

Minicurso 1. Métodos Computacionais: HPC e machine learning


O Que É Aprendizado de Máquina?

Lilianne Nakazono

Dados em Astronomia

Medimos luz, posição, tempo e contexto.

Instrumentos diversos
observerão em diferentes
comprimentos de onda e
resolução.




Dados em Astronomia

Images




Credit: S-PLUS

Spectra and Photometry



Adapted from Nakazono+21

Light Curves



Adapted from Moore+23

Dados em Astronomia

Cubes




Catalogs

	ID	RA	DEC	A	B	KRON_RAD...	FWHM_n	MU_MAX_I...	ISOarea
1	IDR5_3_STRIPE82-0003_0000001	0,74137	-1,37967	0,000204	0,000102	7,90908	1,96348	20,6443	2,33410E-8
2	IDR5_3_STRIPE82-0003_0000002	0,70738	-1,37958	0,000204	0,000165	3,21479	1,45574	19,9723	1,86728E-7
3	IDR5_3_STRIPE82-0003_0000003	0,73549	-1,37937	0,000213	0,000122	7,04948	2,20191	20,7577	9,33642E-8
4	IDR5_3_STRIPE82-0003_0000004	0,74365	-1,37889	0,000217	0,00011	4,63158	2,11113	20,5659	9,33642E-8
5	IDR5_3_STRIPE82-0003_0000005	0,74688	-1,379	0,000272	0,000204	5,16087	2,09552	19,4571	4,43480E-7
6	IDR5_3_STRIPE82-0003_0000006	0,85699	-1,37858	0,000111	6,89582E-5	1,82	1,1778	20,8298	2,33410E-8
7	IDR5_3_STRIPE82-0003_0000007	0,82666	-1,37868	0,000205	0,000112	1,82	2,06868	20,3826	4,66821E-8
8	IDR5_3_STRIPE82-0003_0000008	0,6603	-1,38008	0,000292	0,000256	4,19813	1,20017	18,2692	9,10301E-7
9	IDR5_3_STRIPE82-0003_0000009	0,75732	-1,37836	0,00021	0,000187	3,08624	0,972412	19,2498	3,26775E-7
10	IDR5_3_STRIPE82-0003_0000010	0,89848	-1,37818	0,000134	0,000131	2,66863	1,03745	20,2072	1,16705E-7
11	IDR5_3_STRIPE82-0003_0000011	0,94574	-1,37814	0,00022	0,000122	1,82	1,35644	20,7338	4,66821E-8
12	IDR5_3_STRIPE82-0003_0000012	0,79429	-1,37807	0,000221	0,000168	3,02718	2,63501	20,5056	1,16705E-7
13	IDR5_3_STRIPE82-0003_0000013	0,71954	-1,37868	0,000292	0,000255	3,23533	1,55785	18,8604	8,63619E-7
14	IDR5_3_STRIPE82-0003_0000014	1,01727	-1,37766	7,69682E-5	7,55487E-5	0,	1,01823	20,3327	2,33410E-8
15	IDR5_3_STRIPE82-0003_0000015	0,95699	-1,3775	0,000119	7,62368E-5	5,41854	0,	20,9444	0,
16	IDR5_3_STRIPE82-0003_0000016	0,8579	-1,37747	7,64183E-5	7,63103E-5	8,79959	0,057328	20,8067	2,33410E-8
17	IDR5_3_STRIPE82-0003_0000017	0,74631	-1,37833	0,000282	0,000263	5,75973	1,78762	19,4777	6,06867E-7
18	IDR5_3_STRIPE82-0003_0000018	0,9249	-1,37865	0,000498	0,000287	6,65712	5,18143	19,4769	7,93596E-7
19	IDR5_3_STRIPE82-0003_0000019	0,76685	-1,37714	0,000216	8,55751E-5	7,39486	0,	20,603	2,33410E-8
20	IDR5_3_STRIPE82-0003_0000020	0,75258	-1,37687	0,000207	0,000131	1,82	2,17456	20,4954	7,00231E-8
21	IDR5_3_STRIPE82-0003_0000021	0,70199	-1,37828	0,000245	0,00022	4,29991	1,04647	18,5862	5,83526E-7
22	IDR5_3_STRIPE82-0003_0000022	0,7408	-1,37669	0,000182	0,000146	1,82	2,19659	20,5176	4,66821E-8
23	IDR5_3_STRIPE82-0003_0000023	0,72492	-1,3768	0,000164	0,000158	6,97142	2,006	20,5894	1,16705E-7
24	IDR5_3_STRIPE82-0003_0000024	0,94936	-1,37737	0,000225	0,000197	3,61028	1,12194	18,9935	4,20139E-7
25	IDR5_3_STRIPE82-0003_0000025	0,65759	-1,3765	7,75900E-5	7,51032E-5	3,28595	1,01948	20,6432	4,66821E-8
26	IDR5_3_STRIPE82-0003_0000026	1,00225	-1,37745	0,00037	0,000285	5,18488	1,83223	18,9359	1,07369E-6
27	IDR5_3_STRIPE82-0003_0000027	1,01577	-1,37639	0,000224	0,000198	1,82	1,83723	19,7703	3,03434E-7
28	IDR5_3_STRIPE82-0003_0000028	1,23575	-1,37562	0,000173	4,40968E-5	10,6275	0,	20,2855	0,
29	IDR5_3_STRIPE82-0003_0000029	0,79698	-1,37584	0,000253	0,000199	4,38289	2,29447	20,1695	3,50116E-7
30	IDR5_3_STRIPE82-0003_0000030	0,68581	-1,37553	0,0002	8,60425E-5	7,9019	1,78329	20,3299	2,33410E-8
31	IDR5_3_STRIPE82-0003_0000031	0,97711	-1,37836	0,000363	0,000205	3,63235	1,32698	14,4733	2,07735E-6
32	IDR5_3_STRIPE82-0003_0000032	0,76911	-1,37979	0,000394	0,00029	3,18298	1,45823	13,9091	5,27508E-6
33	IDR5_3_STRIPE82-0003_0000033	0,8323	-1,37848	0,000313	0,000291	3,50243	0,991016	15,638	2,54417E-6
34	IDR5_3_STRIPE82-0003_0000034	1,21271	-1,37524	0,000439	7,63313E-5	1,82	0,	20,5332	0,
35	IDR5_3_STRIPE82-0003_0000035	1,18802	-1,37518	0,000148	0,000106	1,82	0,	20,9452	0,
36	IDR5_3_STRIPE82-0003_0000036	1,11072	-1,37503	0,000199	0,000156	4,45234	2,40854	20,7195	9,33642E-8
37	IDR5_3_STRIPE82-0003_0000037	0,80183	-1,37496	0,00025	0,000189	5,55002	2,40982	20,2972	2,33411E-7
38	IDR5_3_STRIPE82-0003_0000038	0,93145	-1,37554	0,000219	0,000208	3,49983	1,03275	18,5362	5,13503E-7
39	IDR5_3_STRIPE82-0003_0000039	1,29028	-1,37493	0,000204	0,0001	6,90245	1,22901	18,9456	1,16705E-7
40	IDR5_3_STRIPE82-0003_0000040	0,92322	-1,37771	0,000359	0,000321	5,30273	1,06517	18,1427	1,00367E-6

Dados em Astronomia

Simulations



Text

Fri, 12 Jun 2026 (showing first 50 of 87 entries)

[1] [arXiv:2606.13666](#) [pdf, html, other]

Centrally concentrated star formation in young clusters II: Jet feedback

[Adilkhan Assilkhan](#), [Sabrina M. Appel](#), [Bekdaulet Shukirgaliyev](#), [Ernazar Abdikamalov](#), [Simon Portegies Zwart](#), [Eric P. Andersson](#), [Mukhagali Kalambay](#), [Mordecai-Mark Mac Low](#)

Comments: Data products associated with this work will be made publicly available through the American Museum of Natural History Digital Library after the paper is accepted for publication

Subjects: [Astrophysics of Galaxies](#) (astro-ph.GA)

[2] [arXiv:2606.13600](#) [pdf, html, other]

Feasibility of up-the-ramp sampling under variable sky for ground-based spectrographs

[Gaia Gaspar](#), [Marcin Sawicki](#), [Nelson Nunes](#), [Rubén J. Díaz](#), [James E. H. Turner](#)

Comments: To appear in SPIE Proceedings for the Astronomical Telescopes + instrumentation 2026 conference. 17 pages, 7 figures, 3 tables

Subjects: [Instrumentation and Methods for Astrophysics](#) (astro-ph.IM)

[3] [arXiv:2606.13574](#) [pdf, html, other]

AESTRA II: Generative Spectral Modeling of the Sun as a Star for Precise Radial Velocities

[Yan Liang](#), [Joshua N. Winn](#), [Peter Melchior](#), [Sicong Lu](#), [Quang H. Tran](#)

Comments: 24 pages, 10 figures, submitted to The Astronomical Journal

Subjects: [Earth and Planetary Astrophysics](#) (astro-ph.EP); [Instrumentation and Methods for Astrophysics](#) (astro-ph.IM); [Solar and Stellar Astrophysics](#) (astro-ph.SR)

[4] [arXiv:2606.13567](#) [pdf, html, other]

The effect of near-core mixing on rejuvenation and the asteroseismic properties of massive accretors

[Jan Henneco](#), [Dominic M. Bowman](#)

Comments: 16 pages + 8-page appendix, 22 figures, 2 tables. Accepted for publication in MNRAS on the 7th of June 2026

Subjects: [Solar and Stellar Astrophysics](#) (astro-ph.SR)

[5] [arXiv:2606.13538](#) [pdf, other]

A local Universe catalogue of structures and voids dynamically identified using Cosmic-Flows4++ ZOA peculiar velocities

[A.M. Hollinger](#), [H. M. Courtois](#)

Comments: Submitted to A&A : aa61411-26

Você acabou de aprender a computar em larga escala.

Agora: o que computamos?



A HPC nos dá

Computação paralela massiva — clusters, GPUs, armazenamento distribuído.



A astronomia nos dá

Petabytes de imagens, espectros e séries temporais de cada levantamento.



Aprendizado de máquina é

O conjunto de métodos que transforma computação bruta e dados em descoberta.

O Que É Aprendizado de Máquina?



Programação Tradicional

Você escreve regras explícitas.

Regras + Dados → Respostas

Exemplo: "se o fluxo cair mais de 1%, marcar como possível trânsito."



Aprendizado de Máquina

O algoritmo aprende as regras.

Dados + Respostas → Regras

Exemplo: mostre milhares de curvas de luz rotuladas, e ele aprende como é um trânsito.

Em resumo: o ML encontra padrões em dados complexos ou volumosos demais para codificar manualmente.

Por que a Astronomia precisa de Aprendizado de Máquina?

Levantamentos modernos geram muito mais do que humanos conseguem inspecionar a olho nu.



Rubin Observatory/NSF/AURA/A. Pizarro D.

20 TB

de imagens por
noite
— Observatório
Vera C. Rubin
(LSST)

10M+

alertas por
noite
de fontes
variáveis no céu

Três Tipos de Aprendizado de Máquina



Supervisionado

Aprende a partir de exemplos rotulados

"Este espectro é uma supernova tipo Ia."

Usado para: classificação e regressão



Não supervisionado

Encontra estrutura sem rótulos

Agrupar estrelas por composição química
sem que os grupos sejam informados.



Por reforço


Aprende por tentativa, recompensa e erro

Otimizar o agendamento do telescópio
para maximizar o retorno científico.

O Fluxo de Trabalho de Aprendizado de Máquina



O Fluxo de Trabalho de Aprendizado de Máquina



Estudo de Caso: Classificando Formas de Galáxias

O problema

Milhões de imagens de galáxias — espiral, elíptica ou em fusão? Demais para astrônomos classificarem só a olho nu.

Uma abordagem

Galaxy Zoo: coletar centenas de milhares de classificações humanas via crowdsourcing.

Uma abordagem de ML

Treinar uma rede neural convolucional com esses rótulos humanos — depois classificar milhões de imagens a mais em segundos.

O resultado

O ML hoje cuida da classificação de rotina em levantamentos como o SDSS e o DES



A mesma receita funciona para:

- Classificação de transientes / supernovas
- Separação estrela–galáxia
- Busca por lentes gravitacionais

O Que Vem na Aula 2

Dos conceitos à mecânica — como os modelos realmente aprendem.



Algoritmos essenciais

Regressão, árvores de decisão, k-NN, agrupamento, PCA



Como funciona o treinamento

Funções de perda e gradiente descendente



Sobreajuste vs. subajuste

Regularização e validação cruzada



Avaliando modelos

Acurácia, precisão/revocação, matrizes de confusão



Redes neurais

De perceptrons a CNNs para imagens astronômicas



Limites e ética

Viés, caixas-pretas e reprodutibilidade

Principais Conclusões

- O ML permite que algoritmos aprendam regras a partir dos dados, em vez de as codificarmos manualmente.
- A astronomia é um dos maiores motores da adoção do ML — o volume de dados exige isso.
- Aprendizado supervisionado, não supervisionado e por reforço resolvem tipos diferentes de problemas.
- Todo projeto de ML segue o mesmo fluxo: dados → atributos → modelo → treinar → avaliar.

Perguntas?