

Medidas de linhas de emissão com aprendizado de máquina

Lis Cristine Fortes e Natalia Vale Asari

Universidade Federal de Santa Catarina

Resumo

Transições eletrônicas em íons de nebulosas presentes em galáxias emitem fótons com energias características, despontando dos espectros das galáxias como linhas de emissão. Medidas dos fluxos de linhas de emissão são fundamentais no entendimento deste sistema físico. Por exemplo, a largura equivalente da linha espectral nebulosa H α está ligada à taxa de formação estelar específica de uma galáxia e é também útil para quantificar a presença do gás difuso ionizado em galáxias. Dado que na astrofísica trabalha-se com cubos que contêm milhares de espectros por galáxia, é importante avaliar o método utilizado para extrair as propriedades físicas dos dados, haja vista a grande demanda computacional envolvida. Para tanto, a proposta deste trabalho consistiu na aplicação de uma rede neural convolucional para medir amplitude e fluxo obtidos de linhas de emissão H α geradas a partir de uma função gaussiana. Os resultados apresentam-se promissores e o aprendizado eficiente. A perspectiva é aplicar o método para dados do MUSE (*Multi Unit Spectroscopic Explorer*).

Abstract

Electronic transitions in nebula ions present in galaxies emit photons with characteristic energies, emerging from the spectra of galaxies as emission lines. Measurements of emission line fluxes are fundamental in understanding this physical system. For example, the equivalent width of the nebular spectral line H α is linked to the specific star formation rate of a galaxy and is also useful for quantifying the presence of ionized diffuse gas in galaxies. Given that in astrophysics we work with cubes that contain thousands of spectra per galaxy, it is important to evaluate the method used to extract the physical properties of the data, given the great computational demand involved. To this end, the proposal of this work consisted of applying a convolutional neural network to measure amplitude and flux obtained from H α emission lines generated from a Gaussian function. The results are promising and the learning is efficient. The perspective is to apply the method to data from MUSE (Multi Unit Spectroscopic Explorer).

Palavras-chave: aprendizado de máquina, astrofísica, galáxias

Keywords: machine learning, astrophysics, galaxies

DOI: [10.47456/Cad.Astro.v5nEspecial.44988](https://doi.org/10.47456/Cad.Astro.v5nEspecial.44988)

1 Introdução

Hoje em dia, na astrofísica, é possível trabalhar com cubos de dados que possuem milhares de espectros para cada galáxia. Mas, há cerca de duas décadas, o surgimento das grandes bases de dados, como a do Sloan Digital Sky Survey (SDSS)¹, tornou necessário o desenvolvimento de ferramentas automáticas para extrair as propriedades físicas dos dados. Atualmente, essas ferramentas estão começando a precisar de reavaliação. Por exemplo, um cubo de dados do *Multi Unit Spectroscopic Explorer* (MUSE [1]), em um *cluster* com 32 nós, demanda um dia de

processamento. Portanto, é necessário reavaliar os métodos utilizados para obter as informações físicas dos cubos.

Assim, o objetivo desse estudo foi analisar a viabilidade do aprendizado de máquina para obter propriedades físicas de cubos de dados de forma mais rápida. Para tanto, foi efetuada a exploração de um método de aprendizado de máquina, que se comprovou acurado [2] quando aplicado a dados obtidos com o instrumento *Spectromètre Imageur à Transformée de Fourier pour l'Étude en Long et en Large de raies d'Émission* (SI-TELLE).

¹<https://www.sdss.org/>

1.1 Linhas de emissão

As linhas de emissão são um incremento no fluxo em um determinado comprimento de onda e são originadas a partir da sobreposição de grande quantidade de fótons gerados quando elétrons passam por transições em que saem de um estado de maior energia para um estado de menor energia [3]. A energia de cada fóton terá o mesmo valor que a queda na energia do elétron ao efetuar a transição. É possível quantificar esse valor a partir da equação de Planck–Einstein:

$$\Delta E = h\nu. \quad (1)$$

A quantificação do fluxo das linhas de emissão torna possível obter diversas propriedades físicas de galáxias. Por exemplo, a largura equivalente da linha espectral nebular $H\alpha$ está ligada à taxa de formação estelar de uma galáxia e também à quantidade de gás difuso ionizado nela; a razão entre as luminosidades das linhas $H\alpha$ e $H\beta$ é indicativo da atenuação por poeira; e, ainda, a densidade superficial da luminosidade de $H\alpha$ está ligada à massa de gás ionizado.

Através deste estudo, pretende-se, futuramente, quantificar o fluxo de linhas de emissão a partir de informações extraídas de cubos de dados de galáxias.

1.2 O aprendizado de máquina supervisionado e a rede neural convolucional

O aprendizado de máquina supervisionado é um método no qual os dados inseridos para treinamento (dados de entrada) são rotulados e a máquina aprende a identificá-los, conseguindo generalizar o que aprendeu e aplicar para novos dados. Ele difere do aprendizado não supervisionado porque neste último não há rótulos.

A rede neural artificial é um método que pode ser construído basicamente de camadas de neurônios artificiais; a camada de entrada consiste nos dados inseridos. As camadas ocultas seguintes são compostas de neurônios que obtêm pesos e vieses para a saída da camada anterior, e que calculam valores de entrada para a camada seguinte. Por fim, existe uma camada de saída, consistindo nos resultados obtidos [4].

A rede neural convolucional que compõe o conjunto de ferramentas Pamplemousse [2] é uma

adaptação da rede neural convolucional StarNet [4]. A diferença entre a rede neural convolucional e a artificial é que uma utiliza a função de convolução e a outra não. Esta rede neural convolucional consiste em uma combinação de camadas convolucionais e camadas totalmente conectadas. Nas camadas convolucionais, filtros são aplicados para extrair informações locais da camada anterior. Desta forma, a rede aprende quais filtros ativar quando encontra determinadas características, criando mapas de características. Em uma segunda camada convolucional, que imediatamente sucede a primeira camada convolucional, ocorre a convolução do mapa de características da camada anterior, permitindo o aprendizado de recursos de ordem superior. Já as camadas totalmente conectadas computam várias combinações lineares dos valores de entrada, com objetivo de produzir um vetor de saída [4]. Assim, explorando o trabalho de C. Rhea et al., 2020 [2], os dados de entrada foram linhas $H\alpha$ simuladas e a saída foram as estimativas da amplitude e do fluxo destas linhas.

2 Método

Esta investigação consistiu em avaliar o desempenho da rede neural convolucional² estudada, para obter valores de amplitude e fluxo da linha de emissão $H\alpha$ com formato gaussiano.

3 Dados de entrada

Inicialmente, foi elaborada uma função gaussiana, G , para gerar linhas de emissão $H\alpha$. Os parâmetros da função foram a velocidade do centro da linha v_0 , a amplitude A , a velocidade v , a dispersão intrínseca, que é a dispersão das velocidades dos íons H^+ na nebulosa (que chamamos de dispersão de velocidade) σ , a dispersão instrumental σ_i ; as duas últimas se somam em quadratura, resultando na dispersão de velocidade observada σ_{obs} . Além disso, v é calculada, considerando-se velocidades baixas, utilizando o comprimento de onda de repouso, (λ_0), o comprimento de onda, λ , e a velocidade da luz, c .

Desta forma, foram utilizadas as seguintes equações:

²<https://github.com/sitelle-signals/Pamplemousse>

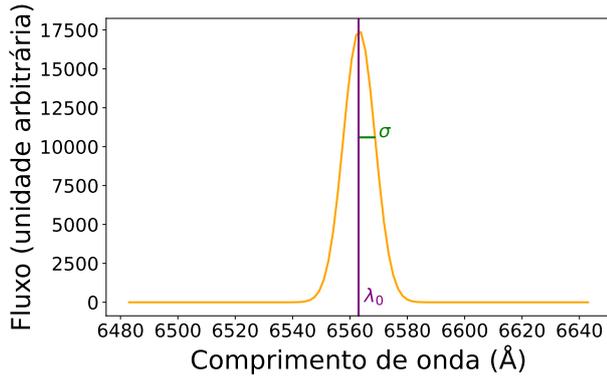


Figura 1: Espectro gerado com a equação 2. Em verde está destacado o desvio padrão da distribuição, e em roxo o comprimento de onda central, λ_0 . Para os treinamentos efetuados, como utilizamos a dispersão instrumental, σ_i , igual a zero, o desvio padrão corresponde à dispersão de velocidade, σ_{obs} , conforme pode ser visto na equação 4.

$$G = Ae^{(v-v_0)^2/2\sigma_{\text{obs}}^2}, \quad (2)$$

em que

$$v = \frac{\lambda - \lambda_0}{\lambda_0}c \quad (3)$$

e

$$\sigma_{\text{obs}} = \sqrt{\sigma^2 + \sigma_i^2}. \quad (4)$$

A integral da equação 2 resulta no fluxo integrado:

$$f = A\sigma_{\text{obs}}\sqrt{2\pi}. \quad (5)$$

Os espectros foram gerados na faixa de comprimentos de onda entre 6483 e 6643 Å, com 100 pontos de igual espaçamento. O valor da c usado foi 2.998×10^5 km/s e o λ_0 foi fixado em 6563 Å. Foi adicionado ruído com formato gaussiano, cujo desvio padrão foi 0,001 e a média nula.

Foram gerados 100 valores igualmente espaçados de A na faixa de 1 a 10^7 em unidade arbitrária e 100 valores igualmente espaçados de σ de 10 a 500 km/s. Esses valores foram combinados para que fossem geradas 10000 gaussianas. O valor de v_0 foi fixado em 10 km/s e o valor de σ_i foi nulo.

Na Figura 1, é apresentado um espectro gerado com a equação 2. Em roxo é apresentado o valor central da distribuição, que representa o λ_0 do sistema. Em verde está indicada a σ_{obs} .

4 Aprendizado da rede neural convolucional

Os espectros obtidos foram utilizados para as etapas de treinamento, validação e teste da rede. Para o treinamento, foram utilizados 70% dos espectros, totalizando 7000. Para validação, 20%, totalizando 2000 e para teste, 10%, totalizando 1000 espectros. Como resultado para a etapa de teste, foram obtidas as Figuras 2 e 3. O resíduo apresentado na coordenada vertical da Figura 2, R_A , é definido como o módulo da diferença entre a amplitude obtida pela rede A_r e a amplitude esperada, A :

$$R_A = |A_r - A|. \quad (6)$$

O mesmo ocorre para o resíduo apresentado na coordenada vertical da Figura 3, R_f , ele é o resultado do módulo da diferença entre o fluxo obtido pela rede, f_r , e o fluxo esperado, f :

$$R_f = |f_r - f|. \quad (7)$$

Na Figura 2 há três linhas sobrepondo os dados: uma indicando a relação de mesma ordem de grandeza entre o R_A e a A , a outra, tracejada, indicando onde o R_A é 10% de A e a última, pontilhada, indicando onde o R_A é 1% de A . Da mesma forma, na Figura 3, há quatro linhas estabelecendo relações entre o R_f e o f : as três primeiras têm a mesma relação que foi descrita para a Figura 2, e a última estabelece onde o R_f é 0,1% do f .

Assim, é possível perceber que para o teste de amplitude, constante na Figura 2, o R_A possui ordem de grandeza próximo de 10% do valor de A , em que a maioria dos dados encontra-se acima deste fator. Há alguns pontos em que R_A está entre 10 e 1% de A . Poucos são os valores em que R_A e A possuem mesma ordem de grandeza; nota-se o mesmo para a faixa em que R_A é menor do que 1% de A . Os dados apresentados indicam o bom treinamento da rede.

Já para teste de fluxo, Figura 3, é possível ver que, para valores de f até 10^3 , R_f possui ordem de grandeza superior ao f , indicando que o treinamento não foi eficiente neste intervalo. Para valores maiores, o R_f é reduzido, chegando a cerca de 1% do valor do f no entorno de 10^5 e após, permeia valores entre 1 e 0,1% do f , indicando o bom treinamento da rede.

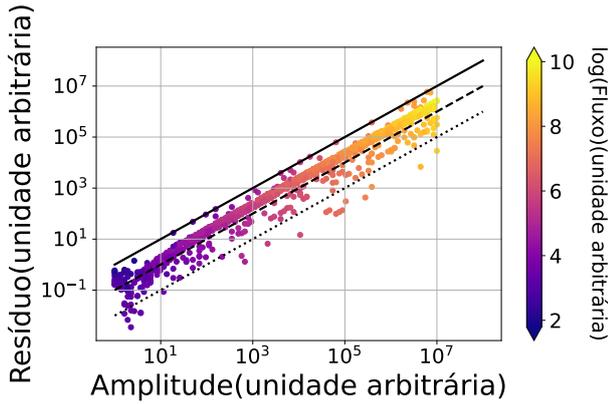


Figura 2: Resíduo da amplitude, R_A , em função da amplitude, A . A linha superior indica onde o R_A tem a mesma ordem de grandeza da A , a linha tracejada, onde R_A é 10% da A e a linha pontilhada, onde ele é 1% da A . Percebe-se que, para a maioria dos pontos o R_A está em torno de 10% da A .

Os resultados são interessantes para futuras análises em galáxias do MUSE, que apresentam ordem de grandeza do fluxo de $H\alpha$ variando de 0 a 10^6 em unidades de $10^{-20} \text{erg s}^{-1} \text{cm}^{-2} \text{\AA}^{-1}$.

5 Conclusão

Através do trabalho efetuado, pôde-se vislumbrar a possível aplicação desta rede neural convolucional para futuras análises em dados observacionais de galáxias do MUSE, apresentando-se como uma alternativa para superar a demanda de tempo de processamento dos dados; esta informação já foi apontada por outros autores [2], no contexto de aplicação aos dados do SITELLE. Os resultados do treinamento apresentaram-se promissores, sendo que os resíduos, R_A e R_f , apresentam-se em maioria no entorno de 10% da amplitude e entre 0,1 e 1% do fluxo, respectivamente. Pondera-se que ainda é necessário, no futuro, avaliar o desempenho da rede neural convolucional para espectros semelhantes aos dos dados observacionais.

Agradecimentos

Agradecemos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo apoio financeiro concedido.

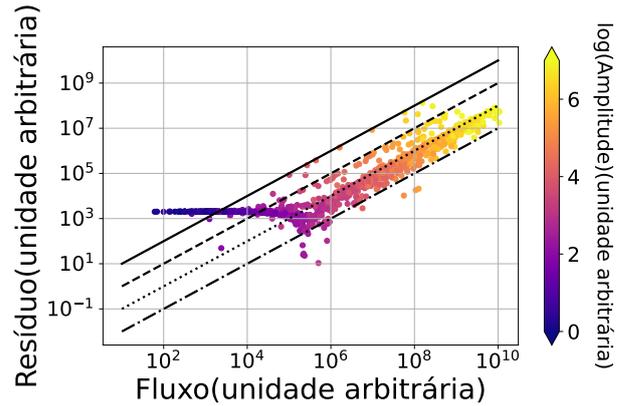


Figura 3: Resíduo do fluxo, R_f , em função do fluxo, f . A linha superior indica onde o R_f tem a mesma ordem de grandeza do f , a linha tracejada, onde R_f é 10% do f , a linha pontilhada, onde ele é 1% do f , e a linha pontilhada-tracejada, onde ele é 0,1% do f . Percebe-se que, para a maioria dos pontos, o R_f permeia o intervalo entre 0,1 e 1% do f .

Sobre as autoras

Lis Cristine Fortes é técnica em Agroindústria pelo IFSC, instituição onde começou sua formação como pesquisadora, atuando na área de Ciência e Tecnologia de Alimentos. Atualmente é graduanda em Física na UFSC. Desde 2021 pesquisa na área de Astrofísica Extragaláctica. Também possui experiência na área de Materiais Nanoestruturados.

Natalia Vale Asari é professora no Departamento de Física da UFSC desde 2014 e subcoordenadora do Programa de Pós-Graduação em Física da UFSC desde 2021. Recebeu o Prêmio Carolina Nemes da Sociedade Brasileira de Física em 2019. Sua pesquisa, em colaboração com colegas na França, México, Polônia e Escócia, é voltada para populações estelares e abundâncias químicas de galáxias.

Referências

- [1] R. Bacon et al., *The MUSE second-generation VLT instrument*, in *Ground-based and airborne instrumentation for Astronomy III*, editado por I. S. McLean, S. K. Ramsay e H. Takami (2010), vol. 7735 de *Society of Photo-Optical Instrumentation Engineers*

- (*SPIE*) *Conference Series*, 773508. [ArXiv:2211.16795](#).
- [2] C. Rhea et al., *A machine-learning approach to integral field unit spectroscopy observations. I. H ii region kinematics*, *Astrophysical Journal* **901**(2), 152 (2020). [ArXiv:2008.08093](#).
- [3] B. Ryden e B. M. Peterson, *Foundations of astrophysics* (Addison-Wesley, 2010).
- [4] S. Fabbro et al., *An application of deep learning in the analysis of stellar spectra*, *Monthly Notices of the RAS* **475**(3), 2978 (2018). [ArXiv:1709.09182](#).