

# EL4005 Principios de Comunicaciones

## Clase No.8: Procesos ARMA y Procesos de Markov



Patricio Parada

Departamento de Ingeniería Eléctrica  
Universidad de Chile

9 de Noviembre de 2011

# Contenidos de la Clase (1)

---

## Procesos Auto-Regresivos y de Media Móvil

- Proceso auto-regresivo

- Ajuste de un proceso auto-regresivo

- Proceso de Media Móvil

## Procesos y Cadenas de Markov

- Procesos de Markov

- Cadenas de Markov

## Resumen y Lecturas

## Otros Modelos de Procesos Aleatorios

---

- Existen dos modelos elementales que se utilizan para introducir “memoria” en un proceso, de manera diferente a los procesos de Markov.
  - Proceso auto-regresivo (AR)
  - Proceso de media móvil (MA: *moving average*)
- Estos modelos son empleados en forma extensiva en filtros digitales, análisis de secuencias aleatorias (series de tiempo), sistemas de control, extracción de características, etc.

## Operador Backshift $B$

---

- Antes introducir los modelos vamos a introducir el operador  $B$ :

$$BX_n = X_{n-1} \quad (1)$$

- Por inducción es directo de mostrar que:

$$B^k X_n = X_{n-k} \quad k \in \mathbb{Z} \quad (2)$$

## Proceso Auto-Regresivo (1)

---

- Un proceso es auto-regresivo de orden  $p$  - denotado como  $AR(p)$  - si existe una dependencia directa entre el valor de una muestra en un instante arbitrario  $n$  y sus  $p$  valores anteriores:

$$X_n = \sum_{i=1}^p \alpha_i X_{n-i} + W_n \quad (3)$$

donde  $W_n$  es un proceso de ruido aditivo independiente de  $X$ .

- Si usamos la notación con el operador  $B$  entonces:

$$X_n = \sum_{i=1}^p \alpha_i B^i X_n + W_n$$
$$\Rightarrow \phi(B)X_n = W_n$$

## Proceso Auto-Regresivo (2)

---

- donde



$$\phi(B) = 1 - \sum_{i=1}^p \alpha^i B^i. \quad (4)$$

- En la práctica hay dos formas en que uno puede utilizar un proceso auto-regresivo:
  - Si los parámetros del modelo  $(\alpha_1, \dots, \alpha_p)$  y el orden  $p$  son conocidos, entonces el modelo puede ser utilizado para generar un proceso auto-regresivo.
  - Ejemplo:

$$X_n = 0,1X_{n-1} + 0,5X_{n-2} + W_n \quad (5)$$

con  $W_n \sim \mathcal{N}(0, 1)$  y  $X_0 = 0$ .

## Proceso Auto-Regresivo (3)



## Proceso Auto-Regresivo (4)

---

- Desde el punto de vista de sistemas, un proceso auto-regresivo no es más que la salida de un sistema LTI sin ceros y cuyos polos son las raíces del polinomio

$$\phi(z) = 1 - \sum_{i=1}^p \alpha_i z^i. \quad (6)$$

- Si los zeros de  $\phi(z)$  están dentro del círculo unitario, entonces el proceso será estacionario.
- La segunda forma en que un modelo auto-regresivo puede ser empleado es para ser “ajustado” a una serie de observaciones de un proceso.
- Esta tarea es muy común en la práctica y su solución no es única.

## Ajustes de Procesos Auto-Regresivos

---

- P: ¿Qué queremos decir con el término “ajustar”?
- R: Simplemente, que queremos determinar los parámetros del modelo  $p$  y  $(\alpha_1, \dots, \alpha_p)$  que mejor “explican” las observaciones.
- El criterio de ajuste más común se basa en la **minimización del error cuadrático medio** entre el modelo y los observaciones.
- El problema se expresa de la siguiente forma:

$$\min_{p \in \mathbb{N}} \min_{(\alpha_1, \dots, \alpha_p) \in \mathbb{R}^p} \mathbb{E}[(X_n - \sum_{i=1}^p \alpha_i X_{n-i})^2]. \quad (7)$$

## Coeficientes Óptimos $(\alpha_1, \dots, \alpha_p)$ (1)

---

- Para encontrar los coeficientes que minimizan el error cuadrático medio podemos utilizar técnicas básicas de optimización.
- Sea  $\epsilon_n = X_n + \sum_{i=1}^p \alpha_i X_{n-i}$ . Luego

$$\mathbb{E}[\epsilon_n^2] = \mathbb{E}[X_n^2] - 2 \sum_{i=1}^p \alpha_i \mathbb{E}[X_n X_{n-i}] + \sum_{i=1}^p \sum_{j=1}^p \alpha_i \alpha_j \mathbb{E}[X_{n-i} X_{n-j}] \quad (8)$$

- Notar que  $\mathbb{E}[X_n^2] = R_X[n; n]$ ,  $\mathbb{E}[X_n X_{n-i}] = R_X[n; n-i]$  y  $\mathbb{E}[X_{n-i} X_{n-j}] = R_X[n-i; n-j]$ .

## Coeficientes Óptimos $(\alpha_1, \dots, \alpha_p)$ (2)

---

- Luego, en el óptimo se cumple que  $\frac{\partial \mathbb{E}[\epsilon^2]}{\partial \alpha_k} = 0$ :

$$\frac{\partial \mathbb{E}[\epsilon^2]}{\partial \alpha_k} = -2R_X[n; n - k] + 2 \sum_{i=1}^p \alpha_i R_X[n - k; n - i] \quad (9)$$

- Si el proceso  $\{X_n : n \in \mathbb{N}\}$  es estacionario en sentido amplio, las expresiones dejan de depender de  $n$  y se simplifican a lo siguiente:

$$\Rightarrow R_X[k] = \sum_{i=1}^p \alpha_i R_X[k - i], \quad k = 1, \dots, p.$$

## Coeficientes Óptimos $(\alpha_1, \dots, \alpha_p)$ (3)

---

- Si expresamos estas ecuaciones en forma matricial obtenemos lo siguiente:

$$\underbrace{\begin{bmatrix} R_X[0] & R_X[-1] & \dots & R_X[1-p] \\ R_X[1] & R_X[0] & \dots & R_X[2-p] \\ & & \ddots & \\ R_X[k-1] & R_X[k-2] & \dots & R_X[k-p] \\ & & & \ddots \\ R_X[p-1] & R_X[p-2] & \dots & R_X[0] \end{bmatrix}}_{\mathbf{R}_X} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_k \\ \vdots \\ \alpha_p \end{bmatrix} = \underbrace{\begin{bmatrix} R_X[1] \\ R_X[2] \\ \vdots \\ R_X[k] \\ \vdots \\ R_X[p] \end{bmatrix}}_{\mathbf{r}_X} \quad (10)$$

## Coeficientes Óptimos $(\alpha_1, \dots, \alpha_p)$ (4)

---

- Notemos que por definición la función de autocorrelación es simétrica, pues

$$R_X[n; m] = \mathbb{E}[X[n]X[m]] = \mathbb{E}[X[m]X[n]] = R_X[m; n]$$

- Luego la matriz  $\mathbf{R}_X$  es simétrica y puede ser diagonalizada - y por lo tanto invertida.
- Finalmente

$$\boldsymbol{\alpha}^* = \mathbf{R}_X^{-1} \mathbf{r}_X. \quad (11)$$

## Análisis de la solución

---

- La solución encontrada para  $\alpha^*$  depende de dos elementos:
  - Que la función de autocorrelación  $R_X[k]$  sea conocida para  $k = 0, \dots, p$ .
  - Del condicionamiento de la matriz  $\mathbf{R}_X$ .
- Si la matriz  $\mathbf{R}_X$  está mal condicionada, esto es, si uno de sus valores propios es muy cercano a 0, la inversa va a estar llena de elementos pequeños excepto por los asociados a este valor propio que serán muy grandes.

## Regularización del problema original (1)

---

- Una manera de mejorar la calidad de la solución es agregando una restricción sobre la magnitud del vector  $\alpha$ .
- Esto lleva a reescribir el problema como

$$\min_{p \in \mathbb{N}} \min_{\substack{(\alpha_1, \dots, \alpha_p) \in \mathbb{R}^p \\ \|\alpha\|^2 < A}} \mathbb{E}[(X_n - \sum_{i=1}^p \alpha_i X_{n-i})^2]. \quad (12)$$

donde  $A$  es una constante real positiva grande.

## Regularización del problema original (2)

---

- El procedimiento de solución es el mismo que utilizamos para derivar las expresiones (11) pero se debe agregar al lagrangiano el término

$$+\theta(\|\alpha\|^2 - A) \quad (13)$$

donde  $\theta$  es el multiplicador de Lagrange asociado a la restricción.

- En la práctica, es preferible utilizar un término de **regularización** que permita, por ejemplo, controlar la magnitud del vector  $\alpha$ .
- Regularización es un proceso que permite transformar un problema mal condicionado en uno que está bien condicionado, incorporando información adicional al problema.

## Regularización del problema original (3)

---

- La forma más típica de regularización se conoce como **Regularización de Tikhonov** y modifica la función objetivo original del problema así:

$$\text{f.o.} = \mathbb{E}[(X_n - \sum_{i=1}^p \alpha_i X_{n-i})^2] \rightarrow \mathbb{E}[(X_n - \sum_{i=1}^p \alpha_i X_{n-i})^2] + \|\Gamma \boldsymbol{\alpha}\|^2 \quad (14)$$

donde  $\Gamma$  es una matriz de transformación.

- En la mayoría de las aplicaciones  $\Gamma = \gamma \mathbf{I}$  lo que simplifica la expresión.
- $\gamma$  es un parámetro que uno controla a voluntad para obtener una solución que minimiza el error cuadrático medio condicionado a que la magnitud de  $\boldsymbol{\alpha}$  permanezca acotada.

## Regularización del problema original (4)

---

- Notemos que la nueva función objetivo tiene la forma:

$$\begin{aligned} f(\boldsymbol{\alpha}) &= \mathbb{E}[X_n^2] - 2\boldsymbol{\alpha}^T \mathbf{r}_X + \boldsymbol{\alpha}^T R_X \boldsymbol{\alpha} + (\Gamma \boldsymbol{\alpha})^T \Gamma \boldsymbol{\alpha} \\ &= \mathbb{E}[X_n^2] - 2\boldsymbol{\alpha}^T \mathbf{r}_X + \boldsymbol{\alpha}^T (R_X + \Gamma^T \Gamma) \boldsymbol{\alpha} \end{aligned}$$

- En el óptimo,  $\nabla f(\boldsymbol{\alpha}) = 0$ , es decir:

$$\boldsymbol{\alpha}^* = (\mathbf{R}_X - \Gamma^T \Gamma)^{-1} \mathbf{r}_X. \quad (15)$$

- Notar que si  $\Gamma = \gamma I$ , entonces  $\boldsymbol{\alpha}^* = (\mathbf{R}_X - \gamma^2 I)^{-1} \mathbf{r}_X$ .

## Entrenamiento y Validación de los resultados (1)

---

- En la práctica ni la matriz  $\mathbf{R}_X$  ni el vector  $\mathbf{r}_X$  son conocidos.
- Uno deben estimarlos a partir de datos y empleando algunas suposiciones básicas que uno asume como verdaderas (como que el proceso sea estacionario).
- Esto puede llevar a errores en el resultado final, y que el modelo que se construye tenga un desempeño bajo.
- Una manera de resolver esta situación es estudiando el desempeño del modelo en dos escenarios distintos:
  - Explicando los datos utilizados para estimar  $\mathbf{R}_X$  y  $\mathbf{r}_X$ .
  - Explicando datos nuevos, no utilizados en el proceso anterior.

## Entrenamiento y Validación de los resultados (2)

---

- Estas dos etapas reciben el nombre de **entrenamiento** y **validación** del modelo, y son parte fundamental de una gran cantidad de algoritmos de aprendizaje estadístico.
- Para poder implementar esto en la práctica uno debe dividir el conjunto de datos en dos subconjuntos:
  - Datos de Entrenamiento
  - Datos de Validación
- En el caso del ajuste de un modelo  $AR(p)$  vamos a observar en la práctica que si los datos provienen de un proceso estacionario, entonces, el error cuadrático medio de aproximación se reduce a medida que aumenta  $p$ .

## Entrenamiento y Validación de los resultados (3)

---

- Sin embargo, el desempeño del mismo modelo con los datos de validación tenderá a empeorar con a medida que aumenta el orden del modelo.
- Este fenómeno se denomina **sobreajuste** y es un fenómeno no deseado.
- Para evitarlo, un criterio de diseño empleado habitualmente es seleccionar  $p$  de forma que se minimice conjuntamente tanto el error cuadrático medio para los datos de entrenamiento como para los de validación.

## Proceso de Media Móvil (1)

---

- Un proceso de media móvil de orden  $q$  - denotado como  $MA(q)$  - es un proceso estocástico  $X_n$  que “suaviza” o promedia los valores de otro proceso  $W_n$ .

$$X_n = \sum_{j=-m}^{q-1-m} \beta_j W_{n-j}. \quad (16)$$

para algún  $m \in \mathbb{N}$ .

- Mediante este promedio se logra remover las variaciones locales del proceso original (el ruido de la señal) y rescatar la tendencia o valor medio del proceso.
- Notemos que si el proceso  $W_n$  no es estacionario, entonces veremos que este promedio debería variar considerablemente en el tiempo (lo que justifica su nombre).

## Proceso de Media Móvil (2)

---

- Al igual que un proceso auto-regresivo, el proceso de media móvil puede ser descrito en forma compacta mediante un operador:

$$X_n = \theta(B)W_n \quad (17)$$

con

$$\theta(B) = \sum_{j=-m}^{q-1-m} \beta_j B^j. \quad (18)$$

para algún  $m \in \mathbb{N}$ .

## Proceso de Media Móvil (3)

---

- El modelo de media móvil es general, y no restringe sobre los parámetros  $\beta_j$  ni sobre su causalidad o falta de ella.
- Este enfoque es el que toman Box & Jenkins en su libro *Time Series Analysis: Forecasting and Control* (ver referencia bibliográfica al final).
- Sin embargo, en aplicaciones en finanzas y estadística es habitual imponer como condición que

$$\sum_{j=-m}^{q-1-m} \beta_j = 1. \quad (19)$$

- En este curso adoptaremos esta última convención, aunque deben tener presente que en general esta restricción no tiene porque cumplirse.

## Proceso de Media Móvil (4)

---

- Otro tema que merece mención es si el modelo es causal o no.
- Esto tiene relación con el valor de  $m$ .
- Si  $m = 1$ , el modelo será causal y si  $m > 1$  será no causal.
- Nuevamente, Box & Jenkins imponen como condición la causalidad, i.e.

$$X_n = \sum_{j=1}^q \beta_j W_{n-j} \quad (20)$$

- Por otro lado, en finanzas y estadística se tiende a imponer la no causalidad:

$$X_n = \sum_{j=-(q-1)/2}^{(q-1)/2} \beta_j W_{n-j} \quad (21)$$

para  $q$  impar.

## Proceso de Media Móvil (5)

---



- Notar que si  $q$  es par entonces se define como proceso  $MA(q)$  al siguiente proceso:

$$\begin{aligned} X_n &= \frac{1}{2} \left( \sum_{j=-q/2}^{q/2-1} \beta_j W_{n-j} + \sum_{j=-q/2+1}^{q/2} \beta_j W_{n-j} \right) \\ &= \frac{1}{2} \beta_{-q/2} W_{n+q/2} + \beta_{-q/2+1} W_{n+q/2-1} + \dots + \beta_{q/2+1} W_{n-q/2+1} + \frac{1}{2} \beta_{q/2} W_{n-q/2} \end{aligned}$$

## Proceso de Media Móvil (4)

- Ejemplo:  $MA(3)$



$$X_n = \frac{1}{2}W_{n-1} + \frac{1}{3}W_n + \frac{1}{3}W_{n+1} \quad (22)$$



## Proceso de Media Móvil (5)

- Ejemplo:  $MA(7)$



$$X_n = \frac{1}{7} \sum_{j=-3}^3 W_{n-j} \quad (23)$$



## Proceso de Media Móvil (6)

- Ejemplo:  $MA(12)$

$$X_n = \frac{1}{24}W_{n+6} + \frac{1}{12} \sum_{j=-5}^5 W_{n-j} + \frac{1}{24}W_{n-6} \quad (24)$$



## Proceso Auto-Regresivo de Media Móvil (1)

---

- Un proceso auto-regresivo de media móvil de orden  $(p, q)$  -denotado como  $ARMA(p, q)$  - es un proceso estocástico que combina los efectos de suavizado del ruido con la memoria propia del proceso bajo estudio.
- La expresión del proceso es la siguiente:

$$X_n = \sum_{i=1}^p \alpha_i X_{n-i} + \sum_{j=1}^q \beta_j W_{n-j} \quad (25)$$

## Proceso Auto-Regresivo de Media Móvil (2)

---

- Este proceso puede ser representado en forma compacta de igual forma que los procesos AR y MA por si solos.
- Si definimos los operadores:

$$\phi(B) = 1 - \sum_{i=1}^p \alpha_i B^i \text{ y } \theta(B) = \sum_{j=1}^q \beta_j B^j \quad (26)$$

entonces

$$\phi(B)X_n = \theta(B)W_n. \quad (27)$$

## Procesos de Markov (1)

---

- Un proceso de Markov corresponde a un proceso aleatorio dependiente o “con memoria”.
- Es similar a los procesos auto-regresivos, excepto que la caracterización del proceso se realiza con las distribuciones de probabilidad del proceso en lugar de los valores que toma el proceso mismo.
- Los procesos de Markov puede ser de tiempo continuo o de tiempo discreto y pueden tomar valores continuos o discretos.
- En el caso particular que el proceso sea de tiempo discreto y tome valores discretos recibe el nombre de **Cadena de Markov**.

## Procesos de Markov (2)

---

- Un proceso continuo de Markov de primer orden satisface que

$$f_X(x_n|x_{n-1}, \dots, x_1; t_n, \dots, t_1) = f_X(x_n|x_{n-1}; t_n, t_{n-1}) \quad (28)$$

para todo  $x_1, x_2, \dots, x_n$  y  $t_1 < t_2 < \dots, < t_n$  y todo entero  $n > 0$ .

- Un proceso discreto de Markov de primer orden satisface que

$$P_X(x_n|x_{n-1}, \dots, x_1; t_n, \dots, t_1) = P_X(x_n|x_{n-1}; t_n, t_{n-1}) \quad (29)$$

para todo  $x_1, x_2, \dots, x_n$  y  $t_1 < t_2 < \dots, < t_n$  y todo entero  $n > 0$ .

## Ejemplo (1)

---

- Consideremos el caso de dos computadores independientes conectados a un router inalámbrico.
- Podemos modelar el número de computadores transmitiendo simultáneamente como un sistema con tres estados:
  - 0 computadores transmitiendo.
  - 1 computador transmitiendo.
  - 2 computadores transmitiendo.

## Ejemplo (2)

---

- Consideremos las siguientes condiciones:
  - La duración de una transmisión se distribuye de manera exponencial en el tiempo, con  $\lambda > 0$  (el mismo para ambos equipos).
  - La duración de cada silencio se distribuye de manera exponencial en el tiempo, con  $\mu > 0$ .
  - Las duraciones de las transmisiones y silencios son independientes entre ellas y entre computadores.

## Ejemplo (3)

---

- Sea  $X(t)$  el estado del sistema en un tiempo  $t$ .
- Entonces  $X = \{X(t) : t \in \mathbb{R}\}$  es un proceso de Markov de tiempo continuo.
- Por qué? Porque los tiempos entre transiciones se distribuyen exponencialmente y estos no tienen memoria.
- La transición de 0 a 1 ocurre cuando uno de los computadores comienza a transmitir.
- Denotaremos por
  - $T_1$ : instante en que el PC<sub>1</sub> comienza a transmitir.
  - $T_2$ : instante en que el PC<sub>2</sub> comienza a transmitir.

## Ejemplo (4)

---

- Luego, la transición ocurre en

$$\tau_{0 \rightarrow 1} = \text{mín}\{T_1, T_2\} \quad (30)$$

- Pero el mínimo entre dos exponenciales de parámetro  $\mu$  es otra exponencial de parámetro  $2\mu$ .
- Luego, la transición de  $0 \rightarrow 1$  ocurre a una tasa  $2\mu$  por segundo.
- La transición de  $1 \rightarrow 2$ , ocurre cuando el segundo equipo comienza a transmitir, es decir, lo hace una tasa  $\mu$ .

## Ejemplo (5)


---

- Similarmente, la transición de  $1 \rightarrow 0$  ocurre a una tasa  $\lambda$ , ya que  $1/\lambda$  es la duración promedio de una transmisión.
- Finalmente, la transición de  $2 \rightarrow 1$  ocurre cuando uno de los dos equipos deja de transmitir, es decir, con tasa  $2\lambda$ .

## Diagrama de Transición de Corto Plazo

---

- Un proceso de Markov de tiempo continuo puede ser representado de manera gráfica mediante una figura como la presentada en la figura



- Los pesos de cada rama son las probabilidades de transición de corto plazo, es decir, cuando  $\Delta t \rightarrow 0$ .

## Cadenas de Markov (1)

---

- Una cadena de Markov es una secuencia aleatoria que toma valores discretos en un espacio de estado  $\mathcal{S}$ .
- La probabilidad condicional que define a la cadena está dada por:

$$P_X(X[n]|X[n-1], X[n-2], \dots, X[n-N]) = P_X(X[n]|X[n-1]) \quad (31)$$

para todo  $n$ , todos los valores  $X[k]$ , y para cualquier entero  $N > 1$ .

## Cadenas de Markov (2)

---

- Si el espacio de estado tiene cardinalidad finita - digamos  $M$  - las probabilidades condicionales pueden ser escritas en una matriz  $\mathbf{P}[n]$  cuyas entradas son de la forma:

$$\begin{aligned} p_{ij}[n] &= P_{X[n]|X[n-1]}(j|i) \\ &= P(X[n] = j | X[n-1] = i), \end{aligned}$$

para  $1 \leq i, j \leq M$ .

- Las filas de la matriz deben sumar 1.

## Distribución de probabilidad de los estados de la cadena

---

- Para poder determinar el valor de la distribución de probabilidad de los estados de la cadena en un instante arbitrario es necesario conocer dos elementos:
  - La distribución de probabilidad de estados en  $n = 0$ , que denotaremos por  $\mathbf{p}[0]$ ,
  - La matriz de transición de estados  $\mathbf{P}[n]$  para todo  $n > 0$ .
- Luego

$$\mathbf{p}[1] = \mathbf{p}[0]\mathbf{P}[1]$$

$$\mathbf{p}[2] = \mathbf{p}[1]\mathbf{P}[2]$$

$$\vdots$$

$$\mathbf{p}[n] = \mathbf{p}[n - 1]\mathbf{P}[n].$$

## Cadenas de Markov Homogéneas (1)

---

- Si la matriz  $\mathbf{P}[n]$  es independiente del tiempo, decimos que la cadena es **homogénea**, y por lo tanto

$$\mathbf{p}[n] = \mathbf{p}[0]\mathbf{P}^n. \quad (32)$$

- Un caso particular en el que estamos interesados es en determinar la distribución de probabilidad del régimen permanente, si es que existe:

$$\mathbf{p}[\infty] = \lim_{n \rightarrow \infty} \mathbf{p}[n] \quad (33)$$

- De existir el límite, entonces tendríamos que

$$\mathbf{p}[\infty] = \mathbf{p}[\infty]\mathbf{P}. \quad (34)$$

## Cadenas de Markov Homogéneas (2)

---

- Por lo tanto,  $\mathbf{p}[\infty]$  es el vector propio (por la izquierda) asociado al valor propio  $\lambda = 1$  de la matriz  $\mathbf{P}$ .
- Se obtiene entonces

$$\mathbf{p}[\infty](\mathbf{I} - \mathbf{P}) = \mathbf{0} \quad (35)$$

lo que nos entrega  $M - 1$  ecuaciones linealmente independientes para calcular  $\mathbf{p}[\infty]$ .

- La última ecuación se obtiene de la condición de normalización que  $\mathbf{p}[\infty]$  satisface.

## Aplicaciones de las Cadenas de Markov

---

- El modelo de cadenas de Markov es aplicable en cualquier situación donde los valores que tome un determinado proceso aleatorio sean discretos, y existe sospecha que hay condicionalidad temporal.
- Algunos ejemplos clásicos son los siguientes:
  - Modelamiento del tráfico que llega a los servidores y equipos de red en una red de computadores.
  - Modelamiento de un canal de comunicaciones punto-a-punto.
  - Modelamiento de una fuente de información con memoria.

# Resumen

---

Hemos revisado:

- Procesos auto-regresivos, de media móvil y ARMA.
- Análisis de estimación de MSE para modelo  $AR(p)$ .
- Procesos de Markov.
- Cadenas de Markov.

## Lecturas

---

- Salehi & Proakis, *Communication Systems Engineering*, Capítulo 4.
- Box, Jenkins, & Reinsel, *Time Series Analysis: Forecasting and Control*, 4th Edition, Capítulo 3.
- Stark & Woods, *Probability and Random Processes with Applications to Signal Processing*, 3rd. Edition, Sección 9.1.