

# Sun Tracker: um algoritmo de inteligência artificial que prevê eventos do tipo Carrington

Mariana Vale Taveira, Roseno Gonçalves Lopes Filho, Leonardo Kuhn (Orientador), Leandro Vidal Costa Castelani (Coorientador)

Colégio CIMAN, Brasília - DF

## RESUMO

Em 1859, uma nuvem massiva de gás eletrificado e partículas subatômicas altamente carregadas atingiram a magnetosfera terrestre, causando danos nas redes telegráficas mundiais. Causado por uma violenta ejeção de massa coronal (CME), o Evento de Carrington foi a maior tempestade geomagnética já registrada. Se um evento semelhante ocorresse nos dias atuais, as consequências seriam, no entanto, econômica e socialmente devastadoras, tendo em vista a alta dependência da sociedade na eletricidade e em linhas de energia quando comparada à época do ocorrido. Assim sendo, a fim de criar uma ferramenta auxiliadora na antevisão de tempestades solares parecidas, desenvolveu-se neste trabalho um algoritmo de inteligência artificial capaz de prever eventos do tipo Carrington com base na velocidade de prótons não-lineares originados por fenômenos relativos à atividade magnética do Sol. O Sun Tracker, nome dado ao algoritmo pelos autores, foi desenvolvido por meio de um modelo de *machine learning* do tipo Árvore de Decisão, o qual utilizou bases de dados das missões espaciais DSCOVR e WIND para os conjuntos de treino e teste. Sun Tracker obteve 79,5% de precisão, evidenciando a eficácia do modelo na previsão de eventos solares de risco à infraestrutura elétrica e eletrônica terrestre.

- Palavras-Chave: Evento de Carrington, Fenômenos solares, Machine Learning.

## I. INTRODUÇÃO

O ciclo solar descreve um período de, aproximadamente, 11 anos de atividade solar impulsionado pelo campo magnético do Sol e indicado pela frequência e intensidade das manchas solares visíveis na superfície e de outros fenômenos ligados à atividade magnética solar, como ejeções de massa coronal (CMEs, sigla em inglês para “coronal mass ejections”), erupções e ventos solares (MENEZES, 2021). A variação na contagem de manchas solares foi descoberta em 1843 pelo astrônomo alemão Samuel Heinrich Schwabe (WHITEHOUSE, 2020). Partindo de uma análise de ciclos solares ao longo dos séculos, pode concluir-se que nos máximos solares (picos de atividade no ciclo), a frequência de erupções e CMEs aumentam (média de 2 a 3 CMEs por dia), enquanto nos mínimos, diminuem (cerca de uma CME por semana) (BRAGA, 2007).

Assim como o vento solar, quando CMEs atingem a Terra podem afetar o espaço próximo, nossa magnetosfera e ionosfera (MENEZES, 2021). As ejeções de massa coronal interrompem o fluxo do vento solar e podem produzir intensas tempestades geomagnéticas e tempestades de prótons que podem atingir a Terra com resultados catastróficos.

O Evento de Carrington de 1859 foi a tempestade solar mais intensa da história. Ele atingiu o pico em setembro de 1859, durante o ciclo solar 10, quando uma série de ejeções de massa coronal atingiu a Terra. O fenômeno ganhou visibilidade principalmente devido às auroras intensas produzidas no céu noturno e às falhas no sistema de comunicações telegráficas ao redor do mundo (RODGER et al., 2008). Devido à ausência de linhas de transmissão de energia elétrica de alta tensão, o Evento de Carrington teve pouco impacto na segurança e economia global. Entretanto, se um grande evento climático espacial semelhante ao Evento de Carrington ocorresse hoje, os impactos para a sociedade poderiam ser devastadores, afetando diretamente satélites de telecomunicações e navegação, linhas de energia, sistemas elétricos e eletrônicos e muitos outros equipamentos que têm seu funcionamento baseado nas ondas eletromagnéticas refletidas em nossa atmosfera (BACCARO, 2004).

A questão relativa aos perigos apresentados pelas erupções solares e CMEs, estão novamente assumindo pautas de maior relevância global, uma vez que o Sol recentemente adentrou seu vigésimo-quinto ciclo: em dezembro de 2019, um grupo internacional de especialistas co-patrocinado pela NASA (Administração Nacional Aeronáutica e Espacial) e pela NOAA (Administração Nacional Oceânica e Atmosférica), anunciou um mínimo solar, marcando o início de um novo ciclo de atividades. Segundo Whitehouse (2020, p.13), o Painel de Previsão do Ciclo Solar 25 da NOAA prevê que o ciclo pode ter um início lento, e eles antecipam que o máximo solar ocorrerá entre 2023 e 2026, com uma faixa de pico de 95 a 130 manchas solares. Em outras palavras, esse novo período ilustra um futuro próximo de picos de atividade solar, com possíveis eventos danosos às sociedades tecnológicas da Terra.

## II. OBJETIVO E QUESTÃO PROBLEMA

A partir do tema aqui apresentado e da relevância da predição de eventos solares potencialmente adversos, surge o

questionamento da possibilidade de integrar o *machine learning* como ferramenta auxiliadora no processo de previsão de tempestades solares do tipo Carrington, que possam causar danos econômicos, sociais, militares e outros ligados direta e indiretamente à infraestrutura elétrica e eletrônica do planeta.

O presente trabalho tem como objetivo geral desenvolver um algoritmo de inteligência artificial capaz de prever tempestades solares do tipo Carrington - adversas à infraestrutura elétrica e eletrônica do planeta Terra - além de gerar respostas antecipadas para a preparação de contramedidas. Ainda convém delimitar os objetivos específicos que nortearam este projeto:

- 1) Determinar a existência de uma correlação matemática entre a incidência de radiações solares em diferentes eixos, seus ângulos de derivação, a distância Terra-Sol, e a velocidade resultante dos ventos solares;
- 2) Verificar a viabilidade de antever a ocorrência de eventos do tipo Carrington por meio da determinação da velocidade de prótons não-lineares provenientes de atividades solares;
- 3) Comparar os resultados obtidos pelo algoritmo com os dados obtidos pelas espaçonaves DSCOVR e WIND, a fim de conseguir uma alta taxa de precisão;
- 4) Evidenciar a importância do algoritmo no monitoramento de atividades solares potencialmente danosas à Terra, visando estimular a cooperação global e a descentralização de meios para alcançar o bem maior.

### III. DESCRIÇÃO DE MATERIAIS E MÉTODOS

Com o intuito de prever a velocidade resultante de prótons não-lineares (partículas dispersas em diferentes eixos de propagação), oriundos de erupções solares e CMEs, foi desenvolvido um modelo de *machine learning* do tipo Árvore de Decisão. Ou seja, um algoritmo de classificação e regressão para uso na modelagem preditiva de atributos discretos e contínuos, nesse caso, previsões fundadas nas relações entre colunas de entrada: a base de dados; e as informações resultantes: a velocidade dos prótons.

Para prever essas velocidades, foi preciso, primeiramente, determinar uma base de dados, cujas informações serviram de parâmetro para o treinamento do algoritmo. Tais parâmetros foram primordialmente compostos pelas seguintes informações:

- A incidência de radiações solares nos eixos Bx, By e Bz, detectada pelos satélites WIND e DSCOVR da NASA, cujos parâmetros possuem alta confiabilidade;
- O ângulo de derivação dessas radiações;
- A data de detecção;
- A distância da Terra ao Sol em determinada data;
- A velocidade nos eixos  $V_x$  e  $V_y$  dos prótons que acompanham as radiações solares, e a sua resultante sendo essa expressa pela Equação (I).

$$V_r = \sqrt{V_x^2 + V_y^2} \quad \text{Equação (I)}$$

Dessa forma, o banco de dados do Sun Tracker - nome dado pelos autores ao algoritmo em questão - foi preenchido com aproximadamente 180 mil registros, cobrindo todas as datas de janeiro de 2022 até o final de agosto. Um fragmento do banco de dados está representado na Figura 1, e sua versão de visualização mais abrangente na Figura 2.

PT/Instituto	mes	Data/hora	Bx	By	Bz	historico_cpm_30m	AVGDEV
371.071	1.77836	2022-01-23 08:2...	0.0875054	1.06875	-0.202487	-1.76021	22.8075
389.246	3.77670	2022-03-23 07:1...	-0.0593380	0.801474	-0.0741732	-0.00674395	22.5822
563.029	7.80426	2022-07-24 03:0...	0.0641294	0.863526	-0.089618	0.670596	21.4513
573.396	6.07822	2022-06-26 08:1...	0.0362413	0.856057	-0.252566	0.854461	18.0222
438.446	2.91484	2022-02-27 10:4...	0.0322364	0.887775	0.240388	-0.689947	16.2659
313.837	6.85067	2022-06-10 12:2...	0.182113	0.398538	0.0321355	0.888495	15.8698
468.175	4.40328	2022-04-13 01:3...	-0.0577309	-0.459857	0.0463312	0.366427	15.2222
803.461	4.53854	2022-04-16 03:4...	-0.359223	-0.237953	0.527978	0.415478	14.6781
443.765	1.38738	2022-01-19 02:5...	0.10705	-0.365962	0.146361	-2.26799	14.5914
365.195	5.19062	2022-05-05 17:1...	0.0040554	0.377701	0.170421	0.867919	14.2596
340.253	5.2834	2022-05-08 12:0...	0.119335	0.607454	0.332543	0.695566	13.8289
506.904	8.0706	2022-08-14 02:5...	-0.247962	0.557065	-0.10044	0.413028	13.8284
416.664	3.86766	2022-03-28 15:0...	0.0879738	0.531848	-0.102871	0.123874	13.7215
375.532	3.1235	2022-03-03 16:5...	-0.181486	0.492021	0.0890161	-0.478127	13.4995
638.384	6.89328	2022-06-26 20:3...	0.253093	0.437395	0.422947	0.852909	13.2705
309.339	4.51403	2022-04-19 13:0...	-0.086241	0.606231	-0.140865	0.404027	13.21
373.578	3.20512	2022-03-09 03:4...	-0.0756137	0.568282	0.00390322	-0.336951	13.2444
429.023	1.75037	2022-01-22 12:1...	-0.194134	-0.081854	-0.00203307	-1.79786	13.1713
604.223	8.6135	2022-08-18 09:4...	0.782715	-0.0345275	0.257333	0.344102	13.1168
525.824	2.12778	2022-02-03 20:6...	-0.0346494	-0.040148	-0.00949355	-1.3807	13.1034
365.484	1.36514	2022-01-11 13:1...	0.180282	0.0560491	-0.144033	-2.22385	12.848
455.77	1.80456	2022-01-26 12:5...	-0.190123	0.259675	-0.114281	-1.64023	12.656
575.388	6.54336	2022-06-16 07:1...	-0.242505	0.489572	0.222767	0.370997	12.613
455.147	8.58481	2022-08-17 13:6...	0.998954	0.402732	0.888983	0.358323	12.5962
622.218	1.63542	2022-01-16 01:3...	0.40504	0.263296	-0.174214	-2.04481	12.5874
351.021	7.19558	2022-07-05 20:4...	0.202278	0.166937	-0.186236	0.81432	12.4842
525.181	1.97981	2022-01-29 08:3...	-0.208744	0.331266	0.668823	-1.54622	12.3825
474.585	4.42521	2022-04-12 18:0...	-0.21795	0.386744	-0.0411617	0.361948	12.2334
460.054	4.42556	2022-04-12 18:2...	0.230522	0.48023	-0.327586	0.361519	12.2334
533.571	1.55682	2022-01-16 19:4...	0.0496885	0.656232	0.173277	-2.01956	11.9923
469.917	8.89881	2022-08-14 24:6...	0.0738323	0.372346	-0.386073	0.346663	11.8203

Figura 1 - Fragmento do banco de dados. Fonte: Autoria própria, (2022).



Figura 2 - Visualização interativa do banco de dados no software *Orange*. Fonte: Autoria própria, (2022).

Em seguida, por meio do software de visualização de dados de código aberto e mineração, *Orange Data Mining*, foi suscitada uma programação visual para análise exploratória de dados quantitativos e a percepção interativa de dados. A visualização do funcionamento do algoritmo no software está disposta na Figura 3.

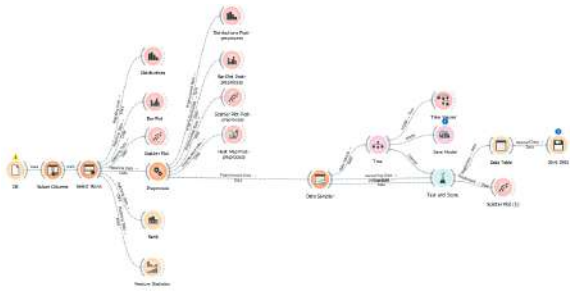


Figura 3 - Funcionamento do algoritmo no *Orange*.  
Fonte: Autoria própria, (2022).

Nessa etapa, o algoritmo passou a buscar relações matemáticas entre os regressores e os precursores da base de dados (no caso do Sun Tracker, esses termos correspondem, respectivamente, à velocidade dos prótons e os outros dados da base supracitados). Mais especificamente, via cálculo da entropia, o algoritmo tenta entender quanto a oscilação de um valor vai impactar na modelagem. A fim de rodar os testes de precisão e coerência do algoritmo, a base de dados foi separada em dois grupos menores. O primeiro, que continha 70% dos dados da base maior, pode ser classificado como o grupo de treino, que viabiliza a aprendizagem do algoritmo e sua modelagem. Já o segundo, que continha outros 30% da base de dados, o grupo de testes, tem função de comparar os valores reais do banco de dados com os obtidos pelo algoritmo já treinado.

Após encontradas as possíveis relações entre os dados, o algoritmo Sun Tracker foi posto a teste quanto a sua precisão, por meio de duas métricas de desempenho:

A primeira, o  $R^2$ , mede a aderência dos dados a um modelo, podendo variar de 0% a 100%. A segunda, o MAE (sigla em inglês que, traduzida, significa Erro Médio Absoluto), consiste na média das distâncias entre os valores preditos ( $y_i$ ), nesse caso, as velocidades encontradas pelo algoritmo, e os valores reais ( $x_i$ ), as velocidades detectadas pelos satélites. O MAE pode ser calculado por meio da Equação (2).

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad \text{Equação (2)}$$

#### IV. RESULTADOS E DISCUSSÃO DOS RESULTADOS

A avaliação de desempenho do modelo feita pela métrica  $R^2$  foi de 0,795, ou seja, o algoritmo obteve 79.5% de adesão.

O MAE, por sua vez, foi de  $2.9103 \cdot 10^7 m \cdot s^{-1}$ . Com esses dados, pode-se analisar o potencial de precisão do algoritmo. Para efeito de conscientização do Erro Médio Absoluto, destaca-se que a velocidade observada dos ventos

solares nessa base de dados varia entre  $2.5872 \cdot 10^7 m \cdot s^{-1}$  e  $7.70727 \cdot 10^8 m \cdot s^{-1}$

É possível observar na Figura 4 um gráfico que plota sobre o eixo x os valores preditos pelo algoritmo, e, sobre o eixo y, os valores reais da base de dados. Um algoritmo ideal teria esse mesmo gráfico representado por uma reta bissetriz aos eixos do plano, no entanto, apesar de sua forte adesão, o algoritmo Sun Tracker carece de exatidão nos resultados obtidos.




Figura 4 - Gráfico da correlação do algoritmo. Fonte: Autoria própria, (2022).

A fim de melhor ilustrar os resultados alcançados, a Tabela 1 compara os resultados obtidos pelo algoritmo de previsão e os resultados reais obtidos pelos satélites, quanto à velocidade resultante dos prótons não lineares.

Tabela 1 - Velocidades reais e velocidades previstas

Data (2022)	$V_R$ real	$V_R$ prevista
01/01/2022	555516 m/s	541082 m/s
01/02/2022	4338863 m/s	461778 m/s
01/03/2022	542980 m/s	454923 m/s
01/04/2022	440048 m/s	426417 m/s

Fonte: Autoria própria, (2022).

Embora os resultados do algoritmo sejam promissores, a precisão do mesmo ainda pode ser refinada. Para isso, faz-se necessário a implementação de uma maior entrada de dados e variáveis para o processo de treinamento do modelo, no entanto, isso só seria possível com a contribuição de demais órgãos, agentes e instituições que monitoram a atividade solar. Além do mais, durante a computação da base de dados, foi encontrada uma aberração numérica no ângulo de derivação das radiações: entre 13 e 20 de março de 2022, os dados apontavam um valor constante de  $100000^\circ$  para tal ângulo. Supõe-se que isso se deve a uma falha técnica nas sondas, podendo haver diversos motivos para

tal. Esses valores foram computados como um erro e desprezados durante o treinamento do algoritmo, uma vez que, aberrações como essa apresentam grande risco para as previsões do modelo matemático.

#### V. CONCLUSÕES

Foi possível desenvolver um algoritmo capaz de encontrar correlações matemáticas entre dados dos ventos solares e antever a velocidade dos prótons energeticamente carregados por erupções solares. A partir de um estudo teórico, de uma análise quantitativa de dados e da criação de um modelo matemático, o projeto foi capaz de evidenciar a importância de algoritmos como o Sun Tracker para o monitoramento e previsão de atividades solares, buscando cooperar para a descentralização de meios que visam o bem-estar global.

Ao final, a pesquisa gerou conclusões primordialmente quantitativas devido a seu caráter experimental. Dessa forma, foi feita a análise da incidência e da velocidade de radiações solares, permitindo que uma correlação matemática entre os valores previsse a velocidade resultante de prótons não lineares que ameaçam atingir a Terra. Já uma interpretação qualitativa desses dados, possibilitou a especulação quanto a possibilidade de futuros picos de atividade solar e ocorrências semelhantes ao Evento de Carrington de 1859. Provando-se, assim, a viabilidade do uso de tecnologias básicas no ramo da inteligência artificial para a previsão da atividade solar.

#### VI. REFERÊNCIAS BIBLIOGRÁFICAS

BACCARO, Marco. INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Modelo Hidrodinâmico Bidimensional de Ejeção de Massa Coronal, 2004. 95p, il. Dissertação (Mestrado).

BRAGA, Bruna; CECATTO, José Roberto; INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Espectroscopia da atividade solar na banda de ondas de rádio associada a fenômenos de “ejeção de massa coronal - (CME)”, 2007. 20p, il. Dissertação (Projeto de iniciação científica).

COSTA, E. Jr. et al. O vento solar e a atividade geomagnética. Revista Brasileira de Ensino de Física, v.33, n.4, p. 4301, 2011.

ECHER, E. Magnetosferas planetárias. Revista Brasileira de Ensino de Física, v.32, n.2, p. 2301, 2010.

FEYNMAN, Joan.; GABRIEL, S. B. On space weather consequences and prediction. Journal of Geophysical Research, v.105, n.5, p. 10543-10564, 2000.

GUEDES, Márcia. INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Ejeções de Massa Coronal nos Ciclos Solares 23 e 24 - Evolução da ocorrência,

periodicidades e fenômenos associados, 2015. 131p, il. Tese (Doutorado)

LANZEROTTI, Louis J. Space Weather Effects on Technologies. Geophysical Monograph Series – Bell Laboratories, Lucent Technologies, Murray Hill: New Jersey, 2013.

MENEZES, Fabian. UNIVERSIDADE PRESBITERIANA MACKENZIE, Centro de Rádio Astronomia e Astrofísica Mackenzie. Influência da atividade magnética na atmosfera solar e na propagação de ejeções de massa coronal de estrelas do tipo-solar, 2021. 193p, il. Tese (Doutorado)

RODGER, Craig J. et al. Atmospheric impact of the Carrington event solar protons. Journal of Geophysical research, v.113, doi:10.1029/2008JD010702, 2008.

WHITEHOUSE, The next solar cycle and why it matters for climate. ed. Londres: The global warming policy foundation, 2020. 18 p, il.