

# Séries Temporais, Processos Estocásticos e Transformações de Variáveis

Prof. Caio Azevedo

# Modelos para Séries Temporais

- Os modelos utilizados para descrever séries temporais são processos estocásticos, isto é, processos controlados por leis probabilísticas.
- Definição: Seja  $T$  um conjunto arbitrário. Um **processo estocástico** é uma família

$$Y = \{Y(t); t \in T\},$$

tal que, para cada  $t \in T$ ,  $Y(t)$  é uma variável aleatória (va ou v.a.).

- Como usual:  $Y(t)$  : variável aleatória e  $y(t)$  : valor observado da variável aleatória

## Cont.

- Mais rigorosamente,  $Y(t)$  é uma função de dois argumentos:  $Y(t; \omega)$ , para  $t \in T$  e  $\omega \in \Omega$ .
- Para cada  $t \in T$  fixado,  $Y(t; \omega) \equiv Y(\omega)$  é uma variável aleatória definida sobre o espaço amostral  $\Omega$ .
- Para cada  $\omega \in \Omega$  fixado,  $Y(t; \omega) = Y(t)$ , é uma função de  $t$ , ou seja, uma realização ou trajetória do processo estocástico, ou ainda, uma série temporal.

# Ilustração gráfica





Figura: Um processo estocástico interpretado como uma família de variáveis aleatórias

## Comentários (figura anterior)

- Olhando o gráfico em função de  $t \times Z(t, \omega)$ , para cada valor de  $\omega$ , podemos traçar uma curva (representando um processo estocástico).
- Olhando o gráfico em função de  $t \times f_Z(z)$ , para cada valor de  $t$ , temos uma densidade (“aparentemente” Gaussiana).
- $\mu(t)$  seria a média do processo

## Ilustração Gráfica 2



## Comentários (figura anterior)

- Como na página 21 dos slides [Introdução](#), podemos definir várias configurações de Processos Estocásticos (ST), dependendo dos objetivos/restrições :
  - Para  $t_i, i = 1, 2, \dots, n$  fixado. ST: por exemplo, os valores de  $Y^{(j)}(t_i), j = 1, 2, \dots, m$ .
  - Para  $t_i, i = 1, 2, \dots, n$  variando com em função de  $(j)$ . ST: por exemplo, os valores de  $(Y^{(2)}(t_1), Y^{(m-1)}(t_2), \dots, Y^{(m-1)}(t_n))$ .
  - Para  $j, i = 1, 2, \dots, m$ , considera-se o mesmo  $t_i$ . ST: por exemplo, os valores de  $(Y^{(1)}(t_3), Y^{(2)}(t_3), \dots, Y^{(m)}(t_3))$ .
  - Para  $j, i = 1, 2, \dots, m$ , considera-se uma transformação de cada  $Y^{(j)}(t_i)$ . ST: por exemplo, tomar algum tipo de média de cada curva.

## Cont.

- Ao se definir um processo estocástico é necessário introduzir três características:
  - O espaço onde está definido o processo.
  - O conjunto dos índices  $T$ .
  - A estrutura de dependência das v.a.'s,  $Y(t), t \in T$ .



## Cont.

- O conjunto de valores  $\{Y(t), t \in T\}$  é chamado de espaço de estados ( $S$ ), do processo estocástico, e cada valor de  $Y(t)$  é chamado de estado.
- O espaço de estados pode ser discreto ou contínuo:
  - No caso discreto  $Y(t)$  pode representar uma contagem, como o número de transações de uma ação, durante um dia.
  - No caso contínuo,  $Y(t)$  pode representar uma medida que varia continuamente, como o retorno de um ativo ou volume negociado, em cada dia.

## Cont.

- O conjunto dos índices  $T$  também pode ser discreto ou contínuo.
  - Caso o conjunto seja finito ou enumerável, como por exemplo  $\mathbb{Z}$ , o processo diz-se com parâmetro discreto.
  - Caso o conjunto seja um intervalo dos  $\mathbb{R}$ , por exemplo, teremos um processo com parâmetro contínuo.

## Cont.

- É de particular interesse a utilização das chamadas distribuições finito-dimensionais (DFD) (pois, na prática, temos um conjunto finito de observações de uma ST).
- As distribuições acima são uma forma alternativa de definirmos um processo estocástico  $\{Y(t), t \in T\}$ .
- Assim, dados  $t_1, \dots, t_k \in T$ , então as DFD's correspondem as distribuições conjuntas de  $(Y(t_1), \dots, Y(t_k))'$ , ou seja:

$$F(y_1, \dots, y_k; t_1, \dots, t_k) = P(Y(t_1) \leq y_1, \dots, Y(t_k) \leq y_k)$$

## Cont.

- Um problema é que na prática só dispomos (em geral) de uma única realização do processo. Assim, para que seja viável propor uma distribuição conjunta apropriada (segundo critérios estatísticos e em termos do problema), certas restrições tem de ser impostas.
- No caso dos processos estocásticos, as restrições que devem (podem) ser impostas são de dois tipos
  - Na heterogeneidade temporal (como as DFD's variam com o tempo).
  - Na memória do processo (estrutura de dependência).

# Restrições na heterogeneidade temporal

- Pode-se assumir que a distribuição conjunta é invariante por translações. Ou seja, dado um subconjunto de índices de  $T$ , digamos  $\{t_1 < t_2 < \dots < t_m\}$ , a restrição imposta à heterogeneidade temporal, em nosso caso, corresponde à assumir que as distribuições conjuntas de

$$\{Y(t_1), Y(t_2), \dots, Y(t_m)\}$$

e

$$\{Y(t_1 + \tau), Y(t_2 + \tau), \dots, Y(t_m + \tau)\}$$

- são idênticas  $\forall \tau \in \mathbb{Z}^+$ .

# Restrições na heterogeneidade temporal

- Ou seja,  $\forall \tau \in \mathbb{Z}^+$ , temos que: (do slide anterior)

$$\begin{aligned} P(Y(t_1) \leq y_1, \dots, Y(t_k) \leq y_k) = \\ P(Y(t_1 + \tau) \leq y_1, \dots, Y(t_k + \tau) \leq y_k) \end{aligned} \quad (1)$$

- Tais processos são chamados de **estritamente estacionários**
- Em termos práticos é muito difícil ter-se e/ou conseguir verificar se um processo é estritamente estacionário.

# Comentários

- Em geral, o que se faz é considerar restrições nos Momentos do processo Estocástico, i.e,  $\mathcal{E} [Y^k(t)]$ ,  $k \in \mathbb{Z}^+$ , em particular, nos dois primeiros momentos, os quais são dados por:

- Função média:  $\mathcal{E}(Y(t)) = \mu(t)$ .
- Função de auto-covariância (facv):

$$\begin{aligned}\gamma(t_1, t_2) &= \mathcal{E} [(Y(t_1) - \mu(t_1))(Y(t_2) - \mu(t_2))] \\ &= \mathcal{E} [Y(t_1)Y(t_2)] - \mu(t_1)\mu(t_2)\end{aligned}$$

$\forall t_1, t_2 \in T$ .

- Em particular, se  $t_1 = t_2 = t$ , então  $\gamma(t, t) = \mathcal{E} [Y^2(t)] - \mu^2(t) = \mathcal{V}(Y(t)) = V(t) = \sigma^2(t)$  é a (função) variância.

# Comentários

- A  $\text{facv}$  fornece a estrutura de dependência temporal do processo estocástico ( $Y$ ). Contudo, assim como no caso usual probabilístico, a correlação é mais apropriada do que a covariância, para tal fim.
- Função de auto-correlação ( $\text{fac}$ ):

$$\rho(t_1, t_2) = \frac{\gamma(t_1, t_2)}{\sigma(t_1)\sigma(t_2)},$$

em que  $\sigma(\cdot) = \sqrt{\sigma^2(\cdot)}$ .



# Restrição na Memória do Processo

- Por outro lado, com relação a memória do processo estocástico (“grau e ordem de dependência”), um caminho simples seria assumir que o processo não tem memória. Isto é, que ele seja não (auto-) correlacionado ou independente.
- A restrição de independência é muito forte e pouco plausível, uma vez que séries temporais apresentam algum tipo de dependência temporal.
- Assim, uma forma mais apropriada é considerar que para instantes de tempo muito afastados a correlação seja nula. Dessa forma, o processo tem memória, mas esta vai diminuindo com o aumento dos intervalos entre os instantes de tempo.

# Processos estacionários

- De modo semelhante ao contexto dos modelos de regressão (ME 613), o número de parâmetros tende a ser muito grande (maior do que o número de observações), caso restrições (modelagem) não sejam consideradas (heterogeneidade temporal e/ou memória do processo).
- Por exemplo, para  $t=1,2,\dots,n$ , teremos  $y_1, \dots, y_n$  ( $n$  observações) e, pelo menos  $n$  médias ( $\mu(t)$ ) e  $n$  variâncias ( $\sigma^2(t)$ ) para estimar.

# Processos estacionários

- Portanto, faz-se mister reduzir o número de parâmetros para podermos realizar processos inferenciais de forma adequada.
- Uma das estruturas (hipóteses simplificadoras) mais comuns é a **estacionariedade** (que, à rigor, tem relação com a heterogeneidade temporal e a memória do processo).

## Cont.

- Como dito anteriormente, a suposição de estacionariedade estrita (Equação (1)) é difícil de ser avaliada (ser apropriada).
- Uma alternativa, é considerar uma estrutura de estacionariedade menos rígida, restringindo somente alguns momentos.
- Consideraremos (ao menos na parte inicial do curso) ST que (mesmo que sob alguma transformação) sejam fracamente estacionárias.

# Processo fracamente estacionário

- Um processo estocástico  $\{Y(t), t = 1, 2, \dots\}$ , com segundo momento finito  $\mathcal{E}\{Y^2(t)\} < \infty$  é dito ser fracamente estacionário (estacionário de segunda ordem, estacionário no sentido amplo ou estacionário em covariância) se, se somente se:

1  $\mathcal{E}[Y(t)] = \mu$  (constante),  $\forall t \in T$ .

2  $\mathcal{V}[Y(t)] = \mathcal{E}[(Y(t) - \mu)^2] = \sigma^2$  (constante),  $\forall t \in T$ .

- 3 A função de autocovariância (facv) é tal que  $(\forall t_1, t_2, \tau)$

$$\begin{aligned}\gamma(t_1, t_2) &= \text{Cov}[Y(t_1), Y(t_2)] = \text{Cov}[Y(t_1 + \tau), Y(t_2 + \tau)] \\ &= \gamma(t_1 + \tau, t_2 + \tau) = f(t_2 - t_1)\end{aligned}$$

Ou seja,  $\forall t_1, t_2, \tau \in T$  depende apenas da distância entre as observações e não dos instantes em si.

# Processo fracamente estacionário

- Com efeito, se  $t_1 = t_2 + \tau$ , temos que

$$\begin{aligned}\gamma(t_2 + \tau, t_2) &= \text{Cov}[Y(t_2 + \tau), Y(t_2)] = \text{Cov}[Y(\tau), Y(0)] \\ &= \gamma(\tau, 0) \equiv \gamma(\tau),\end{aligned}$$

pois  $|(t_2 + \tau) - t_2| = |\tau - 0| = |\tau|$ .

## Cont.

- Se  $\mu = 0$ , então  $\gamma(\tau) = \mathcal{E} [Y(t)Y(t + \tau)]$ .
- Assim, é possível provar que (exercício):
  - 1  $\gamma(0) > 0$ .
  - 2  $\gamma(-\tau) = \gamma(\tau)$ .
  - 3  $|\gamma(\tau)| \leq \gamma(0)$ .
- Uma outra importância (além da modelagem da dependência temporal) da correta especificação da função média e da cov deve-se ao fato de que, se as distribuições finito-dimensionais de  $Y(t)$  são normais (**multivariadas**), o processo estocástico será totalmente conhecido, em se conhecendo  $\mu$  e  $\gamma$ .

## Cont.

- No caso geral, em que  $\mu \neq 0$ , temos que:

$$\gamma(\tau) = \text{Cov}[Y(t), Y(t + \tau)] = \mathcal{E}[(Y(t) - \mu)(Y(t + \tau) - \mu)]$$

$\forall t, \tau \in T$ , dependa somente de  $\tau$  e não de  $t$ .

- Existem formas empíricas e inferenciais de verificar se uma ST é fracamente estacionária (veremos algumas ao longo do curso).
- Muitas das classes de modelos que serão vistas são apropriadas para ST fracamente estacionárias.



## Cont.

- Se os dois primeiros momentos existirem, então

Estacionariedade forte  $\rightarrow$  Estacionariedade fraca

- A volta só vale se as distribuições finito-dimensionais de  $Y(t)$  (ou seja, de  $(Y(t_1), \dots, Y(t_k))'$ ) forem **normais (multivariadas)** (Processo Gaussiano).
- Sob estacionariedade fraca ( $\mathcal{V}[Y(t)] = \mathcal{V}[Y(t + \tau)]$ ), a fac torna-se

$$\rho(\tau) = \frac{\text{Cov}[Y(t), Y(t + \tau)]}{\sqrt{\mathcal{V}[Y(t)]}\sqrt{\mathcal{V}[Y(t + \tau)]}} = \frac{\gamma(\tau)}{\gamma(0)}$$

- A representação gráfica da expressão anterior (fac) é chamada de correlograma.

## Cont.

- Como na prática, temos somente uma única realização de um processo estocástico (isto é, uma única série temporal observada), podemos calcular apenas as funções amostrais (estimadores/estimativas), considerando uma ST de tamanho  $n$ :

- Função média amostral:  $\hat{\mathcal{E}}(Y(t)) = \hat{\mu} = \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i.$

- Função variância amostral:  $\hat{\mathcal{V}}(Y(t)) = \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^2.$

- Função de auto-covariância amostral:  $\hat{\gamma}(\tau) = \frac{1}{n} \sum_{i=1}^{n-\tau} (Y_i - \bar{Y})(Y_{i+\tau} - \bar{Y}).$

## Cont.

- Cont. (estimadores)

- Função de autocorrelação amostral:

$$\hat{\rho}(\tau) = \frac{\hat{\gamma}(\tau)}{\hat{\gamma}(0)} = \frac{\frac{1}{n} \sum_{i=1}^{n-\tau} (Y_i - \bar{Y})(Y_{i+\tau} - \bar{Y})}{\frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^2}$$

- As respectivas estimativas são dadas por:

- Função média amostral:  $\tilde{\mathcal{E}}(Y(t)) = \tilde{\mu}(t) = \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i.$

- Função variância amostral:  $\tilde{\mathcal{V}}(Y(t)) = \tilde{\sigma}^2(t) = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2.$

## Cont.

- Cont. (estimativas)

- Função de auto-covariância amostral:

$$\tilde{\gamma}(\tau) = \frac{1}{n} \sum_{i=1}^{n-\tau} (y_i - \bar{y})(y_{i+\tau} - \bar{y}).$$

- Função de auto-correlação amostral:

$$\tilde{\rho}(\tau) = \frac{\tilde{\gamma}(\tau)}{\tilde{\gamma}(0)} = \frac{\frac{1}{n} \sum_{i=1}^{n-\tau} (y_i - \bar{y})(y_{i+\tau} - \bar{y})}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}$$

- Na prática, calculamos  $\tilde{\rho}(\tau)$ ,  $\tau = 1, 2, \dots, l$ , em que  $l < n$  é chamado de lag (defasagem) máxima.

# Ilustração do cálculo das auto-correlações ( $\tau = 0$ )

$Y_1$	.	.	...	.	.
$Y_2$	$Y_2$	.	...	.	.
$Y_3$	$Y_3$	$Y_3$	...	.	.
$\vdots$	$\vdots$	$\vdots$	$\ddots$	.	.
$Y_{n-2}$	$Y_{n-2}$	$Y_{n-2}$	...	.	.
$Y_{n-1}$	$Y_{n-1}$	$Y_{n-1}$	...	$Y_{n-1}$	.
$Y_n$	$Y_n$	$Y_n$	...	$Y_n$	$Y_n$

# Ilustração do cálculo das auto-correlações ( $\tau = 1$ )

$Y_1$	.	.	...	.	.
$Y_2$	$Y_2$	.	...	.	.
$Y_3$	$Y_3$	$Y_3$	...	.	.
$\vdots$	$\vdots$	$\vdots$	$\ddots$	.	.
$Y_{n-2}$	$Y_{n-2}$	$Y_{n-2}$	...	.	.
$Y_{n-1}$	$Y_{n-1}$	$Y_{n-1}$	...	$Y_{n-1}$	.
$Y_n$	$Y_n$	$Y_n$	...	$Y_n$	$Y_n$

# Ilustração do cálculo das auto-correlações ( $\tau = 2$ )

$Y_1$	.	.	...	.	.
$Y_2$	$Y_2$	.	...	.	.
$Y_3$	$Y_3$	$Y_3$	...	.	.
$\vdots$	$\vdots$	$\vdots$	$\ddots$	.	.
$Y_{n-2}$	$Y_{n-2}$	$Y_{n-2}$	...	.	.
$Y_{n-1}$	$Y_{n-1}$	$Y_{n-1}$	...	$Y_{n-1}$	.
$Y_n$	$Y_n$	$Y_n$	...	$Y_n$	$Y_n$

## Observação (Processo Estacionário)

- É possível provar que  $(a_i, i = 1, \dots, n$  não aleatórios):

$$\mathcal{V} \left( \sum_{i=1}^n a_i Y_i \right) = \sum_{i=1}^n \sum_{j=1}^n a_i a_j \gamma(i-j) \geq 0.$$

- Dessa forma, um estimador para a variância acima, tem de gerar estimativas  $\geq 0$  com probabilidade 1, ou seja

$$\hat{\mathcal{V}} \left( \sum_{i=1}^n a_i Y_i \right) = \sum_{i=1}^n \sum_{j=1}^n a_i a_j \hat{\gamma}(i-j) \geq 0.$$

- O estimador  $\hat{\gamma}(\tau)$  garante a restrição acima, mas o estimador  $\hat{\gamma}^*(\tau) = \frac{n}{n-\tau} \hat{\gamma}(\tau)$ , não. Contudo, ambos são viciados.



## Cont.

- **Bartlett (1946)** mostrou que se uma ST apresentar um comportamento puramente aleatório (essencialmente, as observações tem correlação nula), então os estimadores dos coeficientes de auto-correlação  $\hat{\rho}(\tau)$  terão distribuição aproximadamente  $N(0, \frac{1}{n})$ , em que  $n$  é o tamanho da amostra (tamanho da ST).

## Cont.

- Assim, não é difícil demonstrar que o intervalo de confiança (assintótico) bicaudal, com por exemplo  $\delta\%$  de confiança, para qualquer  $\rho(\tau)$  será dado por:

$$\widehat{\rho}(\tau) \pm z_\delta \frac{1}{\sqrt{n}}$$

em que  $P(Z \leq z_\delta) = \frac{1 + \delta}{2}$ ,  $Z \sim N(0, 1)$ .

# Ruído branco (RB)

- Um outro processo estocástico bastante útil em ST é o chamado ruído branco (“white noise”). Esse termo é emprestado da engenharia de processamento de sinais.
- Dizemos que um processo  $\{\epsilon(t), t \in \mathbb{Z}\}$ , é um RB se as variáveis aleatórias ( $\epsilon(t)$ ) forem não correlacionadas, ou seja, se 
$$\text{Cov}[\epsilon(t), \epsilon(t - \tau)] = 0, \forall t \in \mathbb{Z} \text{ e } \forall \tau \neq 0.$$
- Tal processo será estacionário se  $\mathcal{E}[\epsilon(t)] = \mu$  e  $\mathcal{V}[\epsilon(t)] = \sigma^2, \forall t$ . Esse tipo de RB será bastante utilizado ao longo do curso.

# FAC e estacionariedade

- Um processo estacionário pode ser identificado por sua FAC, à medida que esta vai para zero “rapidamente” (com o aumento de  $\tau$ ) para processos desse tipo.
- O que é “rapidamente”? A dependência em relação ao passado diminui exponencialmente, por exemplo.

## Cont.

- A função de autocorrelação (FAC) proporciona evidências sobre a estacionariedade de uma ST. Tipicamente, séries temporais não-estacionárias apresentam FAC's com valores altos e significativos para muitas defasagens.
- Nos quatro exemplos a seguir, simulamos  $n = 1.000$  valores das ST em que  $\sigma^2 = 4$  e os demais parâmetros mencionados nos respectivos slides.

# Exemplo 1

- Considere o seguinte processo (RB):

$$Y(t) = \epsilon(t), t = 1, 2, 3, \dots$$

$$\epsilon(t) \sim NID(0, \sigma^2)$$

em que  $NID(\mu, \sigma^2)$  significa iid (independente e identicamente distribuídas)  $N(\mu, \sigma^2)$ .

- $Y(t)$  é fracamente estacionária? Notemos que,  $\mathcal{E}(Y(t)) = 0, \forall t$ ,  $\mathcal{V}(Y(t)) = \sigma^2$ ,  $Cov(Y(t), Y(t - \tau)) = 0$ . Logo,  $Y(t)$  é fracamente estacionária.

# Ilustração gráfica




Figura: Exemplo 1

## Exemplo 2

- Considere o seguinte processo:

$$Y_t = \delta_0 + \delta_1 t + \epsilon_t, t = 1, 2, 3, \dots$$

$$\epsilon_t \sim NID(0, \sigma^2), \delta_1 \neq 0$$

- 1  $Y_t$  é fracamente estacionária?
  - 2  $Y_t - E(Y_t)$  é fracamente estacionária?
  - 3  $Y_t - Y_{t-1}$  é fracamente estacionária?
  - 4 Qual a intuição dos procedimentos (2) e (3)?
- Nos próximos dois slides discutiremos os quatro pontos acima.



## Cont.

- 1 Temos que  $\mathcal{E}(Y_t) = \delta_0 + \delta_1 t$ , que não é constante. Assim, apesar de que  $\mathcal{V}(Y_t) = \sigma^2$  e  $\text{Cov}(Y_t, Y_{t-h}) = 0, \forall t, h \geq 1$ , o processo não é fracamente estacionário.
- 2 Defina  $Z_t = Y_t - E(Y_t)$ . Assim, pelo item 1),  $Z_t = \epsilon_t$  e, pelo exemplo 1, o processo em questão é fracamente estacionário.

## Cont.

- 3 Defina  $W_t = Y_t - Y_{t-1}$ . Pelo enunciado, temos que  $W_t = \delta_1 + \epsilon_t - \epsilon_{t-1}$ . Assim,  $\mathcal{E}(W_t) = \delta_1$ ,  $\mathcal{V}(W_t) = 2\sigma^2$  e  $\text{Cov}(W_t, W_{t-h}) = \text{Cov}(\epsilon_t - \epsilon_{t-1}, \epsilon_{t-h} - \epsilon_{t-h-1}) = -\mathcal{V}(\epsilon_{t-1}) = -\sigma^2$ , se  $h = 1$  e  $0$ , caso contrário. Assim, o processo em questão é fracamente estacionário.
- 4 A intuição dos procedimentos (2) e (3) é buscar transformações que gerem processos que dependam apenas do RB e, eventualmente, também de quantidades não aleatórias.

# Ilustração gráfica ( $\delta_0 = 1, \delta_1 = 0,05$ )




Figura: Exemplo 2

## Exemplo 3

- Considere o seguinte processo:

$$Y_t = Y_{t-1} + \epsilon_t, t = 1, 2, 3, \dots$$

$$\epsilon_t \sim NID(0, \sigma^2), Y_0 \equiv 0$$

- 1  $Y_t$  é fracamente estacionária?
- 2  $Y_t - Y_{t-1}$  é fracamente estacionária?
- 3 Qual a intuição do procedimento (2)?

- No próximo slide discutiremos os quatro pontos acima.

## Cont.

- Primeiramente, note que (exercício)  $Y_t = \sum_{i=1}^t \epsilon_i$  (representação de médias móveis). Assim,  $\mathcal{E}(Y_t) = 0$ , que é constante  $\forall t$ . Mas,  $\mathcal{V}(Y_t) = \sigma^2 t$ , o qual não é constante em  $t$ . Além disso,  $Cov(Y_t, Y_{t-\tau}) = Cov\left(\sum_{i=1}^t \epsilon_i, \sum_{i=1}^{t-\tau} \epsilon_i\right) = \mathcal{V}\left(\sum_{i=1}^{t-\tau} \epsilon_i\right) = \sigma^2(t-\tau)$ . Portanto o processo não é fracamente estacionário.
- Defina  $W_t = Y_t - Y_{t-1}$ . Pelo enunciado, temos que  $W_t = \epsilon_t$ . Assim,  $\mathcal{E}(W_t) = 0$ ,  $\mathcal{V}(W_t) = \sigma^2$  e  $Cov(W_t, W_{t-h}) = Cov(\epsilon_t, \epsilon_{t-h}) = 0$ , caso contrário. Assim, o processo em questão é fracamente estacionário.

# Ilustração gráfica





Figura: Exemplo 3

## Exemplo 4

- Considere o seguinte processo:

$$Y_t = \epsilon_t - \alpha\epsilon_{t-1}, t = 1, 2, 3, \dots$$

$$\epsilon_t \sim NID(0, \sigma^2), \alpha \neq 0, \epsilon_0 \equiv 0$$

- $Y_t$  é fracamente estacionária? Note que  $\mathcal{E}(Y_t) = 0$ ,  $\mathcal{V}(Y_t) = \sigma^2(1 + \alpha^2)$  e  $Cov(Y(t), Y(t - \tau)) = Cov(\epsilon_t - \alpha\epsilon_{t-1}, \epsilon_{t-\tau} - \alpha\epsilon_{t-\tau-1}) = -\alpha\sigma^2$ , se  $\tau = 1$  e 0, caso contrário. Assim, o processo em questão é fracamente estacionário.

# Ilustração gráfica ( $\alpha = 1$ )




Figura: Exemplo 4



# Exercício 1

- Considere o seguinte processo:

$$Y_t = \alpha + Y_{t-1} + \epsilon_t, t = 1, 2, 3, \dots$$

$$\epsilon_t \sim NID(0, \sigma^2), \alpha \neq 0, Y_0 = 0 \text{ (constante)}$$

- 1  $Y_t$  é fracamente estacionária?
- 2  $Y_t - Y_{t-1}$  é fracamente estacionária?
- 3 Simule  $t=1.000$  observações com  $\alpha = 1$  e  $\sigma^2 = 4$ , apresentando os gráficos da série gerada e do respectivo ACF.

## Exercício 2

- Considere o seguinte processo:

$$Y_t = \phi Y_{t-1} + \epsilon_t, t = 1, 2, 3, \dots$$

$$\epsilon_t \sim NID(0, \sigma^2), Y_0 = 0 \text{ (constante)}$$

- 1  $Y_t$  é fracamente estacionária?
- 2  $Y_t - \phi Y_{t-1}$  é fracamente estacionária?
- 3 Para  $\phi = 1, 1$ , simule  $t=1.000$  observações com  $\alpha = 1$  e  $\sigma^2 = 4$ , apresentando os gráficos da série gerada e do respectivo ACF.
- 4 Para  $\phi = -1, 1$ , simule  $t=1.000$  observações com  $\alpha = 1$  e  $\sigma^2 = 4$ , apresentando os gráficos da série gerada e do respectivo ACF.

## Cont.

- 5 Para  $\phi = 0,8$ , simule  $t=1.000$  observações com  $\alpha = 1$  e  $\sigma^2 = 4$ , apresentando os gráficos da série gerada e do respectivo ACF.
- 6 Para  $\phi = -0,8$ , simule  $t=1.000$  observações com  $\alpha = 1$  e  $\sigma^2 = 4$ , apresentando os gráficos da série gerada e do respectivo ACF.
- 7 Sob quais condições você acredita que  $Y_{t \geq 1}$  seja estacionária? Justifique adequadamente a sua resposta.

# Transformações

- Como mencionado, uma das principais suposições a serem consideradas é a estacionariedade, uma vez que muitas das abordagens que serão vistas, dependem da validade de tal suposição.
- Comumente, a ST original não apresenta tal propriedade.
- Uma forma de lidar com essa situação é através de transformações apropriadas.

## Transformações: operador diferença

- Um operador bastante útil e comum em ST é o chamado operador diferença( $\Delta$ ), o qual é definido por:

$$\Delta Y_t = Y_t - Y_{t-1}$$

- Aplicando novamente o operador diferença na equação acima vem que:

$$\begin{aligned}\Delta^2 Y_t &= \Delta(Y_t - Y_{t-1}) = Y_t - Y_{t-1} - (Y_{t-1} - Y_{t-2}) \\ &= Y_t - 2Y_{t-1} + Y_{t-2}\end{aligned}$$

# Transformações: operador diferença

- A n-ésima diferença é obtida recursivamente por:

$$\Delta^n Y_t = \Delta (\Delta^{n-1} Y_t)$$

- Normalmente, uma ou duas diferenças são suficientes para tornar uma dada série estacionária.

# Transformação potência

- Proposta por [Tukey \(1957\)](#), dada por:

$$Y_t^{(\lambda)} = g(Y_t) = \begin{cases} Y_t^\lambda, \lambda \neq 0 \\ \ln Y_t, \lambda = 0 \end{cases} \quad (2)$$

- Casos particulares (além da transformação  $\ln(\cdot)$ ).
  - $\lambda = 1$ , então  $g(Y_t) = Y_t$ .
  - $\lambda = 2$ , então  $g(Y_t) = Y_t^2$ .
  - $\lambda = 1/2$ , então  $g(Y_t) = \sqrt{Y_t}$ .

# Transformação Box-Cox

- Para mitigar problemas de descontinuidade (para  $\lambda = 0$ ), [Box & Cox \(1964\)](#) propuseram:

$$Y_t^{(\lambda)} = g(Y_t) = \begin{cases} \frac{Y_t^\lambda - 1}{\lambda}, \lambda \neq 0 \\ \ln Y_t, \lambda = 0 \end{cases} \quad (3)$$

- As transformações dadas em (2) e (3), são mais apropriadas quando se busca obter normalidade da ST (não se prestam, à rigor, para a obtenção de estacionariedade). Veja também [aqui](#).



## Ilustração gráfica: Exemplo 2 ( $t \times \Delta Y_t$ )




Figura: Exemplo 2 (transformação diferença de ordem 1)

## Ilustração gráfica: Exemplo 3 ( $t \times \Delta Y_t$ )




Figura: Exemplo 2: (transformação diferença de ordem 1)