

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 Ω .
- 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 ω , 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.

Cont.

- Se $\mu(t) = 0, \forall t$, então $\gamma(t_1, t_2) = \mathcal{E}[Y(t_1)Y(t_2)]$.
- Além disso, sem perda de generalidade, defina:

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

- Assim, é possível provar que (exercício):
 - 1 $\gamma(0) > 0$.
 - 2 $\gamma(-\tau) = \gamma(\tau)$.
 - 3 $|\gamma(\tau)| \leq \gamma(0)$.

Comentários

- A *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 (*fac*):

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

em que $\sigma(\cdot) = \sqrt{\sigma^2(\cdot)}$. Analogamente à $\gamma(\cdot, \cdot)$ temos que

$$\rho(t, t - \tau) = \frac{\gamma(t, t - \tau)}{\sigma(t)\sigma(t - \tau)}$$

Comentários

- Uma outra importância 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 μ e γ .

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, e 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

$$\gamma(t_1, t_2) = \text{Cov}[Y(t_1), Y(t_2)] = f(t_2 - t_1)$$

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

Cont.

- O item 3) do slide anterior, é análogo à que :

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

$\forall t \in T$ e $\forall \tau \geq 1$, dependa somente de τ 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: $\hat{\mathcal{E}}(Y(t)) = \hat{\mu}(t) = \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i$.

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

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

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.

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 (asintótico) 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 τ) 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, $\text{Cov}(Y_t, Y_{t-\tau}) = \text{Cov}\left(\sum_{i=1}^t \epsilon_i, \sum_{i=1}^{t-\tau} \epsilon_i\right) = \mathcal{V}\left(\sum_{i=1}^{t-\tau} \epsilon_i\right) = \sigma^2(t-\tau)$. Portanto o processo não é fracamente estacionário.
- Defina $W_t = Y_t - Y_{t-1}$. Pelo enunciado, temos que $W_t = \epsilon_t - \epsilon_{t-1}$. Assim, $\mathcal{E}(W_t) = 0$, $\mathcal{V}(W_t) = 2\sigma^2$ 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.

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(Δ), 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)