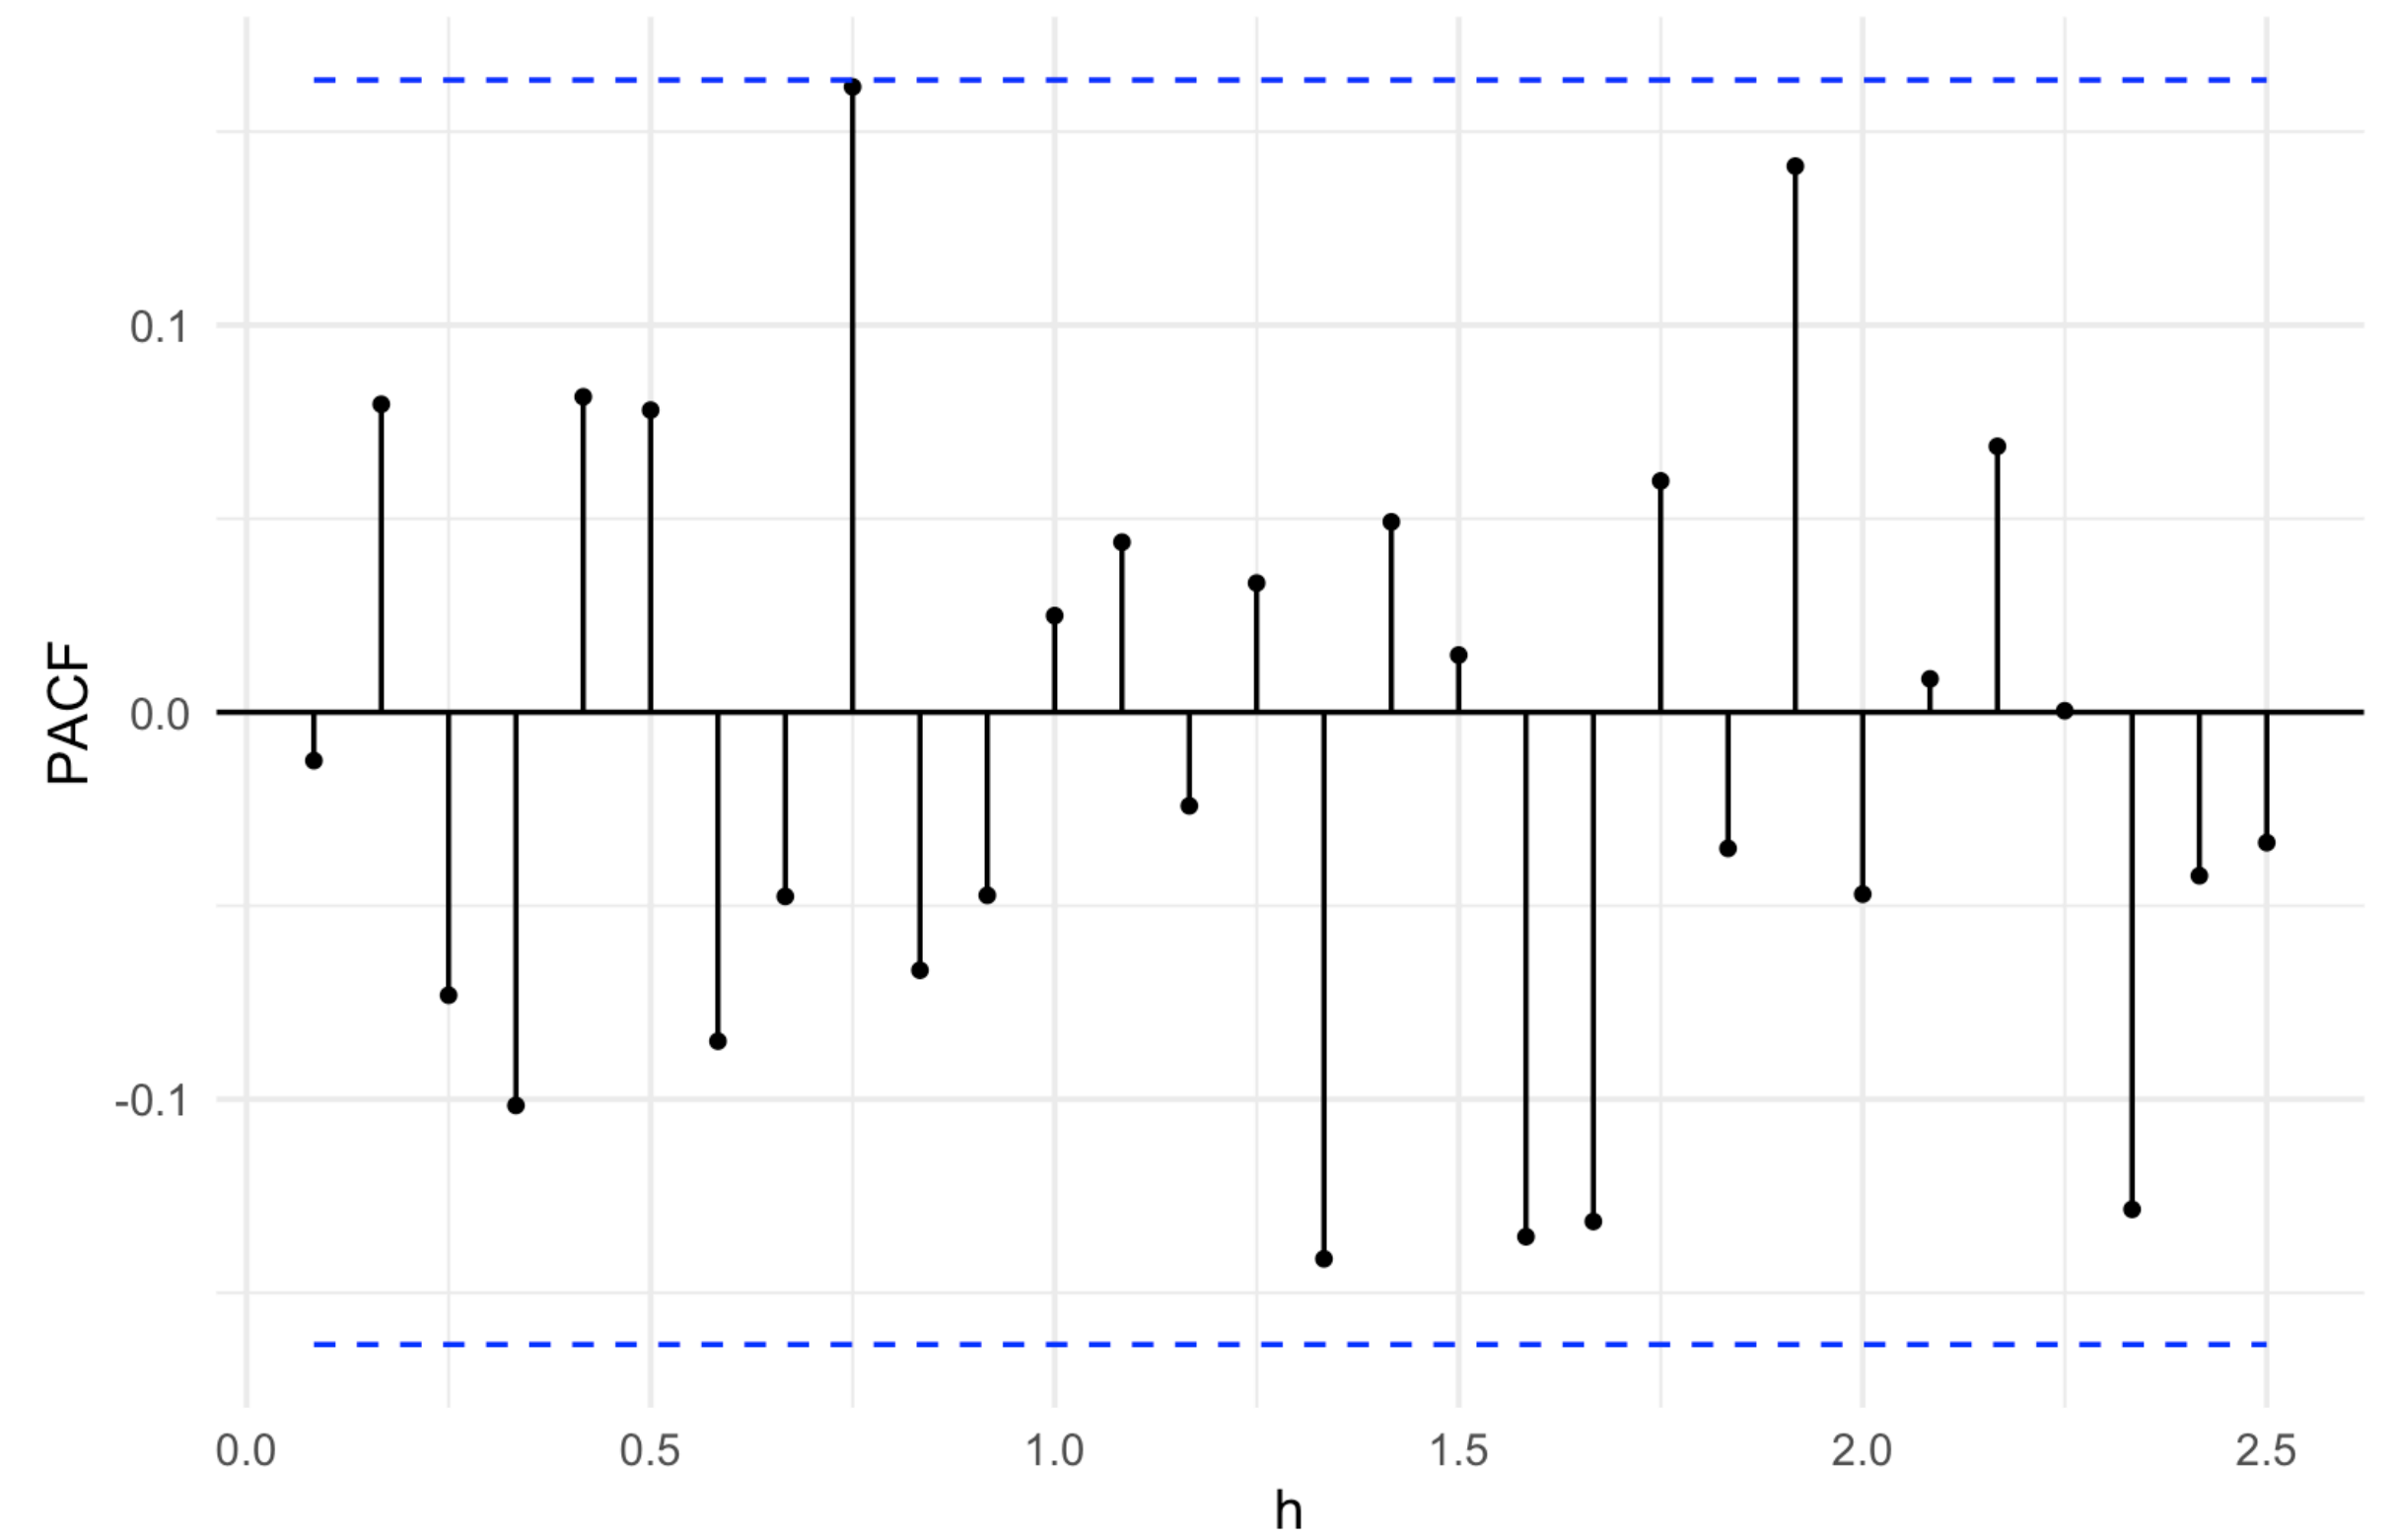

# Residuales

- Parece ser estacionario




# Residuales

- ▶ Prueba de Ljung-Box : p-valor = 0.6863



# Predicción

- ▶ En escala logarítmica



# Predicción

- ▶ Regresando a escala original

