

Panorama de modelos de previsão de explosões solar utilizando aprendizado de máquina

Juliana Sabino Ferreira^{1, 2}, Andre Leon S. Gradvohl¹,
Ana Estela Antunes da Silva¹, Guilherme P. Coelho¹

¹Faculdade de Tecnologia - Universidade Estadual de Campinas, ²Instituto Federal de Sao Paulo

ABSTRACT

Solar activities, including solar flares and coronal mass ejections, influence Space Weather and consequently affect Earth. In particular, technological systems orbiting the Earth and other systems on the ground are affected by solar radiation. Therefore, predicting solar flares helps in taking actions that aim to minimize the consequences of these phenomena in these technologies. The solar activity data is captured by specialized instruments and made available for prediction models to perform solar flare forecasting. However, the mechanism of solar flares is not fully understood. There are several models for predicting solar flares, many using machine learning. Despite being different models, we noted several common characteristics between them, which point to important factors that indicate characteristics of solar flares. One of the examples is the attributes extracted from solar data, which we classify as magnetic or morphological and help in prediction models. Thus, the research reported here sought to outline the works in the scientific literature that predict solar flares using machine learning. In this analysis, we consider some aspects, such as the algorithms and data used, as well as the types of attributes – magnetic or morphological – used. In addition, this research aims to verify the frequency of some characteristics present in these models, such as data sources, attributes, methods used, and forecast windows. The results pointed to the greater efficiency of models that use magnetic attributes to forecast solar flares. Other factors that also influence these models were the forecast windows, database and algorithms used.

Keywords: Solar Flares, Machine Learning, morphological parameters, magnetic parameters.

INTRODUÇÃO

O Clima Espacial exerce grande influência na Terra. Dentre os principais fenômenos do Clima Espacial estão as explosões solares. Elas, por sua vez, podem prejudicar o funcionamento dos sistemas de comunicação, por satélite, a propagação de ondas de rádio, a distribuição de energia elétrica, as naves espaciais e aeronaves e a

saúde humana dos astronautas. Todos esses fatores podem causar prejuízos sócio-econômicos e à vida humana [1, 2, 3, 4, 5, 6, 7, 8].

As explosões solares são erupções violentas, brilhos repentinos, que ocorrem na atmosfera solar e liberam enormes quantidades de energia. Além disso, as explosões solares emitem raios-x e radiação ultravioleta e eletromagnética [9, 10, 11].

Devido aos danos causados pelas explosões solares, existe a necessidade de prever sua ocorrência para que sejam tomadas medidas de amenização dos danos causados pela radiação solar. Porém, existem dificuldades em realizar esse tipo de previsão. Dentre os motivos é que o mecanismo que provoca as explosões solares ainda não é integralmente conhecido [5, 9, 12, 13, 14, 15].

Muitos autores relacionam as explosões solares com as manchas solares ou as regiões ativas. No caso das manchas solares, existem alguns métodos de classificação que utilizam algumas das suas características para a predição, como a Classificação McIntosh e a Classificação Mount Wilson. No caso das regiões ativas, existem vários parâmetros magnéticos citados na literatura que as relacionam às explosões solares [7, 9, 10, 11, 16, 17, 18, 19, 20].

Uma abordagem para previsão de explosões solares é a utilização de modelos (programas) de aprendizado de máquina que, a partir de dados relacionados à atividade solar, são treinados para descobrir características nos próprios dados que indicam as explosões. Esses modelos são influenciados pelos dados e pelos algoritmos usados, que conseqüentemente extraem atributos diferentes [10, 13].

Considerando a diferença entre os diversos modelos de previsão, esta pesquisa tem como objetivo traçar um panorama dos trabalhos na literatura científica que fazem previsão de explosões solares usando aprendizado de máquina (Machine Learning). Nessa análise consideramos alguns aspectos, como fontes de dados, algoritmos utilizados e tipos de atributos usados – que podem ser do tipo magnético ou do tipo morfológico.

METHODOLOGIA

Para o levantamento bibliográfico, nós consideramos as bases Scopus, Web of Science e IOPScience e selecionamos trabalhos do período que vai de 2015 a 2022, com as palavras-chave (“solar flares” and “(‘forecasting’ or ‘machine learning’) or ‘magnetic parameters’ or ‘morphological parameters’)”. Ao total, encontramos 232 artigos na base Scopus, 151 na Web of Science e 27 na IOPScience. Depois de uma filtragem considerando o escopo dos trabalhos, a eliminação das repetições e as pertinências para essa pesquisa, selecionamos 59 trabalhos.

Após o levantamento bibliográfico, os trabalhos foram tabulados e analisados considerando itens tais como ano de publicação, tipos de atributos, bases de dados, modelos e tipo de problema (classificação, regressão ou agrupamento). Em relação ao ano de publicação, verificamos os anos com maior número de publicações.

Quanto aos tipos de atributos, separamos os trabalhos naqueles que utilizam parâmetros magnéticos, morfológicos ou com a combinação de ambos.

No que se refere às bases de dados, contabilizamos as bases utilizadas em cada estudo. Nota-se que existem algumas bases que são usadas com mais frequência para esse tipo de problema, relatadas em muitos trabalhos, como a base *Spaceweather HMI Active Region Patch* (SHARP) [10, 12, 20]. Outra questão que percebemos é o quanto é comum utilizar mais de uma base para criar um modelo de previsão. Notamos essa característica em diversos trabalhos [7, 9, 11, 21].

Nos modelos de previsão, observamos quais algoritmos de aprendizado de máquina são mais usados para resolver esse tipo de problema. Finalmente, classificamos os trabalhos encontrados a partir da caracterização sobre o tipo de problema, considerando tarefas de aprendizado de máquina, que nos trabalhos se dividiram em classificação e regressão.

DEVELOPMENT

Após a seleção dos trabalhos, criamos uma planilha para compará-los. Nesta pesquisa, foram consideradas a quantidade de publicações por ano, os tipos de atributos, as janelas de previsão e os algoritmos mais utilizados.

Foram selecionadas publicações em todos os anos do período de 2015 a 2022. Notamos um aumento a partir do ano de 2018 (64 trabalhos), em 2019 com 65 e com um maior número de trabalhos no ano de 2020, com 85.

Em relação aos tipos de atributos, 37 trabalhos utilizam parâmetros magnéticos, 18 morfológicos e quatro a combinação de ambos os tipos de atributos. Notamos que a maioria dos trabalhos usa atributos magnéticos, em torno de 63% dos trabalhos. Uma hipótese que levantamos para justificar a prevalência dos trabalhos com atributos magnéticos é a possibilidade desses atributos serem mais precisos, já que, em vários estudos, os próprios autores relatam a criação de bons modelos de previsão usando eles [7, 9, 10, 11, 16, 18, 19, 20]. A combinação de ambos os tipos de atributos está presente em quatro trabalhos [5, 16, 21, 22], mas não é frequente, considerando o que se tem na literatura científica atualmente.

Em relação à janela de previsão, isto é, a antecedência com que o modelo consegue prever se ocorrerá uma explosão solar, 34 dos 59 trabalhos analisados utilizam a janela de 24 horas. Nove trabalhos usam janelas diferentes e 16 não informaram a janela de previsão utilizada. Uma hipótese para a prevalência da janela de 24 horas é a natureza dos dados, já que muitas bases consideram esse período para registrar a explosão. Porém, existem alguns trabalhos [8, 9, 20, 23, 24, 25], que criaram modelos com diferentes janelas e com resultados satisfatórios.

No caso do tipo de problema, 47 trabalhos utilizaram classificação, nove usaram regressão e três a combinação de ambos os tipos de tarefas. Consideramos que o problema de explosões solares tem como

natureza a tarefa de classificação, já que 80% dos trabalhos analisados usou esse tipo de tarefa, e apenas 9% deles usou regressão e 5% uma combinação dos dois tipos de tarefas.

Em relação aos algoritmos usados nos modelos de previsão, foram usados uma grande variedade, inclusive alguns trabalhos usaram mais de um algoritmo [7, 16, 10, 20]. As técnicas mais utilizadas foram o Support Vector Machine (SVM) em 19 trabalhos, Convolutional Neural Network (CNN) em 17 artigos, outros tipos de redes neurais em 13 trabalhos, Random Forest em 11 trabalhos, Multilayer Perceptron (MLP) em sete artigos, KNN em seis artigos, Regressão Logística em quatro artigos e Long Short Term Memory (LSTM) em três trabalhos.

Notamos, de maneira geral, que as redes neurais (considerando que CNN, MLP e LSTM são redes neurais) e o SVM são os algoritmos mais utilizados. Somando todos, há 40 trabalhos que usaram redes neurais, seguido por 19 trabalhos que usaram SVM. Evidencia-se que a maioria dos trabalhos usam redes neurais de uma forma geral, mas ao especificar os algoritmos, o algoritmo SVM prevalece, com 19 trabalhos, seguido da rede neural CNN, com 17 trabalhos.

CONCLUSÃO

Analisando a literatura científica no período entre 2015 a 2022, observamos os seguintes resultados. Verificamos que os atributos magnéticos são mais usados que os atributos morfológicos. Porém, este último tipo de atributo ainda é bastante usado, mesmo que em conjunto com o primeiro.

A maioria dos trabalhos usa janelas de previsão de 24 horas. A razão dessa escolha se deve à natureza dos dados que, em muitos casos, têm esse período por padrão. Porém, existem modelos com horizontes de previsão distintos que também apresentaram bons resultados.

Em relação às tarefas de aprendizado de máquina que os modelos podem usar, no caso de previsão de explosões solares usa-se majoritariamente a classificação. Isso foi constatado em 80% dos trabalhos analisados.

Por fim, em relação às técnicas para previsão, os trabalhos usam prioritariamente redes neurais, SVM, Random Forest, Regressão Logística e KNN.

Essas conclusões nos permitem avaliar melhor as tendências das pesquisas em relação aos tipos de atributos, métodos e janelas de previsão utilizados para prever de explosões solares utilizando algoritmos de aprendizado de máquina. Assim, é possível buscar por lacunas que ainda não foram exploradas e buscar novos métodos que possam atingir melhores resultados frente ao estado-da-arte.

REFERENCES

- [1] HANSLMEIER, Arnold. **The Sun and Space Weather**. 2. ed. New York, NY: Springer, jan. 2007. (Astrophysics and Space Science Library).

- [2] YAMAMOTO, Yukiko et al. Improvement of sun flare prediction by SVM integrated GA. In: 2015 11th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS). Bangkok, Thailand: IEEE, nov. 2015.
- [3] CALDANA, Ismael et al. Using X-ray flux time series for solar explosion forecasting. In: 2017 Brazilian Conference on Intelligent Systems (BRACIS). Uberlandia: IEEE, out. 2017.
- [4] NOVITASARI, Dian Candra Rini et al. Flare identification by forecasting sunspot numbers using fuzzy time series Markov chain model. In: 2019 International Seminar on Intelligent Technology and Its Applications (ISITIA). Surabaya, Indonesia: IEEE, ago. 2019.
- [5] ABED, Ali; QAHWAJI, Rami. An application of the deep belief networks to the prediction of massive solar flare occurrence using SDO/HMI data. In: 2020 IEEE International Conference on Big Data (Big Data). Atlanta, GA, USA: IEEE, dez. 2020.
- [6] ASCHWANDEN, Markus J. Global energetics of solar flares. XI. Flare magnitude predictions of the GOES class. **The Astrophysical Journal**, American Astronomical Society, v. 897, n. 1, p. 16, jun. 2020.
- [7] HAZRA, Soumitra et al. Distinguishing between flaring and nonflaring active regions. **Astronomy & Astrophysics**, EDP Sciences, v. 639, a44, jul. 2020.
- [8] LANDA, Vlad; REUVENI, Yuval. Low-dimensional convolutional neural network for solar flares GOES time-series classification. **The Astrophysical Journal Suppl. Ser.**, American Astronomical Society,
- [9] HUANG, Xin et al. Learning solar flare forecasting model from magnetograms. In: 2017 IEEE Visual Communications and Image Processing (VCIP). St. Petersburg, FL: IEEE, dez. 2017.
- [10] FLORIOS, Kostas et al. Forecasting solar flares using magnetogram-based predictors and machine learning. **Solar Physics**, Springer Science e Business Media LLC, v. 293, n. 2, fev. 2018.
- [11] AHMADZADEH, Azim et al. Challenges with extreme class-imbalance and temporal coherence: A study on solar flare data. In: 2019 IEEE International Conference on Big Data (Big Data). Los Angeles, CA, USA: IEEE, dez. 2019.
- [12] BOBRA, M G; COUVIDAT, S. Solar flare prediction usingsdo/hmi vector magnetic field data with a machine-learning algorithm. **The Astrophysical Journal**, IOP Publishing, v. 798, n. 2, p. 135, jan. 2015.
- [13] NISHIZUKA, Naoto et al. Reliable probability forecast of solar flares: Deep flare net-reliable (DeFN-R). **The Astrophysical Journal**, American Astronomical Society, v. 899, n. 2, p. 150, ago. 2020.
- [14] TLATOV, A G et al. Prediction of solar flares and background fluxes of X-ray radiation according to synoptic ground-based observations using machine-learning models. **Cosmic Research**, Pleiades Publishing Ltd, v. 58, n. 6, p. 444–449, nov. 2020.

- [15] LIU, Hao et al. Predicting solar flares using a long short-term memory network. **The Astrophysical Journal**, American Astronomical Society, v. 877, n. 2, p. 121, jun. 2019
- [16] SHIN, Seulki et al. Development of daily maximum flare-flux forecast models for strong solar flares. **n**, Springer Science e Business Media LLC, v. 291, n. 3, p. 897–909, mar. 2016.
- [17] BASODI, Sunitha et al. Parallel computation of magnetic field parameters from HMI active region patches. In: 2017 IEEE International Conference on Big Data (Big Data). Boston, MA: IEEE, dez. 2017.
- [18] FANG, Yuanhui et al. Deep learning for automatic recognition of magnetic type in sunspot groups. **Advances in Astronomy**, Hindawi Limited, v. 2019, p. 1–10, ago. 2019.
- [19] LIM, Daye et al. Ensemble forecasting of major solar flares with short-, mid-, and long-term active region properties. **The Astrophysical Journal**, American Astronomical Society, v. 885, n. 1, p. 35, out. 2019.
- [20] DESHMUKH, Varad et al. Leveraging the mathematics of shape for solar magnetic eruption prediction. **Journal of SpaceWeather and Space Climate**, EDP Sciences, v. 10, p. 13, 2020.
- [21] CICOGNA, Domenico et al. Flare-forecasting algorithms based on high-gradient polarity inversion lines in active regions. **The Astrophysical Journal**, American Astronomical Society, v. 915, n. 1, p. 38, jul. 2021.
- [22] ABED, Ali K et al. The automated prediction of solar flares from SDO images using deep learning. **Advances in Space Research**, Elsevier BV, v. 67, n. 8, p. 2544–2557, abr. 2021.
- [23] RABOONIK, Abbas et al. Prediction of solar flares using unique signatures of magnetic field images. **The Astrophysical Journal**, American Astronomical Society, v. 834, n. 1, p. 11, dez. 2016.
- [24] CHEN, Yang et al. Identifying solar flare precursors using time series of SDO/HMI images and SHARP parameters. **SpaceWeather**, American Geophysical Union (AGU), v. 17, n. 10, p. 1404–1426, out. 2019.
- [25] RIBEIRO, F; GRADVOHL, A L S. Machine learning techniques applied to solar flares forecasting. **Astronomy & Computing**, Elsevier BV, v. 35, n. 100468, p. 100468, abr. 2021.

CONTACT INFORMATION

Juliana Sabino Ferreira
julianasabfer@gmail.com