

# **Series Cronológicas**

# Introducción

# Series Cronológicas

## Definición

Población  $\tilde{x}$   $\leftrightarrow$  Proceso estocástico  $\tilde{z}(t)$

Muestra  $\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n$   $\leftrightarrow$  Serie cronológica  $\tilde{z}_t$  (equiespaciada)

- ♦  $t$ : tiempo, espacio, variable que induce un orden.

# Series Cronológicas

## Momentos

$$\mu(t) = \mathbb{E}\tilde{z}(t)$$

$$\sigma_z^2(t) = \gamma_0 = \mathbb{E}(\tilde{z} - \mu)^2$$

$$\gamma_k = \mathcal{V}^{\rho}(\tilde{z}(t); \tilde{z}(t+k)) \quad \text{autocovarianza de rezago } k$$

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad \text{autocorrelación de rezago } k$$

Observación:  $\gamma_{-k} = \gamma_k$

# Series Cronológicas

## Estacionariedad

- ♦ Proceso estacionario (estricto):

$$\tilde{z}(t) \text{ estacionario} \Leftrightarrow \forall m, t_1, t_2 \dots t_m : f(z_{t_1}, z_{t_2}, \dots, z_{t_m}) = f(z_{t_1+h}, z_{t_2+h}, \dots, z_{t_m+h})$$

- » Un proceso estacionario tiene la función de densidad de probabilidad constante, por lo tanto todos sus momentos son constantes.

- ♦ Proceso débilmente estacionario:


$\tilde{z}(t)$  estacionario de orden  $m \Leftrightarrow$  Sus momentos hasta el orden  $m$  son constantes

- » El caso más importante es para  $m=2$ :  $\mu = cte$        $\gamma_k = cte$
- » La estacionariedad estricta es difícil de determinar.
- » Si  $\tilde{z} : \mathcal{N}$  coinciden las definiciones de estacionariedad estricta y débil.

# Series Cronológicas


## Estacionariedad

**Cantidad diaria de autos defectuosos**




Estacionaria en  $\mu$  y  $\sigma^2$

**Rendimiento diario Merval**



Estacionaria en  $\mu$  pero no en  $\sigma^2$

**Demanda anual de Tabaco**




No estacionaria


# Series Cronológicas

## Estacionalidad y Ciclo

**Demanda trimestral de cerveza**




**Precio mensual del polipropileno**



# Series Cronológicas

## Producción de Leche





# Series Cronológicas

## Momentos Empíricos

- ♦ Dada la serie (muestra):  $z_1, z_2, \dots, z_T$

$$\hat{\mu} = \bar{z} = \frac{1}{T} \sum_{t=1}^T z_t$$

$$\hat{\sigma}_z^2 = \hat{\gamma}_0 = c_0 = \frac{1}{T} \sum_{t=1}^T (z_t - \bar{z})^2$$

$$\hat{\gamma}_k = c_k = \frac{1}{T} \sum_{t=1}^{T-k} (z_t - \bar{z})(z_{t+k} - \bar{z})$$

$$\hat{\rho}_k = r_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0}$$

- ♦ Son necesarias muestras grandes porque la autocorrelación puede “retener” al proceso en una zona durante cierto tiempo.

# Modelo de Filtro Lineal

# Series Cronológicas

## Notación de Operadores

♦ Definición:

Retroceso:  $Bz_t = z_{t-1}$

Avance:  $Fz_t = z_{t+1}$

Diferencia:  $\nabla z_t = z_t - z_{t-1}$

Suma:  $Sz_t = \nabla^{-1} z_t$

♦ Propiedades:


$$B^m z_t = z_{t-m} \quad F = B^{-1} \quad \nabla = 1 - B$$

$$Sz_t = (1 - B)^{-1} z_t = (1 + B + B^2 + \dots) z_t = \sum_{j=0}^{\infty} z_{t-j}$$

- » Estos operadores son lineales y forman un álgebra conmutativa con las operaciones suma y composición.

# Series Cronológicas

## Modelo de Filtro Lineal



$a_t$  : ruido blanco o innovación: VA indep. con:  $\mathbb{E}a_t = 0$   $\mathcal{V}a_t = \sigma^2$

$$z_t = \mu + a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots$$

$$\boxed{z_t = \mu + \psi(B)a_t}$$

con:  $\psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots$  función de transferencia

# Series Cronológicas

## Modelo de Filtro Lineal – Forma Autoregresiva

- ♦ Asumiendo que la serie está centrada (sin pérdida de generalidad):

$$z_t = \psi(B)a_t \quad \text{forma de media móvil} \quad \psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots$$

$$\pi(B)z_t = a_t \quad \text{forma autorregresiva} \quad \pi(B) = 1 - \pi_1 B - \pi_2 B^2 - \dots$$

$$\pi(B) = \psi^{-1}(B) \Rightarrow \psi(B)\pi(B) = 1$$

	1	$-\pi_1 B$	$-\pi_2 B^2$	$-\pi_3 B^3$	
1	1	$-\pi_1 B$	$-\pi_2 B^2$	$-\pi_3 B^3$	
$\psi_1 B$	$\psi_1 B$	$-\psi_1 \pi_1 B^2$	$-\psi_1 \pi_2 B^3$	$-\psi_1 \pi_3 B^4$	
$\psi_2 B^2$	$\psi_2 B^2$	$-\psi_2 \pi_1 B^3$	$-\psi_2 \pi_2 B^4$	$-\psi_2 \pi_3 B^5$	
$\psi_3 B^3$	$\psi_3 B^3$	$-\psi_3 \pi_1 B^4$	$-\psi_3 \pi_2 B^5$	$-\psi_3 \pi_3 B^6$	

$$\Rightarrow \begin{cases} \psi_1 - \pi_1 = 0 \\ \psi_2 - \psi_1 \pi_1 - \pi_2 = 0 \\ \psi_3 - \psi_2 \pi_1 - \psi_1 \pi_2 - \pi_3 = 0 \\ \vdots \end{cases}$$

$$\pi_j = \psi_j - \sum_{i=1}^{j-1} \psi_{j-i} \pi_i \qquad \psi_j = \pi_j + \sum_{i=1}^{j-1} \psi_i \pi_{j-i}$$

Permiten el cálculo recurrente

# **Modelos Estacionarios**

## **ARMA(p,q)**

# Modelos de Media Móvil $MA(q)$

- ◆ Definición:

$$z_t = \theta(B)a_t \qquad z_t : \text{ centrada}$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 \dots - \theta_q B^q$$

- ◆ Estacionariedad:

- » Como  $\psi(B) = \theta(B)$  es finito siempre converge. Luego son siempre estacionarios.

- ◆ Invertibilidad:

- » Expresando el modelo en su forma auto-regresiva  $\pi(B)z_t = a_t$  a veces los coeficientes  $\pi_j$  aumentan con el rezago. Esto no tiene sentido práctico, y se dice que el modelo no es invertible.

$$z_t = \theta(B)a_t \quad \text{invertible} \quad \Leftrightarrow \quad \forall B \in \mathbb{C} / \theta(B) = 0: |B| > 1$$

# Modelos de Media Móvil $MA(q)$

## Momentos

- ♦ Varianza:

$$\gamma_0 = \mathbb{E}z_t^2 = \mathbb{E}(\theta(B)a_t)^2$$

» Todos los términos cruzados tienen  $\mathbb{E}a_t a_s = 0$  entonces:

$$\gamma_0 = (1 + \theta_1^2 + \theta_2^2 \dots + \theta_q^2) \sigma^2$$

- ♦ Auto-covarianzas:

$$\gamma_k = \gamma_{-k} = \mathbb{E}z_t z_{t-k} = \mathbb{E}[\theta(B)a_t \theta(B)a_{t-k}]$$

$$\gamma_k = (-\theta_k + \theta_{k+1}\theta_1 + \theta_{k+2}\theta_2 \dots + \theta_q \theta_{q-k}) \sigma^2$$

$$\rho_k = \frac{\gamma_k}{\gamma_0}$$

- ♦ Estas ecuaciones permiten estimar  $\sigma^2$  y  $\theta_j$ , pero esta estimación por momentos no es buena.



# Modelos Auto-Regresivos $AR(p)$

- ◆ Definición:

$$\phi(B)z_t = a_t$$

$z_t$  : centrada

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 \dots - \phi_p B^p$$

- ◆ Estacionariedad:

$$\phi(B)z_t = a_t \text{ estacionario} \iff \forall B \in \mathbb{C} / \phi(B) = 0: |B| > 1$$

- ◆ Invertibilidad:

- » Como  $\pi(B) = \phi(B)$  es finito siempre converge. Luego son siempre invertibles.
- » Si bien los coeficientes pueden crecer con el rezago, esto no continúa indefinidamente pues  $\pi_j = 0$  para  $j > p$  .

# Modelos Auto-Regresivos $AR(p)$

## Momentos

- ♦ Varianza:

$$\begin{aligned}\gamma_0 &= \mathbb{E}z_t^2 = \mathbb{E}[z_t(\phi_1 z_{t-1} + \phi_2 z_{t-2} \dots + \phi_p z_{t-p} + a_t)] \\ &= \phi_1 \gamma_1 + \phi_2 \gamma_2 \dots + \phi_p \gamma_p + \mathbb{E}[z_t a_t]\end{aligned}$$

- » Pero  $\mathbb{E}[z_t a_t] = \mathbb{E}[(\phi_1 z_{t-1} + \phi_2 z_{t-2} \dots + \phi_p z_{t-p} + a_t)a_t] = \sigma^2$
- » Porque  $z_{t-j}$  con  $j \geq 1$  son independientes de  $a_t$ , entonces:

$$\begin{aligned}\gamma_0 &= \phi_1 \gamma_1 + \phi_2 \gamma_2 \dots + \phi_p \gamma_p + \sigma^2 \\ \gamma_0 &= \frac{\sigma^2}{1 - \phi_1 \rho_1 - \phi_2 \rho_2 \dots - \phi_p \rho_p}\end{aligned}$$

# Modelos Auto-Regresivos $AR(p)$

## Momentos

- ♦ Auto-covarianzas:

$$\begin{aligned}\gamma_k &= \mathbb{E}z_t z_{t+k} = \mathbb{E}[z_t (\phi_1 z_{t+k-1} + \phi_2 z_{t+k-2} \dots + \phi_p z_{t+k-p} + a_{t+k})] \\ &= \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} \dots + \phi_p \gamma_{k-p}\end{aligned}$$

- » Pues  $a_{t+k}$  indep de  $z_t$  si  $k > 1$

$$\begin{aligned}\gamma_k &= \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} \dots + \phi_p \gamma_{k-p} \\ \rho_k &= \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} \dots + \phi_p \rho_{k-p}\end{aligned}$$

Ecuaciones de  
Yule-Walker

- ♦ Estas ecuaciones permiten estimar  $\sigma^2$  y  $\phi_j$ , aunque las estimaciones por máxima verosimilitud o cuadrados mínimos son mejores.

# Modelos $ARMA(p,q)$

- ◆ Definición:

$$\phi(B)z_t = \theta(B)a_t \quad z_t : \text{ centrada}$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 \dots - \phi_p B^p$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 \dots - \theta_q B^q$$

- ◆ Estacionariedad:

- » Un modelo ARMA es estacionario cuando su parte AR lo es.

$$\phi(B)z_t = \theta(B)a_t \quad \text{estacionario} \quad \Leftrightarrow \quad \forall B \in \mathbb{C} / \phi(B) = 0 : |B| > 1$$

- ◆ Invertibilidad:

- » Un modelo ARMA es invertible cuando su parte MA lo es.

$$\phi(B)z_t = \theta(B)a_t \quad \text{invertible} \quad \Leftrightarrow \quad \forall B \in \mathbb{C} / \theta(B) = 0 : |B| > 1$$

# Modelos $ARMA(p,q)$

## Inversión

- ♦ Reemplazando  $z_t$  por  $\sum_0^{\infty} \psi_j a_{t-j}$  en vertical:

$$z_t - \phi_1 z_{t-1} - \phi_2 z_{t-2} \dots \dots \dots - \phi_p z_{t-p} = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} \dots \dots \dots - \theta_q a_{t-q}$$

$$\psi_0 a_t = a_t$$

$$\psi_1 a_{t-1} - \phi_1 \psi_0 a_{t-1} = -\theta_1 a_{t-1}$$

$$\psi_2 a_{t-2} - \phi_1 \psi_1 a_{t-2} - \phi_2 \psi_0 a_{t-2} = -\theta_2 a_{t-2}$$

$$\psi_3 a_{t-3} - \phi_1 \psi_2 a_{t-3} - \phi_2 \psi_1 a_{t-3} = -\theta_3 a_{t-3}$$

⋮

- ♦ Entonces:  $\psi_j = \sum_{i=1}^{\infty} \phi_i \psi_{j-i} - \theta_j$

» Que permite el cálculo recurrente de  $\psi_j$  pues las  $\phi_j, \theta_j$  se anulan para  $i > p$  y  $j > q$

# Modelos $ARMA(p,q)$

## Selección del Modelo

- ♦ Los procesos  $MA(q)$  se detectan por la función de auto-correlación ya que:

$$\forall k > q: \rho_k = 0$$

- ♦ Se demuestra que:

$$\forall k > q: r_k : \mathcal{N}(0; \frac{1}{T} (1 + 2 \sum_{j=1}^q \rho_j^2))$$

- » Que permite ensayar  $H_0) \rho_k = 0$  y determinar  $q$ .
- » Hay que considerar la reducción de  $\alpha$  por ensayos simultáneos:  $\alpha' = 1 - (1 - \alpha)^r$

# Modelos $ARMA(p,q)$

## Selección del Modelo

- ♦ Los procesos  $AR(p)$  se detectan por la función de auto-correlación parcial.
- ♦ Las ecuaciones de Yule-Walker permiten estimar los  $\phi_j$

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} \dots + \phi_p \rho_{k-p}$$

- ♦ El coeficiente  $\phi_p$  es la correlación entre  $z_t$  y  $z_{t-p}$  después de eliminar el efecto de  $z_{t-1}$ ,  $z_{t-2}$ , ...,  $z_{t-p+1}$  sobre  $z_t$ :

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} \dots + \phi_p z_{t-p} + a_t$$

- ♦ Entonces se lo llama auto-correlación parcial de orden  $p$ :  $\phi_{pp}$
- ♦ Para cada  $k$  se puede estimar  $\phi_{kk}$  por Yule-Walker. Si se encuentra un  $\phi_{kk} = 0$  entonces el proceso es  $AR(p)$  con  $p=k-1$ .

# Modelos $ARMA(p,q)$

## Selección del Modelo

- ♦ Se demuestra que en un  $AR(p)$ :

$$\forall k > p: \hat{\phi}_{kk} : \mathcal{N}(0; \frac{1}{T})$$

- » Que permite ensayar  $H_0) \phi_{kk} = 0$  y determinar  $p$ .
- » Hay que considerar la reducción de  $\alpha$  por ensayos simultáneos:  $\alpha' = 1 - (1 - \alpha)^r$

- ♦ Los modelos  $ARMA(p,q)$  sólo pueden validarse después de ser estimados.



# **Procesos No Estacionarios**

## **ARIMA(p,d,q)**

# Procesos No Estacionarios

- ♦ Se puede modelar a tendencia  $\mu$  en función del tiempo y otras variables (lineal, exponencial, etc.) y los residuos estacionarios por ARMA. O hacerlo simultáneamente: ARMAX (no lineales).

- ♦ Pero a veces el proceso pasa largas temporadas sobre o bajo la media.

$$\phi(B)z_t = \theta(B)a_t \quad \text{estacionario} \quad \Leftrightarrow \quad \forall B \in \mathbb{C} / \phi(B) = 0: |B| > 1$$

- ♦ Si alguna  $|B| < 1$  el proceso diverge inexorablemente y pierde interés como proceso estocástico. Ej: crecimiento bacteriano ad-libitum.
- ♦ Si alguna  $|B| = 1$  el proceso no es estacionario pero no diverge: es homogéneo. Cuando  $B$  es compleja o  $B = -1$  el proceso toma formas regulares artificiales. Entonces el caso de interés práctico es  $B = 1$ .

# Procesos No Estacionarios

- ♦ Si hay  $d$  raíces unitarias  $B = 1$ :

$$\phi'(B) = \phi(B)(1-B)^d = \phi(B)\nabla^d$$

- ♦ Que es un modelo  $ARIMA(p,d,q)$

$$\boxed{\phi(B)\nabla^d z_t = \theta(B)a_t}$$

- » Donde la serie  $\nabla^d z_t$  es estacionaria.

- ♦ Se llama “integrado” porque

$$\nabla^d z_t = w_t \quad \Rightarrow \quad z_t = S^d w_t$$

- » Donde la serie  $w_t$  es estacionaria.

# Procesos No Estacionarios

- ♦ En la práctica  $d = 1$  o  $2$ , y los modelos más comunes son:

$$IMA(1,1): \quad \nabla z_t = a_t - \theta_1 a_{t-1}$$

$$IMA(2,2): \quad \nabla^2 z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

- ♦ Los procesos integrados pueden ser difíciles de distinguir:

$$ARMA(1,1): \quad z_t = \phi z_{t-1} + a_t - \theta a_{t-1}$$

$$IMA(1,1): \quad z_t = z_{t-1} + a_t - \theta a_{t-1}$$

- » Si  $\phi \cong 1$  son muy parecidos, aunque sus comportamientos futuros pueden ser bien diferentes.

# Procesos No Estacionarios

- ♦ Un correlograma largo es señal de un proceso no estacionario. Las series diferenciadas deben mostrar correlogramas cortos.
- ♦ Ejemplos de procesos no estacionarios:
  - » Precio de activos financieros.
  - » Ventas de algunos productos.

# Pronóstico

# Pronóstico

- ♦ Dada la serie  $z_t$  (centrada) observada en el instante  $t$ :

$\hat{z}_t(l)$  : pronóstico para el instante  $t + l$  con datos hasta el instante  $t$  ( $l$  : lead time)

$z_{t+l}$  : valor futuro de la serie en el instante  $t + l$ , aleatorio.

- ♦ Expresando la serie según el modelo de filtro lineal:

$$z_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots + \psi_j a_{t-j} + \dots$$

- ♦ Se define el pronóstico como:  $\hat{z}_t(l) = \mathcal{F}_t z_{t+l}$

» Donde  $\mathcal{F}_t$  : esperanza en el instante  $t$ .

- ♦ Ahora: 
$$\begin{cases} \forall j \leq t : a_j \text{ conocido (no observado)} \Rightarrow \mathcal{F}_t a_j = a_j & \mathcal{V}_t a_j = 0 \\ \forall j > t : a_j \text{ aleatorio} & \Rightarrow \mathcal{F}_t a_j = 0 & \mathcal{V}_t a_j = \sigma^2 \end{cases}$$

- ♦ Entonces:  $\hat{z}_t(l) = \mathcal{F}_t z_{t+l} = \mathcal{F}_t [a_{t+l} + \psi_1 a_{t+l-1} + \psi_2 a_{t+l-2} + \dots + \psi_l a_t + \psi_{l+1} a_{t-1} + \dots]$

$$\hat{z}_t(l) = \psi_l a_t + \psi_{l+1} a_{t-1} + \dots$$

# Pronóstico

- ♦ El error de pronóstico es:

$$\mathcal{E} = z_{t+l} - \hat{z}_t(l) = a_{t+l} + \psi_1 a_{t+l-1} + \psi_2 a_{t+l-2} + \dots + \psi_{l-1} a_{t+1} + \dots$$

$$\Rightarrow \mathbb{E}_t \mathcal{E} = 0$$

$\Rightarrow$  El error mínimo cuadrático concide con la varianza y es mínimo

$$\mathcal{V}_t z_{t+l} = \mathcal{V}[a_{t+l} + \psi_1 a_{t+l-1} + \psi_2 a_{t+l-2} + \dots + \psi_l a_t + \psi_{l+1} a_{t-1} + \dots]$$

$$\boxed{\mathcal{V}_t z_{t+l} = (1 + \psi_1^2 + \dots + \psi_{l-1}^2) \sigma^2}$$

Que permite hacer el intervalo de pronóstico



# Pronóstico

- ♦ Naturaleza de los impulsos aleatorios:

$$z_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots$$

$$\hat{z}_t(1) = \psi_1 a_t + \psi_2 a_{t-1} + \dots$$

$$\hat{z}_{t-1}(1) = \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots$$

$$\Rightarrow z_t - \hat{z}_{t-1}(1) = a_t$$

- » El impulso aleatorio es el error de pronóstico con lead time = 1

# Pronóstico a partir de un Modelo *ARIMA*

- Todo modelo *ARIMA*( $p,d,q$ ) puede expresarse como un modelo *ARMA*( $p+d,q$ ).  
Entonces, sin pérdida de generalidad analizaremos un modelo *ARMA*.

- Por ejemplo para el *ARMA*(3,2):

$$z_t - \phi_1 z_{t-1} - \phi_2 z_{t-2} - \phi_3 z_{t-3} = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

$$z_{t+l} = \phi_1 z_{t+l-1} - \phi_2 z_{t+l-2} - \phi_3 z_{t+l-3} + a_{t+l} - \theta_1 a_{t+l-1} - \theta_2 a_{t+l-2}$$

$$\hat{z}_t(l) = \mathcal{F}_t z_{t+l} = \phi_1 \mathcal{F}_t z_{t+l-1} + \phi_2 \mathcal{F}_t z_{t+l-2} + \phi_3 \mathcal{F}_t z_{t+l-3} + \mathcal{F}_t a_{t+l} - \theta_1 \mathcal{F}_t a_{t+l-1} - \theta_2 \mathcal{F}_t a_{t+l-2}$$

- Ahora: 
$$\forall j \leq t : \begin{cases} \mathcal{F}_t z_j = z_j \\ \mathcal{F}_t a_j = z_j - \hat{z}_{j-1}(1) \end{cases} \quad \forall j > t : \begin{cases} \mathcal{F}_t z_j = \hat{z}_t(j-t) \\ \mathcal{F}_t a_j = 0 \end{cases}$$

- Entonces: 
$$\hat{z}_t(1) = \phi_1 z_t + \phi_2 z_{t-1} + \phi_3 z_{t-2} + 0 - \theta_1 a_t - \theta_2 a_{t-1}$$

$$\hat{z}_t(2) = \phi_1 \hat{z}_t(1) + \phi_2 z_t + \phi_3 z_{t-1} + 0 - 0 - \theta_2 a_t$$

$$\hat{z}_t(3) = \phi_1 \hat{z}_t(2) + \phi_2 \hat{z}_t(1) + \phi_3 z_t + 0 - 0 - 0$$

$$\hat{z}_t(4) = \phi_1 \hat{z}_t(3) + \phi_2 \hat{z}_t(2) + \phi_3 \hat{z}_t(1) + 0 - 0 - 0$$

:

# Pronóstico a partir de un Modelo *ARIMA*

- ♦ Para un modelo *ARI* los predictores se calculan recursivamente hacia el futuro.
- ♦ Cuando el modelo tiene componentes *MA*, el calculo se inicia ab aeterno. En la práctica en el pasado remoto:  $t-h$ , cuando se puede despreciar  $a_{t-h}$ , no por pequeño sino porque casi no influye sobre el presente.

$$\hat{z}_{t-1}(1) = \mathcal{F}_t z_t = z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \phi_3 z_{t-3} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

$$\hat{z}_{t-2}(1) = \mathcal{F}_t z_{t-1} = z_{t-1} = \phi_1 z_{t-2} + \phi_2 z_{t-3} + \phi_3 z_{t-4} + a_{t-1} - \theta_1 a_{t-2} - \theta_2 a_{t-3}$$

⋮

$$\hat{z}_{t-h}(1) = \mathcal{F}_t z_{t-h+1} = z_{t-h+1} = \phi_1 z_{t-h} + \phi_2 z_{t-h-1} + \phi_3 z_{t-h-2} + a_{t-h+1} - \theta_1 a_{t-h} - \theta_2 a_{t-h-1}$$

$$\hat{z}_{t-h-1}(1) = \mathcal{F}_t z_{t-h} = z_{t-h} = \phi_1 z_{t-h-1} + \phi_2 z_{t-h-2} + \phi_3 z_{t-h-3} + a_{t-h} - \theta_1 a_{t-h-1} - \theta_2 a_{t-h-2}$$

- ♦ Asumiendo  $\forall j \geq h+1: a_{t-j} \cong 0$  se pueden estimar  $a_{t-h} \dots a_t$  a partir de estas  $h+1$  ecuaciones recursivamente empezando de la ultima.

$$a_{t-h} = z_{t-j} - \phi_1 z_{t-j-1} + \phi_2 z_{t-j-2} + \phi_3 z_{t-j-3} + \theta_1 a_{t-j-1} + \theta_2 a_{t-j-2} \quad j = h, h-1 \dots 0$$

# Pronóstico a partir de un Modelo *ARIMA*

- ♦ Con las  $a_{t-h} \dots a_t$  se pueden calcular los pronósticos:  $\hat{z}_t(l)$
- ♦ Sólo se usan:  $a_t \dots a_{t-q-1}$

- ♦ Bandas de pronóstico:

$$\begin{aligned} z_{t+l} &: \hat{z}_t(l) \pm z_{1-\alpha/2} \hat{\sigma}_{z_{t+l}} \\ \hat{\sigma}_{z_{t+l}} &= (1 + \hat{\psi}_1^2 + \dots + \hat{\psi}_{l-1}^2) \hat{\sigma}^2 \end{aligned}$$