

A era digital e suas implicações sociais: Desafios e contribuições

MAGNETOGRAMAS COLORIDOS E PRETO E BRANCO NA CLASSIFICAÇÃO DE REGIÕES ATIVAS

Paulo Ricardo Rotband Rangel¹, Amita Muralikrishna¹, Aline de Lucas²

¹Instituto Federal de Educação, Ciência e Tecnologia de São Paulo/Campus São José dos Campos,
Rodovia Pres. Dutra, km 145, Jardim Diamante, São José dos Campos-SP, Brasil,
paulo.rangel@aluno.ifsp.edu.br, amita@ifsp.edu.br

²Instituto Federal de Educação, Ciência e Tecnologia de São Paulo/Campus Jacareí, Rua Antônio
Fogaça de Almeida, 200, Jardim Elza Maria, Jacareí-SP, Brasil.
delucas@ifsp.edu.br

Resumo

O estudo do clima espacial concentra-se na influência do Sol sobre a Terra, abordando fenômenos como as emissões de massa coronal (CMEs) e *Solar Flares*. As regiões ativas (RAs), complexas áreas magnéticas na fotosfera solar, são analisadas por meio de magnetogramas, utilizando o sistema de classificação *Mount Wilson*. Este trabalho propõe avaliar a classificação automatizada de RAs usando redes neurais artificiais, testando a performance de classificação em magnetogramas coloridos e em preto e branco. Imagens do *Space Weather Live* e do *Solar Dynamics Observatory* (SDO) foram usadas para os testes, empregando o *Google Teachable Machine*. Os resultados visam compreender a relação entre classificações *alfa* e *beta* em diferentes magnetogramas.

Palavras-chave: Clima Espacial. Fenômenos Solares. Emissões de Massa Coronal (CMEs). *Solar Flares*. Classificação de Regiões Ativas.

Área do Conhecimento: Ciências Exatas e da Terra, Ciência da Computação.

Introdução

O estudo do clima espacial possui como ponto chave o estudo sobre o Sol e os fenômenos envolvidos na influência dele sobre a Terra. Os eventos frequentemente relacionados com a interação Sol-Terra são as Ejeções Coronais de Massa (CMEs) e os *Solar Flares*.

De acordo com Schwenn (2006), as CMEs são como nuvens gigantescas de gás ionizado ejetadas para o espaço interplanetário, que, após algumas horas, ou dias, podem, eventualmente, atingir a Terra e causar, entre outros efeitos, tempestades geomagnéticas. Por outro lado, os *flares* são como flashes de radiação que cobrem uma imensa gama de comprimentos de onda (desde as ondas de rádio aos raios gama) que podem, por exemplo, atingir a atmosfera terrestre em poucos minutos, de tal forma que os satélites caem em órbitas mais baixas.

Uma das relações mais visíveis de alguns fenômenos solares com o clima do Sol é a ligação das manchas solares e suas regiões ativas com a frequência e intensidade de alguns desses fenômenos. Por exemplo, o aumento da atividade de *flares* está correlacionado com a complexidade das classes de manchas solares. Diversos estudos estatísticos e de casos têm sido realizados para investigar as propriedades das regiões ativas que abrigam a atividade de flares (JAEGGLI *et al.*, 2016).

As regiões ativas (RAs) formam um conjunto complexo de campos magnéticos com diferentes polaridades observadas na região da fotosfera do Sol (BUZULUKOVA *et al.*, 2022). Normalmente, as RAs são analisadas e observadas através de magnetogramas, gráficos que representam visualmente no espaço as variações da intensidade, polaridade e localização do campo magnético.


De acordo com Jaeggli *et al.* (2016), para a classificação das RAs se utiliza o sistema de classificação magnética *Mount Willson* que consiste em: 1) Classifica-se como α (*alfa*) as regiões que contêm uma única mancha solar ou um grupo de manchas solares com a mesma polaridade; 2) A classificação β (*beta*) refere-se às regiões que têm duas manchas solares ou grupos de manchas solares de polaridade oposta; 3) As do tipo γ (*gama*) referem-se às classes que a RA tem uma região complexa de manchas solares com polaridade mista. Esta classificação também pode ser utilizada individualmente para descrever uma RA que não tenha um comportamento magnético organizado; 4) A classificação δ (*delta*) indica que pelo menos uma mancha solar na região contém polaridades magnéticas opostas dentro de uma penumbra comum.

A era digital e suas implicações sociais: Desafios e contribuições

Este trabalho propõe a utilização de uma comparação entre dois tipos de magnetogramas para uma avaliação de precisão e eficiência de rede neural artificial na classificação de regiões ativas dentro do padrão *Mount Willson* de forma automatizada, sendo entregue à rede somente imagens dos magnetogramas.


Existem diversos tipos de magnetogramas, porém, os abordados e comparados serão um modelo colorido, no qual a cor verde representa o norte magnético e o sul é representado em amarelo; E um modelo preto e branco, que mostra exatamente o mesmo, porém com o norte e sul magnéticos respectivamente representados em branco e preto. A Figura 1 ilustra ambos os modelos através de imagens obtidas do SDO (*Solar Dynamics Observatory*) da NASA de uma região ativa do tipo *beta*, do dia 10 de janeiro de 2015.

Figura 1 - Comparação dos magnetogramas da mesma região ativa em diferentes cores. A imagem à esquerda mostra o magnetograma, do tipo beta, colorido e a figura da direita, em preto e branco, de uma observação do dia 10 de Janeiro de 2015.



Fonte: SDO/NASA.

Figura 2 - Comparação dos magnetogramas da mesma região ativa em diferentes cores do tipo alfa, observação do dia 18 de Outubro de 2014.



Fonte: SDO/NASA.

A era digital e suas implicações sociais: Desafios e contribuições

Metodologia

Para a realização dos testes foram utilizadas imagens disponibilizadas do site *Space Weather Live* que possui um registro enorme de regiões ativas classificadas, enquanto em paralelo, outras imagens complementares foram adquiridas através do site pertencente ao SDO.

Os testes realizados foram feitos para a classificação dos tipos *alfa* ou *beta*, sendo divididos em dois grupos que possuem as mesmas regiões ativas, porém dos diferentes tipos de magnetogramas, visto que, entre esses testes o desempenho de uma rede neural artificial somente teria uma possível diferença vindo dos tipos de magnetogramas.

A ferramenta disponibilizada gratuitamente pelo Google, o *Teachable Machine*, uma rede neural baseada numa técnica de *deep learning* que foi utilizada para a realização dos testes nos quais uma parte das imagens *alfa* e *beta* foram disponibilizadas e outra parte foi dedicada para validar o aprendizado do modelo, sendo então 26 imagens para o treinamento e 20 utilizadas para a validação.

As configurações padrões foram utilizadas, com exceção das épocas que foram alteradas para 60 ao invés do padrão de 50 para que o desempenho do aprendizado chegasse ao máximo possível no intervalo de aprendizado, sem que isso prejudicasse o modelo pelo vício aos dados alimentados.


As regiões ativas utilizadas serão do tipo *alfa* e *beta* para uma classificação um exemplo de imagem utilizada do tipo *beta* pode ser vista na figura 1 e uma de tipo *alfa* pode ser vista na figura 2.

Resultados

Como resultado da bateria de testes, com as mesmas imagens e configurações, com as imagens em preto e branco, alguns dos gráficos de perda por época foram obtidos, os quais a perda (representadas em azul) é a taxa de erro usando as imagens nas quais a rede foi treinada, já a perda de teste (representada em laranja) é a taxa de erro utilizando imagens inéditas para a rede.

Os gráficos foram fornecidos pelo próprio *Teachable Machine* e estão representados na Figura 2. Note que as perdas de teste a as perdas de treinamento divergem na maioria dos casos, porém a perda de teste do último modelo é baixa de forma praticamente ideal, é importante lembrar que os testes consecutivos mostram a variação de desempenho durante diversas tentativas de treino da rede, visto que, pela aleatoriedade dos pesos atribuídos às imagens de treino, ou a influência das imagens de treino na saída da classificação.

Figura 3 - Gráficos dos resultados dos testes aplicados em imagens em preto e branco do magnetograma.




Fonte: Autoral, via *Teachable Machine*.

A era digital e suas implicações sociais: Desafios e contribuições

A Figura 3 mostra os principais testes realizados com os modelos baseados nos magnetogramas coloridos. Note que nenhum dos modelos produziu um gráfico de baixa perda de teste.

Figura 4 - Gráficos dos resultados dos testes aplicados em imagens coloridas do magnetograma.



Fonte: Autoral, via Teachable Machine.

Discussão

Esse estudo de comparação dos magnetogramas e o impacto de cada tipo para a classificação em *machine learning* pode impactar em futuros modelos de redes neurais convolucionais para realizar a automação da classificação das regiões ativas, visto que, de acordo com Krizhevsky et al (2017) são classes de redes neurais que na sua maioria fazem suposições fortes e certas na natureza das imagens.

A classificação automatizada da classificação pode ser útil na previsão de diversos eventos climáticos solares, como por exemplo tempestades solares que, de acordo com Omatola e Okeme (2012) podem afetar comunicações de rádio, comunicações por satélite, radares e sistemas de navegação que são de suma importância para as atividades na Terra.

Como sequência a este trabalho, pretende-se estudar outras arquiteturas de redes convolucionais mais direcionadas ao perfil de imagens dos magnetogramas, buscando aliar também técnicas de segmentação de imagens na fase de pré-processamento, para gerar imagens de regiões ativas de maior resolução e padronizadas para utilizar como entrada para a classificação.

Conclusão

Conclui-se que a comparação dos resultados entre os tipos de magnetogramas revelou diversos dados importantes sobre o desempenho e eficiência da classificação. Enquanto os magnetogramas coloridos demonstraram uma maior taxa de acerto em relação às RAs do tipo alfa, os magnetogramas em preto e branco tiveram um desempenho mais variável e maior no geral quando aplicados em beta. Esses resultados sugerem que a abordagem de aprendizado de máquina pode ser uma ferramenta valiosa na classificação automatizada das RAs. Esta pesquisa contribui para o entendimento da relação entre diferentes tipos de magnetogramas e suas implicações na classificação de RAs, abrindo caminho para aplicações futuras na previsão de eventos climáticos solares e seus impactos em tecnologias de comunicação e navegação.

A era digital e suas implicações sociais: Desafios e contribuições

Referências:

BUZULUKOVA, Natalia; TSURUTANI, Bruce. Space Weather: From solar origins to risks and hazards evolving in time. **Frontiers in Astronomy and Space Sciences**, v. 9, p. 1017103, 2022.

CHOLA, Channabasava; BENIFA, JV Biabl. Detection and classification of sunspots via deep convolutional neural network. **Global Transitions Proceedings**, v. 3, n. 1, p. 177-182, 2022.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. MIT press, 2016.

GOOGLE, **Teachable Machine**. Disponível em: <<https://teachablemachine.withgoogle.com/>>. Acesso em: 18 de Agosto de 2023.

JAEGGLI, Sarah A.; NORTON, Aimee A. The magnetic classification of solar active regions 1992–2015. **The Astrophysical Journal Letters**, v. 820, n. 1, p. L11, 2016.

NASA, **Solar Dynamics Observatory**. Disponível em: <<https://sdo.gsfc.nasa.gov/data/aiahmi/>>. Acesso em: 18 de Agosto de 2023.

OMATOLA, K. M.; OKEME, I. C. Impacts of solar storms on energy and communications technologies. **Archives of Applied Science Research**, v. 4, n. 4, p. 1825-1832, 2012.

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. ImageNet classification with deep convolutional neural networks. **Communications of the ACM**, v. 60, n. 6, p. 84-90, 2017.

SCHWENN, Rainer. Space weather: The solar perspective. **Living reviews in solar physics**, v. 3, n. 1, p. 1-72, 2006.

SINGH, Ashok Kumar et al. Physics of space weather phenomena: a review. **Geosciences**, v. 11, n. 7, p. 286, 2021.

SPACE WEATHER LIVE, **SpaceWeatherLive.com | Real-time data and plots auroral activity**. Disponível em: <<https://www.spaceweatherlive.com/>>. Acesso em: 18 de Agosto de 2023.