

AGA 0505 - Análise de Dados em Astronomia

12. Séries Temporais

Laerte Sodré Jr.

1o. semestre, 2024

aula de hoje:

1. séries temporais em astronomia
2. fenômenos que dependem do tempo
3. algumas técnicas de análise de séries temporais:
 - 3.1 autocorrelação
 - 3.2 filtragem
 - 3.3 análise harmônica
 - 3.4 wavelets
 - 3.5 modelos autoregressivos
 - 3.6 *machine learning*

A única razão para o tempo é que as coisas não aconteçam de uma vez.

Albert Einstein

séries temporais (ST) em astronomia

- fenômenos dependentes do tempo estão na origem da astronomia e da ciência moderna
- astronomia na Babilônia
 - calendário, eclipses, movimento dos planetas...

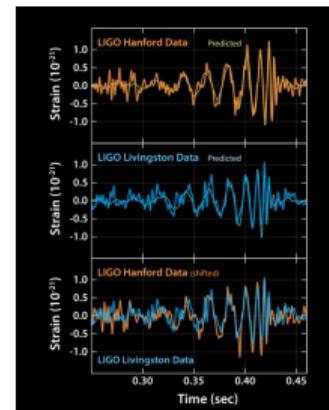
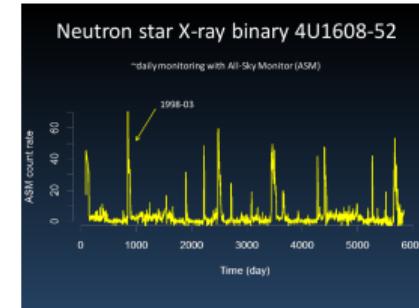
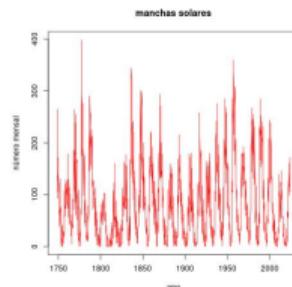
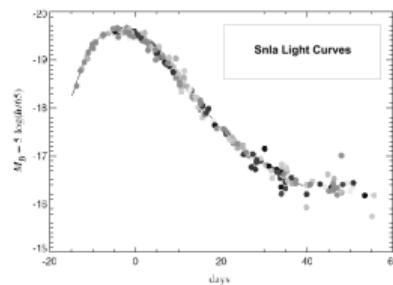


OBSERVAT. SIDEREAE							
Iuxta: Impinguis à frequenti occidens min. 5. hac ve-							
yo à reliqua occidentium min. 3. erant annus circu-							
Orl.	*	○	*	*	*	○	Occ.
min. 10. hac erat aliquanto minus orientali. Sed linea							
6. orientalis proximior erat loca dilatatio noctis mi. 8.							
6. occidentalis dilatatio noctis mi. 12. foliis min. 12.							
Tunc in variis dilatationibus in eadem recta, & am-							
bus fusi rugosi, graffitis orientatis in secunda dilata-							
tione.							
Dir. decimū primū H.1. dur aderat Stella, orienta-							
tiva inā luce dilatatio min. 3. Occidentalis altera dilat-							
Orl.	*	○	*	*	*	○	Occ.

RECENS HABITAE.							
Iuxta m. 1. dico. 5. iuxta ab occidente frequenti min. 3.							
Orl.	*	○	*	*	*	○	Occ.
hac verò ab occidente frequenti m. 7 erat fere aequalis, enim							
talis ratione. Iuxta proxima reliqui erat paulo minor,							
erantque in eadem recta Eclipysis per rectas.							
Dir. 15. Ho. 1. m. 9. Stellarum duas intercedentes occidet							
à leuce conspicte frequenti min. 3. & in eadem							
Orl.	*	○	*	*	*	○	Occ.
dū cum leuce ad eclipysis, ac frequenti Eclipysis duobus							
diffinis. Propinquae à leuce dilatatio m. 7. hac verò							
ab occidente m. 6.							
Dir. 15. Nubilum fuit calum.							
Dir. 15. Ho. 1. m. 10. stellarum mer. fuit culpa cerne-							
bunum in hac conformatio. Orientalis sinist. à leuce							
Orl.	*	○	*	*	*	○	Occ.
ma. Impinguis ab occidente frequenti m. 3. hac regi ab							
occidente m. 7. crant ad regulā in eadem recta Ecli-							
pys parallela.							
Dir. 15. Ho. 1. m. 10. eam superioreibus miles sofi-							
bus fuit nubilus obclaudit) tria apparetur sed							
Orl.	*	○	*	*	*	○	Occ.
le. Orientales duas, quarum dilatatio interē, & à leuce							
G. * Eclipys							

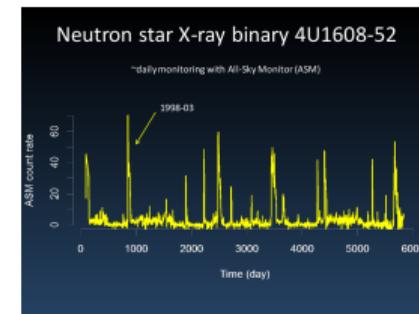
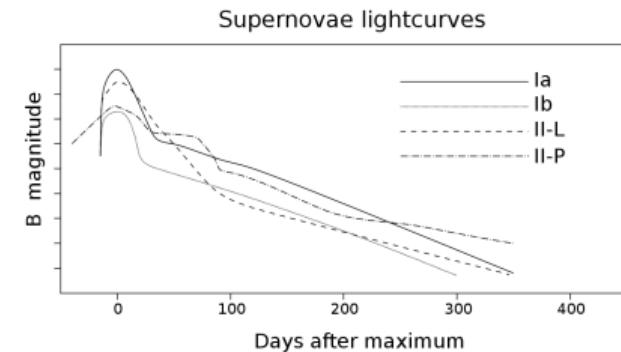
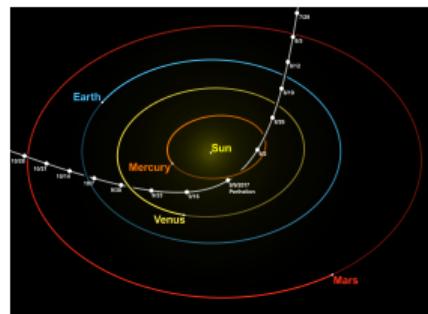
séries temporais (ST) em astronomia

- fenômenos dependente do tempo estão por todo lado em Astronomia



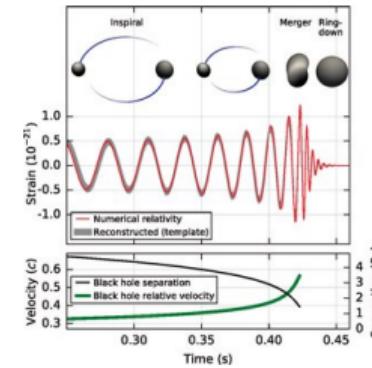
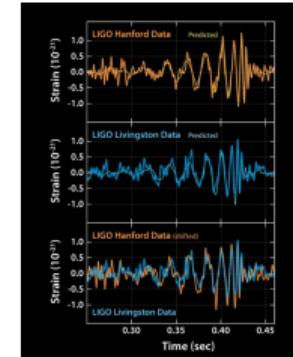
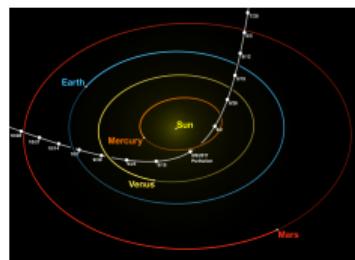
processos dependentes do tempo

- 3 tipos de fenômenos que dependem do tempo:
 - processos **periódicos ou determinísticos**
 - * órbitas
 - processos **transientes ou explosivos**
 - * supernovas
 - processos **semi-periódicos, estocásticos ou caóticos**
 - * discos de acreção



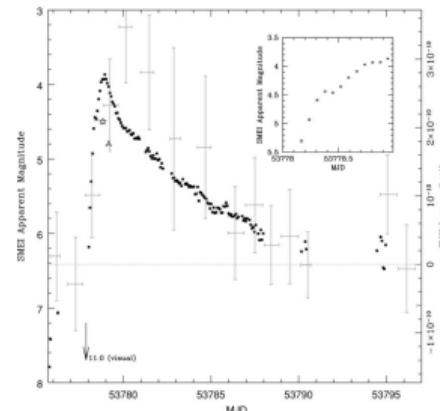
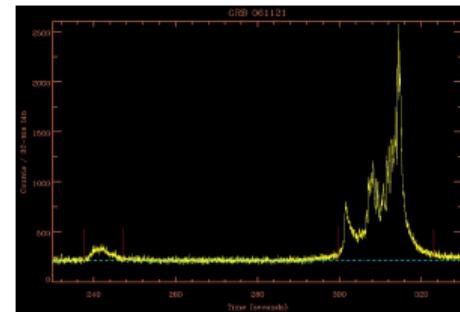
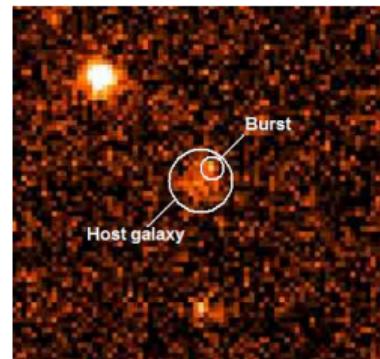
processos dependentes do tempo

- processos **periódicos ou determinísticos**:
 - órbitas - planetas, Oumuamua, estrelas binárias, ...
 - rotação/ciclos - ciclo solar, pulsares, cefeidas, ondas gravitacionais ...
- o que se pode fazer:
 - modelagem dos processos
 - estimativa dos parâmetros do modelo: órbitas, massas ...



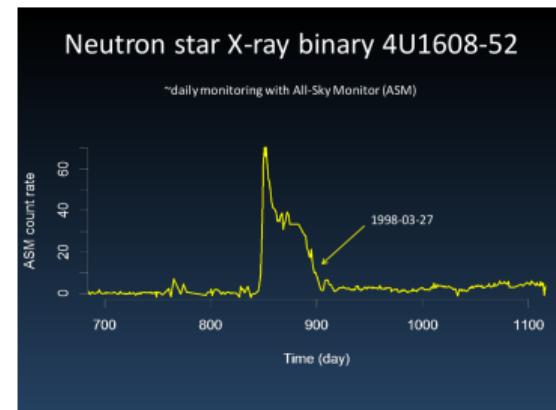
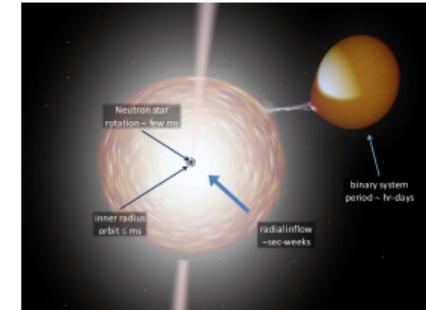
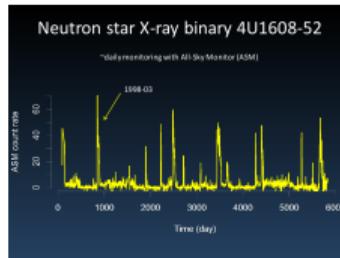
processos dependentes do tempo

- processos **transientes ou explosivos**:
 - supernovas, atividade estelar, GRBs (*gamma ray bursts*), FRBs (*fast radio bursts*)
- o que se pode fazer:
 - detecção, identificação, classificação
 - modelagem e estimativa de parâmetros



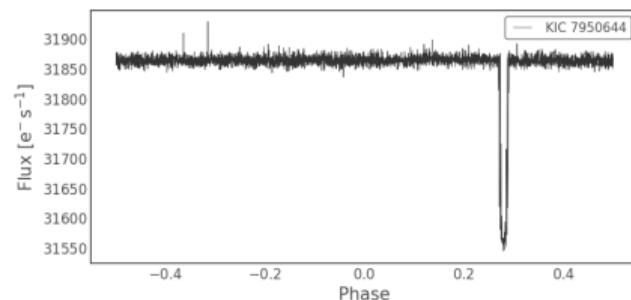
processos dependentes do tempo

- processos **semi-periódicos, estocásticos ou caóticos**:
 - flutuações de brilho em discos de acreção, jatos, ...
 - fenômenos quasi-periódicos
 - não se pode prever com precisão a série temporal
- o que se pode fazer:
 - comparação estatística entre dados e modelos para se inferir os parâmetros físicos do sistema



séries temporais em astronomia

- ST em astronomia não são como as encontradas em outras áreas:
 - muitas vezes a série não é igualmente espaçada
 - as observações individuais estão sujeitas a erros heterocedásticos
 - as escalas de tempo relevantes podem ser muito variadas
 - as variações das fontes e da contribuição do fundo que precisa ser subtraído são frequentemente correlacionadas
- em geral, *em astronomia estamos mais interessados em modelagem que em predição*
- algumas técnicas de análise de ST:
 - autocorrelação
 - análise harmônica
 - modelos autoregressivos
 - wavelets
 - *machine learning*
 - ...



curva de luz obtida pelo satélite Kepler

autocorrelação

- medida de estruturas correlacionadas numa série temporal:

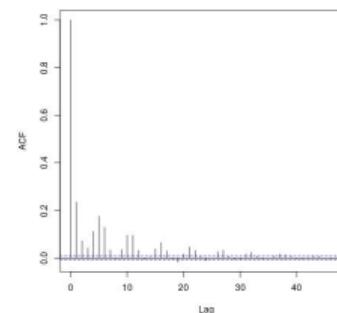
- ST: $\{X_1, X_2, \dots, X_t, \dots, X_n\}$
 X_i : valor da variável X no instante i
 - função de autocorrelação (ACF): é uma função do *lag/atraso k*

$$ACF(k) = \frac{\sum_{t=k+1}^n (X_t - \bar{X})(X_{t-k} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2}$$

mede a correlação média normalizada entre X_t e X_{t-k} em uma ST igualmente espaçada

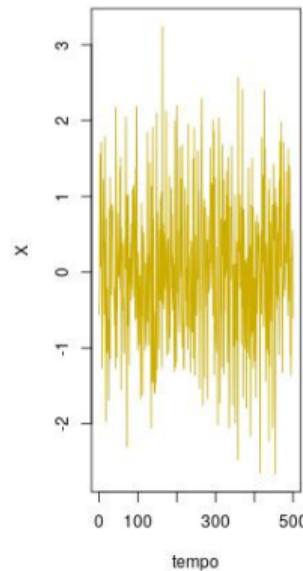
- k : número inteiro > 0 , *lag time*
 - \bar{X} : valor médio da série temporal
 - note que $ACF(0) \equiv 1$

- comportamentos complicados na série temporal podem ter um comportamento mais simples na ACF
 - ruído aleatório não-correlacionado (ruído branco) produz valores perto de zero.
 - às vezes ACFs são difíceis de se interpretar, principalmente quando se tem tendências e processos estocásticos juntos

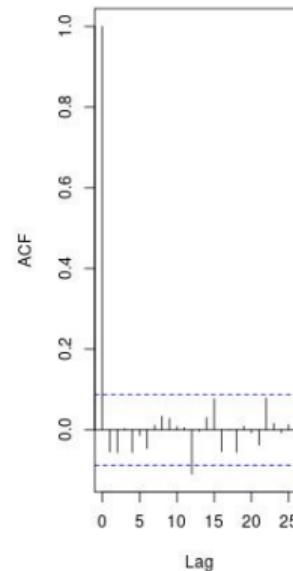


autocorrelação

ruido gaussiano

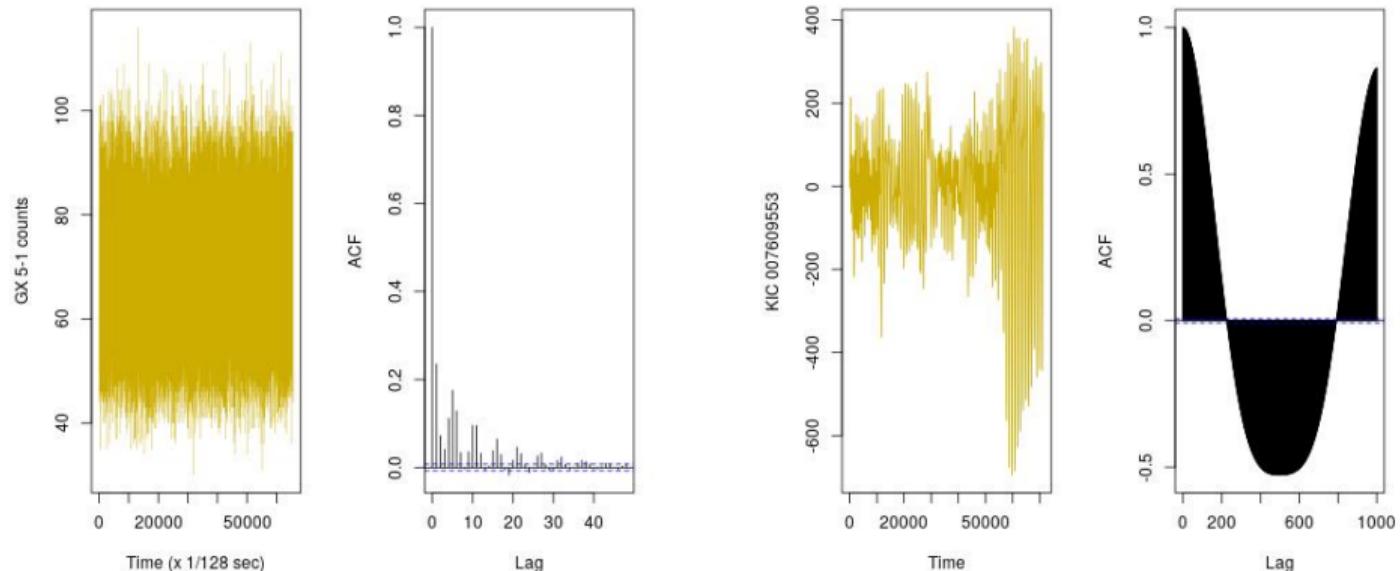


modelo periódico simples



as linhas tracejadas azuis na ACF delimitam o intervalo de confiança de 95%.

autocorrelação

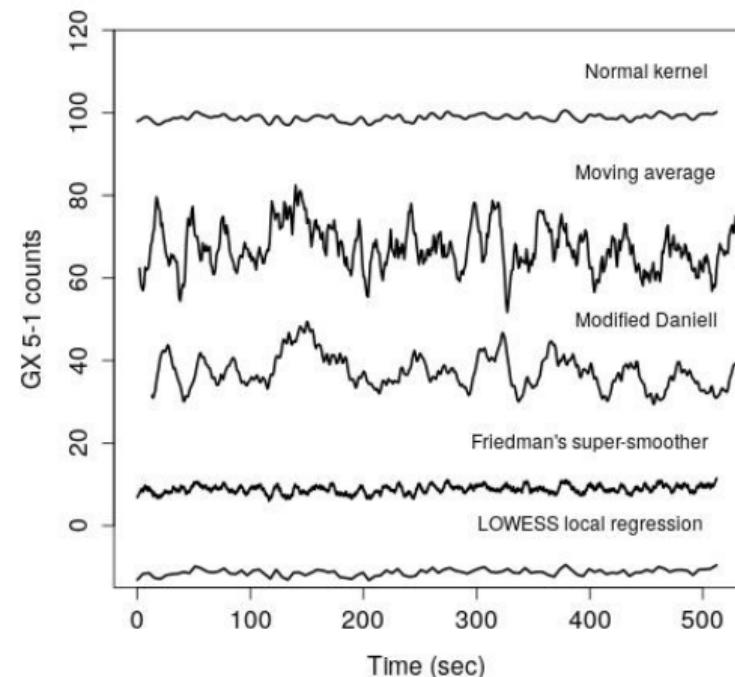


as linhas tracejadas azuis na ACF delimitam o intervalo de confiança de 95%
GX 5-1 é um sistema binário de raios-X

KIC 007609553 é uma estrela que mostra variabilidade quase-periódica devido à presença de rotação e manchas estelares

filtragem

- objetivo: melhorar a visualização do comportamento da ST removendo variações de alta-frequência
- exemplo: média móvel de comprimento 3 substitui-se X_t pela média de X_{t-1}, X_t, X_{t+1}
- filtro de Daniell modificado: média móvel ponderada
- Friedman's super smoother: baseado numa regressão linear local com largura de banda (bandwidth) adaptativa
- LOWESS: regressão polinomial local
- *a filtragem reduz a variância mas introduz viés*



análise harmônica: a transformada de Fourier discreta

- objetivo: identificar ciclos dominantes numa ST
- qualquer ST pode ser expressa como uma super-posição de senos e cossenos com frequências ω_i (ou períodos $T_i = 1/\omega_i$), amplitudes A_i e fases ϕ_i diferentes
- exemplo de uma série periódica:

$$X_t = A \cos(2\pi\omega t + \phi)$$

- uma ST pode ser representada por uma transformada de Fourier discreta (DFT):

$$Y_k = \sum_{j=0}^{n-1} X_j e^{-2\pi i(jk/n)}, \quad k = 1, \dots, n$$

ou

$$Y_k = \sum_{j=0}^{n-1} X_j \left[\cos\left(\frac{2\pi jk}{n}\right) + i \sin\left(\frac{2\pi jk}{n}\right) \right]$$

- transformada inversa:

$$X_j = \frac{1}{n} \sum_{k=0}^{n-1} Y_k e^{2\pi i(jk/n)}$$

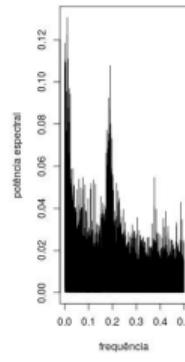
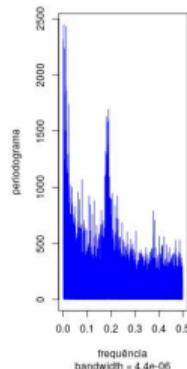
- FFT: *Fast Fourier Transform*: algoritmo eficiente para calcular a transformada de Fourier discreta

análise harmônica: o periodograma

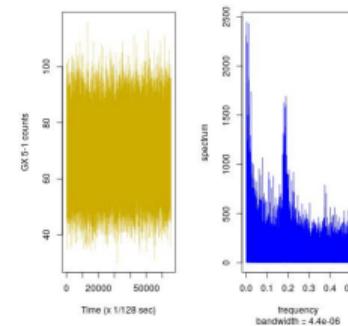
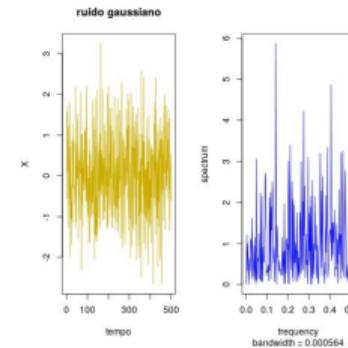
- espectro de potência: mede como a potência do sinal varia com a frequência:

$$P(k) = \frac{4}{n^2} |Y_k|^2$$

- o periodograma é equivalente (a menos da normalização) ao espectro de potências

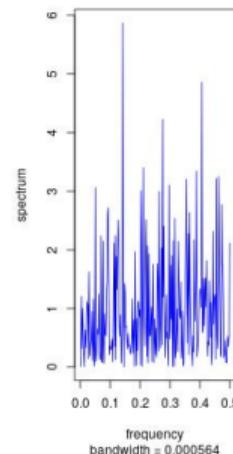
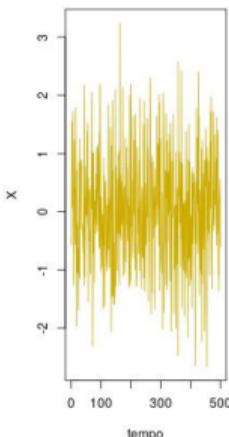


periodogramas:

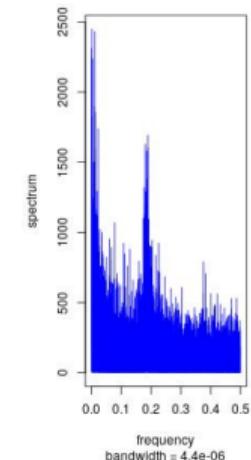
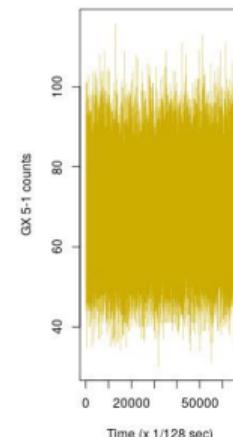
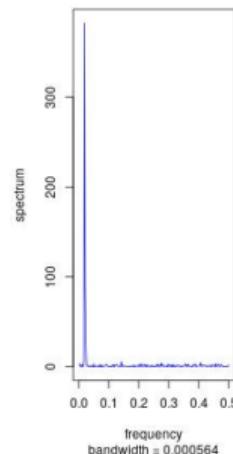
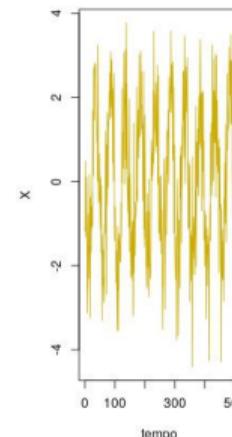


análise harmônica: o periodograma

ruido gaussiano



modelo periódico simples



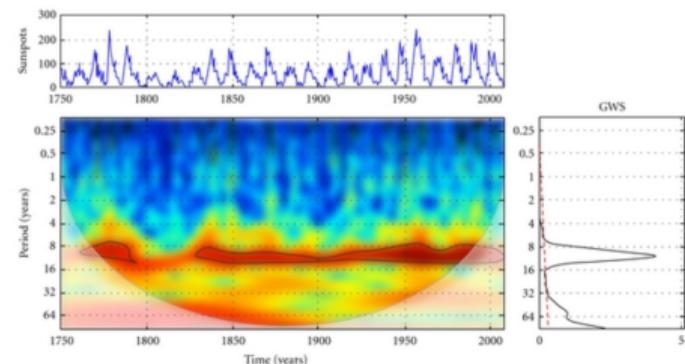
problemas com a análise harmônica

- E. Feigelson: *Harmonic analysis is a complicated 'art' rather than a straightforward 'procedure'*
- a DFT depende de hipóteses raramente encontradas na prática: séries estacionárias infinitas igualmente espaçadas e com alta taxa de amostragem, ruído gaussiano, etc
- frequência de Nyquist: para uma dada taxa de amostragem (amostragem/s), é a frequência cujo período é o dobro do intervalo entre as amostras
- frequentemente deve-se usar filtragem, *tapering* ("afunilamento", que reduz a amplitude do sinal nos extremos da série) e outros procedimentos
- processos não periódicos podem produzir picos no espectro de potência ou periodograma
- ...

wavelets

- a transformada de Fourier converte uma série temporal para o espaço de frequências
- a wavelet descreve a série temporal em termos de tempo e frequência
- considere um sinal cuja frequência varia com o tempo: uma TF daria apenas a informação sobre as frequências presentes, mas não sobre quando ocorrem

- exemplo: séries com o número de manchas solares



Perez-Peraza et al. 2012

modelos autoregressivos

- regressão baseada em valores anteriores da série (os *lags*)
- séries estacionárias: o comportamento temporal, estocástico ou determinístico, é invariante estatisticamente por deslocamentos arbitrários no tempo
- modelos $AR(p)$: X_t depende linearmente de seus p valores anteriores mais um termo estocástico:

$$X_i = \alpha_1 X_{i-1} + \alpha_2 X_{i-2} + \dots + \alpha_p X_{i-p} + \epsilon_i$$

- exemplo: modelo $AR(0)$ - “random walk”:

$$X_i = \alpha_1 X_{i-1} + \epsilon_i, \quad \epsilon_i \sim N(0, \sigma)$$

por substituição:

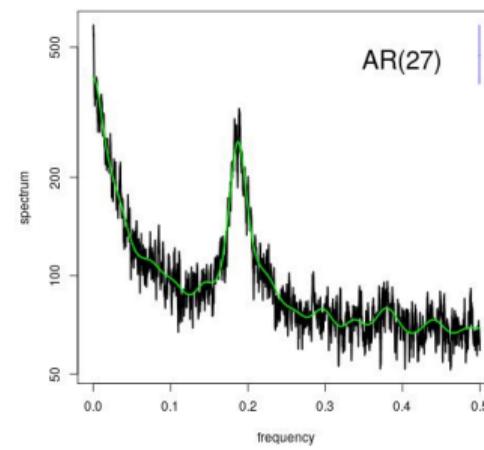
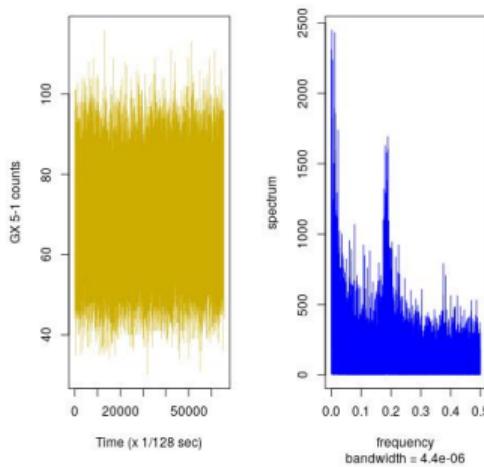
$$X_i = \alpha_1^i X_0 + \{\alpha_1^{i-1} \epsilon_1 + \alpha_1^{i-2} \epsilon_2 + \dots + \epsilon_i\}$$

o termo entre chaves é *ruído branco*

- os coeficientes de um modelo $AR(p)$ podem ser obtidos por máxima verossimilhança e os erros por bootstrap
- seleção de modelos: qual o melhor p ? AIC ou BIC
- a regressão em princípio pode ir até o começo da série
 $(t-1, t-2, \dots, 0)$: modelos de *memória longa*

modelos autoregressivos

- exemplo: modelo autoregressivo de GX 5-1
- melhor modelo: $p = 27$
- comparação do periodograma observado e modelado por AR(27):



modelos autoregressivos

- modelos MA: *moving average*- previsão baseada nos erros das previsões anteriores
- exemplo: $MA(1)$

$$X_t = \beta_1 e_{t-1} + \epsilon_t$$

e_{t-1} : diferença entre o valor observado e o previsto em $t - 1$

- são modelos de *memória curta*:

$$X_{t-1} = \beta_1 e_{t-2} + \epsilon_{t-1}$$

$$X_t = \beta_1 e_{t-1} + \epsilon_t$$

note que X_t não depende de e_{t-2}
(e termos anteriores)

- $MA(q)$:

$$X_t = \beta_1 e_{t-1} + \dots + \beta_q e_{t-q} + \epsilon_t$$

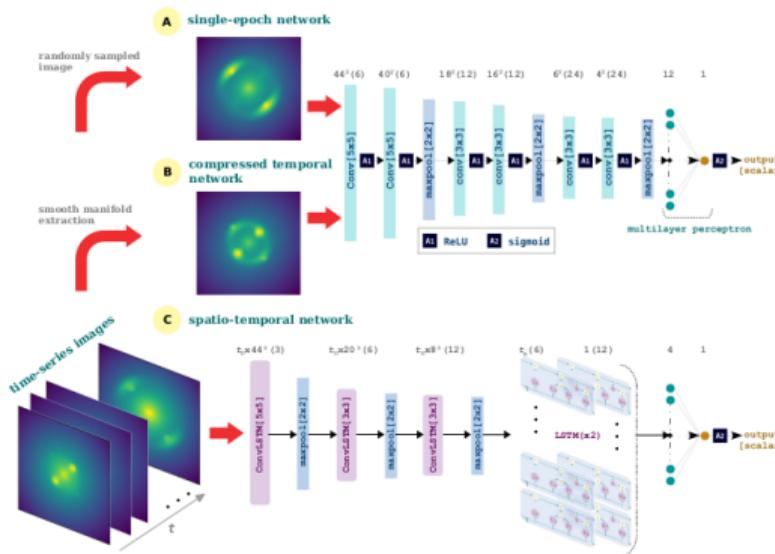
- generalização: ARIMA
autoregressive integrated moving average
- exemplo: $ARIMA(p, 0, q)$

$$X_t = \alpha_1 X_{t-1} + \dots + \alpha_p X_{t-p} +$$

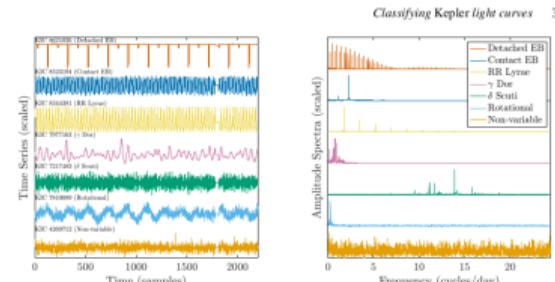
$$+ \beta_1 e_{t-1} + \dots + \beta_q e_{t-q} + \epsilon_t$$

métodos de aprendizado de máquina

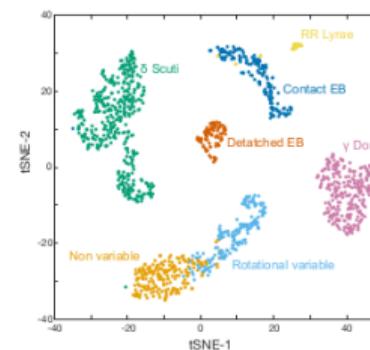
8 D. Kodi Ramanah, N. Arendse, R. Wojtak



sistema para descoberta de supernovas amplificadas gravitacionalmente em imagens ópticas (arXiv:2107.12399)



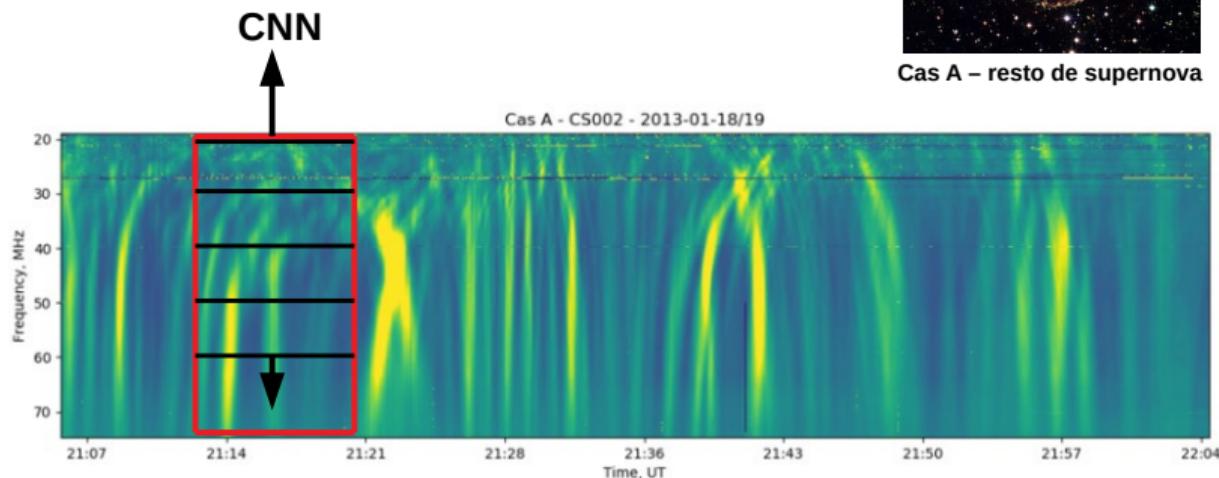
Classifying Kepler light curves



Barbara et al. (arXiv:2205.03020)

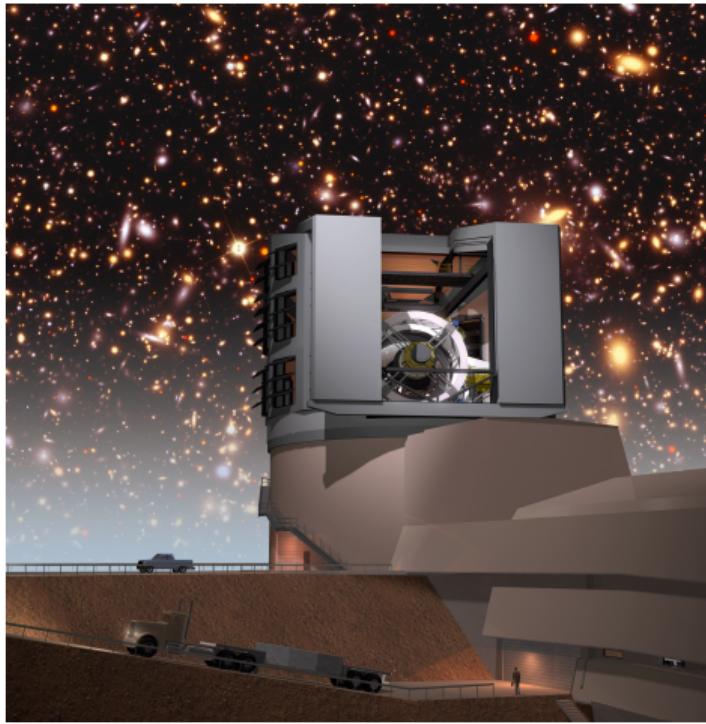
métodos de aprendizado de máquina

espectrogramas podem ser tratados como imagens



<https://pithia-nrf.eupithia-nrf-users/tnainodes/lofar-node-1tna-to-lofar-node> Dr Maaijke Mevius (mevius@astron.nl), Dr Richard Fallows(fallows@astron.nl)

Rubin Observatory/LSST



<https://rubinobservatory.org/>

- *Probing dark energy and dark matter.*
- *Taking an inventory of the solar system.*
- *Exploring the transient optical sky.*
- *Mapping the Milky Way.*

- espelho de 8.4m
- câmera de 3200 megapixels: 9.6 graus quadrados
- observação de todo o céu visível em algumas noites
- ~100 visitas a cada ponto do céu por ano
- ~38 bilhões de objetos detectados em 10 anos

referências

- Feigelson, E., https://sites.psu.edu/astrostatistics/files/2021/02/Tutorial_4_Time_Series.html, 2021
- Modern Statistical Methods for Astronomy: With R Applications , Feigelson & Babu, 2012
- Statistics, Data Mining, and Machine Learning in Astronomy, Ivezić, Connolly, VanderPlas & Gray, 2014
- Vaughan, S., *Random time series in astronomy*, Phil. Trans. Roy. Soc., 371, 20110549, 2012