

Tópicos Avançados em IA

Prof. James Moraes de Almeida




- Séries temporais:
 - 01/10/2026: O que são e decomposição.
 - 08/10/2026: Previsão.
 - 22/10/2026: Métodos de aprendizado de máquina.
- Aprendizado ativo e otimização bayesiana:
 - 29/10/2026: Aprendizado ativo.
 - 05/11/2026: Processos gaussianos e otimização bayesiana.
 - 12/11/2026: Transformers.
- 19/11/2026: Prova/Apresentação.


Séries Temporais

- A Aula 01 em uma figura


os componentes



aditiva: amplitude fixa




multiplicativa: amplitude cresce com o nível




- série = tendência + sazonalidade + resíduo

- Tem sazonalidade mesmo?


série sintética (Aula 01): de 100 a 482




rupia por dólar: de 7 a 74 rúpias



sua sazonalidade, na mesma escala: $\pm 20,1$




sua "sazonalidade", na mesma escala: $\pm 0,31$ rúpia



- A decomposição sempre devolve uma sazonalidade; na rupia ela é menor que o ruído.

Séries Temporais

- Previsão de séries temporais




- Previsão de séries temporais.
 - A primeira coisa que precisamos é separar os conjuntos de treino e teste:
 - Já sabemos fazer isso professor, aprendemos no 2º semestre.
 - Ok, mas funciona uma separação aleatória para uma série temporal?




Séries Temporais

- Previsão de séries temporais.
 - A primeira coisa que precisamos é separar os conjuntos de treino e teste:
 - Já sabemos fazer isso professor, aprendemos no 2º semestre.
 - Ok, mas funciona uma separação aleatória para uma série temporal?
 - Não!
 - Temos que separar uma porção do “futuro”


Airline passengers train and test sets




- Previsão de séries temporais.
 - A primeira coisa que precisamos é separar os conjuntos de treino e teste:
 - E se eu quero fazer validação cruzada?
 - Janela deslizante (sliding window).



- Previsão de séries temporais.
 - A primeira coisa que precisamos é separar os conjuntos de treino e teste:
 - E se eu quero fazer validação cruzada?
 - Janela deslizante com lacuna (sliding window with gap).



- Previsão de séries temporais.
 - A primeira coisa que precisamos é separar os conjuntos de treino e teste:
 - E se eu quero fazer validação cruzada?
 - Janela em expansão (expanding window).




- Previsão de séries temporais.
 - A primeira coisa que precisamos é separar os conjuntos de treino e teste:
 - No Scikit-Learn, há um método específico para isso, o TimeSeriesSplit.
 - Aplica o método da janela em expansão.
 - Escrevi no Notebook da aula como gerar as diferentes divisões de teste e treino.

Séries Temporais

- A série desta aula


$$y_t = 100 + 0,8t + 15 \sin\left(\frac{2\pi t}{7}\right) + \varepsilon_t, \quad \varepsilon_t \sim \mathcal{N}(0, 4^2), \quad t = 0, 1, \dots, 199 \text{ dias}$$



- u.a.: unidades arbitrárias. A série é sintética, não tem unidade física.

Séries Temporais

- Antes de qualquer modelo: ele ganha de uma regra boba?



- Walk-forward: prever um passo, revelar o valor real, repetir.

- Como comparar os modelos

$$\text{MAE} = \frac{1}{n} \sum_t |e_t|$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_t e_t^2}$$


$$\text{MASE} = \frac{\text{MAE}}{\text{MAE da ingênua sazonal no treino}}$$

- MAE (mean absolute error): o erro absoluto médio.
- RMSE (root mean squared error): a raiz do erro quadrático médio.
- MASE (mean absolute scaled error): o MAE escalado pela ingênua sazonal.
- $\text{MASE} < 1$: melhor que repetir a semana passada. Não tem unidade.


Séries Temporais

- Olhando a série: uma reta e um padrão semanal

o que se vê: uma reta...



... e um padrão que se repete toda semana




- O que se vê já é um modelo: tendência + sazonalidade, como na Aula 01.

Séries Temporais

- Modelo 1: reta + dia da semana


$$y_t = a + bt + c_{\text{dia}(t)} + \varepsilon_t$$



- Só olhando a série: MASE 0,52, metade do erro da ingênua sazonal.

Séries Temporais


- Como é uma série estacionária?



- O que sobra de um bom modelo deveria ser assim. O que muda aqui? E o que não muda?

Séries Temporais







- Estacionária: as duas metades dão o mesmo



- Média, variância e covariância não dependem do instante t .

Séries Temporais

- Não estacionária: alguma coisa muda com o tempo







- A mesma régua: em cada série, uma das três medidas muda entre as metades.

Séries Temporais




- ACF, função de autocorrelação: a série comparada com ela mesma, k passos atrás

$$\rho_k = \frac{\text{Cov}(y_t, y_{t-k})}{\text{Var}(y_t)}$$



Séries Temporais

- O que sobra do Modelo 1 tem memória?




- Não: o que sobra é ruído branco. Para esta série, o Modelo 1 basta.


Séries Temporais

- Outra série: o que sobra tem memória


o que sobra: ondas que duram dias



hoje x ontem: 0,76



ACF do que sobra




- Mesma reta e mesmo padrão semanal; o ruído agora carrega o dia anterior.

Séries Temporais

- Usar a memória: somar o que sobrou ontem

$$\hat{y}_t = \text{Modelo } 1_t + \phi \cdot (y_{t-1} - \text{Modelo } 1_{t-1})$$




- MASE de 0,42 para 0,27. Isso é um modelo autorregressivo (AR) no que sobra.

- Autorregressivo (AR): o choque vai sumindo

$$y_t = 0,7 y_{t-1} + \varepsilon_t$$

em geral, $AR(p)$: $y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t$

AR(1), $\phi = 0,7$: o choque vai sumindo




- ε : o choque, um sorteio novo e independente a cada instante (ruído branco).
- Um choque de hoje pesa 0,7 amanhã, 0,49 depois de amanhã: a memória decai

- Média móvel (MA): o choque some depois de q dias

$$y_t = \varepsilon_t + 0,7 \varepsilon_{t-1} \quad \text{em geral, MA}(q): \quad y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q}$$

MA(1), $\theta = 0,7$: o choque some depois de 1 dia



- Não é a média móvel da Aula 01: é uma regressão nos choques passados.

- ARMA(p, q): as duas memórias juntas

$$y_t = \underbrace{\phi_1 y_{t-1} + \cdots + \phi_p y_{t-p}}_{\text{valores passados (AR)}} + \varepsilon_t + \underbrace{\theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q}}_{\text{choques passados (MA)}}$$


símbolo	o que é
p	quantos valores passados entram
q	quantos choques passados entram
ϕ e θ	os pesos, estimados dos dados

Séries Temporais


- Outro jeito de tirar a tendência: hoje menos ontem

$$\Delta y_t = y_t - y_{t-1}$$

dia	hoje	ontem	hoje – ontem
01/01	101,2		
02/01	108,4	101,2	7,2
03/01	119,2	108,4	10,8
04/01	112,7	119,2	-6,5
05/01	88,9	112,7	-23,8
06/01	84,2	88,9	-4,7
07/01	93,6	84,2	9,4



hoje – ontem: sem tendência, média 0,82




Séries Temporais


- Diferença sazonal: menos o mesmo dia da semana anterior

$$\Delta y_t - \Delta y_{t-7}$$

hoje – ontem: o padrão se repete a cada 7 dias





menos o mesmo dia da semana anterior



Séries Temporais



- Série não estacionária: a ACF decai devagar



- Depois das duas diferenças, a ACF cai logo: sobram picos isolados nos lags 1 e 7.

- Teste ADF (Dickey-Fuller aumentado): a série volta para a média?


$$\Delta y_t = \alpha + \gamma y_{t-1} + \sum_{i=1}^p \delta_i \Delta y_{t-i} + \varepsilon_t$$



- $\gamma < 0$: volta, estacionária. $\gamma = 0$: não volta, como o passeio aleatório.

Séries Temporais

- O ADF em seis séries




- Nas três de cima sabemos a resposta, e o teste acerta.

- Predições!
 - Vamos começar com o método ARIMA:
 - Autoregressive Integrated Moving Average.
 - ARIMA(p,d,q)
 - p: nº de valores passados (lag).
 - Ex.: $p = 1$ usa só o valor de ontem.
 - d: nº de diferenças, já vistas.
 - Para deixar os dados estacionários.
 - q: nº de erros passados no modelo.

Séries Temporais

- d: quantas vezes aplicar "hoje menos ontem"



$$\Delta y_t = y_t - y_{t-1}$$

$$\Delta^2 y_t = \Delta y_t - \Delta y_{t-1}$$

$$d = \min \{ k : \Delta^k y_t \text{ é estacionária} \}$$

- Cada diferença baixa o grau da tendência:

$$a + bt \xrightarrow{\Delta} b \quad (d = 1)$$

$$a + bt + ct^2 \xrightarrow{\Delta} b - c + 2ct$$
$$\xrightarrow{\Delta} 2c \quad (d = 2)$$

- Na série da aula a tendência é uma reta: d = 1.

- ARIMA(p, d, q): prever a mudança e somar de volta


y'_t = a série depois de d diferenças, prevista por um ARMA(p , q)

$$\hat{y}_{t+1} = y_t + \hat{y}'_{t+1} \quad (d = 1)$$


$$\text{mudança prevista} = \text{média das mudanças} = \frac{y_{199} - y_0}{199} = \frac{100,12 - 2,04}{199} = 0,49 \quad (\text{inclinação verdadeira: } 0,5)$$

a série com tendência em reta do slide anterior: $0,5 \cdot t + \text{ruído}$

1. o modelo prevê a mudança



2. somando de volta: a previsão da série




- Somar de volta é o I de ARIMA (integrated). No código: ARIMA(y, order=(p, d, q)).

Séries Temporais

- SARIMA, o ARIMA sazonal: a sazonalidade também tem memória

$$y_t = y_{t-m} + \varepsilon_t$$

cada seta: o mesmo dia da semana, 7 dias depois



- m vem do calendário: diário 7 • mensal 12 • horário 24

- P e Q: AR e MA no lag do período

$$\underbrace{y_t = \Phi_1 y_{t-m} + \varepsilon_t}_{P=1}$$

$$\underbrace{y_t = \varepsilon_t + \Theta_1 \varepsilon_{t-m}}_{Q=1}$$

- P: hoje depende do mesmo dia do período anterior.
- Q: hoje carrega o choque do mesmo dia do período anterior.

- O modelo da aula: SARIMA (p=0, d=1, q=1)(P=0, D=1, Q=1, m=7)


$$\underbrace{(y_t - y_{t-1}) - (y_{t-7} - y_{t-8})}_{d=1 \text{ e } D=1} = \underbrace{\varepsilon_t + \theta \varepsilon_{t-1} + \Theta \varepsilon_{t-7} + \theta \Theta \varepsilon_{t-8}}_{q=1 \text{ e } Q=1}$$

- Esquerda: a mudança de hoje menos a do mesmo dia da semana passada.
- Direita: o choque de ontem e o da semana passada.
- No código: SARIMAX(y, order=(0, 1, 1), seasonal_order=(0, 1, 1, 7)); sem exógenas, é um SARIMA.

- Escolher as ordens: o AIC, critério de informação de Akaike

$$AIC = 2k - 2 \ln \hat{\mathcal{L}}$$

16 SARIMA com $d = 1$, $D = 1$, $m = 7$: o AIC escolhe




- Ajusta vários candidatos no treino e fica o de menor AIC; quase empatados, o mais simples.

Séries Temporais

- O resultado na série da aula – teste: os últimos 40 dias

modelo	MAE	RMSE	MASE
Modelo 1: reta + dia da semana	3,23	4,11	0,52
SARIMA (0,1,1)(0,1,1,7)	3,26	4,01	0,53
ARIMA (7,1,0)	4,48	5,66	0,72
ingênua sazonal	6,36	7,42	1,02
ARIMA (1,1,1)	8,61	10,46	1,38
ingênua	9,32	11,61	1,50



- SARIMAX: o X é de exógena, uma causa conhecida fora da série


$$y_t = \beta x_t + \eta_t, \quad \eta_t \text{ segue um SARIMA}$$

- A regra que decide tudo: x precisa ser conhecida no instante da previsão.

exemplo	alvo y	exógena x
comércio	vendas diárias	dia de promoção (0 ou 1)
energia	consumo de eletricidade	temperatura prevista e feriados
hidrologia	vazão de um rio	chuva nos dias anteriores
saúde	casos semanais de dengue	chuva de semanas antes
aviação	passageiros por mês	feriados prolongados no mês

- Medindo o efeito: a série da aula com promoções

modelo	MASE	erro médio nos dias de promoção	efeito estimado
SARIMA, sem a promoção	0,67	35,0 u.a.	—
SARIMAX, com a promoção	0,30	1,9 u.a.	$\beta = 39,5$ (real: 40)



- Atividade ST: passageiros aéreos por mês, 1949–1960
 - Olhe a série: tendência, sazonalidade ($m = 12$), a oscilação cresce? (log)
 - Modelo 1: reta + mês do ano. O que sobra tem memória? (ACF)
 - SARIMA com as ordens pelo AIC; últimos 24 meses como teste, walk-forward.
 - Compare com as ingênuas por MAE, RMSE e MASE.

Séries Temporais



- Vamos agora para o Jupyter!

OBRIGADO

James Moraes de Almeida



ilum.cnpem.br



Centro Nacional de Pesquisa
em Energia e Materiais