

# Modelagem de Séries Temporais





# Modelos AR

- No nosso exemplo de suavização exponencial temos a fórmula:

$$\hat{y}(t) = \alpha y(t) + (1 - \alpha)\hat{y}(t - 1)$$

Como a mesma fórmula funciona para  $t - 1$ , também temos que:

$$\hat{y}(t - 1) = \alpha y(t - 1) + (1 - \alpha)\hat{y}(t - 2)$$

Substituindo fica:

$$\hat{y}(t) = \alpha y(t) + (1 - \alpha)\alpha y(t - 1) + (1 - \alpha)^2 \hat{y}(t - 2).$$

Logo, estamos construindo uma previsão  $\hat{y}$  que é a média das anteriores, mas uma média que dá muito mais peso para a primeira do que as anteriores.

# Modelos AR

- De fato, modelos com essa cara são importantes e recebem até um nome específico: modelos auto-regressivos. Nesses modelos, a equação da nossa previsão é parecida com:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2}$$

Claro que podemos pegar muitos dados para trás:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p}$$

Normalmente admitimos que essa equação tem algum tipo de erro, então, parecido com o caso de uma regressão, dizemos que o modelo tem um erro  $\epsilon_t$  ruído branco:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \epsilon_t$$

Dizemos que esse modelo é Auto-Regressivo de ordem  $p$  ou  $AR(p)$

# Exemplos de modelos AR

Modelos AR normalmente desenham retinhas em que pontos próximos são parecidos:

escolhendo  $p = 1$  e  $\phi_1 = 0.9$

# Exemplos de modelos AR

Note como esse desenho é diferente do ruído branco:

Inclusive, o ruído branco aparece quando escolhemos  $p = 1$  e  $\phi_1 = 0$

# Exemplos de modelos AR

Exemplo muito especial:

O gráfico abaixo, um AR com  $p = 1$  e  $\phi_1 = 1$ , te lembra alguma coisa?

# Porque o modelo auto regressivo é importante?

- Alguns fenômenos são quase que perfeitamente modelos AR, como o preço de uma ação, por exemplo.
- Gráficos de ACF e PACF, que as vezes são meio difíceis de interpretar, tem padrões específicos no modelo.
- O AR(1), por exemplo, tem uma ACF bem especial
- Modelos auto-regressivos costumam ter ACF que decaem rápido, mas ficam um bom tempo longe do zero. No caso do AR(1), a ACF tem até fórmula:

$$ACF(t) = \phi_1^t$$



# ACF do AR(1)

Vamos pensar no porque isso é desse jeito com  $\phi_1 = .8$

# ACF de um AR com coeficiente negativo

Quando  $\phi$  é negativo fica mais estranho:

$$\phi_1 = -.8$$

# PACF

Justamente pensando no impacto "persistente" do passado na série como um todo, foi inventado o conceito de **Função Auto Correlação Parcial**. Ela é que nem a auto correlação, mas ao invés de fazer a correlação diretamente, ela "limpa" os efeitos persistentes fazendo regressões.

Por exemplo, vamos pensar no modelo AR(1):

$$y_t = y_{t-1} + \epsilon_t$$

$$y_{t-1} = y_{t-2} + \epsilon_{t-1} \implies y_{t-2} = y_{t-1} - \epsilon_{t-1}$$

Como tanto o  $y_t$  quanto o  $y_{t-2}$  podem ser escritos em função de  $y_{t-1}$ , é natural que eles sejam correlacionados: eles são montados a partir do mesmo número. O que a PACF faz é calcular a correlação entre  $\epsilon_{t-1}$  e  $\epsilon_t$ , esses sim são não correlacionados.

# PACF na prática

A PACF na prática nos ajuda a identificar o grau adequado de autocorrelação de uma série. Note como é a forma da PACF de um AR(1) com  $\phi_1 = .8$

# PACF na prática

PACF de um AR(2) e  $\phi_1 = .7$  e  $\phi_2 = .3$

# PACF na prática

# PACF na prática

ACF com bastante autocorrelação:

# PACF na prática

PACF consegue identificar que muita dessa correlação é redundante, temos uma autocorrelação no primeiro grau muito alta e talvez uma autocorrelação de ordem maior.



# Como modelos alterar um modelo AR


Pensar em um AR ajuda a interpretar auto-correlações, mas as PACFs típicas de um modelo AR são muito rígidas. A PACF da série da ANAC não concorda com um AR simples:

# Processo MA

Uma média móvel usa uma ideia parecida com a do AR para montar um modelo que se parece com o ruído branco, mas é varia menos em janelas próximas

$$y_t = \epsilon_t + \theta_1\epsilon_{t-1} + \dots + \theta_q\epsilon_{t-q}$$

# Ruído branco (de novo)



# Média movel

Vamos escolher  $q = 1$  e  $\theta_1 = 0.9$

# ACF do modelo MA(q)

$$q = 1 \text{ e } \theta_q = 0.9$$


# ACF do modelo MA(q)

$$q = 2 \text{ e } \theta_1 = 0.9, \theta_2 = 0.9$$

# Processo ARMA


Um processo ARMA é um processo que mistura a parte autoregressiva com o resíduo média móvel, que pode ter correlações em um janela específica. Isso garante que o "desenho" de um processo arma é menos dentado do que um modelo auto regressivo simples. Considere essa simulação de um ARMA(1,1):

# ARMA(1,1)





# ARMA(1, 6)



# Intuição geral

Um modelo ARMA é um modelo:

- De caráter **Auto Regressivo**:  $y_t, y_{t-1}, y_{t-2}$  etc podem ter relação direta e persistente entre eles.
- Com resíduos em **Média Móvel**:  $y_{t-1}$  vai a  $y_t$  de maneira suave, similar ao jeito que  $y_{t-2}$  foi a  $y_{t-1}$

Aparentemente olhando todos os modelos  $ARMA(p, q)$  temos uma grande ferramenta para ajustarmos praticamente qualquer série temporal, mas faltam dois elementos **tendência** e **sazonalidade**.

# Diferenças

Um jeito rudimentar de "limpar" uma série temporal de tendência e possivelmente de sazonalidade é através do método das diferenças. Isso é, criar uma nova série temporal  $d$  da seguinte forma:

$$d_t = y_t - y_{t-1}$$

# Voltando à série da ANAC

Essa série tem tendência e possivelmente também tem sazonalidade:

# Diferenças da série da ANAC

Aqui a tendência sumiu:

# ACF da série de Diferenças da ANAC

# PACF da série de Diferenças da ANAC

# Diferença da diferença

Aqui a série talvez já possa ser modelada adequadamente por um ARMA...



# ACF da série de Diferenças da ANAC

# Modelo ARIMA

Assim como sugerimos no último exemplo, um modelo ARIMA nada mais é que um modelo ARMA (auto regressivo e com resíduo em média móvel) ajustado à uma (ou mais) diferenças de uma série temporal. Justamente por essa característica, fora os pesos, um modelo ARIMA costuma vir acompanhando de três letras:

- $p$  que vem do  $AR(p)$ ,
- $d$  que vem da ordem da diferença (se é diferença simples, ou diferença da diferença, ou diferença da diferença da diferença etc)
- $q$  que vem do  $MA(q)$

Logo, um  $ARIMA(p, 1, q)$  seria:

$$y_t - y_{t-1} = d_t \sim ARMA(p, q)$$

Já um  $ARIMA(p, 2, q)$  seria:

$$d_t - d_{t-1} = y_t - y_{t-1} - y_{t-1} + y_{t-2} \sim ARMA(p, q)$$

# ARIMA Sazonal

Temos ainda a situação em que tentamos estimar dois ARMAS ao mesmo tempo