



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2024/06.28.11.44-TDI

**REDES CONVOLUCIONAIS E TÉCNICAS DE
APRENDIZADO PROFUNDO PARA DETECÇÃO DE
ONDAS DE CHOQUE INTERPLANETÁRIAS COM O
USO DE GRÁFICOS DE SÉRIES TEMPORAIS**

Luís Eduardo Sales do Nascimento

Dissertação de Mestrado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Élcio Hideiti Shiguemori, e Aline de Lucas, aprovada em 17 de maio de 2024.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4BHMKUE>>

INPE
São José dos Campos
2024

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2024/06.28.11.44-TDI

**REDES CONVOLUCIONAIS E TÉCNICAS DE
APRENDIZADO PROFUNDO PARA DETECÇÃO DE
ONDAS DE CHOQUE INTERPLANETÁRIAS COM O
USO DE GRÁFICOS DE SÉRIES TEMPORAIS**

Luís Eduardo Sales do Nascimento

Dissertação de Mestrado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Élcio Hideiti Shiguemori, e Aline de Lucas, aprovada em 17 de maio de 2024.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4BHMKUE>>

INPE
São José dos Campos
2024

Dados Internacionais de Catalogação na Publicação (CIP)

Nascimento, Luís Eduardo Sales do.

Na17r Redes convolucionais e técnicas de aprendizado profundo para detecção de ondas de choque interplanetárias com o uso de gráficos de séries temporais / Luís Eduardo Sales do Nascimento. – São José dos Campos : INPE, 2024.

xxiv + 98 p. ; (sid.inpe.br/mtc-m21d/2024/06.28.11.44-TDI)

Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2024.

Orientadores : Drs. Élcio Hideiti Shiguemori, e Aline de Lucas.

1. Clima espacial. 2. Vento solar. 3. Ejeções coronais de massa interplanetárias. 4. Detecção de ondas de choque interplanetárias. 5. Aprendizado de máquina. I. Título.

CDU 004.85:52-4



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÃO



INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

DEFESA FINAL DE DISSERTAÇÃO DE LUÍS EDUARDO SALES DO NASCIMENTO BANCA Nº 088/2024, REG. 237812/2022

No dia 17 de maio de 2024, às 14:00h, na sala 33 do prédio LAC, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Computação Aplicada / Inteligência Artificial para Aplicações Espaciais, com a exigência de que o trabalho final a ser publicado deverá incorporar as correções sugeridas pela Banca Examinadora, com revisão pelo(s) orientador(es).

Título: "Redes convolucionais e técnicas de aprendizado profundo para detecção de ondas de choque interplanetárias com o uso de gráficos de séries temporais."

Membros da Banca:

Dr. Rafael Duarte Coelho Dos Santos – Presidente – INPE
Dr. Élcio Hideiti Shiguemori – Orientador – INPE
Dra. Aline de Lucas - Orientadora - IFSP
Dr. Nandamudi Lankalapalli Vijaykumar – Membro Interno – INPE
Dr. Tardelli Ronan Coelho Stekel – Membro Externo – IFSP



Documento assinado eletronicamente por **Rafael Duarte Coelho dos Santos, Pesquisadora**, em 21/05/2024, às 16:35 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **nandamudi lankalapalli vijaykumar (E), Usuário Externo**, em 22/05/2024, às 12:31 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Tardelli Ronan coelho stekel (E), Usuário Externo**, em 22/05/2024, às 14:08 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Elcio hideiti shiguemori (E), Usuário Externo**, em 22/05/2024, às 15:05 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Aline de Lucas (E), Usuário Externo**, em 22/05/2024, às 15:19 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **11963388** e o código CRC **FAAA9A78**.

Referência: Processo nº 01340.004056/2024-21

SEI nº 11963388

“A vida será mais complicada se você possuir uma curiosidade ativa, além de aumentarem as chances de você entrar em apuros, mas será mais divertida”.

*EDWARD SPEYER em
“Seis Caminhos a Partir de Newton”, 1994*

*Aos meus pais **Carlos e Marília**, às minhas irmãs
Letícia e Lidiane*

AGRADECIMENTOS

O desenvolvimento desse trabalho só foi possível pelo suporte e apoio de diversas pessoas com as quais pude contar ao longo dessa caminhada.

Aqui venho expressar meu sincero agradecimento, em primeiro lugar aos meus pais, Marília e Carlos, por toda a educação, força e apoio que sempre me proporcionaram. Também gostaria de agradecer às minhas irmãs, Letícia e Lidiane, que sempre me motivaram a buscar conhecimento e a estudar cada vez mais.

Aos meus orientadores, Elcio Hideiti Shiguemori e Aline de Lucas, por tornarem possível a minha jornada no mestrado e por me orientarem ao longo do desenvolvimento desta pesquisa.

Agradeço aos meus colegas e professores do programa de pós graduação em Computação Aplicada, pelo genuíno interesse na continuidade dos meus estudos e por todas as oportunidades de aprendizado e conhecimento que me proporcionaram.

Às equipes das missões STEREO, ACE, SOHO e WIND cujos dados foram indispensáveis para o desenvolvimento desta pesquisa expresso minha mais profunda gratidão.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), que apoiou o presente trabalho através da concessão da bolsa de mestrado.

RESUMO

Uma das áreas de estudo do clima espacial analisa as condições do ambiente interplanetário devido à atividade solar e à conseqüente interação do plasma do vento solar com a magnetosfera terrestre. Além disso, investiga como a atividade solar pode afetar o funcionamento de sistemas e serviços terrestres e espaciais, bem como a saúde e a vida na Terra. As estruturas magnéticas conhecidas como Ejeções Coronais de Massa Interplanetárias (ICMEs, do inglês *Interplanetary Coronal Mass Ejections*) podem afetar o funcionamento de equipamentos sensíveis a grandes variações de correntes elétricas, além de serem capazes de interagir com o ambiente terrestre, sendo associados à formação de ondas de choque interplanetárias de larga escala que podem interagir com a magnetosfera terrestre. O presente trabalho teve por finalidade estudar e avaliar a aplicação de técnicas de aprendizado de máquina para previsão, classificação e identificação de ondas de choque interplanetárias em ambiente próximo à Terra, sendo proposta uma nova abordagem considerando o uso de gráficos a serem processados por redes neurais convolucionais. A partir de imagens das séries temporais dos eventos identificados pelos sensores a bordo dos satélites, onde as redes neurais identificaram a ocorrência do choque com uma acurácia aproximada de 91% em uma variedade de janelas de tempo de observação. Isso foi possível através da utilização de técnicas para o reconhecimento de padrões por meio da transferência de aprendizado e a generalização das arquiteturas utilizando um vasto conjunto de dados, totalizando 1059 amostras *negativas*, 88 amostras de choque interplanetários do tipo *reverso rápido* e 500 do tipo *frontal rápido* a partir dos dados in-situ dos satélites ACE, STEREO-A e STEREO-B, juntamente com métricas que avaliaram os resultados obtidos de forma completa. Adicionalmente foi desenvolvida uma abordagem para previsão do tempo de chegada das estruturas magnéticas, sendo obtido arquiteturas de redes neurais que garantiram uma acurácia de 56,6%, onde as amostras são detectadas com um erro igual ou inferior a 13,51 horas, para mais ou para menos. Nessa segunda abordagem, foi empregado o uso de imagens do coronógrafo 2 do satélite SoHO, com um conjunto de dados que totalizou 560 amostras de CMEs que guiaram ou não ondas de choque interplanetárias. Isso permite um grande avanço na detecção de estruturas de ondas de choque interplanetárias em comparação com o uso de técnicas tradicionais.

A capacidade de prever o tempo de chegada ou de detectar estruturas magnéticas com maior precisão em ambiente próximo à Terra tem implicações diretas para a mitigação de riscos associados a eventos solares extremos, demonstrando o potencial desta pesquisa. Em suma, este estudo abordou uma lacuna significativa no campo do clima espacial, introduzindo técnicas avançadas de aprendizado de máquina para a previsão e detecção de ondas de choque interplanetárias. Futuras investigações poderão expandir a aplicabilidade dessas técnicas, explorando outras características dos dados interplanetários e aprimorando ainda mais os resultados obtidos.

Palavras-chave: Clima Espacial. Vento Solar. Ejeções Coronais de Massa Interplanetárias. Detecção de Ondas de Choque Interplanetárias. Aprendizado de Máquina.

CONVOLUTIONAL NETWORKS AND DEEP LEARNING TECHNIQUES FOR DETECTION OF INTERPLANETARY SHOCK WAVES USING TIME SERIES GRAPHS

ABSTRACT

The space weather study area analyzes the conditions of the interplanetary space due to solar activity and the consequent interaction of the solar wind plasma with the Earth's magnetosphere, in addition to investigating how solar activity can affect the functioning of terrestrial and space systems and services, as well as health and life on Earth. Magnetic structures named Interplanetary Coronal Mass Ejections (ICMEs) can affect the functioning of sensitive equipment to large variations in electrical currents, in addition to being capable of interacting with the near Earth's space, associated to the formation of large-scale interplanetary shock waves that can interact with the Earth's magnetosphere. The purpose of this work was to study and evaluate the application of machine learning techniques for prediction, classification, and identification of interplanetary shock waves in an environment close to Earth, proposing a new approach considering the use of graphs as inputs to convolutional neural networks. Using images of the time series of events identified by sensors on board satellites, our neural networks identified the occurrence of the shock with an approximate accuracy of 91% across a range of observation time windows. This was possible using techniques for pattern recognition through transfer learning and the generalization of architectures using a large dataset, which totaled 1059 negative samples, 88 samples of fast reverse interplanetary shocks and 500 fast frontal interplanetary shocks from the in-situ data of the ACE, STEREO-A and STEREO-B satellites, along with appropriate metrics for evaluating the problem addressed. Additionally, an approach was developed for predicting the arrival time of magnetic structures, obtaining neural network architectures that guaranteed an accuracy of 56.6%, where the samples are detected with an error equal to or less than 13.51 hours. In this second approach, the use of images from the coronagraph 2 of the SoHO satellite was employed, with a dataset that totaled 560 samples of CMEs that guided or not interplanetary shock waves. Thus allowing a great advance in the detection of interplanetary shock wave structures compared to the use of traditional techniques.

The ability to predict the arrival time or to detect magnetic structures with a greater precision in environment near Earth has direct implications for mitigating risks associated with extreme solar events, demonstrating the potential of this research. In summary, this study addressed a significant gap in the space weather, introducing advanced machine learning techniques for the prediction and detection of interplanetary shock waves. Future investigations may expand the applicability of these techniques, exploring other characteristics of interplanetary data and further improving the results obtained.

Keywords: Space Weather. Solar Wind. Interplanetary Coronal Mass Ejections. Detection of Interplanetary Shock Waves. Machine Learning.

LISTA DE FIGURAS

	<u>Pág.</u>
1.1 Classificação das ondas de choque interplanetárias.	3
3.1 Evolução da atividade solar entre o período de 1999 e 2014.	14
3.2 Tempo de propagação de alguns tipos de estruturas, partículas e radiação durante a atividade solar.	15
3.3 Representação esquemática da formação de choques frontais e reversos guiados por CIRs.	16
3.4 Identificação dos pontos de Lagrange.	22
3.5 Representação simplificada do funcionamento de um neurônio artificial.	23
3.6 Representação de uma rede MLP, com as entradas, as camadas ocultas e as camadas de saída.	27
3.7 Representação simplificada do funcionamento de um neurônio de uma rede convolucional.	28
3.8 Comparação de exemplos de redes neurais rasas e profundas.	30
3.9 Comparação entre as curvas de aprendizado, com base na quantidade de amostras.	31
3.10 Representação esquemática de uma onda de choque guiada por uma nuvem magnética.	34
4.1 Diagrama da metodologia desenvolvida para detecção das ondas de choque interplanetárias.	38
4.2 Diagrama da metodologia desenvolvida para previsão do tempo de chegada das ondas de choque interplanetárias.	39
4.3 Quantidade de amostras por tipo e estrutura que guiou a onda de choque, para o treinamento das redes convolucionais para detecção e classificação.	41
4.4 Quantidade de amostras obtidas e o tempo, em horas, para chegar à Terra.	43
4.5 Quantidade de amostras por tipo de choque interplanetário.	44
4.6 Exemplo da aplicação do algoritmo LDS.	45
4.7 Exemplo de entrada das redes convolucionais para detecção e classificação da onda de choque interplanetária, do tipo reversa rápida.	46
4.8 Exemplo de entrada das redes convolucionais para detecção e classificação da onda de choque, do tipo frontal rápida.	47
4.9 Exemplo de entrada das redes convolucionais para detecção e classificação da onda de choque interplanetária, do tipo frontal rápida, com a presença de um grande período com <i>gaps</i>	48

4.10	Exemplo de entrada das redes convolucionais para detecção e classificação da onda de choque interplanetária, sem a ocorrência de perturbações que identifiquem uma onda de choque interplanetária.	49
4.11	Pré-processamento das imagens obtidas pelo coronógrafo LASCO C2. . .	50
4.12	Imagens do LASCO C2 com o pré-processamento inicial e com pré-processamento MOR.	51
4.13	Exemplo da propagação inicial de uma CME, ocorrida em 25 de outubro de 2001.	52
4.14	Exemplo da propagação inicial de uma CME, ocorrida em 25 de outubro de 2013.	53
4.15	Exemplo da propagação inicial de uma CME, ocorrida em 15 de março de 2015.	54
5.1	Comparação dos resultados a partir do balanceamento e ajuste dos hiperparâmetros.	61
5.2	Histórico de treinamento da rede com 2 horas de dados utilizando o mapa de atributos extraído pela rede pré-treinada Painters.	62
5.3	Onda de choque interplanetária frontal rápida, detectada pelo satélite ACE, às 04:05 UT do dia 17 de março de 2015.	66
5.4	Onda de choque interplanetária reversa rápida, detectada pelo satélite STEREO-A, às 23:12 UT do dia 22 de julho de 2016.	68
5.5	Onda de choque interplanetária reversa rápida, detectada pelo satélite ACE, às 11:31 UT do dia 15 de junho de 2000.	70
5.6	Onda de choque interplanetária reversa lenta, detectada pelo satélite ACE, às 12:20 UT do dia 17 de junho de 2001.	72
5.7	Exemplo de um caso sem a presença de uma onda de choque interplanetária, no dia 08 de julho de 2003.	74
5.8	Onda de choque interplanetária frontal rápida, detectada pelo satélite ACE, às 20:45 UT do dia 20 de fevereiro de 2000.	75
5.9	Comparação da distribuição empírica com distribuição suavizada.	77
5.10	Distribuição dos erros, sem aplicação do LDS, para o conjunto de teste. .	78
5.11	Distribuição dos erros, com aplicação do algoritmo LDS, para o conjunto de teste.	79
5.12	Comparação dos resultados obtidos com os valores esperados para o conjunto de teste.	80

LISTA DE TABELAS

	<u>Pág.</u>	
3.1	Categorias das tempestades geomagnéticas e as consequências causadas pela ocorrência destes eventos.	17
3.2	Características do imageador e coronógrafo do satélite SoHO.	20
3.3	Satélites, seus instrumentos, parâmetros medidos com resolução temporal para identificação das ondas de choque.	21
3.4	Principais redes neurais pré-treinadas.	32
4.1	Exemplo de uma matriz de confusão.	57
4.2	Métricas de avaliação da arquitetura das redes.	58
5.1	Resultados da avaliação do conjunto de validação de uma das redes treinadas considerando diferentes estágios do treinamento.	62
5.2	Avaliação da abordagem de aprendizado de máquina para o conjunto de teste em cada padrão de tempo observado.	64
5.3	Comparação dos resultados utilizando eventos catalogados pelo satélite ACE durante o SC 23.	65
5.4	Modelos e saídas obtidas para o evento ocorrido no dia 17 de março de 2015.	67
5.5	Modelos utilizados e saídas obtidas para o evento ocorrido no dia 22 de julho de 2016.	69
5.6	Modelos utilizados e saídas obtidas para o evento ocorrido no dia 15 de junho de 2000.	70
5.7	Modelos utilizados e saídas obtidas para o evento ocorrido no dia 22 de julho de 2016.	73
5.8	Comparação das saídas obtidas para o período observado no dia 08 de julho de 2003.	74
5.9	Modelos e saídas obtidas para o evento ocorrido no dia 20 de fevereiro de 2000.	76
5.10	Comparação dos resultados entre as diferentes arquiteturas testadas para obtenção dos resultados.	80
5.11	Comparação dos resultados entre modelos desenvolvidos anteriormente e o novo modelo.	81
5.12	Resultados obtidos para algumas amostras do conjunto de teste para o problema de previsão.	81

LISTA DE ABREVIATURAS E SIGLAS

ACE	–	<i>Advanced Composition Explorer</i>
API	–	<i>Application programming interface</i>
CCE	–	Entropia cruzada categórica
CE	–	Entropia cruzada
CESE	–	<i>Conservation Element and Solution Element</i>
CFNN	–	<i>Cascade Forward Neural Network</i>
CIR	–	Região de interação co-rotante
CME	–	Ejeção coronal de massa
CNN	–	Rede neural convolucional
C2	–	<i>LASCO Coronagraph 2</i>
C3	–	<i>LASCO Coronagraph 3</i>
DL	–	Aprendizado profundo
DNN	–	Redes neurais profundas
ECA	–	<i>Empirical CME arrival</i>
EIT	–	<i>Extreme Ultraviolet Imaging Telescope</i>
ENN	–	<i>Edited Nearest Neighbours</i>
ESA	–	<i>Empirical shock arrival</i>
FF	–	Onda de choque frontal rápida
FN	–	Falso negativo
FP	–	Falso positivo
FR	–	Onda de choque reversa rápida
GB	–	<i>Gradient Boosting</i>
GPU	–	Unidade de processamento gráfico
HF	–	Alta Frequência
IA	–	Inteligência artificial
ICME	–	Ejeção coronal de massa interplanetária
IMF	–	Campo magnético Interplanetário
LASCO	–	<i>Large Angle and Spectrometric Coronagraph Experiment</i>
LDS	–	<i>Label distribution smoothing</i>
L1	–	Ponto Lagrangiano 1
MAE	–	Erro médio absoluto
MC	–	Nuvem magnética
ML	–	Aprendizado de Máquina
MLP	–	Perceptron de Múltiplas Camadas
MSE	–	Erro médio quadrático
OMR	–	<i>Opening by Morphological Reconstruction</i>
ReLU	–	<i>Rectified linear unit</i>
RF	–	Floresta aleatória
RNA	–	Redes Neurais Artificiais
Rs	–	Raio solar
SARM	–	<i>Shock Arrival Model</i>
SEP	–	Partículas energéticas solares
SC	–	Ciclo solar

SF	–	Onda de choque frontal lenta
SIR	–	Região de interação de fluxo
SNN	–	Redes neurais rasas
SoHO	–	<i>Solar and Heliospheric Observatory</i>
SR	–	Onda de choque reversa lenta
SVM	–	Máquina de vetores de suporte
TAF	–	Taxa de alarmes falsos
TD	–	Taxa de detecção
TSS	–	<i>True skill statistics</i>
UA	–	Unidade astronômica
UT	–	Horário universal
VN	–	Verdadeiro negativo
VP	–	Verdadeiro positivo

LISTA DE SÍMBOLOS

- \AA – Unidade de medida de comprimento de onda equivalente 10^{-10} metros (Ångström)
- b – Bias
- Σ – Símbolo matemático de somatório
- \mathbf{B} – Vetor do campo magnético interplanetário de coordenadas B_x , B_y e B_z [nT]
- B – Magnitude do campo magnético interplanetário [nT]
- \mathbf{V} – Vetor da velocidade do vento solar de coordenadas V_x , V_y e V_z [km/s]
- V – Magnitude da velocidade do vento solar [km/s]
- N_p – Densidade dos prótons do vento solar [$1/cm^3$]
- T_p – Temperatura dos prótons do vento solar [K]

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Hipótese	4
1.2 Objetivo	5
1.3 Estruturação do trabalho	5
2 REVISÃO DE TRABALHOS RELACIONADOS	7
2.1 Uso de técnicas tradicionais	7
2.2 Uso de técnicas baseadas em inteligência artificial	9
3 FUNDAMENTAÇÃO TEÓRICA	13
3.1 Clima espacial e eventos extremos	13
3.1.1 Sensores, instrumentos e monitoramento das estruturas	19
3.2 Redes Neurais Artificiais	22
3.2.1 Redes Neurais Convolucionais	27
3.2.2 Aprendizado profundo ou redes neurais profundas	29
3.2.3 Redes pré-treinadas e transferência de aprendizado	30
3.3 Problemática	32
4 MATERIAIS E MÉTODOS	37
4.1 Seleção de ferramentas e instrumentos	40
4.2 Dados observados	41
4.3 Balanceamento do conjunto de dados	43
4.3.1 <i>Undersampling</i> e <i>oversampling</i>	43
4.3.2 Suavização de rótulos	44
4.4 Geração das imagens	45
4.4.1 Pré-processamento para remoção de ruídos nas imagens	50
4.5 Arquitetura das redes	54
4.5.1 Transferência de aprendizado	55
4.5.2 Treinamento das redes	55
4.5.2.1 Detecção das estruturas	55
4.5.2.2 Previsão do tempo de chegada	56
4.5.2.3 Métricas de avaliação	57

5	RESULTADOS E DISCUSSÕES	59
5.1	Resultados da detecção das ondas de choque interplanetárias	59
5.1.1	Balanceamento e ajuste dos hiperparâmetros	59
5.1.2	Resultados obtidos durante o treinamento	61
5.1.3	Generalização	63
5.1.4	Estudos de caso	65
5.1.4.1	Evento de 17 de março de 2015 ou evento de São Patrício	65
5.1.4.2	Evento de 22 de julho de 2016	67
5.1.4.3	Evento de 15 de junho de 2000	69
5.1.4.4	Evento de 17 de junho de 2001	71
5.1.4.5	Caso de estudo para o dia 08 de julho de 2003	73
5.1.4.6	Evento de 20 de fevereiro de 2000	75
5.2	Resultados das redes para previsão do tempo de chegada das estruturas	77
5.2.1	Suavização da distribuição para balanceamento.	77
5.2.2	Treinamento e generalização	78
6	CONCLUSÕES	83
6.1	Classificação geral das redes	83
6.2	Considerações finais	84
	REFERÊNCIAS BIBLIOGRÁFICAS	85

1 INTRODUÇÃO

O espaço entre o Sol e a Terra é preenchido por um gás magnetizado de baixa densidade, composto por íons e elétrons que viajam para longe do Sol, denominado de vento solar. O vento solar é uma expansão da atmosfera solar mais externa, resultado das altas temperaturas encontradas na atmosfera, fazendo com que a força de atração gravitacional do Sol seja menor que a força para expandir a atmosfera (HUNDHAUSEN, 1972; ZIRKER, 1977; SCHWENN; MARSCH, 1990; SCHWENN; MARSCH, 1991; KOHL; CRANMER, 1999; SRIVASTAVA; SCHWENN, 2000; BALOGH et al., 2001; MARSCH et al., 2003; MARSCH, 2006; SCHWENN, 2006). Algumas estruturas magnéticas são originadas na superfície solar e viajam com o vento solar para o meio interplanetário, como é o caso das Ejeções Coronais de Massa (CMEs, do inglês *Coronal Mass Ejections*) (BRUECKNER, 1974; GOSLING et al., 1974; SCHWENN, 1986; KAHLER, 1992; GOSLING, 1997; HUNDHAUSEN, 1997; WEBB et al., 2001; LOW, 2001; GOPALSWAMY, 2004).

Originadas na atmosfera do Sol, como uma consequência da reconexão magnética (DUNGEY, 1961), as CMEs são gigantes quantidades de massa, da ordem de bilhões de toneladas, que se desprendem da superfície solar para o meio interplanetário. Esse tipo de evento envolve a aparição de uma estrutura brilhante, dentro do espectro eletromagnético visível, causando mudanças visíveis e observáveis no campo de visão de coronógrafos (HUNDHAUSEN et al., 1984; SCHWENN, 1996).

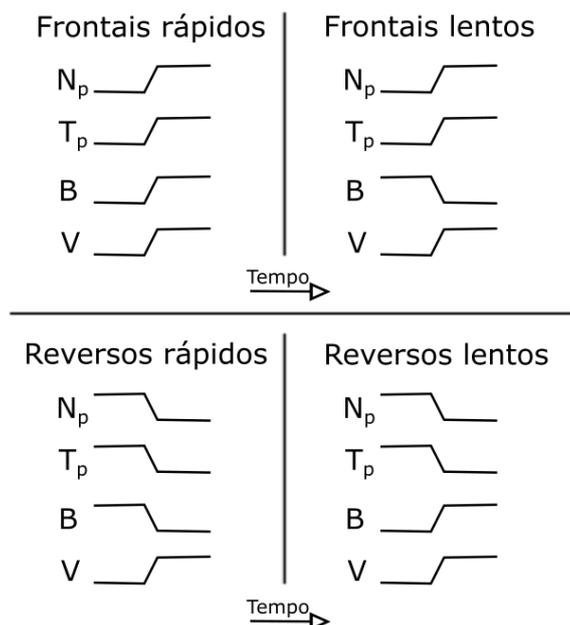
Quando as CMEs se propagam no meio interplanetário, recebem o nome de Ejeções Coronais de Massa Interplanetárias (ICMEs, do inglês *Interplanetary Coronal Mass Ejections*), geralmente associadas com velocidades de propagação acima da velocidade do meio, guiando ondas de choque interplanetárias, que são responsáveis por diversos fenômenos, dentre eles a aceleração de partículas para velocidades quasi-relativísticas (SCHWENN, 2006; REAMES, 2013; DESAI; GIACALONE, 2016; FRASSATI et al., 2022). Além disso, podem interagir com o campo magnético da Terra, injetando energia e partículas para dentro da cavidade magnetosférica, por conta da reconexão magnética (DUNGEY, 1961). As consequências econômicas destes eventos são de grande interesse da comunidade em geral, uma vez que a sociedade moderna tem se tornado cada vez mais dependente de recursos tecnológicos altamente sensíveis às variações do espaço fora da Terra, especialmente quando eventos explosivos ocorrem no Sol (SISCOE, 2000; LANZEROTTI, 2001; BAKER, 2004; DAGLIS et al., 2004; HAPGOOD, 2018).

Outro tipo de estrutura magnética de origem solar são as Regiões de Interação de

Feixe (SIRs, do inglês Stream Interaction Regions), formadas quando um fluxo de vento solar rápido interage com a propagação de vento solar mais lenta, tendo o fluxo mais rápido sua formação a partir da atividade de buracos coronais. Após uma rotação solar completa, a estrutura recebe o nome de Região de Interação Corrotante (CIRs, do inglês *Corotating Interaction Regions*) (ALLEN et al., 2020).

Resultado da propagação de estruturas magnéticas de origem solar, como as ICMEs e as CIRs (SCHWENN, 1990; SCHWENN, 2006), as ondas de choque podem ser classificadas de acordo com as mudanças nos parâmetros de plasma solar e campo magnético interplanetário (IMF, do inglês *Interplanetary Magnetic Field*), sendo detectadas quando a onda de choque e a estrutura que gerou a perturbação no meio passam pelos sensores a bordo de satélites. As principais mudanças ocorrem na densidade do plasma solar, na temperatura e na velocidade do vento solar, além da variação observada no campo magnético interplanetário (ECHER; ALVES, 2006; OLIVEIRA; SILVEIRA, 2016). A Figura 1.1 é uma representação dos principais tipos de choques interplanetários observados pelos satélites. Ela mostra a evolução dos parâmetros de plasma e campo magnético interplanetário, onde todos os parâmetros sofrem alterações, sempre havendo um aumento no parâmetro da velocidade do vento solar. Nos dois painéis superiores da Figura 1.1, os choques frontais apresentam saltos positivos em todos os parâmetros de plasma do vento solar, quando a onda de choque atravessa o satélite. No caso dos choques frontais rápidos (FF, do inglês *Fast Forward*), a intensidade do IMF aumenta, ao passo que, nos choques frontais lentos (SF, do inglês *Slow Forward*), a magnitude do IMF cai. Nos painéis inferiores da Figura 1.1, é representado o comportamento dos parâmetros durante choques reversos que sofrem quedas na densidade e na temperatura do vento solar. Para os choques reversos rápidos (FR, do inglês *Fast Reverse*), a intensidade do IMF cai, enquanto que para os choques Reversos Lentos (SR, do inglês *Slow Reverse*), a intensidade do IMF aumenta.

Figura 1.1 - Classificação das ondas de choque interplanetárias.



A representação mostra as mudanças abruptas que ocorrem durante cada tipo de onda de choque. De cima para baixo, para cada tipo de choque, os parâmetros representados são a densidade do plasma (N_p), temperatura do vento solar (T_p), intensidade do campo magnético interplanetário (B) e velocidade do vento solar (V).

Fonte: Adaptado de Echer e Alves (2006).

Devido à baixa densidade do meio interplanetário e, conseqüentemente, à baixa ocorrência de colisões entre as partículas que nele se propagam, as ondas de choque interplanetárias podem ser definidas como discontinuidades não colisionais. Isso ocorre porque, no estado rarefeito do meio em que se propagam, as partículas ionizadas do vento solar sofrem exclusivamente colisões eletromagnéticas (ECHER et al., 2003; ECHER; ALVES, 2006; OLIVEIRA; SILVEIRA, 2016).

As variações abruptas observadas nos parâmetros do vento solar e nos componentes do vetor campo magnético interplanetário podem influenciar na entrada de energia e partículas na magnetosfera terrestre (WEBB et al., 2001; LUCAS et al., 2007). As ondas de choque interplanetárias são responsáveis pela compressão da magnetosfera terrestre, gerando uma região de campos extremamente perturbados na frente da magnetosfera, contribuindo para o enfraquecimento e aniquilamento do campo magnético, devido ao fenômeno de reconexão magnética (DUNGEY, 1961), levando à ocorrência de tempestades geomagnéticas, que podem causar danos a sistemas de comunicação e distribuição de energia. Desta forma, o estudo das ondas de choque é de grande importância para o Clima Espacial, através do estudo, da análise e

da previsão das ocorrências deste tipo de evento extremo (KILPUA et al., 2015; OLIVEIRA; SILVEIRA, 2016; ECHER et al., 2023).

Diversos trabalhos foram desenvolvidos, a partir de técnicas tradicionais, utilizando-se análise estatística, média móvel, e determinação e flexibilização de limiares (VOROTNIKOV et al., 2008; KRUPAROVA et al., 2013; CASH et al., 2014). Esses estudos focam na identificação da passagem de ondas de choque em satélites próximos ao ambiente terrestre. Em trabalhos como esses, a análise das descontinuidades geradas nas características no vento solar, nos dados do satélite ACE, localizado em órbita no ponto Lagrangeano 1 (L1), podem auxiliar na previsão da chegada da onda na Terra com 15 a 60 minutos de antecedência.

Outras pesquisas apontam a utilização das imagens obtidas pelos coronógrafos, instrumentos capazes de identificar quando as estruturas das CMEs se propagam para fora da atmosfera do Sol, em direção ao espaço interplanetário. Os parâmetros extraídos das imagens capturadas pelos coronógrafos podem ser utilizados para previsão do tempo de propagação das CMEs até ambiente próximo a Terra, ou de sua geofetividade para a formação de perturbações geomagnéticas (GOPALSWAMY et al., 2001; LIU et al., 2018; WANG et al., 2019; BRAGA et al., 2020; FENG; YE, 2021).

Com o propósito de avançar no desenvolvimento de ferramentas para a previsão e detecção de estruturas magnéticas decorrentes da atividade solar no ambiente próximo à Terra, este projeto concentrou-se na aplicação de uma abordagem inovadora com o uso de técnicas de aprendizado de máquina, com ênfase no uso de Redes Neurais Convolucionais (CNNs, do inglês Convolutional Neural Network) e Aprendizado Profundo (DL, do inglês Deep Learning). Utilizando-se de gráficos de séries temporais para detecção e classificação, foi apresentada uma nova aplicação das redes neurais convolucionais que ainda não foi explorada na literatura, no momento em que a estrutura da onda de choque interplanetária atinge o satélite. Além disso, o projeto utiliza sequências de imagens de coronógrafos, capturadas durante a propagação inicial das estruturas que comumente guiam ondas de choque interplanetárias, como é o caso de ICMEs, para previsão do tempo de chegada das estruturas relacionadas em ambiente próximo à Terra.

1.1 Hipótese

Visando buscar alternativas às técnicas tradicionais, nos últimos anos vem se estudando abordagens de Aprendizado de Máquina (ML, do inglês *Machine Learning*) para possíveis aplicações no contexto do Clima Espacial (CAMPOREALE, 2019).

Analisando-se o estado da arte, na área de Inteligência Artificial (IA), dentre várias técnicas, a capacidade de reconhecimento de padrões observada em CNNs vêm apresentando resultados promissores (HAYKIN, 2001; NIELSEN, 2015; SZEGEDY et al., 2015; GOODFELLOW et al., 2016; MEDEIROS, 2018; CAMPOREALE, 2019; SHETTY; SIDDIQA, 2019). Portanto, foi estabelecida a hipótese de que o desenvolvimento de uma abordagem que utilizasse gráficos de séries temporais poderia ser aplicado ao reconhecimento de padrões nos diferentes tipo de ondas de choque interplanetárias, empregando técnicas de visão computacional e aprendizado profundo. Diferentemente do que é normalmente aplicado ao trabalhar com séries temporais e inteligência artificial, como abordagens de redes neurais recorrentes ou redes neurais convolucionais de 1 dimensão, esta pesquisa concentrou-se em utilizar gráficos de séries temporais como entradas de redes convolucionais de 2 dimensões. Isso permite a identificação e o reconhecimento das mudanças severas analisadas nos parâmetros descritos como principais para a observação deste tipo de evento do clima espacial, obtidos por satélites localizados em ambiente próximo à Terra e observados nos painéis dos gráficos gerados a partir das séries temporais.

Por outro lado, a estimativa do tempo de chegada das estruturas das ondas de choque interplanetárias foi baseada em uma arquitetura de rede convolucional adequada, utilizando sequências de imagens das estruturas que guiaram o evento, capturadas por coronógrafos.

1.2 Objetivo

Este trabalho teve por objetivo apresentar metodologias considerando novas abordagens para realizar a previsão e detecção de ondas de choque interplanetárias próximas à Terra. As metodologias apresentadas baseiam-se na utilização de gráficos de séries temporais no lugar das mesma, e na observação da propagação inicial das estruturas que causaram sua formação e passagem por satélites que captam perturbações do vento solar e do clima espacial.

1.3 Estruturação do trabalho

Para a organização do trabalho, os capítulos foram estruturados da seguinte forma: o Capítulo 2 apresenta alguns trabalhos e pesquisas que tiveram como objetivo a caracterização ou a previsão de ondas de choque interplanetárias, fornecendo uma visão do que é possível realizar, além do que já foi feito em trabalhos relacionados. No Capítulo 3, são apresentados os conceitos necessários para o pleno entendimento do que foi abordado nesta pesquisa. Este capítulo descreve os eventos de interesse

do clima espacial, bem como os efeitos que as estruturas magnéticas, derivadas da atividade solar, podem gerar ao atingir a Terra. Também são incluídas informações básicas sobre os instrumentos e sensores utilizados para a coleta dos dados empregados na pesquisa. Além disso, é descrita, de forma sucinta, a fundamentação por trás das redes neurais artificiais e, por fim, é descrita a problemática proposta, relacionando o uso de computação aplicada ao clima espacial. No Capítulo 4 é documentada a metodologia utilizada durante o desenvolvimento da pesquisa. Informando sobre os materiais, catálogos, técnicas, algoritmos e procedimentos empregados para atingir os objetivos propostos. Enquanto que o Capítulo 5 são apresentados os resultados obtidos a partir da execução do fluxo de trabalho apresentado no 4. Expondo informações sobre o ambiente utilizado e casos específicos que evidenciam as capacidades da abordagens aqui desenvolvidas. Por fim, o Capítulo 6 complementa as informações apresentadas nos capítulos anteriores, explicitando os avanços conquistados por essa pesquisa, em relação a detecção e caracterização de ondas de choque interplanetárias, ao mesmo tempo que finaliza indicando sobre os possíveis trabalhos futuros integrados com os temas e abordagens estudadas e apresentadas ao longo da pesquisa.

2 REVISÃO DE TRABALHOS RELACIONADOS

Este capítulo oferece uma análise de trabalhos e pesquisas que exploram aplicações de técnicas e análises computacionais no âmbito do Clima Espacial. São discutidas investigações que empregam tanto abordagens empíricas quanto técnicas de aprendizado de máquina.

2.1 Uso de técnicas tradicionais

Em muitas pesquisas desenvolvidas na área de Clima Espacial, utilizam-se técnicas tradicionais, como o cálculo da média móvel, análises estatísticas dos parâmetros do vento solar possibilitando a caracterização dos melhores parâmetros para identificação, classificação e análise da passagem de estruturas magnéticas por satélites (VOROTNIKOV et al., 2008; KRUPAROVA et al., 2013; CASH et al., 2014).

Os trabalhos desenvolvidos por Vorotnikov et al. (2008) e Cash et al. (2014) são exemplos de pesquisas que fizeram o uso de técnicas tradicionais para caracterização e identificação de ondas de choque através dos dados de observação do satélite ACE (do inglês *Advanced Composition Explorer*) (STONE et al., 1998). A partir de uma análise exploratória dos dados, nos valores antes e após o choque (*upstream* e *downstream*, respectivamente), foram desenvolvidos e refinados algoritmos capazes de identificar a presença de uma onda de choque, automaticamente, em um fluxo de dados em tempo real. Foram considerados os valores da média móvel de cada um dos parâmetros escolhidos, durante a ocorrência de uma onda de choque. De forma semelhante, os mesmos conceitos foram aplicados em Kruparova et al. (2013), porém com o uso de dados *in-situ* do satélite WIND (OGILVIE; DESCH, 1997). No entanto as abordagens sistemáticas de testes, baseados nos valores estatísticos extraídos do conjunto de eventos observados, para determinação dos critérios de identificação utilizados para a classificação resultaram em uma taxa de acerto próxima a $53\% \pm 12\%$, com uma taxa de alarme falsos de aproximadamente $73\% \pm 16\%$.

Outros trabalhos, porém, não têm por finalidade detectar a passagem de tais estruturas magnéticas nos satélites, mas, sim, prever a chegada de eventos iminentes, principalmente pela perspectiva da previsão do Clima Espacial. Alguns modelos de previsão, como em Núñez et al. (2016), utilizaram-se de aproximações empíricas e equações diferenciais, empregando parâmetros das estruturas magnéticas que guiaram as ondas de choque, como as ICMEs. O modelo SARM (do inglês, *Shock Arrival Model*), desenvolvido em Núñez et al. (2016), foi calibrado com 120 eventos de ondas de choque interplanetárias observadas por múltiplos satélites e registrou uma

maior precisão em comparação com outros modelos quando são considerados dados de CME e de *flares* solares, obtendo uma taxa de erro médio absoluto (MAE, do inglês *Mean Absolute Error*) de 7,3 horas.

Por outro lado, alguns trabalhos fizeram previsão do tempo de chegada das ICMEs/choques com uso de modelos para estimativa do tempo de chegada, como apresentado em Schwenn et al. (2005). Em seu trabalho, eles apresentam uma função de previsão do tempo de chegada das ondas de choque IP na Terra, com base na velocidade de expansão das CMEs. Em outro estudo, Braga et al. (2020) realizaram uma abordagem com base na força de arrasto das CMEs para calcular o tempo de propagação da estrutura para 1 UA. No trabalho de Gopalswamy et al. (2001), é feita uma estimativa do tempo de chegada de ICMEs até a distância de 1 AU, com base em uma aceleração efetiva das ICMEs no meio interplanetário, descrita por Gopalswamy et al. (2000). As CMEs estão sujeitas a esta aceleração quando viajam pelo meio interplanetário, considerando as diversas dinâmicas que ocorrem na propagação de estruturas magnéticas derivadas da atividade solar. Uma das dificuldades apresentadas pelos pesquisadores foi a de mensurar a atividade solar durante o máximo solar por conta da interação das estruturas que se tornam mais frequentes e intensas durante esse período. Os resultados apresentados por esses trabalhos apresentam uma taxa de erro médio em torno de 10 horas.

De forma semelhante, a pesquisa realizada por Gopalswamy et al. (2005) teve uma abordagem que estende o método proposto por Gopalswamy et al. (2001), a fim de obter o tempo de propagação de ondas de choques interplanetárias, a 1 UA, com base na velocidade inicial da CME para observações de choques interplanetários relacionados com nuvens magnéticas. Isso mostrou uma forte correlação entre as velocidades dos choques e as nuvens magnéticas, e possibilitando a previsão da chegada de ondas choques interplanetárias utilizando a relação pistão-choque da dinâmica dos gases para conectar as velocidades das CMEs com os tempos de chegada dos choques IP a 1 AU. No entanto, o modelo *Empirical Shock Arrival* (ESA) apresentado por esse trabalho obteve uma taxa de erro, levemente maior se comparado ao modelo *Empirical CME Arrival* (ECA)(GOPALSWAMY et al., 2001), de 12 horas.

Feng et al. (2009) introduz um método para resolver as equações MHD, abordando especificamente um modelo unidimensional de propagação de choque hidrodinâmico baseado no método denominado *Conservation Element and Solution Element* (CESE). O modelo abordado requer entradas de dados observacionais para eventos solares, tais como: a velocidade inicial da estrutura, o tempo de duração do *flare*

solar e a velocidade do vento solar captada no ponto L1, no momento da ocorrência da estrutura que guiou a onda de choque. Tendo sido testado em 137 eventos solares, mostrou resultados de previsão comparáveis aos modelos existentes.

Manoharan et al. (2004) fornecem um modelo empírico para previsão do tempo de chegada de ICME a 1 AU, utilizando-se a velocidade inicial das CMEs como uma informação efetiva para o cálculo do tempo de propagação. Realizando-se um ajuste de segunda ordem para a observação de estruturas rápidas e lentas, até o ambiente terrestre, uma importante relação é estabelecida para entender como as diferentes velocidades iniciais das CMEs afetam o tempo necessário para que os choques associados cheguem à Terra. O melhor ajuste de curva é o resultado com uma taxa de erro médio absoluto de 10 horas. No trabalho de Zhao e Dryer (2014), são discutidas diferentes abordagens para o cálculo do tempo de propagação de CMEs e ondas de choque interplanetárias, apresentando-se resultados e metodologias de diversos trabalhos, incluindo alguns dos citados anteriormente. Além de apresentar métodos empíricos, são discutidas abordagens baseadas em modelos de arraste e também modelos físicos.

2.2 Uso de técnicas baseadas em inteligência artificial

Técnicas de inteligência artificial, em especial o aprendizado de máquina, podem ser empregadas na análise dos parâmetros que caracterizam as estruturas como ICMEs, *flares*, fluxo de prótons, entre outros (CAMPOREALE, 2019). Isso inclui a utilização de redes perceptrons de múltiplas camadas (TURCHENKO et al., 2007), técnicas de aprendizado profundo, redes convolucionais (WANG et al., 2019; FENG; YE, 2021), entre outras abordagens referentes ao aprendizado de máquina (VANDEGRIFF et al., 2005; LIU et al., 2018; BAUMANN; MCCLOSKEY, 2021).

Conforme discutido anteriormente, algumas pesquisas utilizaram a associação entre a propagação de ICMEs, *flares* e ondas de choque interplanetárias com a aceleração de partículas energéticas solares (SEPs, do inglês *Solar Energetic Particles* (REAMES, 2004; SCHWENN, 2006), sugerindo que, durante alguns desses eventos, houvesse um aumento no fluxo de prótons no meio interplanetário. Desta forma, a detecção de um aumento súbito no fluxo de prótons funcionaria como um precursor de grandes estruturas magnéticas. Tais aplicações foram descritas em Cohen et al. (2005) e Makela et al. (2011) e aplicadas em trabalhos como os de Vandegriff et al. (2005) e de Turchenko et al. (2007). Em seus trabalhos, foram utilizadas as assinaturas precursoras observadas nos dados das partículas energéticas do vento solar medidos pelo satélite ACE para previsão do tempo restante para a chegada do

choque interplanetário. Foram treinadas redes neurais artificiais, sendo uma recorrente e a outra uma Perceptron de Múltiplas Camadas (MLP, do inglês *Multi-Layer Perceptron*), respectivamente, com 37 eventos. Após a fase de treinamento, foram utilizados 19 eventos como conjunto de teste para generalização das redes neurais. Foi encontrada uma incerteza absoluta de 14,5 horas para a abordagem que utilizou uma rede recorrente e um MAE de 8,9 horas para a previsão com 24 horas de antecedência. A incerteza caiu para 4,6 horas na previsão com 12 horas de antecedência para a arquitetura MLP.

Outros trabalhos utilizaram-se de algoritmos mais simples para previsão a curto prazo da chegada de ondas de choque interplanetárias. [Baumann e McCloskey \(2021\)](#) fizeram uma comparação entre técnicas e modelos físicos, como os de "propagação balística", entre outros, que se utilizam apenas da velocidade da estrutura e a posição do satélite ACE. Posteriormente, esses mesmos dados foram aplicados a diferentes abordagens de aprendizado de máquina, como Florestas Aleatórias (RF, do inglês *Random Forest*) ([BREIMAN, 2001](#)) e *Gradient boosting* (GB) ([HE et al., 2019](#)), com a finalidade de combinar as vantagens dos métodos tradicionais utilizados, adquirindo, dessa forma, taxas de erro menores.

Algoritmos de aprendizado de máquina baseados em modelos de Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machine*) podem ser usados tanto com séries temporais quanto para problemas com espaço de atributos unidimensional. Conforme aplicado em [Liu et al. \(2018\)](#), foi desenvolvida a ferramenta *CAT-PUMA* para previsão do tempo de chegada de ICMEs, sendo consideradas diversas características de cada evento e dos parâmetros do vento solar até seis horas após o momento em que a ICME é observada. O resultado obtido nesta aplicação foi um dos melhores, ao se comparar com as demais abordagens para previsão do tempo de chegada de ICMEs, obtendo uma taxa de erro de 5.9 horas, para mais ou para menos.

[Minta et al. \(2023\)](#) propuseram uma abordagem de rede neural em cascata denominada *Cascade Forward Neural Network* (CFNN), criando conexões diretas entre todas as camadas, utilizando diferentes atributos de velocidade, tanto da própria estrutura quando do vento solar, como valores de entrada. Para esta pesquisa, verificou-se a correlação entre outros atributos, como a velocidade tridimensional, como possibilidade de substituição para as entradas originais da rede, permitindo, assim, uma flexibilidade na abordagem desenvolvida.

Para as abordagens descritas, fez-se necessária a extração de algumas características

das CMEs, utilizadas como entradas para os modelos. Em Xie et al. (2004), é desenvolvido um modelo, nomeado de *Cone Model*, para determinação das características das estruturas, de forma mais precisa, tais como o ângulo de propagação principal e a velocidade radial em diferentes ângulos, de tal forma a possibilitar novas aplicações para previsão das estruturas magnéticas derivadas da propagação de ICMEs.

Outros modelos, contudo, fizeram uso de aprendizado profundo e redes convolucionais, como em Wang et al. (2019) e Feng e Ye (2021). Em seus trabalhos, imagens de CMEs capturadas pelo instrumento LASCO do satélite *Solar Heliospheric Observatory* (SoHO) (BRUECKNER et al., 1995) são utilizadas como entrada de redes convolucionais para observação de sua propagação no coronógrafo 2. A extração de atributos dessas imagens foi utilizada para classificação de sua geofetividade e previsão do tempo de chegada das estruturas ICMEs/choque guiado pela ICME. Conforme observado nas pesquisas, a propagação inicial da estrutura pode fornecer observações sobre o tempo de chegada para o ambiente próximo à Terra.

Com as mesmas finalidades, a pesquisa aqui desenvolvida utilizou dados *in-situ* de satélites durante a passagem da onda de choque. Contudo, empregou algoritmos de visão computacional nos gráficos das séries temporais para a caracterização da estrutura. Também foi desenvolvida uma abordagem com a utilização de sequências de imagens obtidas de coronógrafos, durante a expansão inicial de ICMEs como metodologia para previsão do tempo de chegada dos eventos em ambiente terrestre.

A metodologia adotada neste estudo, referente à detecção da passagem de ondas de choque interplanetárias, representa um avanço significativo na análise de eventos interplanetários. A integração de algoritmos de visão computacional aplicados aos gráficos das séries temporais constitui uma abordagem inédita na literatura. Essa inovação metodológica não apenas enriquece o campo de estudo com novas ferramentas analíticas, mas também estabelece um precedente para futuras investigações.

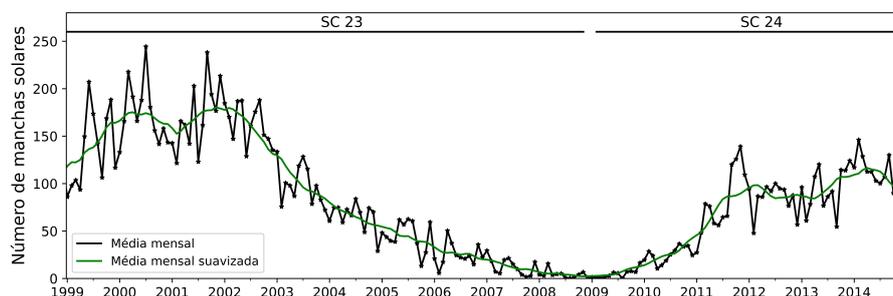
3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os fundamentos teóricos que abordam o trabalho realizado. Inicia-se com uma introdução ao Clima Espacial, incluindo informações sobre a formação, propagação e monitoramento de estruturas magnéticas interplanetárias. Segue-se um detalhamento sobre o aprendizado de máquina e redes neurais artificiais, abrangendo conceitos, aplicações e características de alguns hiperparâmetros. Descreve-se brevemente as características da arquitetura convolucional e outros processos de convolução para extração de padrões espaciais. Na sequência, comparam-se as técnicas e modelos de redes neurais rasas e profundas. Por fim, há uma breve descrição da aplicação abordada neste trabalho para utilização de redes neurais profundas na detecção de ondas de choque interplanetárias.

3.1 Clima espacial e eventos extremos

A ocorrência de eventos explosivos no Sol varia de acordo com o ciclo de atividade solar, aumentando e diminuindo de frequência, respectivamente, em períodos de máximo e mínimo (HATHAWAY, 2015). A Figura 3.1 apresenta a evolução do Ciclo Solar (SC, do inglês *Solar Cycle*) 23 até o período de máximo do SC 24. Um SC tem duração aproximada de 11 anos, seguindo a variação no número e no tamanho de manchas solares, que são regiões na superfície solar observadas pelos telescópios, com temperaturas menores do que a média da região circundante (HATHAWAY, 2015). As manchas solares apresentam um campo magnético mais intenso, o que as torna regiões mais escuras quando observadas na superfície do Sol. Estão associadas a pares de campos magnéticos positivo e negativo, podendo variar de tamanho, sendo observadas em grupos ou aglomerados (PRIEST, 2014).

Figura 3.1 - Evolução da atividade solar entre o período de 1999 e 2014.

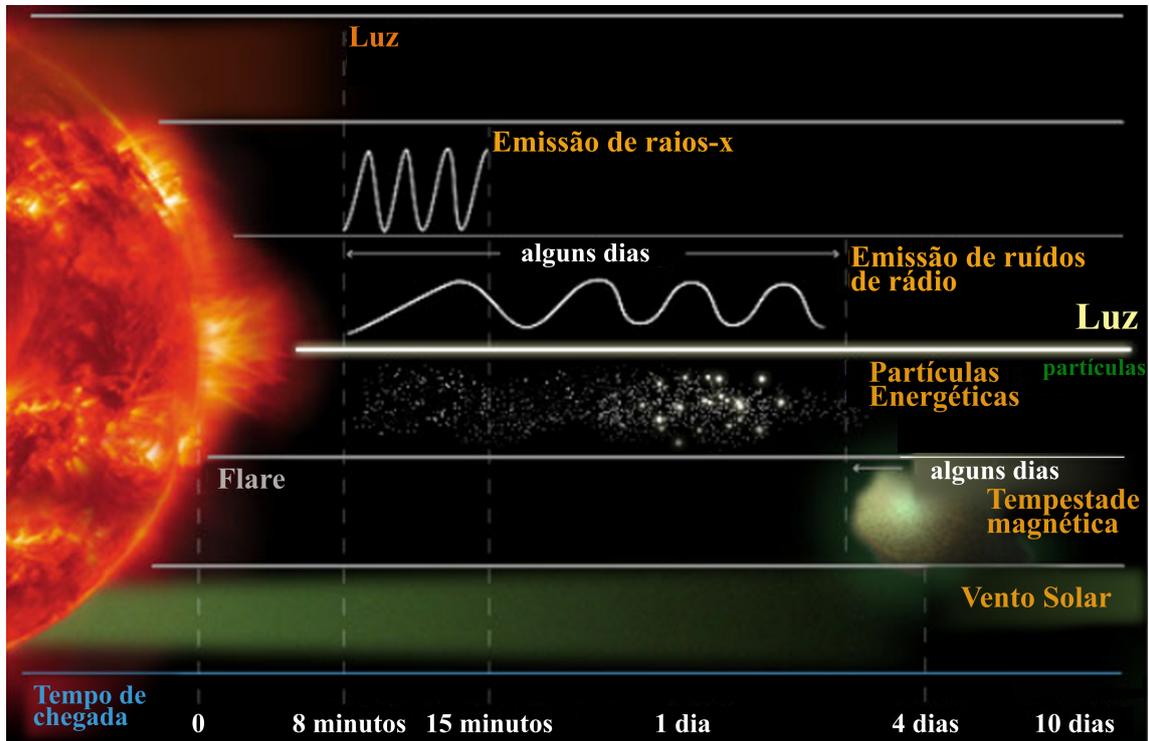


Número de manchas solares observadas de 1999 a 2014, englobando dois ciclos solares SC 23 e 24. A média mensal (linha preta) e a média suavizada (linha verde) mostram que há variações no número de manchas solares neste período.

Quando o processo de reconexão magnética ocorre na atmosfera solar, intensos fluxos de partículas carregadas e radiação são ejetados, podendo gerar os mais diversos tipos de eventos e estruturas magnéticas, como *flares* solares, CMEs, entre outros (OLIVEIRA; SILVEIRA, 2016; HESSE; CASSAK, 2020). Durante os *flares* solares, radiação eletromagnética é liberada, atingindo a Terra em apenas 8 minutos, viajando à velocidade da luz (SCHWENN, 2006; O'CALLAGHAN, 2020; KATAOKA, 2022). Por outro lado, estruturas como as CMEs carregam toneladas de partículas e radiação no espectro da luz visível (HUNDHAUSEN et al., 1984), contudo, dependendo da velocidade com que a estrutura magnética se propaga pelo meio interplanetário, é possível que a mesma atinja a distância de 1 Unidade Astronômica (UA), o equivalente à distância média entre a Terra e o Sol, entre 15 a 18 horas, para eventos mais rápidos. Contudo, para eventos mais lentos, o tempo de chegada das estruturas magnéticas pode variar de 2 a 4 dias (GOPALSWAMY et al., 2007).

Estruturas de origem solar propagam-se juntamente com o vento solar, sofrendo alterações na sua morfologia e encontrando obstáculos no meio interplanetário, o que podem ocasionar mudanças em sua morfologia, suas características e seus parâmetros. Além disso, alguns eventos podem ser direcionados ao ambiente terrestre, sendo de interesse para estudo do Clima Espacial, a fim de antecipar e mitigar possíveis efeitos adversos à vida na Terra. Na Figura 3.2, são apresentados os tempos médios de propagação de diversas estruturas originadas da atividade solar, de forma a identificar o tempo de propagação até o ambiente terrestre, isto é, até atingir a distância de 1 UA.

Figura 3.2 - Tempo de propagação de alguns tipos de estruturas, partículas e radiação durante a atividade solar.



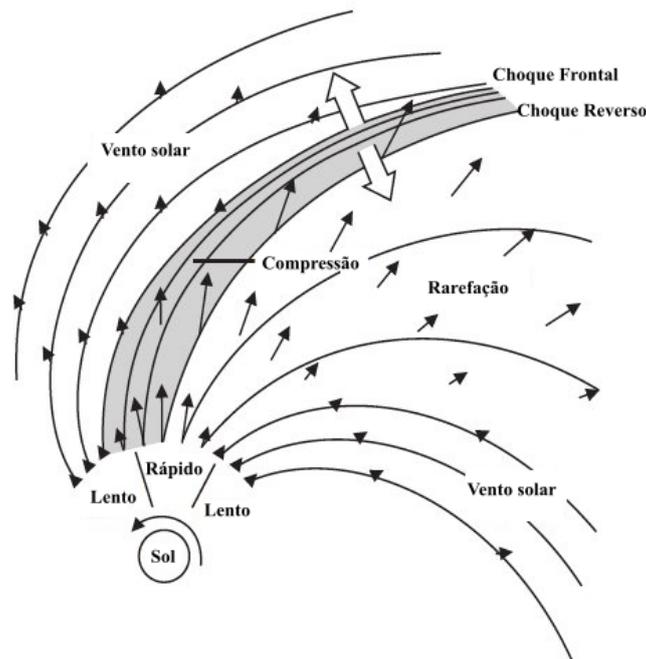
Tempo de propagação de algumas estruturas derivadas da atividade solar. Eventos como fluxo de raios-X, emissões de rádio solar e partículas energéticas podem acompanhar a velocidade da luz, podendo chegar em poucos minutos (~ 8 minutos) à Terra, tornando-se precursores de estruturas como ICMEs, explosões de rádio e ondas de choque interplanetárias. A escala de tempo na parte inferior da imagem identifica o tempo médio necessário para que as estruturas associadas pelas linhas verticais tracejadas atinjam a distância de 1 UA.

Fonte: Adaptado de NASA (2023).

As ICMEs são o resultado da propagação das CMEs, ou seja, gigantes nuvens de plasma de origem solar que são liberadas devido a uma reconfiguração do campo magnético do Sol, conhecido como reconexão magnética (DUNGEY, 1961). Quando viajam no meio interplanetário, podem atingir uma velocidade de propagação acima da velocidade característica do meio - considerando que a velocidade do vento solar calmo é de ~ 400 Km/s (SCHWENN, 2006). Essa rápida propagação pode resultar na formação de ondas de choque interplanetárias que, ao interagirem com a magnetosfera terrestre, desencadeiam eventos de tempestades geomagnéticas (GONZALEZ et al., 1994; WEBB et al., 2001; OLIVEIRA; SILVEIRA, 2016; PANT et al., 2021).

Apesar das ICMEs se apresentarem mais geofetivas (BRUECKNER et al., 1998; GONZALEZ et al., 1999; ECHER et al., 2006), as CIRs, por sua vez, podem guiar choques do tipo reversos rápidos (GOSLING; PIZZO, 1999; ECHER; ALVES, 2006; SCHWENN, 2006; LUCAS et al., 2006; VOROTNIKOV et al., 2008; OLIVEIRA, 2017). A Figura 3.3 é uma representação de uma CIR, que originalmente foi uma SIR, resultado da interação dos fluxos rápidos e lentos do vento solar, contudo sofrendo a ação da rotação do Sol, lhe é adicionada a característica rotativa, propiciando condições ideais para a formação de ondas de choque interplanetárias quando a diferença na interação dos fluxos rápido e lento é maior do que a velocidade do meio, o que resulta em uma instabilidade (OLIVEIRA, 2017).

Figura 3.3 - Representação esquemática da formação de choques frontais e reversos guiados por CIRs.



Fonte: Adaptado de Oliveira (2017).

A interação das ondas de choque interplanetárias guiadas por ICMEs ou CIRs com o campo magnético terrestre pode ocasionar tempestades geomagnéticas (GOSLING et al., 1990; GONZALEZ et al., 1994; GONZALEZ et al., 1999; ECHER; GONZALEZ, 2004; ECHER et al., 2006; GONZALEZ et al., 2011). As tempestades mag-

néticas são definidas como variações globais do campo magnético que excedem as variações no lado diurno da Terra. Mais precisamente, uma tempestade é definida quando o índice Dst (SUGIURA et al., 1964; BURTON et al., 1975) torna-se inferior a $-50nT$ (GONZALEZ et al., 1994; TSURUTANI et al., 2020). O índice Dst é medido em baixas latitudes, a partir das variações causadas no campo geomagnético devido à intensificação de um sistema de corrente, conhecido como corrente de anel, na região equatorial. Em médias latitudes, contudo, outro índice é utilizado para monitorar a atividade da corrente auroral e seus efeitos geomagnéticos. O índice Kp é um valor médio do índice K, medido a partir de 13 observatórios magnéticos espalhados pelo globo, no hemisfério norte. É medido em uma escala quase logarítmica variando de 0 a 9, onde valores mais próximos de 9 indicam que há grande perturbação do campo geomagnético, enquanto que valores mais próximos de 0 indicam um período calmo de atividade solar.

A Tabela 3.1 lista as categorias de eventos geomagnéticos medidos a partir da intensidade do índice Kp, com a identificação de alguns dos efeitos decorrentes da ocorrência de tempestades geomagnéticas (BARTELS, 1949; SIEBERT; MEYER, 1996; MATZKA et al., 2021).

Tabela 3.1 - Categorias das tempestades geomagnéticas e as consequências causadas pela ocorrência destes eventos.

Categoria			Efeitos
Escala	Descritor	Medidas	
G1	Fraco	Kp>5	Sistema elétrico: flutuações fracas na voltagem podem acontecer. Operação de satélite: possível impacto pequeno nas operações. Outros sistemas: animais migratórios são afetados neste nível e em níveis mais altos.

(Continua)

Tabela 3.1 - Continuação.

Categoria			Efeitos
Escala	Descritor	Medidas	
G2	Moderado	Kp>6	Sistema elétrico: sistemas em alta latitude podem experimentar alarmes do nível de voltagem, tempestades de longa duração causam danos aos transformadores. Operação de satélites: podem ser requeridas ações corretivas da orientação pelos controles de solo; possíveis mudanças no arrasto podem afetar a previsão das órbitas. Outros sistemas: propagação em rádio em alta frequência (HF, do inglês <i>high frequency</i>) pode enfraquecer em altas latitudes.
G3	Forte	Kp>7	Sistema elétrico: correções de voltagens podem ser necessárias, alarmes falsos iniciando algum equipamento de proteção. Operação de satélite: sobrecarga estática de superfície nos componentes podem ocorrer, pode ocorrer aumento do arrasto sobre os de baixa órbita, e correções podem ser necessárias para os problemas de orientação. Outros sistemas: podem ocorrer problemas intermitentes na navegação do satélite e navegação em baixa-frequência, comunicação em rádio HF pode ficar intermitente.
G4	Severo	Kp>8	Sistemas Elétricos: problemas gerais de controle de voltagem e problemas com sistemas de proteção que podem ser acionados erroneamente. Operações de Satélites: pode-se experimentar sobrecarga estática na superfície e problemas de rastreamento, correções podem ser necessárias para problemas de orientação. Outros sistemas: correntes induzidas nos dutos afetam medidas preventivas, produzem problemas esporádicos na propagação HF, navegação por baixa-frequência é perturbada.

(Continua)

Tabela 3.1 - Conclusão.

Categoria			Efeitos
Escala	Descritor	Medidas	
G5	Extremo	Kp>9	Sistemas Elétricos: problemas gerais de controle de voltagem e problemas com sistemas de proteção, alguma malha do sistema pode experimentar colapso completo ou blecautes. Transformadores podem ser danificados. Operação de satélites: pode experimentar extensiva sobrecarga estática na superfície, problemas com orientação, problemas com o <i>uplink/downlink</i> e rastreamento dos satélites. Outros sistemas: correntes nos dutos metálicos podem atingir centenas de amperes, propagação em rádio HF pode ficar impossível em muitas áreas por um ou dois dias, navegação por satélite pode ficar degradada por dias, navegação por baixa frequência pode ficar impossível por horas.

Fonte: Adaptado de Costa e Nardin (2011).

3.1.1 Sensores, instrumentos e monitoramento das estruturas

O monitoramento da atividade solar pode ser realizado a partir de diversos satélites e um vasto conjunto de instrumentos, em solo ou em órbita, que detectam desde o surgimento da ejeção de matéria da superfície do Sol até a propagação no espaço interplanetário, além da sua chegada em ambiente terrestre. Dentre alguns dos instrumentos estão os coronógrafos, que são imageadores que captam a luz visível na coroa solar e podem observar estruturas como CMEs sendo ejetadas a partir da atmosfera solar mais externa, a coroa. Sua propagação no meio interplanetário carrega toneladas de plasma de origem solar e radiação em altas velocidades, com registros realizados pelos diversos instrumentos a bordo de satélites ou no solo (SCHWENN, 2006). A Tabela 3.2 detalha as características de alguns instrumentos, como imageadores, que são responsáveis pela coleta de imagens da superfície solar para o monitoramento da atividade do Sol.

Tabela 3.2 - Características do imageador e coronógrafo do satélite SoHO.

Satélite	Instrumento	Detector	Região observada	Espectro observado	Resolução temporal
SOHO	EIT	EIT	Superfície solar	171 Å	~ 360 minutos
			Superfície solar	195 Å	~ 12 minutos
			Superfície solar	284 Å	~ 360 minutos
			Superfície solar	304 Å	~ 360 minutos
	LASCO	C2	1.5 - 6 Rs	Visível	~ 20 minutos
			C3	3.5 - 30 Rs	Visível

Fonte: Adaptado de [Shneider et al. \(2021\)](#).

A propagação de ICMEs e CIRs é uma das principais causas da formação de ondas de choque ([ECHER et al., 2003](#)), tornando-se detectável a partir da observação dos dados *in-situ* dos satélites na forma de séries temporais. São identificados quando há uma variação abrupta nos parâmetros do vento solar e do campo magnético interplanetário ([ECHER et al., 2003](#); [LUCAS et al., 2011](#); [TSURUTANI et al., 2020](#)). A Tabela 3.3 destaca as principais missões espaciais para observação dos choques interplanetários e os instrumentos a bordo dos satélites, bem como os parâmetros do vento solar e do campo magnético interplanetário utilizados para identificar a passagem do choque. Complementarmente, é fornecida a resolução temporal de cada um dos parâmetros utilizados na análise. As séries temporais obtidas a partir destes parâmetros auxiliam na identificação das ondas de choques, devido ao aumento abrupto observado durante a passagem do choque IP.

Tabela 3.3 - Satélites, seus instrumentos, parâmetros medidos com resolução temporal para identificação das ondas de choque.

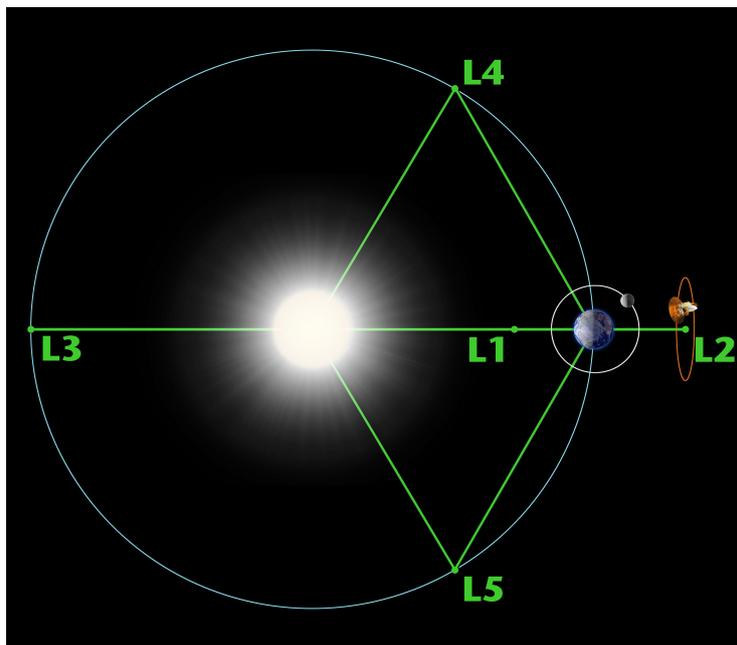
Satélite	Instrumento	Parâmetros	Resolução temporal
ACE	MAG	\mathbf{B} , \mathbf{B}	16 segundos
	SWEPAM	N_p , \mathbf{V} , V , T_p	64 segundos
STEREO	IMPACT/MAG	\mathbf{B} , \mathbf{B}	0.125 segundos
	PLASTIC	N_p , \mathbf{V} , V , T_p	60 segundos
WIND	MFI	\mathbf{B} , \mathbf{B}	3 segundos
	SWE	N_p , \mathbf{V} , V , T_p	\sim 90 segundos

Detalhamento das características de alguns sensores utilizados para detecção de ondas de choque. As variáveis N_p , T_p , \mathbf{B} e \mathbf{V} indicam os parâmetros de densidade dos prótons do vento solar, temperatura dos prótons do vento solar, e magnitude dos vetores do campo magnético interplanetário e velocidade do vento solar, respectivamente, enquanto que \mathbf{B} e \mathbf{V} são os vetores do campo magnético e da velocidade do vento solar, respectivamente.

Fonte: Adaptado de Lumme et al. (2019).

A partir dos instrumentos a bordo dos satélites, em órbita nos pontos Lagrangeanos, são disponibilizados os mais diversos tipos de dados *in-situ*. Os pontos Lagrangeanos são regiões definidas em uma posição entre dois corpos celestes, de tal forma a cancelar a força centrípeta e anular a força gravitacional entre eles, conforme a representação mostrada na Figura 3.4.

Figura 3.4 - Identificação dos pontos de Lagrange.



Representação esquemática fora de escala dos pontos de Lagrange. A região central representa o Sol e os pontos na cor verde representam as posições relativas aos pontos Lagrangeanos. O satélite SoHO encontra-se em órbita no ponto Lagrangeano L1, ficando posicionado em frente à Terra, mas observando o Sol e sua atividade.

Fonte: NASA (2023).

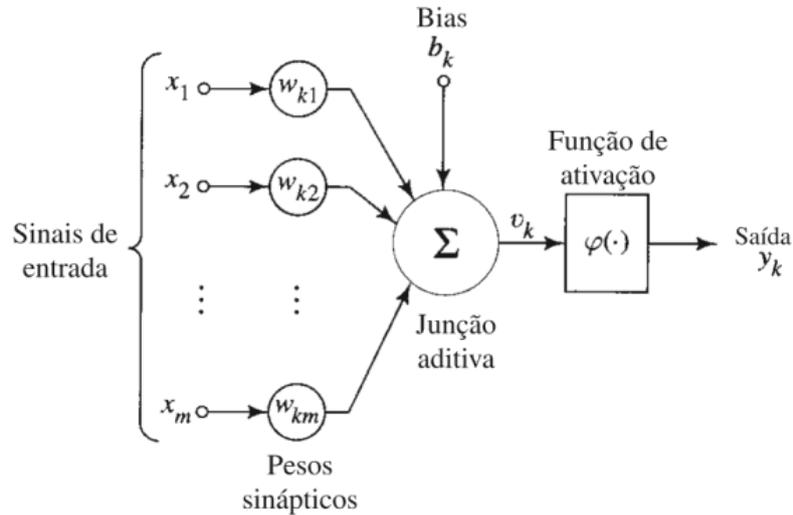
3.2 Redes Neurais Artificiais

Na área de Inteligência Artificial (IA), as redes neurais artificiais (RNAs) são técnicas computacionais que apresentam seu funcionamento inspirado na dinâmica de troca de informações e armazenamento de conhecimento do cérebro humano. Tendo por objetivo a solução de problemas de reconhecimento de padrões, seja pela busca de classificadores, agrupamentos ou regressores não lineares, entre outras tarefas possíveis para aplicação (HAYKIN, 2001; GOODFELLOW et al., 2016). As RNAs são modelos computacionais matemáticos que funcionam tendo como principal estrutura o neurônio matemático, que simula a aprendizagem a partir de um processo simplificado do que seria uma sinapse nervosa.

A Figura 3.5 apresenta o funcionamento simplificado da alimentação de um neurônio com dados de entrada e a obtenção de sua saída, processo denominado *Feed Forward* ou alimentação adiante, onde as entradas da rede *alimentam* os neurônios da rede neural e geram as saídas. Nesse processo, os neurônios das camadas escondidas

servem como entradas para as camadas subsequentes a que estejam conectadas.

Figura 3.5 - Representação simplificada do funcionamento de um neurônio artificial.



Comportamento de um neurônio matemático.

Fonte: Haykin (2001).

A saída de um neurônio matemático é definida por seu comportamento, onde os sinais de entrada são multiplicados pelos pesos das conexões associadas a cada sinal de entrada. O resultado do somatório desses produtos juntamente com o valor do bias, dado por u_k (HAYKIN, 2001; NIELSEN, 2015; MEDEIROS, 2018), pode ser representado por:

$$u_k = \sum_{j=1}^m (x_j * w_{kj}) + b_k, \quad (3.1)$$

onde k é o número associado a cada neurônio, b_k é o valor do bias para o neurônio k , e w_{kj} é o peso da sinapse do neurônio k , associado a cada sinal de entrada x_j .

O valor obtido inicialmente passa pela função de ativação $\varphi(\cdot)$, resultando na saída do neurônio, y_k (HAYKIN, 2001; NIELSEN, 2015; MEDEIROS, 2018).

$$y_k = \varphi(u_k). \quad (3.2)$$

O peso do bias é um parâmetro treinável, ou seja, tem seu valor alterado durante o treinamento da rede, tendo por finalidade aumentar a capacidade de aproximação da rede, transladando a saída obtida no eixo (HAYKIN, 2001), permitindo que haja uma saída não nula, mesmo no caso em que todas as entradas da rede sejam nulas.

A função de ativação de um neurônio define o comportamento e a saída final dos neurônios em cada camada de uma rede neural, e pode ser dada por diversas equações e determinada de acordo com a tarefa imposta. Dentre as mais comuns estão:

- a) **Função Sigmóide:** Esta função de ativação define as saídas dos neurônios entre os valores 0 e 1, tendo como principal funcionalidade a definição de probabilidade em classificações binárias e é definida por:

$$\varphi(x) = \frac{1}{1 + e^{-x}}. \quad (3.3)$$

- b) **Função Tangente Hiperbólica:** Esta função de ativação define as saídas dos neurônios entre os valores -1 e 1, com um comportamento semelhante ao da função sigmóide e sendo definida pela equação:

$$\varphi(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}. \quad (3.4)$$

- c) **Função ReLU** (do inglês, *Rectified Linear Unit*): Esta função de ativação define as saídas dos neurônios entre todos os valores do conjunto dos números racionais positivos, sendo definida por:

$$\varphi(x) = \begin{cases} 0 & \text{se } x < 0; \\ x & \text{se } x \geq 0. \end{cases} \quad (3.5)$$

- d) **Função Softmax:** Esta função é aplicada redes neurais para resolução de tarefas com múltiplas classes, onde cada amostra tem como saída esperada um vetor de tamanho m que identifica a quantidade de classes. Esta função de ativação faz o cálculo da distribuição de probabilidade entre todas as classes possíveis, definida por:

$$\varphi(z_i) = \frac{e^{z_i}}{\sum_{j=1}^m e^{z_j}}; \quad \text{para } i = 1, 2, \dots, K. \quad (3.6)$$

Note que z identifica os valores obtidos para cada neurônio, ou classe, e m representa o número de classes. Isso ocorre porque, diferentemente das

funções de ativação descritas anteriormente, a função *softmax* realiza a normalização das saídas obtidas pela rede, atribuindo novos valores, coletivamente em vez de individualmente, a todos os neurônios da camada. Resultando em saídas que variam de 0 a 1, e que sua soma resulte em 1.

É possível encontrar diversos paradigmas de aprendizado e algoritmos de correção dos pesos sinápticos. O paradigma mais comum utilizado é o de aprendizado supervisionado, determinado por uma matriz de entradas e saídas, definidas pelo ambiente. Nesse paradigma de aprendizagem, as entradas passam pelo modelo da rede que determina um valor de saída para cada amostra. A diferença entre a saída obtida e a esperada, isto é, o erro obtido determina o quão intensa deve ser a alteração nas sinapses dos neurônios a fim de reduzir a função de custo (HAYKIN, 2001; GOODFELLOW et al., 2016).

Por meio das conexões entre os neurônios, das saídas obtidas pela rede e dos resultados da função de custo, os pesos e biases dos neurônios artificiais são atualizados com base no algoritmo de retropropagação. A partir da saída obtida em cada amostra, calcula-se o erro gerado, utilizando uma função de custo. Dentre as funções de custo, pode-se citar o MAE, o erro quadrático médio (MSE, do inglês *Mean Squared Error*), a entropia cruzada (CE, do inglês *Cross-Entropy*), entre outros. A função de custo deve ser determinada de acordo com o problema proposto, de forma a proporcionar um melhor desempenho durante o treinamento, de acordo com as características das amostras, assim como um melhor entendimento dos resultados ao longo do treinamento (CAMPOREALE, 2019).

Para problemas de regressão, utilizam-se, normalmente, as funções MSE e MAE, identificadas como:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2; \quad (3.7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (3.8)$$

Enquanto que, para problemas de classificação, são comumente utilizadas as funções CE, para classificação binária, identificada pela equação:

$$CE = -\frac{1}{n} \sum_{i=1}^n (y_i * \ln \hat{y}_i + (1 - y_i) \ln(1 - \hat{y}_i)), \quad (3.9)$$

onde n é o total de amostras do conjunto ou subconjunto de dados, y_i é a saída esperada e \hat{y}_i é a saída obtida para a amostra i .

Para conjuntos com múltiplas classes, a função de custo mais comum a ser utilizada é a adaptação da Entropia Cruzada Categórica (CCE, do inglês *Categorical Cross-Entropy*) para conjuntos com múltiplas classes, determinada por:

$$CCE = -\frac{1}{n} \sum_{i=1}^n \left(\sum_{j=1}^m (y_{ij} * \ln \hat{y}_{ij}) \right). \quad (3.10)$$

Semelhante à formula original, a função CCE, por sua vez, recebe, em cada amostra, um vetor de tamanho m que representa a quantidade de classes.

A mudança dos pesos das conexões pode ser feita a partir do gradiente descendente, de forma a minimizar a função de custo. A alteração dos pesos dos neurônios é dada pela subtração do peso atual pela multiplicação da taxa de aprendizagem pelas derivadas parciais da função de custo em relação ao peso da conexão (HAYKIN, 2001).

Em alguns casos, é possível alterar a função de custo adicionando penalidades a fim de reduzir o *overfitting*, ou seja, reduzir um superajustamento da rede para as amostras de treinamento. Isso faz com que os pesos se encontrem agrupados entre aqueles com valores extremamente próximos a zero, preferencialmente, ou outros com valores mais elevados (HAYKIN, 2001; NIELSEN, 2015). Essa técnica é chamada de regularização, ou decaimento de pesos, e nas arquiteturas treinadas para essa pesquisa foi inserida a regularização denominada regressão Ridge, ou *Ridge Regression*, determinada por:

$$Ridge \text{ regression} = \frac{\alpha}{2} \sum_{k=1}^m w_k^2. \quad (3.11)$$

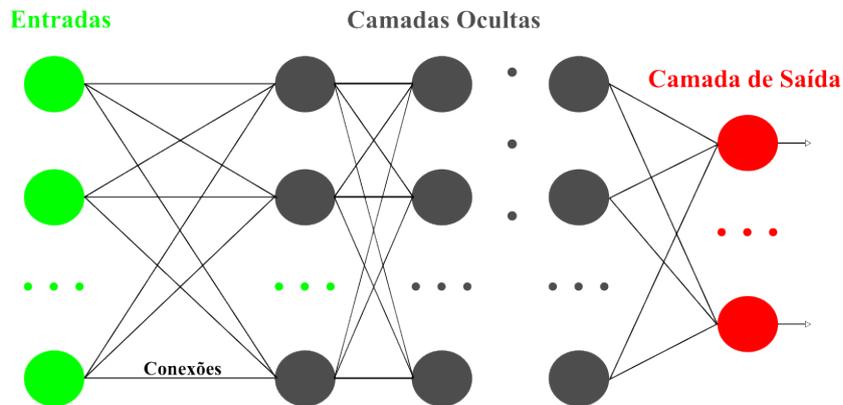
Na função de regularização, pode ser adicionada à função de custo a metade do produto entre a taxa de penalidade, α , e a norma quadrada de todos os pesos sinápticos da rede (HAYKIN, 2001). A partir da expressão Equação 3.11, a função de custo pode ser identificada como:

$$C = C_0 + \frac{\alpha}{2} \sum_{k=1}^m w_k^2, \quad (3.12)$$

sendo C_0 a função de custo não regularizada.

As redes neurais também podem ser caracterizadas de acordo com seu tipo de arquitetura, isto é, como são e como se comportam os neurônios de uma rede. Os tipos de arquitetura mais comuns são as Perceptrons, as Redes Recorrentes e as Redes Neurais Convolucionais (HAYKIN, 2001; GOODFELLOW et al., 2016; MEDEIROS, 2018). A Figura 3.6 representa um modelo de uma rede do tipo MLP, totalmente conectada, ou seja, nesta rede são aplicadas conexões sinápticas entre os neurônios de uma camada com todos os neurônios da camada seguinte (HAYKIN, 2001), contendo representações das entradas, dos neurônios artificiais, em várias camadas ocultas, suas conexões e a camada de saída.

Figura 3.6 - Representação de uma rede MLP, com as entradas, as camadas ocultas e as camadas de saída.



3.2.1 Redes Neurais Convolucionais

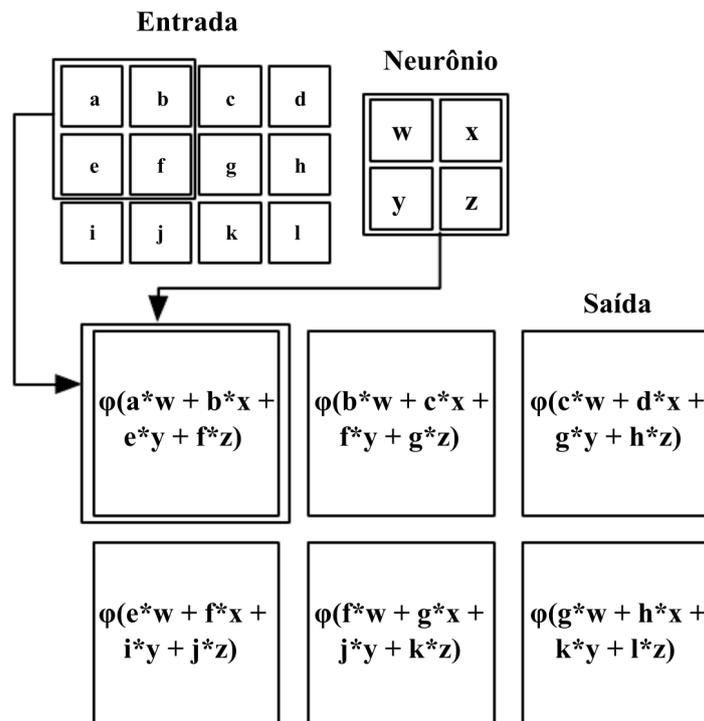
Além de dados espaciais, atribuídos como vetores de entrada, as RNAs possibilitam o processamento de diversos outros tipos de informações, como séries temporais ou imagens. Dentre tantos tipos de arquitetura a serem aplicadas, uma das mais utilizadas no contexto de reconhecimento de padrões em imagens são as CNNs (GOODFELLOW et al., 2016). Nesse tipo de arquitetura, as imagens ocupam um espaço de 2 dimensões, sendo elas largura, altura, além dos canais observados nas imagens,

que são processadas por filtros, ou seja, os neurônios das redes CNN, de forma a extrair um mapa de atributos artificiais como saída das camadas.

As estruturas dos neurônios nesses modelos são matrizes de tamanhos variados, determinados na inicialização de cada camada. Cada filtro contém valores gerados aleatoriamente que são alterados durante o treinamento da rede. Esses filtros passam por toda a imagem em um processo de convolução, ou janelamento, da imagem de entrada, multiplicando seus valores pelos pixels em determinado estágio da convolução. A somatória desses valores passa por uma função de ativação, que determina a saída do filtro, isto é, do neurônio.

A Figura 3.7 é uma representação simplificada do funcionamento de uma rede CNN, recebendo como entrada uma imagem com um único canal aplicado sobre apenas um neurônio.

Figura 3.7 - Representação simplificada do funcionamento de um neurônio de uma rede convolucional.



Cada pixel da imagem de entrada é distinguido pelos valores de a até l , enquanto os pesos do neurônio convolucional são diferenciados entre os valores de w até z . Os pixels da imagem de entrada são multiplicados pelas posições equivalentes do filtro. O somatório resultante passa por uma função de ativação $\varphi(\cdot)$ fornecendo a saída do neurônio, que preenche uma posição na matriz de saída.

Fonte: Adaptado de Goodfellow et al. (2016).

Apesar de comumente utilizada em imagens de 2 dimensões, altura e largura, é possível adaptar o método de convolução para imagens com uma terceira dimensão, ou seja, imagens com profundidade. De acordo com Ji et al. (2018), Feng et al. (2021), aplicações de redes convolucionais 3D são abordagens adequadas para tarefas que envolvam sequência de imagens, onde cada imagem é apresentada como a profundidade ou característica temporal em uma sequência de imagens. Nesse tipo de aplicação, as redes convolucionais fornecem os mesmos conceitos e processos envolvidos nas imagens bidimensionais, porém com filtros com valores de profundidade.

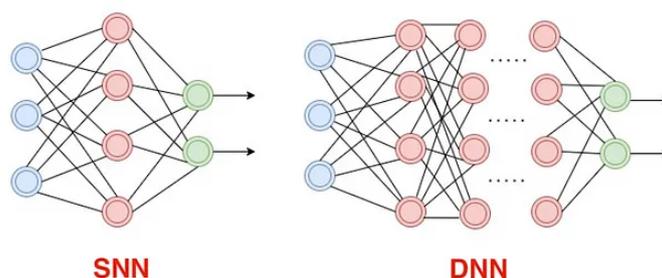
Além das camadas convolucionais, há variações no processo de convolução que simplificam e aceleram a extração do mapa de atributos. Um exemplo são as camadas de *Pooling*, que extraem os valores máximos ou médios dentro da região ocupada pelo filtro. A função principal dentro destas camadas é comumente a redução do tamanho das entradas para as camadas subsequentes.

3.2.2 Aprendizado profundo ou redes neurais profundas

Apesar de sua complexidade, tanto as arquiteturas mais tradicionais de redes neurais quanto as redes convolucionais são envolvidas em outro conceito dentro da área de aprendizado de máquina: o de redes rasas, ou de aprendizado profundo (GOODFELLOW et al., 2016; SANTIAGO, 2021). Apesar de serem muito utilizadas, as redes neurais com poucas camadas ocultas não são capazes de proporcionar o aprendizado de problemas mais complexos. Dessa forma, modelos profundos tornam-se mais adaptáveis e proporcionam uma arquitetura de rede capaz de melhorar os resultados obtidos e generalizar, com mais eficiência, novos conjuntos de dados. Esses tipos de modelos englobam uma nova perspectiva na área de IA, conhecidas como Redes Neurais Profundas (DNN, do inglês *Deep Neural Network*), ou o Aprendizado Profundo (DL, do inglês *Deep Learning*) (GOODFELLOW et al., 2016). A diferença entre arquiteturas de inteligência artificial rasas e profundas pode ser definida, conforme Goodfellow et al. (2016), pela quantidade de camadas escondidas, considerando-se modelos profundos aqueles com 3 ou mais camadas escondidas.

A Figura 3.8 é uma representação de modelos MLP rasos e profundos, onde, para a rede rasa, há a aplicação dos dados de entrada em apenas 1 camada oculta, enquanto que, para a rede profunda, existem mais de 3 camadas, possibilitando uma abstração maior do conjunto de dados.

Figura 3.8 - Comparação de exemplos de redes neurais rasas e profundas.



Comparação visual da quantidade de camadas entre redes rasas (SNNs, do inglês *Shallow Neural Networks*), à esquerda, e redes DNNs, à direita. Note que as redes SNNs possuem menos camadas ocultas em relação às DNNs.

Fonte: [Santiago \(2021\)](#).

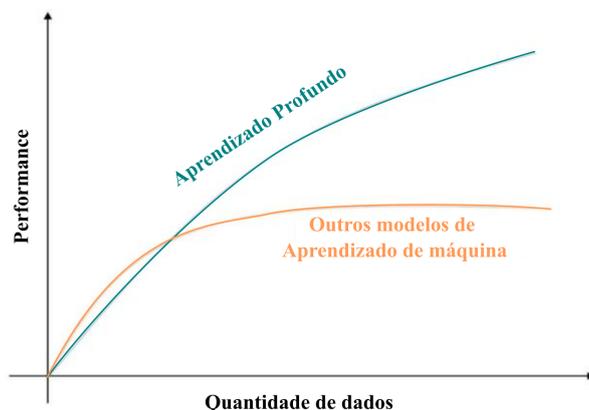
Outra definição bastante utilizada para caracterização de uma arquitetura de rede neural como rasa ou profunda é referente ao custo computacional e ao tempo de treinamento da rede ([SANTIAGO, 2021](#)). Desta forma, mesmo com um número maior de camadas ocultas, determinando assim uma maior complexidade de módulos e técnicas aplicadas, é possível reduzir o tempo e a quantidade de parâmetros treináveis das redes.

3.2.3 Redes pré-treinadas e transferência de aprendizado

O processo de treinamento de uma rede neural, principalmente de redes convolucionais, é um processo com alto custo computacional, com dependência direta da arquitetura, do tamanho do conjunto de dados e do problema proposto.

Quando se trata de redes profundas, a quantidade de dados está altamente interligada à qualidade do modelo, tornando-se indispensável uma quantidade exacerbada de amostras para o treinamento de modelos profundos. Ao mesmo tempo, essas redes apresentam resultados melhores em comparação aos modelos rasos, conforme indicado na Figura 3.9.

Figura 3.9 - Comparação entre as curvas de aprendizado, com base na quantidade de amostras.



Varição da curva de aprendizado entre as arquiteturas profundas e outros modelos de aprendizado de máquina, como uma dependência da quantidade de amostras utilizadas. É possível notar que o aprendizado profundo atinge uma performance maior com um número menor de amostras empregadas.

Fonte: Adaptado de Alom et al. (2019).

O processo de transferência de aprendizado, ou *Transfer Learning*, consiste em utilizar uma rede pré-treinada com outro conjunto de dados para executar tarefas ou objetivos semelhantes. Esses modelos pré-treinados têm sua arquitetura e pesos reutilizados para facilitar a extração de atributos que servem para o treinamento de novas tarefas em um novo conjunto de dados (YOSINSKI et al., 2014; ALOM et al., 2019; HOSNA et al., 2022).

Cada arquitetura possui características próprias, com diferentes números de camadas e números de atributos treináveis. O modelo SqueezeNet propõe o uso de processamento profundo com número reduzido de parâmetros, permitindo tanto um treinamento mais rápido quanto sua ativação embarcada em dispositivos com memória limitada (IANDOLA et al., 2016). Por outro lado, nas redes VGG16 e VGG19, filtros pequenos são aplicados em suas camadas convolucionais, garantindo arquiteturas simples que alcançam resultados considerados estado da arte para o reconhecimento de padrões em imagens (SIMONYAN; ZISSERMAN, 2014). Em Szegedy et al. (2015), são descritos novos módulos convolucionais baseados em alguns princípios para reduzir o custo computacional e equilibrar profundidade com largura, aplicando-os no contexto da melhoria uma nova arquitetura, a Inception-V3.

O modelo *Painters*, por sua vez, baseia-se numa abordagem para reconhecimento de obras de artes, estimulado pela competição *Painter by Numbers: Does every*

painter leave a fingerprint?, disponível na plataforma *Kaggle* (BANACHEWICZ et al., 2022). O *Painter* disponibiliza uma arquitetura com melhor desempenho, onde foi implementada uma abordagem que combina redes supervisionadas e não supervisionadas, unindo suas saídas e compartilhando o gradiente gerado para as alterações nos pesos durante o treinamento da rede supervisionada (ILENIC, 2016).

Além disso, a rede ResNet50 V2 faz parte de uma família de redes profundas que sugerem a aplicação de "saltos" nos sinais sinápticos entre uma sequência de camadas. Essa abordagem permite uma maior profundidade, ou seja, um maior número de camadas, sem o efeito de desaparecimento do gradiente entre o nível de profundidade da arquitetura e a derivada parcial da função de custo (HE et al., 2016).

A Tabela 3.4 identifica algumas redes convolucionais pré-treinadas e suas características. A profundidade de uma arquitetura de rede neural artificial faz referência ao número total de camadas presentes em cada uma das redes listadas.

Tabela 3.4 - Principais redes neurais pré-treinadas.

Modelo	Profundidade	Parâmetros Treináveis	Saída
SqueezeNet	18	1.248 milhão	1000
VGG16	16	138.4 milhões	4096
VGG19	19	143.7 milhões	4096
Painters	16	54.59 milhões	2048
Inception V3	189	23.9 milhões	2048
ResNet50 V2	103	25.6 milhões	2048

3.3 Problemática

As CMEs podem ser observadas a partir de imagens obtidas pelos coronógrafos a bordo de satélites, no momento em que esse tipo de estrutura surge no campo de visão do instrumento, que observa a dinâmica da superfície solar, sendo ejetada em uma direção radial para longe do Sol (GOOD; FORSYTH, 2016). Caso uma CME tenha sua expansão no campo de visão do coronógrafo em um ângulo próximo aos 360°, ela é denominada de CME do tipo *Full Halo*, sendo denominadas desta forma por estarem provavelmente direcionadas ao satélite que obteve as imagens ou na direção oposta, se afastando do satélite, tornando-se aparentemente maiores e envolvendo o Sol como em uma auréola (SHARIFF et al., 2017). Outra denominação de CMEs com comportamento semelhante são as CMEs do tipo *Partial Halo*, contudo,

com uma expansão inferior a 360° .

A confirmação de que os eventos estão direcionados à Terra precisa ser complementada com as imagens obtidas pelos telescópios que mostram o local aproximada da origem do evento na superfície visível do Sol. Já, no meio interplanetário, sensores a bordo dos satélites detectam a passagem das estruturas magnéticas como as ICMEs através das variações abruptas na velocidade, na temperatura, na densidade do vento solar, bem como os parâmetros baseados nestas medidas.

Com os dados medidos e a observação da propagação inicial das CMEs, é possível realizar análises sobre o comportamento das estruturas e a relação entre os parâmetros, possibilitando a previsão do tempo de chegada da onda de choque e da estrutura guiando o choque interplanetário, caso estejam direcionadas à Terra.

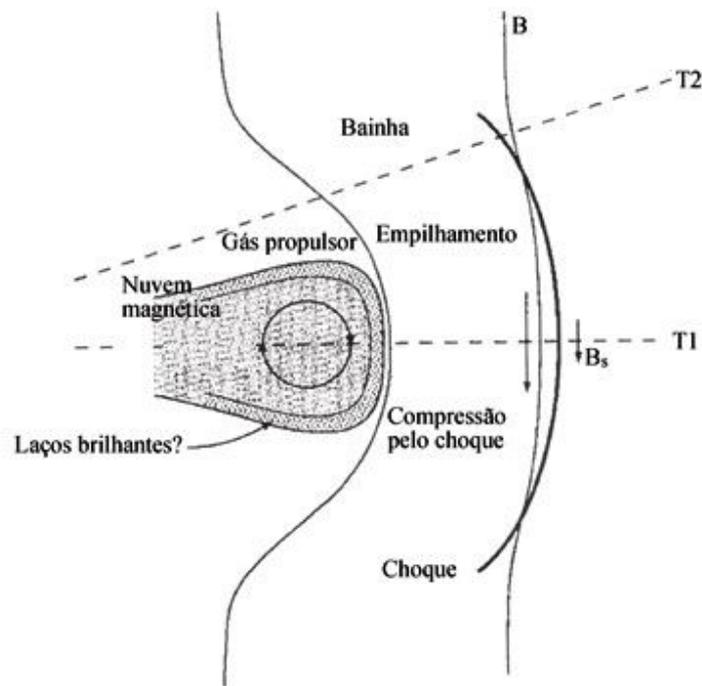
A propagação das estruturas magnéticas derivadas da atividade solar podem interagir com o vento solar de diferentes maneiras, gerando diferentes tipos de ondas interplanetárias, cada qual com características específicas e com diferentes mudanças nos parâmetros do vento solar.

As ondas frontais rápidas são descontinuidades caracterizadas pelo aumento abrupto na velocidade, densidade e temperatura do vento solar, além da intensidade do campo magnético interplanetário, sendo a classificação de choque mais comum (ECHER et al., 2003; ECHER; ALVES, 2006; LUCAS et al., 2006), seguido de choques reversos rápidos, que por sua vez são caracterizados por diminuições nos valores do IMF, densidade e temperatura, porém com um aumento na velocidade.

Figura 3.10 é a representação esquemática de um choque guiado por uma nuvem magnética (MC, do inglês *Magnetic Cloud*) (BURLAGA et al., 1981). Cerca de um terço de todos os choques guiados por ICMEs são seguidos por MCs, consideradas um tipo especial de ICMEs (KILPUA et al., 2013). Conforme ilustrado, o plasma solar é comprimido, empilhado e arrastado, gerando uma região de intensos campos magnéticos, chamada de bainha magnética (GONZALEZ et al., 1999; ECHER; ALVES, 2006; LUCAS et al., 2006). Por sua vez, atrás da frente do choque, surge uma região de alta perturbação entre as partículas carregadas pelo vento solar, com mudanças intensas nos valores da velocidade, da temperatura e da densidade das partículas do plasma solar e do campo magnético interplanetário. Uma componente do campo magnético interplanetário direcionada para o sul (B_S) surge e pode interagir com o campo geomagnético, comprimindo-o ou reconectando-se, permitindo a entrada de partículas para dentro da cavidade magnetosférica. Dois satélites obser-

vam a estrutura: um está no caminho central da MC (T_1) e o outro observa somente o choque interplanetário (T_2) (GONZALEZ et al., 1999).

Figura 3.10 - Representação esquemática de uma onda de choque guiada por uma nuvem magnética.



Onda de choque guiada por uma nuvem magnética, um tipo especial de ICME. A região formada entre a nuvem magnética e a onda de choque é conhecida como bainha magnética, uma região de campos magnéticos perturbados e empilhados. De acordo com a representação, um satélite está na parte frontal da estrutura (T_1) e outro observa somente a onda de choque guiada (T_2). A representação mostra que o satélite é um único ponto no espaço para observar uma estrutura de larga escala, o que depende de onde ele se encontra no momento da passagem da estrutura.

Fonte: Adaptado de Gonzalez et al. (1999).

As ondas de choque podem viajar na direção do ambiente terrestre, o que justifica o monitoramento por satélites estrategicamente posicionados no ponto L1. Quando essas estruturas atingem os satélites, podem ser detectadas por meio de instrumentos que coletam dados do vento solar. Essas ondas de choque podem ser identificadas e classificadas manualmente com base nas mudanças observadas nas séries temporais, ou a partir de métodos automatizados. Os métodos automatizados podem utilizar algoritmos tradicionais a partir da análise estatística dos valores médios dos parâ-

metros *upstream* e *downstream*, isto é, os valores médios antes e após a passagem da estrutura, respectivamente. Alternativamente, podem-se empregar técnicas baseadas em aprendizado de máquina. Neste estudo, foram utilizados gráficos das séries temporais dos parâmetros do vento solar e do campo magnético como entrada para redes convolucionais profundas.

O estudo desenvolvido e os resultados obtidos da aplicação das técnicas de visão computacional e aprendizado profundo possibilitam uma nova evolução do estado da arte, especialmente no que se refere a novas aplicações dentro da área do Clima Espacial. Isso inclui a exploração de novas possibilidades para abordagens em tarefas de previsão e caracterização de estruturas magnéticas derivadas da atividade solar.

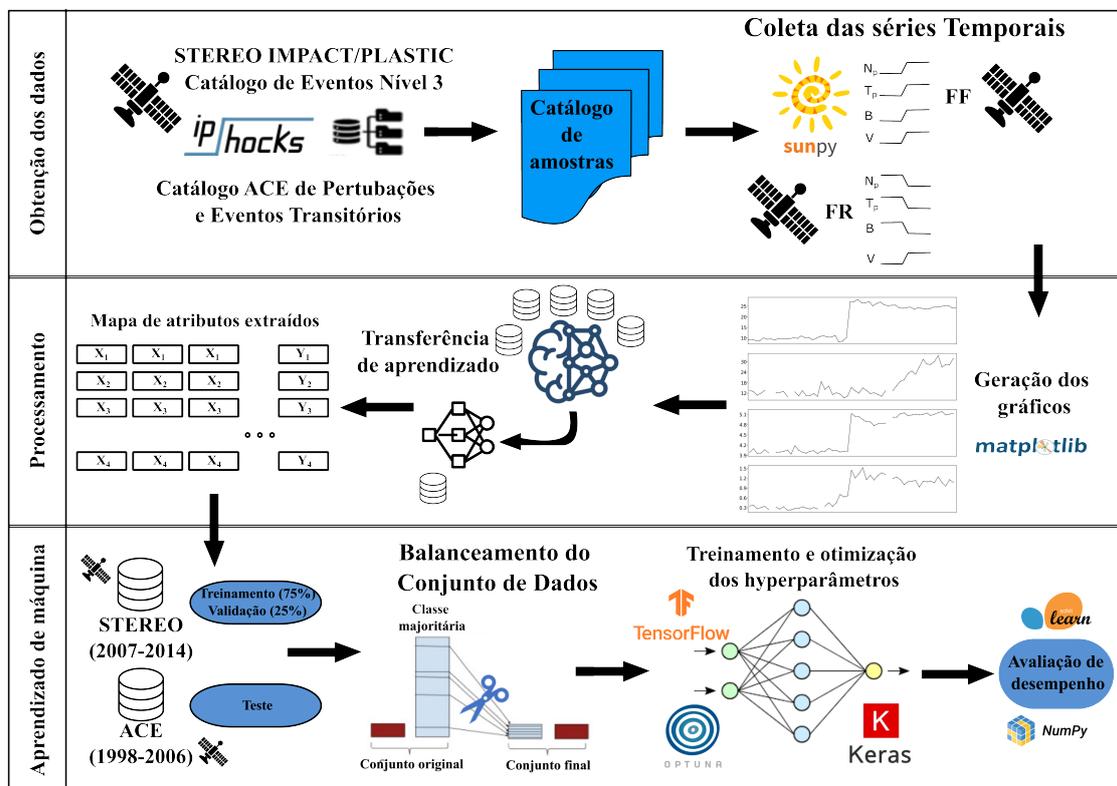
4 MATERIAIS E MÉTODOS

Os eventos solares, como as CMEs, *flares*, entre outros fenômenos e seus efeitos podem ser detectados na Terra, e têm o potencial de causar danos significativos. O desenvolvimento de técnicas para previsão e detecção de estruturas magnéticas derivadas da atividade solar torna-se fundamental, visto que a sociedade moderna é altamente dependente de recursos tecnológicos (HAPGOOD, 2018). O objetivo principal é mitigar os impactos e proteger as tecnologias e os sistemas críticos.

O monitoramento realizado pelos satélites resulta em uma grande quantidade de dados a serem analisados para a correta interpretação das informações ali contidas. Uma abordagem inovadora para o processamento das grandes quantidades de dados gerados pelas missões espaciais aplicado para a prevenção e solução da tarefa de prevenção de danos seria a utilização de técnicas de aprendizado de máquina nos dados disponíveis. Dentre algumas das possibilidades, decidiu-se trabalhar com a aplicação de redes convolucionais nas imagens de coronógrafos para previsão do tempo de chegada das estruturas do choque. Adicionalmente, empregaram-se gráficos de séries temporais para a detecção da passagem das estruturas pelos satélites utilizando visão computacional, por meio de redes convolucionais.

O fluxograma apresentado na Figura 4.1 exibe a ordem de etapas efetuadas para detecção dos eventos de ondas de choques interplanetárias, iniciando pela coleta das séries temporais e geração dos gráficos para cada evento observado. Após esta etapa, seguiu-se com a transferência de aprendizado por várias redes pré-treinadas, a separação dos subconjuntos de dados e a remoção de amostras majoritárias, além do treinamento dos classificadores e da avaliação do modelo.

Figura 4.1 - Diagrama da metodologia desenvolvida para detecção das ondas de choque interplanetárias.



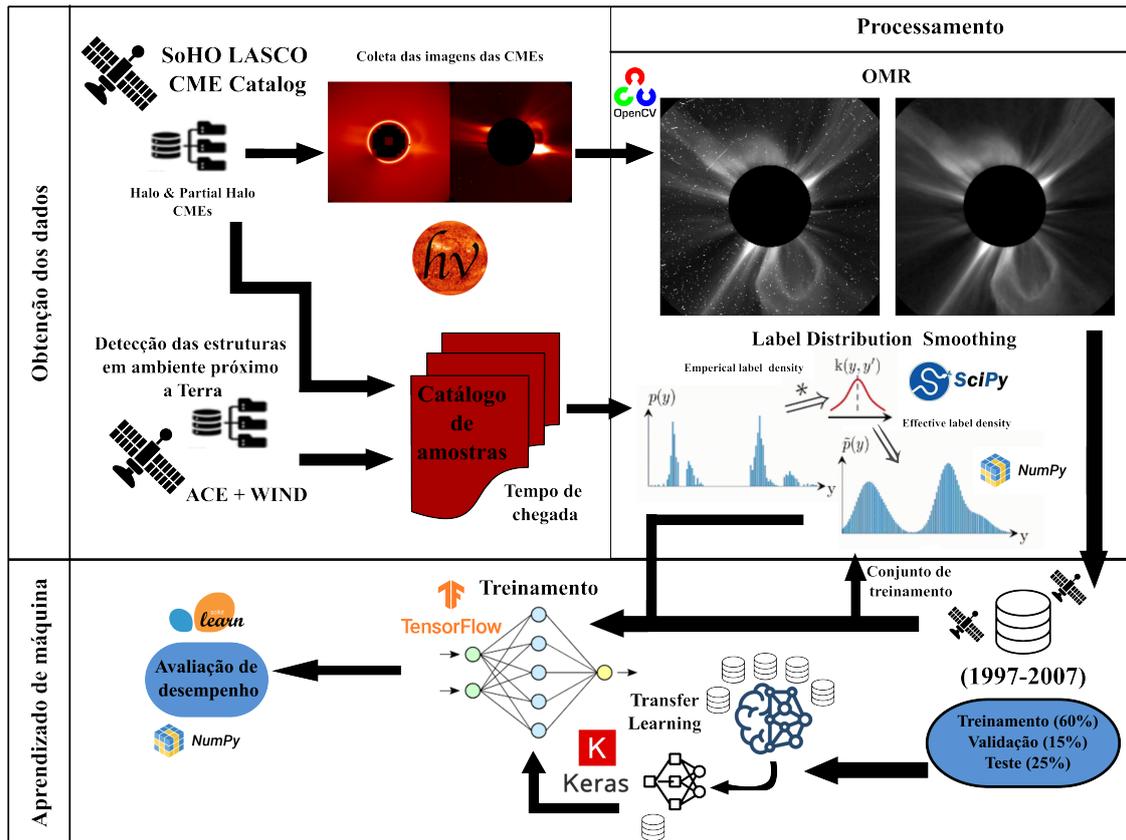
Processo de metodologia da seleção e coleta das amostras de treinamento para utilização da transferência de aprendizagem nas entradas para detecção e classificação das estruturas. As principais etapas são a obtenção dos dados, o processamento dos gráficos das séries temporais e o aprendizado de máquina.

Paralelamente à abordagem anterior, referente à detecção de ondas de choque interplanetárias exibida na Figura 4.1, foram desenvolvidas técnicas para a previsão da chegada das ondas de choque a partir da visualização da propagação inicial das ICMEs nas imagens dos coronógrafos. Conforme o diagrama apresentado na Figura 4.2, é possível observar a sequência das etapas empregadas para a previsão do tempo de chegada de ICMEs associadas ou não ao processo de propagação de uma onda de choque interplanetária.

Iniciou-se pela coleta das imagens da propagação inicial de CMEs, obtidas pelo imageador C2 do satélite SOHO, direcionadas ao ambiente terrestre e relacionando cada evento com seu tempo de propagação, determinado pela perturbação no vento solar detectadas pelo sensores dos satélites ACE e WIND (SZABO, 2015). Logo após, foi realizado um processo de filtragem com a finalidade de remover ruídos e artefatos indesejados, presentes na imagens dos coronógrafos, provenientes de diversas fontes. Antes de realizar o processo de treinamento das redes neurais, o conjunto de

treinamento foi balanceado por meio da utilização do algoritmo *Label distribution smoothing* (LDS), onde foram inseridos pesos para cada amostra do conjunto de treinamento, seguido pelo treinamento e generalização das redes neurais convolucionais.

Figura 4.2 - Diagrama da metodologia desenvolvida para previsão do tempo de chegada das ondas de choque interplanetárias.



Processo de metodologia aplicado para a previsão do tempo de chegada das estruturas magnéticas em ambiente terrestre. As principais etapas são a obtenção dos dados, o processamento das imagens, através do OMR, o balanceamento do conjunto de dados e o aprendizado de máquina.

O método de reconstrução das imagens dos coronógrafos citado anteriormente é chamado de OMR, sigla que vem do inglês *Openings by Morphological Reconstruction*. Na aplicação desse algoritmo, filtros matemáticos de abertura são aplicados em diferentes aspectos e condições da imagem original de forma a remover artefatos indesejados sem comprometer a visualização da estrutura da CME.

Apesar de ambas as tarefas seleccionadas estarem intimamente ligadas a aplicações em dados espaço-temporais, a escolha de uso de redes convolucionais se deve à capa-

cidade dessas redes de extrair e interpretar informações importantes, possibilitando a análise de padrões mesmo com a existência de *gaps* (ou seja, dados faltantes) nas séries temporais. A aplicação de redes recorrentes nas amostras dessas séries temporais exigiria pré-processamentos computacionalmente custosos, como a interpolação de dados, o que poderia comprometer a veracidade da amostra. Além disso, como apontado em Feng e Ye (2021), as redes recorrentes perdem capacidade para o reconhecimento de padrões em tarefas onde não há uma cadência específica nos dados e quando há um grande intervalo de tempo entre as informações adjacentes de uma mesma amostra.

4.1 Seleção de ferramentas e instrumentos

Para o desenvolvimento do trabalho, foram utilizadas diversas ferramentas e ambientes de programação, além das bibliotecas específicas. Para a implementação das redes convolucionais, foram utilizadas as ferramentas e ambientes como *Orange*, *Keras*, *Tensorflow* (DEMŠAR et al., 2013; CHOLLET et al., 2015; ABADI et al., 2015). A partir do uso de programação em linguagem *Python*, as bibliotecas *Numpy*, *matplotlib*, *opencv*, *pandas*, *Sunpy* (BRADSKI, 2000; HUNTER, 2007; MCKINNEY, 2010; MUMFORD et al., 2020; HARRIS et al., 2020) entre outras foram utilizadas, compondo as etapas de pré-processamento, além da organização, da análise e da visualização dos dados.

A escolha dos satélites da missão STEREO, STEREO-A e STEREO-B, e da missão ACE foi baseada na eficiência apresentada para coleta e apresentação dos dados em diversas plataformas e *Frameworks* como, por exemplo: CDAWeb, OmniWeb, Sunpy. Além disso, foi a possibilidade de identificação de estruturas que estão se aproximando da Terra, principalmente quando estas se propagam e atingem a posição relativa ao ponto L1, equivalente a 1 centésimo da distância entre a Terra e o Sol, de forma a permitir a previsão a curto prazo de impactos iminentes de estruturas magnéticas na magnetosfera terrestre (BAUMANN; MCCLOSKEY, 2021). Isso possibilitaria que outros satélites, mais próximos da atmosfera terrestre, entrem em modo de segurança, que redes de distribuição de energia evitem sobrecarga, redirecionando suas cargas de energia, e que astronautas, em órbita, coloquem equipamentos de proteção adequados a fim de evitar a exposição à radiação extrema (WEBB et al., 2001; MENDEZ et al., 2004; DOBRIJEVIC, 2022).

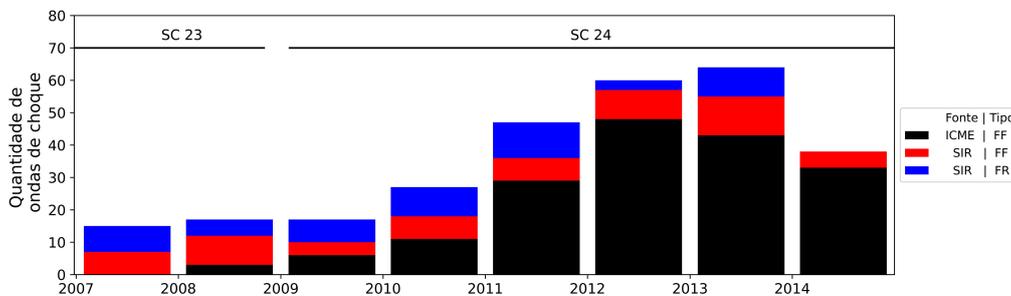
Para a estruturação da abordagem para previsão do tempo de chegada, utilizaram-se os catálogos que relacionassem a onda de choque interplanetária com a sua fonte de origem. No presente trabalho, foram utilizados os catálogos [University of Science](#)

and Technology of China (USTC) (2016), George Mason University (GMU) (2018), Goddard Space Flight Center (GSFC) (2021), Instituto Pushkov de Magnetismo Terrestre, Ionosfera e Propagação de Ondas de Rádio (IZMIRAN) (2021), Havard Dataverse (2024). Com base nas observações de CMEs e na chegada dos eventos detectados pelos satélites ACE e WIND, posicionados no ponto L1, e também a partir dos dados relacionados às estruturas que os guiaram, foi possível determinar o tempo de propagação das estruturas direcionadas à Terra.

4.2 Dados observados

O método abordado nesse estudo para a classificação e detecção automatizada das ondas de choque, guiadas por estruturas do tipo ICMEs ou SIRs/CIRs, utilizou-se de gráficos das séries temporais de dados *in-situ* de satélites. A Figura 4.3 representa a quantidade de amostras de choques interplanetários identificados por tipo de choque e estrutura que guiou o choque. Tais amostras foram utilizadas para as fases de treinamento e teste das redes para detecção das ondas de choque interplanetárias, ao longo dos anos, dentro do período de 2007 a 2014, cobrindo partes dos ciclos solares 23 e 24.

Figura 4.3 - Quantidade de amostras por tipo e estrutura que guiou a onda de choque, para o treinamento das redes convolucionais para detecção e classificação.



Entre 2007 e 2014, período que corresponde à parte dos ciclos solares 23 e 24, choques frontais rápido (FF), guiados por ICMEs e SIRs, e reversos rápidos (FR), guiados por SIRs, foram identificados. Há um aumento na quantidade de choques guiados por ICMEs, conforme o ciclo solar avança para a fase ascendente, até atingir o máximo e fase descendente. Nas fases de mínimo, há uma predominância de choques guiados por SIRs/CIRs.

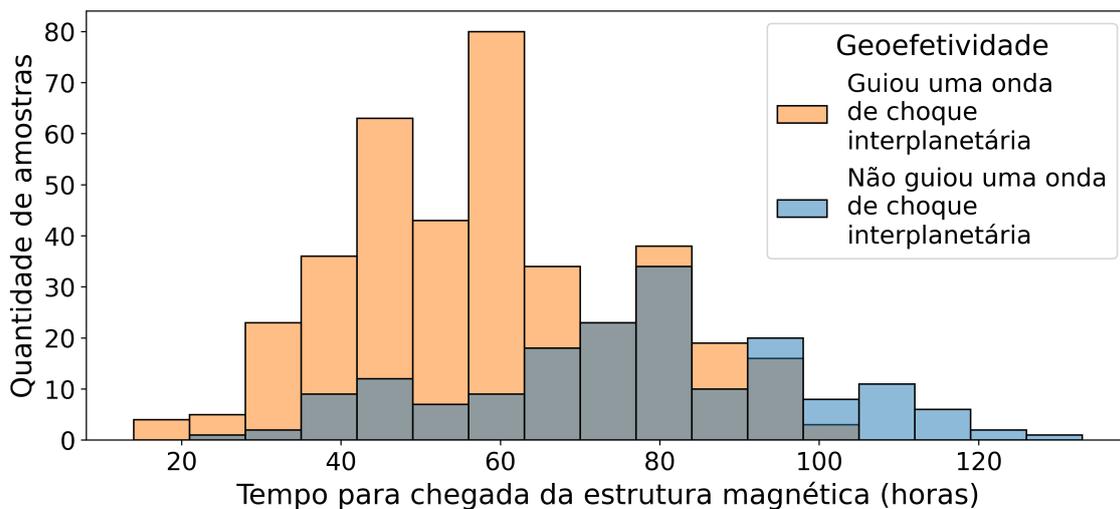
A seleção do período de 2007 a 2014, para o conjunto de treinamento da abordagem de detecção de ondas de choque interplanetárias, foi definida com base na disponibilidade e integridade dos eventos catalogados pela missão STEREO. A missão iniciou suas atividades de observação das perturbações no vento solar e no campo

magnético interplanetário em 2007, e a comunicação com o satélite STEREO-B foi interrompida em outubro de 2014 devido a falhas múltiplas que afetaram o sistema de controle de orientação do satélite. Isso encerrou a possibilidade de obter uma lista conjunta e contínua de eventos, abrangendo ambos os satélites da missão.

Para validação dos resultados obtidos durante o treinamento das arquiteturas, o conjunto foi dividido em dois outros, sendo eles o conjunto de treinamento e o conjunto de validação. O conjunto de validação recebeu 25% das amostras do conjunto original, totalizando 1010 eventos detectados pelos satélites STEREO-A e STEREO-B, restando para o subconjunto de treinamento 474 amostras negativas, 234 amostras FF e 50 amostras FR.

Paralelamente, outro conjunto de dados foi utilizado, a fim de treinar as redes para previsão do tempo de chegada das estruturas. Entre os eventos com origem determinada para a previsão do tempo de chegada, a coleta das amostras observaram apenas eventos guiados por CMEs do tipo *Full Halo* e *Partial Halo*, durante o período de 1997 a 2017, totalizando 261 eventos a serem analisados. A fim de aumentar a quantidade de amostras, foi realizada a coleta das imagens desde o surgimento da CME, no campo de visão do coronógrafo, até 1 hora depois, com cadência aproximada de 30 minutos. Adicionalmente, foi realizando um janelamento de 30 minutos até 1 hora após o primeiro surgimento da estrutura no campo de visão do sensor LASCO C2, de forma que isso possibilitou a geração de um conjunto de dados com 560 amostras, com sequências de imagens de CMEs direcionadas à Terra, que guiaram ou não ondas de choque interplanetárias. Conforme indicado na Figura 4.4, existem não apenas diferentes comportamentos, referente ao tempo de propagação em relação à geofetividade das CMEs, entre as amostras, mas também um desbalanceamento na quantidade de eventos mais rápidos e mais lentos.

Figura 4.4 - Quantidade de amostras obtidas e o tempo, em horas, para chegar à Terra.



Quantidade total de CMEs que guiaram ou não ondas de choque interplanetárias e o tempo em que a estrutura foi detectada pelos sensores a bordo de satélites posicionados no ponto L1. Note que as estruturas não acompanhadas de choque apresentam um tempo de propagação maior.

4.3 Balanceamento do conjunto de dados

Um dos problemas mais comuns enfrentados em abordagens de aprendizado de máquina é o desbalanceamento dos dados de entrada para os modelos. A aplicação de conjuntos desbalanceados pode resultar no treinamento de redes tendenciosas em geral ou que simplesmente não tenham uma alta capacidade de generalização. Contudo, existem diversos algoritmos e técnicas que visam a solução de problemas de balanceamento em conjuntos de dados (JOHNSON; KHOSHGOFTAAR, 2019; VARGAS et al., 2022).

4.3.1 *Undersampling e oversampling*

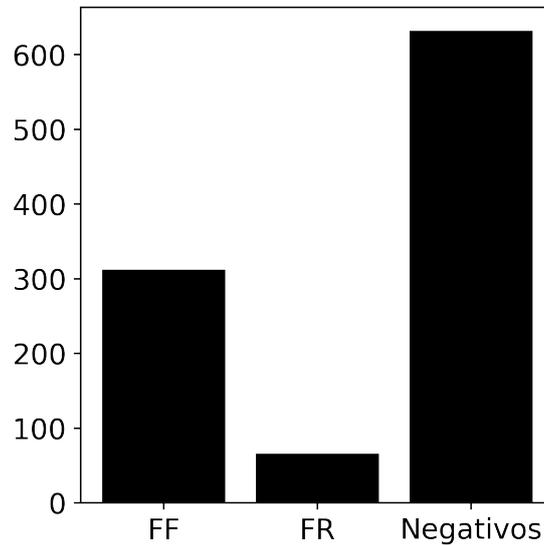
Uma das soluções para o desbalanceamento dos dados é o uso de algoritmos de *undersampling* ou *oversampling*, ou seja, para remoção ou adição de amostras, respectivamente.

Como observado em Figura 4.5, o conjunto de dados contém uma quantidade majoritária de amostras fontais rápidas, porém também pode ser observado que há uma quantidade ainda maior de amostras negativas.

A fim de evitar que as arquiteturas treinadas criem tendências para as classes majoritárias, foi implementado um algoritmo de *undersampling*, ou seja, para remoção

das amostras majoritárias. A partir do uso desse tipo de técnica, é possível obter um subconjunto do conjunto original, sem a presença majoritária de uma classe.

Figura 4.5 - Quantidade de amostras por tipo de choque interplanetário.



As classes FF, FR e Negativos representam as classes de choques que foram apresentadas às redes neurais para treinamento. Os conjuntos de treinamento e de validação totalizaram 1010 eventos distintos, divididos nas três classes de eventos que as redes neurais foram treinadas para identificar.

Neste trabalho, foi utilizado o algoritmo *Edited Nearest Neighbours* (ENN) para remoção de algumas amostras negativas. Esse tipo de algoritmo calcula a distância dos atributos entre as amostras de cada classe, removendo amostras ambíguas, com base no tamanho determinado para a vizinhança (WILSON, 1972).

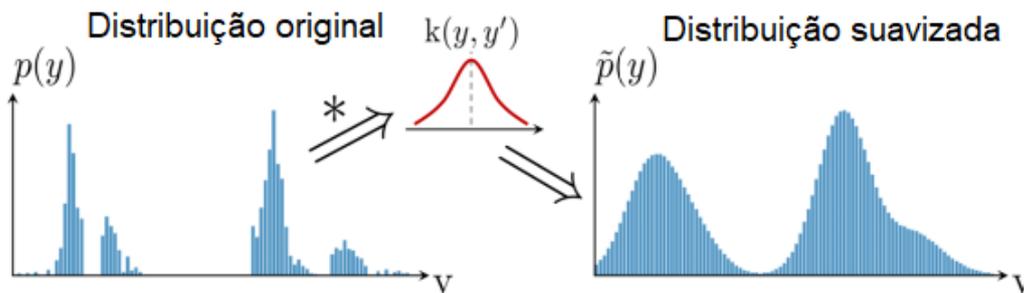
4.3.2 Suavização de rótulos

A suavização de rótulos, ou *label smoothing*, é outra abordagem utilizada para a correção de um conjunto de dados desbalanceado. A utilização de técnicas para suavização na aplicação de ruídos nas saídas das amostras, justificado pela possível existência de erros no conjunto de dados, cria rótulos suavizados para cada amostra com base na sua distribuição, de forma a evitar que haja um superajustamento da rede para as classes majoritárias (GOODFELLOW et al., 2016; ZHANG et al., 2021).

Outro problema enfrentado foi o balanceamento de um conjunto de dados com valo-

res contínuos com poucas amostras, apesar do janelamento realizado para aumentar a quantidade de amostras por evento observado. A fim de evitar que as redes neurais obtivessem resultados tendenciosos aos valores médios de 63 ± 22 horas de propagação até atingir distância aproximada de 1 UA, foi aplicado o algoritmo LDS. Esse método de balanceamento aplica diferentes pesos a cada amostra para o treinamento das redes, de forma a conceder valores de custo proporcionais ao peso de cada amostra. Esses pesos, por sua vez, são determinados pela densidade de uma distribuição simétrica aplicada em um espaço de atributo (YANG et al., 2021). A Figura 4.6 exemplifica a suavização da distribuição de um conjunto desbalanceado em um espaço de atributo contínuo.

Figura 4.6 - Exemplo da aplicação do algoritmo LDS.



Comparação das densidades em um espaço de atributo contínuo entre uma distribuição empírica (painel à esquerda) e uma distribuição suavizada, obtida a partir do processo de convolução com um filtro simétrico (painel à direita).

Fonte: Adaptado de Yang et al. (2021).

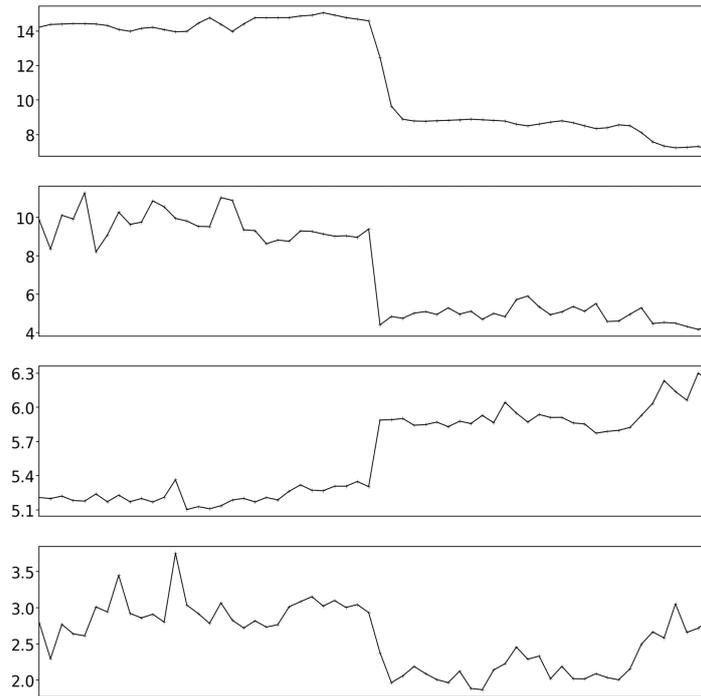
4.4 Geração das imagens

A partir dos dados *in-situ* de diversos satélites, foram gerados gráficos das séries temporais que, posteriormente, foram utilizadas como entradas das redes CNNs profundas pré-treinadas. Gráficos de séries temporais foram gerados utilizando os parâmetros de velocidade, densidade e temperatura do vento solar, além do campo magnético interplanetário, em períodos de 1 hora, 30 minutos, 15 minutos e 10 minutos, antes e depois da identificação da passagem da onda de choque. Os gráficos, apresentados em forma de painel, com os parâmetros de plasma do vento solar e do IMF, compuseram o conjunto de amostras que foram utilizadas no treinamento da rede neural. Com essa aplicação, foi possível obter redes neurais artificiais capazes

de identificar, automaticamente, a passagem de uma onda mesmo com a presença de *gaps* nos dados.

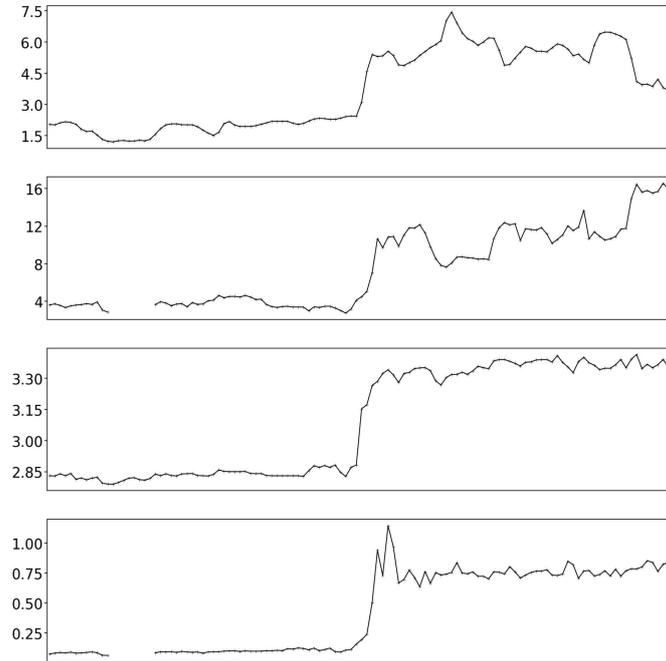
As Figuras 4.7, 4.8, 4.9, 4.10 são representações reais das informações utilizadas como entradas para o modelo de detecção de ondas de choque interplanetárias, em ambiente próximo à Terra. Foram utilizados gráficos de séries temporais, onde estão dispostos os parâmetros referentes à magnitude do campo magnético interplanetário ($B[nT]$), e os parâmetros do vento solar, como densidade dos prótons ($N_p[1/cm^3]$) velocidade do vento solar ($V[km/s]$) e temperatura dos prótons ($T_p[^\circ K]$). Os gráficos apresentados como entradas das redes neurais foram gerados e alguns de seus elementos removidos, como os valores do eixo horizontal, referentes ao momento observado, e a informação do eixo vertical relativa ao parâmetro que cada painel representa, com a finalidade de evitar informações desnecessárias.

Figura 4.7 - Exemplo de entrada das redes convolucionais para detecção e classificação da onda de choque interplanetária, do tipo reversa rápida.



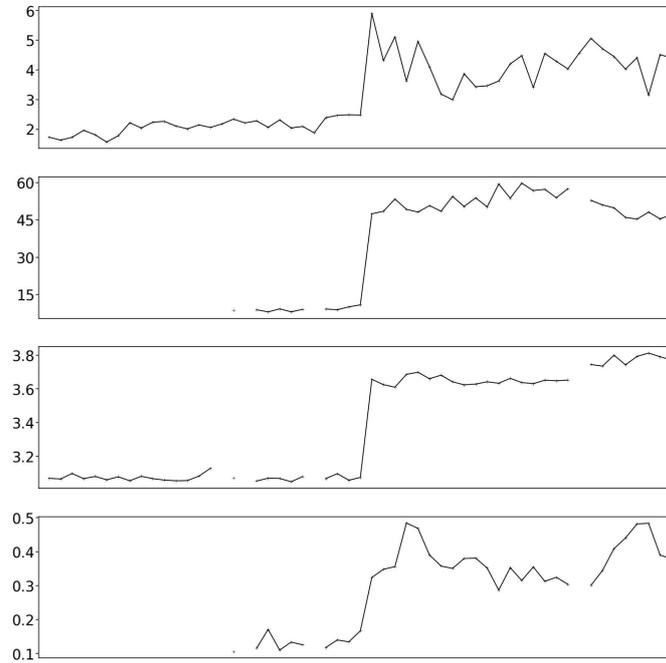
Exemplo de uma amostra de choque reverso rápido, guiada por uma SIR, com dados *in-situ* do satélite STEREO-A, às 23h12 no horário universal (UT, do inglês Universal time) do dia 22 de julho de 2016, gerada para entrada da rede de detecção, com total de 1 hora de dados observados. Os painéis, dispostos de cima para baixo, representam os parâmetros da magnitude do campo magnético interplanetário ($B[nT]$), densidade dos prótons ($N_p[1/cm^3]$), velocidade do vento solar ($V[km/s]$), em escala de 10^2 , e temperatura dos prótons ($T_p[^\circ K]$), em escala de 10^5 .

Figura 4.8 - Exemplo de entrada das redes convolucionais para detecção e classificação da onda de choque, do tipo frontal rápida.



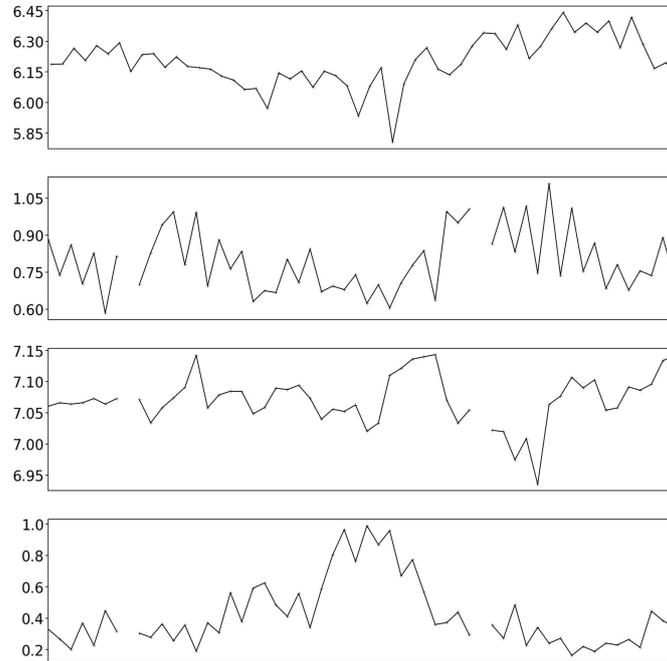
Exemplo de uma amostra de onda de choque interplanetária frontal rápida, guiada por uma SIR, com dados *in-situ* do satélite STEREO-B, às 11h27 UT do dia 26 de outubro de 2009, gerada para entrada da rede de detecção, com total de 2 horas de dados observados. Os painéis, dispostos de cima para baixo, representam os parâmetros da magnitude do campo magnético interplanetário ($B[nT]$), densidade dos prótons ($N_p[1/cm^3]$) velocidade do vento solar ($V[km/s]$), em escala de 10^2 , e temperatura dos prótons ($T_p[^\circ K]$), em escala de 10^5 .

Figura 4.9 - Exemplo de entrada das redes convolucionais para detecção e classificação da onda de choque interplanetária, do tipo frontal rápida, com a presença de um grande período com *gaps*.



Exemplo de uma amostra de choque frontal rápido com dados *in-situ* do satélite ACE, às 08h43 UT do dia 30 de abril de 1998, gerada para entrada da rede de detecção, com total de 1 hora de dados observados. Os painéis, dispostos de cima para baixo, representam os parâmetros da magnitude do campo magnético interplanetário ($B[nT]$), densidade dos prótons ($N_p[1/cm^3]$), velocidade do vento solar ($V[km/s]$), em escala de 10^2 , e temperatura dos prótons ($T_p[^\circ K]$), em escala de 10^5 .

Figura 4.10 - Exemplo de entrada das redes convolucionais para detecção e classificação da onda de choque interplanetária, sem a ocorrência de perturbações que identifiquem uma onda de choque interplanetária.



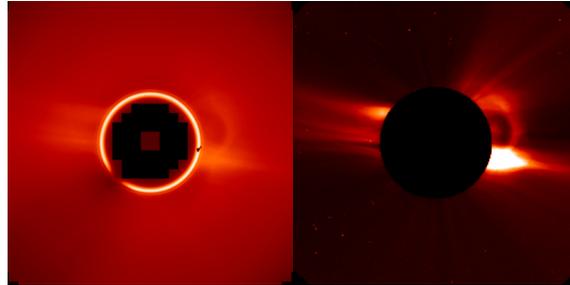
Exemplo de uma amostra onde não há uma perturbação, ou seja, não foi caracterizada a presença de uma onda de choque interplanetária, de acordo com as observações dos dados *in-situ* do satélite ACE, entre 04h35 e 05h35 UT do dia 13 de novembro de 2005, gerada para entrada da rede de detecção, com total de 1 hora de dados observados. Os painéis, dispostos de cima para baixo, representam os parâmetros da magnitude do campo magnético interplanetário ($B[nT]$), densidade dos prótons ($N_p[1/cm^3]$), velocidade do vento solar ($V[km/s]$), em escala de 10^2 , e temperatura dos prótons ($T_p[^\circ K]$), em escala de 10^5 .

O outro método que compõe a solução dos problemas propostos é a utilização de imagens do coronógrafo LASCO C2 do satélite SoHO para prever o tempo de chegada das estruturas. As entradas das redes desenvolvidas são seqüências de imagens de CMEs, processadas para remoção de ruídos e projetadas como uma imagem multicanal. As imagens obtidas são tratadas previamente, ocultando a região até 2 raios solares (R_S), evitando o efeito de eclipse gerado pelo imageador, convertendo o formato das imagens de .fits para .jpeg.

A Figura 4.11 demonstra o tratamento inicial das imagens do coronógrafo C2, realizado pela Interface de Programação de Aplicações (API, do inglês *Application Programming Interface*) do *heliowiewer*, a biblioteca HVPy (IRELAND et al., 2009), diminuindo a intensidade dos pixels, reduzindo a resolução e aplicando uma máscara

sobre a área do eclipse, ou seja, ocultando o disco solar até $2 R_S$.

Figura 4.11 - Pré-processamento das imagens obtidas pelo coronógrafo LASCO C2.

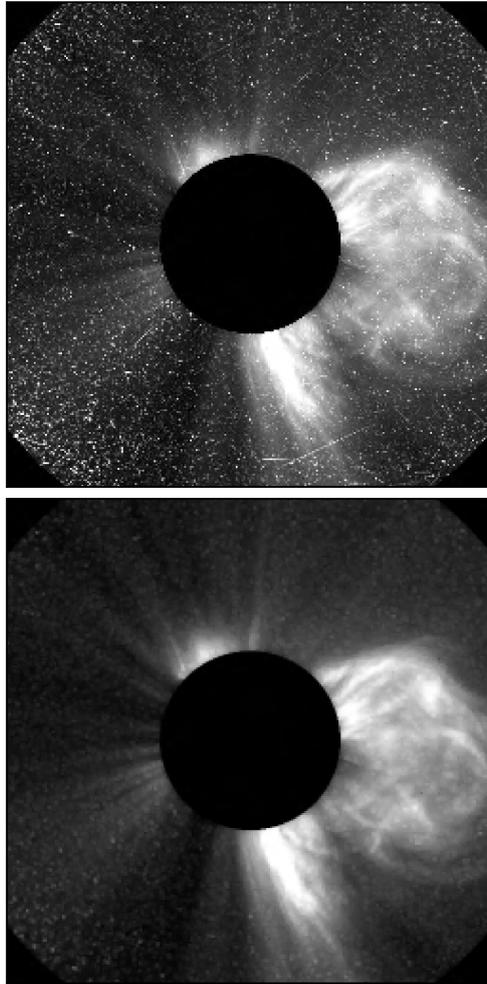


Comparação da imagem original, à esquerda, captada pelo coronógrafo LASCO C2, e a imagem que passou pelo pré-processamento, à direita, realizado pela API do *Heliviewer*.

4.4.1 Pré-processamento para remoção de ruídos nas imagens

Nas imagens obtidas pelo imageador LASCO C2, é possível observar a propagação inicial das CMEs em direção ao espaço interplanetário. Contudo, essas imagens podem conter ruídos de diversas fontes, como a passagem de satélites, a presença de cometas na região observável, ou o impacto de raios cósmicos nos sensores (PAGOT et al., 2014). A fim de evitar que esses artefatos interferissem negativamente no treinamento das redes, foi aplicado um pré-processamento baseado em alterações morfológicas nas imagens. A Figura 4.12 mostra a diferença entre uma imagem com e sem o pré-processamento OMR onde é possível observar a remoção de ruídos, sejam eles corpos celestes, ou causados pelo impacto de raios cósmicos. Desta forma, a rede não considera tais corpos como padrões importantes das características das ICMEs.

Figura 4.12 - Imagens do LASCO C2 com o pré-processamento inicial e com pré-processamento MOR.



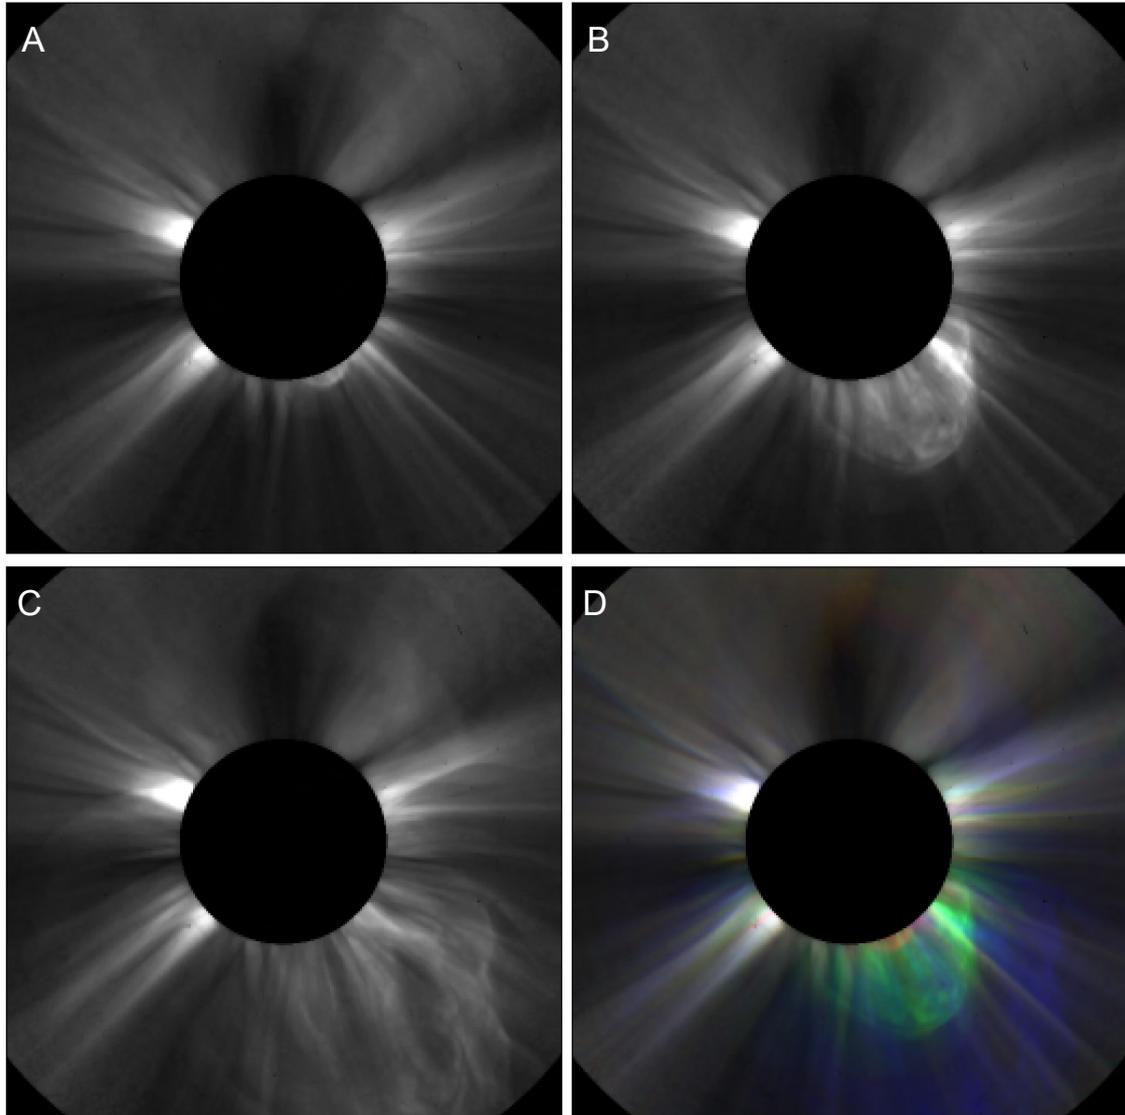
A imagem do topo é o resultado da aplicação do pré-processamento inicial, enquanto que a imagem inferior mostra o resultado da aplicação adicional do pré-processamento OMR na imagem pré-processada. Note que os ruídos foram removidos, ficando em destaque apenas o evento da CME.

Nesse método de reconstrução de imagens dos coronógrafos, são aplicados filtros matemáticos por meio do processo de convolução, utilizando filtros de abertura conhecidos como filtragem por OMR. Isso resulta na remoção de pequenas regiões de alta intensidade que estão rodeadas por regiões de menor intensidade, reduzindo ou eliminando áreas ou pixels ruidosos. Em seguida, é parcialmente devolvida a intensidade de valores nessas regiões. Essa restauração de valores ocorre com base nos valores dos pixels vizinhos, determinados pelo tamanho do filtro aplicado.

As Figuras 4.13, 4.14, 4.15 exibem algumas sequências que exemplificam as entradas para o modelo de previsão do tempo de chegada de ondas de choque interplanetárias em ambiente próximo à Terra. São empregadas imagens do Coronógrafo 2 do satélite

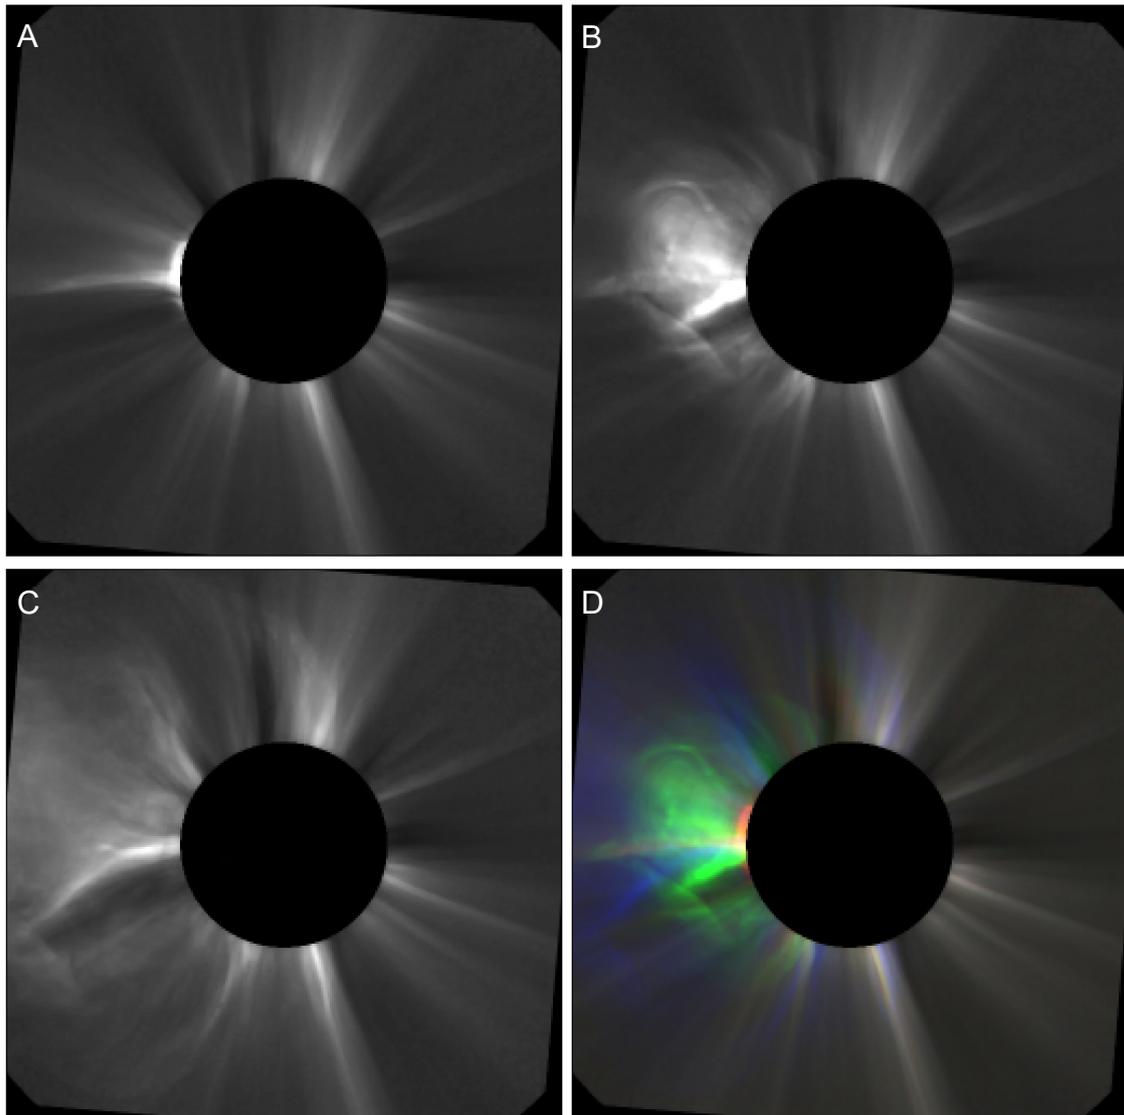
SoHO, no espectro da luz visível, onde é ocultada a região do disco solar até $2 R_s$. O pré-processamento OMR é aplicado para remoção de ruídos das imagens.

Figura 4.13 - Exemplo da propagação inicial de uma CME, ocorrida em 25 de outubro de 2001.



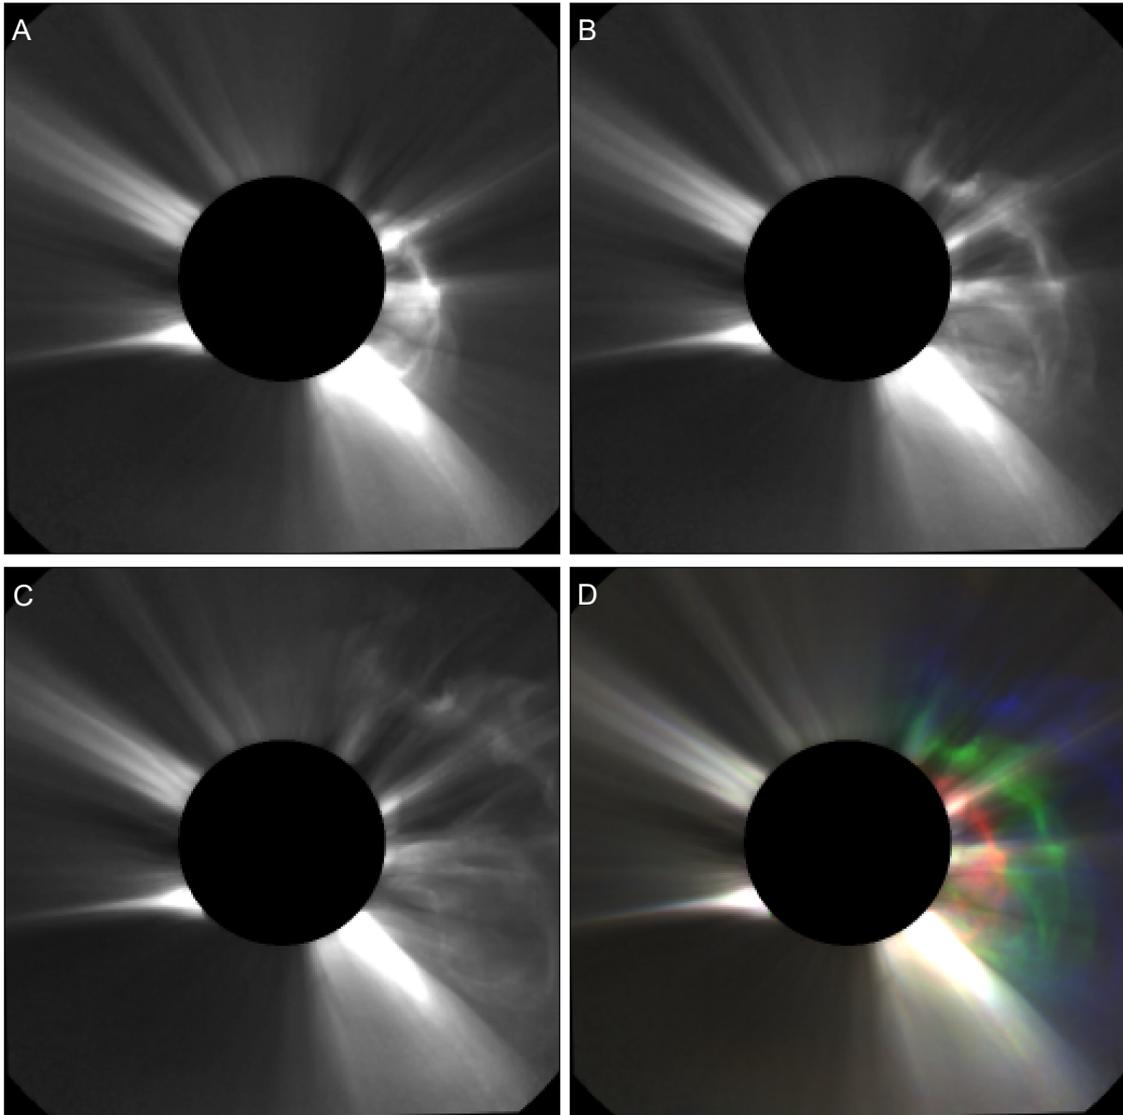
Evolução temporal da CME utilizada como entrada para a metodologia de previsão, observada às 15h26 UT do dia 25 de outubro de 2001. Os painéis A, B e C indicam a propagação inicial da CME em cada passagem do tempo, na respectiva ordem cronológica e representando a passagem do tempo até 1 hora após a primeira aparição da estrutura no campo de visão do LASCO C2. Enquanto que o painel D é uma composição, utilizando o padrão de cores RGB, que representa o padrão de entrada para as redes neurais treinadas.

Figura 4.14 - Exemplo da propagação inicial de uma CME, ocorrida em 25 de outubro de 2013.



CME utilizada como entrada para a metodologia de previsão, observada às 15h12 UT do dia 25 de outubro de 2013. Os painéis A, B e C indicam a propagação inicial da CME em cada passagem do tempo, na respectiva ordem cronológica, representando a passagem do tempo até 1 hora após a primeira aparição da estrutura no campo de visão do LASCO C2. O painel D é uma composição, utilizando o padrão de cores RGB, que representa o padrão de entrada para as redes neurais treinadas.

Figura 4.15 - Exemplo da propagação inicial de uma CME, ocorrida em 15 de março de 2015.



Exemplo de uma CME utilizada como entrada para a metodologia de previsão, observada às 01h48 UT do dia 15 de março de 2015. Os painéis A, B e C indicam a propagação inicial da CME em cada passagem do tempo, na respectiva ordem cronológica, representando a passagem do tempo até 1 hora após a primeira aparição da estrutura no campo de visão do LASCO C2. O painel D é uma composição, utilizando o padrão de cores RGB, que representa o padrão de entrada para as redes neurais treinadas.

4.5 Arquitetura das redes

A arquitetura de uma rede neural faz referência a todas as suas características de forma geral, abordando desde a sua profundidade, isto é, a quantidade de camadas ocultas, até elementos e módulos que visam aumentar sua eficiência de alguma maneira.

Na área de IA, os hiperparâmetros são utilizados para identificar parâmetros, variáveis, métodos, algoritmos, taxas e valores que determinam a arquitetura da rede e suas características (NIELSEN, 2015). Durante o treinamento de redes neurais, a escolha dos hiperparâmetros estabelece e ajusta a eficácia da rede neural. Desta forma, a escolha de valores ideais visa obter uma menor taxa de erro para o treinamento e uma melhor capacidade de generalização da arquitetura com novos conjuntos de dados.

4.5.1 Transferência de aprendizado

Utilizando-se os gráficos das séries temporais e as imagens dos coronógrafos como entradas das arquiteturas, as CNNs desenvolvidas extraem, por meio de filtros não lineares, padrões de informação que alimentam os classificadores que determinam a probabilidade da amostra pertencer a cada classe. As arquiteturas testadas nessa pesquisa utilizaram como base arquiteturas convolucionais profundas para extrair características espaciais e diminuir o espaço de atributos do conjunto de dados.

4.5.2 Treinamento das redes

4.5.2.1 Detecção das estruturas

Os novos parâmetros extraídos pelas camadas convolucionais são utilizados como entradas para as camadas perceptrons. A última camada de todas as arquiteturas é dotada da função de ativação *softmax*, permitindo o cálculo da distribuição de probabilidade para cada neurônio na camada de saída. Essa distribuição representa a chance da amostra pertencer à classe determinada pelo neurônio. Nesse contexto, a classe com o maior valor é determinada como a saída do modelo. Para corrigir o erro gerado, utilizou-se a função de custo CCE (Equação 3.10), uma vez que essa abordagem envolve 3 classes.

A fim de determinar a melhor arquitetura de rede, utilizou-se a biblioteca *Optuna* para otimização dos hiperparâmetros dos classificadores MLP. A otimização automatizada dos hiperparâmetros, realizada pelo *framework Optuna*, permitiu que diversas variações de arquiteturas fossem treinadas, cada uma com diferentes números de camadas, quantidade de neurônios, função de ativação nas camadas ocultas, taxa de regularização e de aprendizagem. Esse processo visou determinar a melhor arquitetura para cada mapa de atributo, extraídos pelas redes pré-treinadas, em cada padrão de tempo observado.

4.5.2.2 Previsão do tempo de chegada

Antes de realizar o processo de treinamento das redes para a abordagem de previsão das estruturas, foi necessário padronizar as saídas das amostras, de forma a favorecer o desempenho das redes neurais diminuindo a necessidade de convergência do gradiente para a adaptação dos pesos. As saídas das amostras para previsão do tempo de chegada foram padronizadas, removendo o valor médio do parâmetro e escalando o desvio padrão no valor 1, com a finalidade de facilitar e agilizar o treinamento, garantindo que as variáveis fiquem na mesma ordem de grandeza e que características diferentes se tornem escaladas e sejam tratadas de forma semelhante, além de diminuir o espaço de atributos. O cálculo da padronização é determinado por:

$$z = \frac{x_i - u}{\sigma} \quad \text{para } i = 1, 2, \dots, N, \quad (4.1)$$

onde u e σ são, respectivamente, a média e o desvio padrão do conjunto z , e N é o tamanho do conjunto.

Para a correção do erro gerado, foi utilizada a função de custo MSE, conforme a Equação 3.7. Uma vez que, em relação a MAE, demonstrada na Equação 3.8, essa função aplica uma maior correção em relação a erros mais altos.

As arquiteturas desenvolvidas para resolver a previsão do tempo de chegada utilizaram um único neurônio na camada de saída, que possui a função de ativação linear para regressão do tempo de chegada, em horas.

Conforme identificado por Wang et al. (2019), Feng e Ye (2021), as características das CMEs apresentam espaçamentos relativamente amplos entre si, permitindo a aplicação de filtros maiores. Ao contrário do convencional, onde é empregado filtros de tamanho 3 ou 5 *pixels*², nas camadas convolucionais ocultas foram utilizados filtros de tamanhos que variavam de 9 a 13 *pixels*². Além disso, foram incorporados módulos *Inception*, que empregam filtros assimétricos, visando a redução de parâmetros e do custo computacional (SZEGEDY et al., 2015), e a introdução do aprendizado residual entre algumas camadas. Desta forma, viabilizou-se o desenvolvimento de arquiteturas convolucionais específicas para a previsão do tempo de chegada das estruturas observadas.

4.5.2.3 Métricas de avaliação

Em relação à tarefa de classificação, foram avaliadas as redes com base em métricas de verdadeiro/falso positivos e negativos, ou seja, métricas extraídas a partir de uma matriz de confusão, como é representada na Tabela 4.1.

Tabela 4.1 - Exemplo de uma matriz de confusão.

Saída esperada	Saída obtida	
	Classe positiva	Classe negativa
Classe positiva	Verdadeiro Positivo (VP)	Falso Negativo (FN)
Classe negativa	Falso Positivo (FP)	Verdadeiro Negativo (VN)

A primeira coluna identifica a saída esperada: classe positiva e negativa, enquanto que a segunda coluna identifica qual foi a saída obtida a partir da aplicação da rede, resultando nos verdadeiros/falsos positivos e negativos.

Entre as classificações de choques, as redes treinadas são capazes de identificar os choques do tipo frontal rápido e reverso rápido, além de identificar quando não há a passagem de uma onda de choque pelo satélite, nomeadas respectivamente de: *FF*, *FR* e *Neg*. O problema foi considerado para ter 2 classes positivas e uma negativa, permitindo uma adaptação de algumas métricas que consideram a capacidade de identificar as amostras corretas das classes positivas. Para a avaliação das arquiteturas, foram utilizadas métricas de avaliação como Macro Sensibilidade, Taxa de Detecção, Taxa de Alarmes Falsos e uma adaptação da *True Skill Statistic* (TSS).

Dentre as aplicações das métricas escolhidas, pode-se discutir sobre suas funcionalidades, permitindo a escolha das melhores redes com base no problema de detecção de um evento extremo, como aplicado nesta pesquisa. As métricas relacionadas à taxa de detecção e à taxa de falsos alarmes representam, respectivamente, a taxa de acerto entre as amostras positivas, ou seja, as amostras com onda de choque, e a porcentagem de amostras com falsos alarmes, ou seja, amostras negativas classificadas como positivas.

A aplicação dos valores macro representa os valores médios das métricas para todas as classes. Portanto, tem-se *Macro Recall* como taxa de acerto médio entre todas as classes. A métrica TSS leva em conta erros de omissão e de comissão, ou seja, amostras de uma determinada classe identificadas erroneamente. Neste estudo, a

métrica TSS adaptada conta as amostras mal-classificadas entre as classes positivas e a classe negativa.

As métricas utilizadas para avaliação das arquiteturas, desenvolvidas no presente trabalho para detecção das ondas de choque interplanetárias, são mostradas na Tabela 4.2, juntamente com suas equações, definindo, assim, como são obtidos os valores para escolha das melhores redes neurais para cada padrão de tempo.

Tabela 4.2 - Métricas de avaliação da arquitetura das redes.

Métrica	Abreviatura	Fórmula
Sensibilidade	S	$\frac{VP}{VP + FN}$
Macro Sensibilidade	-	$\frac{S_{Neg} + S_{FF} + S_{FR}}{3}$
Taxa de detecção	TD	$\frac{S_{FF} + S_{FR}}{2}$
Taxa de alarmes Falsos	TAF	$1 - S_{Neg}$
True Skill Statistic	TSS	$TD - TAF$

Além dessas métricas, foi utilizado também o MAE para identificar a taxa de erro, em horas, na previsão do tempo de chegada das estruturas. Adicionalmente, a taxa de acurácia identifica quantas amostras têm um erro menor que o valor médio obtido.

5 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados, de forma geral, os resultados obtidos em cada etapa do desenvolvimento da presente pesquisa. Os resultados são fruto do treinamento das redes neurais para detectar as ondas de choque que atingiram o ambiente próximo à Terra. Foram empregados os padrões de tempo observados, conforme descrito anteriormente, a partir dos atributos extraídos pelas redes VGG16, VGG19, Painters, Inception-V3 e SqueezeNet para identificar a passagem da onda de choque interplanetária.

Por outro lado, para a previsão do tempo de chegada de estruturas magnéticas em distâncias de 1 AU, foram utilizadas redes pré-treinadas como a ResNet50-V2 e a Inception-V3. Adicionalmente, outras arquiteturas de redes convolucionais foram elaboradas e treinadas, a fim de conseguir a arquitetura ideal para a tarefa de previsão do tempo de chegada dos choques até as proximidades da Terra.

Os resultados foram obtidos utilizando-se a plataforma online *Kaggle*, que disponibiliza acesso remoto a um ambiente com as seguintes especificações:

Processador: Intel(R) Xeon(R) CPU @ 2.00GHz;

Memória RAM de 29 GB; e

Placa de vídeo (GPU): Tesla P100-PCIE-16GB.

5.1 Resultados da detecção das ondas de choque interplanetárias

Nesta seção, descreve-se o comportamento geral dos resultados a partir do balanceamento do conjunto de dados e da otimização dos hiperparâmetros das arquiteturas a partir do *Framework Optuna* para as redes que buscam detectar e caracterizar a passagem das ondas de choque pelos satélites.

5.1.1 Balanceamento e ajuste dos hiperparâmetros

Uma parte essencial para obtenção de resultados adequados durante o desenvolvimento de redes neurais é o ajuste de diversos fatores que podem contribuir positivamente no treinamento da rede. Isso inclui o balanceamento do conjunto de dados, a aplicação de técnicas para pré-processamento dos dados e a otimização dos hiperparâmetros das arquiteturas.

Foi utilizado o algoritmo ENN com uma vizinhança dos 3 vizinhos mais próximos

repetindo-se o processo por duas vezes, no total, para obtenção de um novo conjunto para o treinamento. Dessa forma, foram removidas algumas amostras negativas, mantendo todas as amostras positivas pertencentes às classes *FF* e *FR*.

Utilizando-se o *framework* *Optuna*, houve o treinamento de diversas arquiteturas, realizando automaticamente a busca dos hiperparâmetros. Foram feitas variações dos parâmetros em torno de:

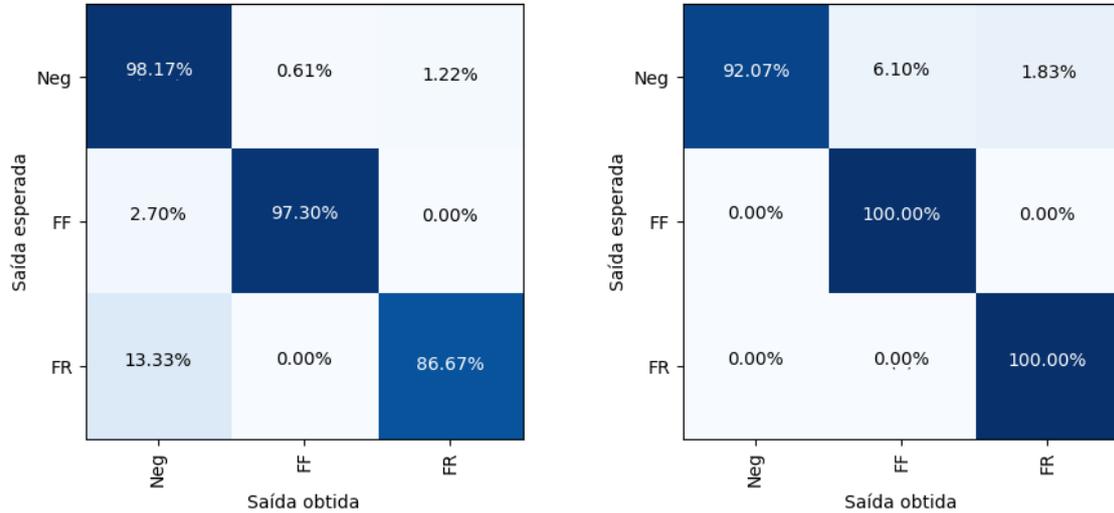
- a) **Número de camadas ocultas:** entre 1 e 5;
- b) **Quantidade de neurônios para cada camada oculta:** entre 4 e 128;
- c) **Função de ativação:** ReLU, sigmóide ou tangente hiperbólica, igual para todas as camadas ocultas;
- d) **Taxa de regularização:** entre 10^{-5} e 10^{-1} , igual para todas as camadas;
- e) **Taxa de aprendizagem:** entre 10^{-5} e 10^{-1} .

Cada arquitetura gerada foi treinada durante 500 épocas e a melhor rede foi selecionada automaticamente a partir da adaptação da métrica TSS. A Figura 5.1 identifica, de forma aproximada, a taxa de acerto para cada classe de choque interplanetário, antes e após o ajuste dos atributos associados às arquiteturas e ao conjunto de dados.

Após o balanceamento do subconjunto de treinamento, uma pequena melhora foi observada na capacidade da rede em detectar amostras positivas, principalmente de amostras de ondas de choque do tipo reversas rápidas, apesar do aumento na taxa de alarmes falsos. Torna-se preferível a identificação e detecção da ocorrência desses eventos devido às possíveis consequências de não identificar ou sinalizar um evento a tempo. A detecção de eventos solares é crucial para proteger efetivamente a vida de astronautas em órbita, minimizar falhas ou perdas de satélites e reduzir outros danos potenciais.

Juntamente com este resultado, a otimização das arquiteturas gerada pelo *Optuna* foi capaz de identificar, automaticamente, a melhor rede neural, buscando uma taxa de acerto maior entre as classes, mas, principalmente, entre as amostras positivas.

Figura 5.1 - Comparação dos resultados a partir do balanceamento e ajuste dos hiperparâmetros.

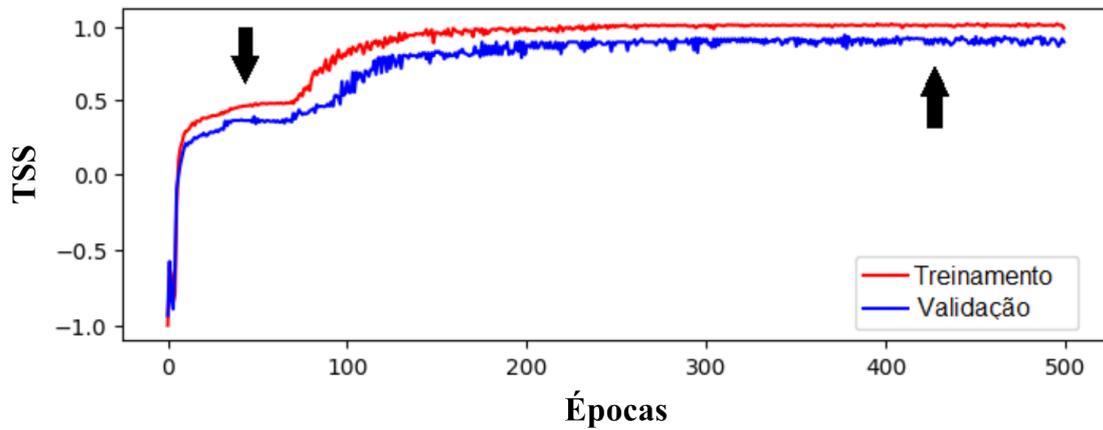


Os painéis apresentados são os resultados obtidos a partir do conjunto de validação. À esquerda, a matriz de confusão é obtida antes da aplicação de técnicas para balanceamento e ajuste dos hiperparâmetros, enquanto que, à direita, observa-se a matriz de confusão obtida com as melhorias realizadas nos processos.

5.1.2 Resultados obtidos durante o treinamento

Durante o treinamento de uma rede neural, os pesos sinápticos são alterados, buscando-se sempre a diminuição do valor de custo, ou seja, do erro gerado. Em diferentes fases do treinamento, é possível observar seu comportamento a partir de diferentes métricas.

Figura 5.2 - Histórico de treinamento da rede com 2 horas de dados utilizando o mapa de atributos extraído pela rede pré-treinada Painters.



Comportamento observado durante o treinamento utilizando-se a adaptação da métrica TSS. A linha azul indica os resultados obtidos pelo subconjunto de validação, enquanto que a linha vermelha mostra o resultado para o subconjunto de treinamento. As setas indicam diferentes momentos: a da esquerda sinaliza quando a rede atingiu um mínimo local, ao passo que a seta à direita, nas últimas épocas de treinamento, identifica os melhores resultados que a rede conseguiu gerar.

O comportamento mostrado na Figura 5.2 indica que, no início do treinamento, a rede adaptou os pesos para diminuir, majoritariamente, o erro para a classe Negativa e FF. Depois disso, conseguiu uma melhora para a classe FR, ao mesmo tempo que corrigia a taxa de acerto FF, mediante um pequeno aumento da taxa de alarmes falsos, conforme indicado na Tabela 5.1.

Tabela 5.1 - Resultados da avaliação do conjunto de validação de uma das redes treinadas considerando diferentes estágios do treinamento.

Época observada	Métricas			
	TD	TAF	Macro Sensibilidade	TSS
25	39,19	13,41	54,99	25,78
75	49,32	4,88	64,59	44,44
225	86,66	10,37	87,65	76,29
500	98,65	11,59	95,23	87,06

Ao se trabalhar com problemas de otimização, como é feito pelo algoritmo de gradi-

ente descendente para minimização da função de custo em redes neurais, depara-se com questões como identificar os diferentes momentos gerados pelo treinamento otimizador. Esses momentos denominados de mínimos e máximos locais e globais identificam diferentes situações em relação à função de custo utilizada. No caso do mínimo local, como apontado na Figura 5.2, é um momento onde a função de custo obteve um valor mínimo em relação com os valores otimizados dos pesos das sinapses da rede neural. Por outro lado, o mínimo global representa o valor mais baixo que a função de custo pode atingir para todas as configurações possíveis dos pesos sinápticos. No entanto, alcançar o mínimo global é um desafio significativo, exigindo um grande número de reinicializações dos pesos, que são inicialmente aleatórios, e um alto número de épocas de treinamento. Isso se deve ao processo de otimização, que busca a direção dos valores mínimos em relação à configuração atual dos pesos das sinapses da rede neural. É importante notar que mesmo que a otimização gerada pelo algoritmo de gradiente descendente encontre um mínimo local, não há garantia de que o mesmo seja o mínimo global, ou seja, a configuração de pesos que resulta no menor valor possível para a função de custo. Esse mesmo comportamento pode ser descrito de forma geral, para todas as redes treinadas, havendo pequenas variações nas métricas de avaliação. Ou seja, independente da arquitetura ou das entradas, as redes neurais obtiveram resultados semelhantes ao longo do treinamento.

5.1.3 Generalização

Após selecionar as melhores arquiteturas para cada padrão de tempo e rede pré-treinada utilizando o *framework Optuna*, as redes foram avaliadas com um novo conjunto de dados contendo amostras que não foram previamente apresentadas durante o treinamento.

A fim de avaliar a capacidade de generalização das redes, foram utilizadas amostras obtidas através das medições feitas pelo satélite ACE. O novo conjunto de amostras foi utilizado como um conjunto de teste. A partir das métricas descritas anteriormente, foram selecionadas as melhores redes, desenvolvidas nesta pesquisa, para cada padrão de tempo observado.

O conjunto de teste contém amostras de ondas de choque interplanetárias que ocorreram durante o SC 23. Todas as novas amostras passaram pelo mesmo processamento para coleta das séries temporais, sendo transformadas em gráficos contendo o mesmo padrão de escala, tamanho e ordem dos parâmetros que as amostras de treinamento e validação. A etapa de generalização consiste em interpretar novas entradas e comparar as saídas obtidas com as esperadas, utilizando as métricas de avaliação, mas

sem treinar a rede, ou seja, sem alterar os valores dos pesos.

Cada padrão de tempo observado refere-se ao total de tempo utilizado para detecção da estrutura, englobando os valores *upstream* e *downstream* da perturbação gerada pela passagem da onda de choque interplanetária. Alguns resultados são mostrados na Tabela 5.2, onde são identificadas as métricas da melhor arquitetura gerada para cada padrão de tempo.

Tabela 5.2 - Avaliação da abordagem de aprendizado de máquina para o conjunto de teste em cada padrão de tempo observado.

Tempo observado	Rede pré-treinada	Métricas			
		Macro Sensibilidade	Taxa de Detecção	Taxa de alarmes falsos	TSS
2 horas	Painters	0,93	0,95	0,12	0,83
1 hora	VGG16	0,93	0,91	0,03	0,88
30 minutos	VGG19	0,93	0,90	0,02	0,88
20 minutos	Inception	0,93	0,91	0,04	0,87

Com a abordagem apresentada, foi possível realizar a detecção de estruturas com uma taxa de detecção aproximada de 91% e apenas 5% de alarmes falsos, enquanto que, como identificado em Cash et al. (2014), as técnicas tradicionais obtiveram uma taxa de detecção média de $53\% \pm 12\%$ e uma taxa de alarmes falsos de $73\% \pm 16\%$.

A Tabela 5.3 apresenta a comparação das métricas utilizadas entre os modelos desenvolvidos e o uso de técnicas tradicionais para a detecção e classificação das ondas de choque a partir do conjunto de dados de choques IP do satélite ACE durante o SC 23.

Tabela 5.3 - Comparação dos resultados utilizando eventos catalogados pelo satélite ACE durante o SC 23.

Quantidade de dados	Modelo	Taxa de Detecção	Taxa de Alarmes Falsos
10 minutos	Cash et al. (2014)	0,56	0,65
10 minutos	Kruparova et al. (2013)	0,64	0,92
20 minutos	Vorotnikov et al. (2008)	0,60	0,88
20 minutos	* Inception V3	0,91	0,04
30 minutos	* VGG19	0,90	0,02
1 hora	* VGG16	0,91	0,03
2 horas	* Painters	0,95	0,12

A primeira coluna identifica a janela de observação em torno do choque utilizada em cada caso, enquanto que a segunda coluna referencia as técnicas tradicionais, ao mesmo tempo que identifica qual rede neural pré-treinada foi escolhida para cada padrão de tempo observado utilizado nesta pesquisa. As linhas com * identificam quais itens foram desenvolvidos aqui. As duas últimas colunas realizam a comparação da taxa de detecção e da taxa de alarmes falsos, respectivamente, entres as técnicas tradicionais e os resultados obtidos nesta pesquisa.

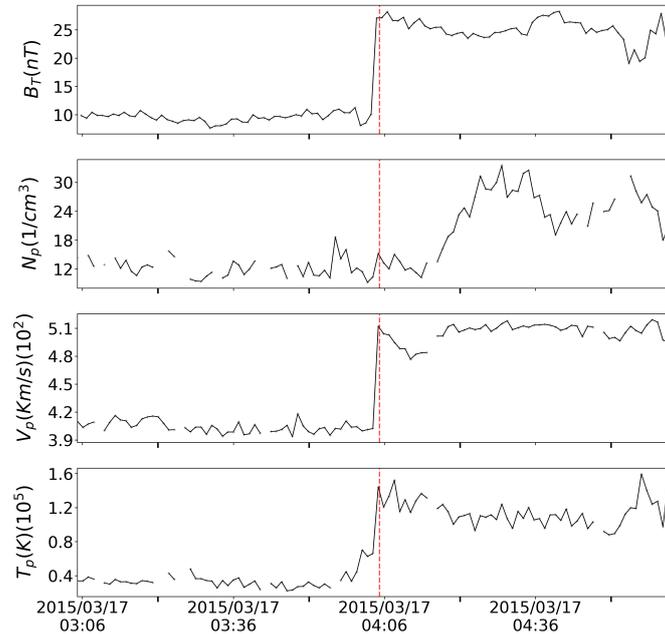
5.1.4 Estudos de caso

5.1.4.1 Evento de 17 de março de 2015 ou evento de São Patrício

No dia 17 de março de 2015, uma onda de choque frontal rápida foi detectada pelos sensores do satélite ACE, às 04:05 UT. Além do choque IP, a região da bainha magnética, atrás do choque, e a nuvem magnética foram as responsáveis por causar a primeira tempestade geomagnética do SC 24, nomeada como *St. Patrick's Day storm*, ou tempestade de São Patrício (WU et al., 2016; RAWAT et al., 2018).

Na Figura 5.3, é possível observar o comportamento da estrutura, com um aumento considerável nos parâmetros de plasma e campo magnético. Há um salto na velocidade, indo de 400 para 510 km/s , além da temperatura, que oscila de $6,0 \times 10^4$ para $1,5 \times 10^5$ K, complementada pelo aumento na intensidade do campo magnético interplanetário de 11 para 28 nT e um aumento inicial no parâmetro da densidade de prótons do vento solar, saindo de 10 para $15/cm^3$, no exato momento em que a estrutura atravessa os sensores. Porém, é possível notar a existência de um atraso na informação para a densidade, que atingiu um máximo de $32/cm^3$.

Figura 5.3 - Onda de choque interplanetária frontal rápida, detectada pelo satélite ACE, às 04:05 UT do dia 17 de março de 2015.



Amostra de um evento frontal rápido, gerada para entrada da rede de detecção, com total de 2 horas de dados observados. Os painéis, dispostos de cima para baixo, representam os parâmetros da magnitude do campo magnético interplanetário ($B[nT]$), densidade dos prótons ($N_p[1/cm^3]$), velocidade do vento solar ($V[km/s]$), em escala de 10^2 , e temperatura dos prótons ($T_p[^\circ K]$), em escala de 10^5 . A linha vertical tracejada indica o momento em que a onda de choque interplanetária atingiu o satélite.

As técnicas tradicionais citadas anteriormente apresentam, em sua maioria, uma classificação binária, identificando apenas amostras do tipo FF. A Tabela 5.4 realiza a comparação entre os resultados obtidos pelas técnicas tradicionais e os resultados obtidos pela nova abordagem.

Tabela 5.4 - Modelos e saídas obtidas para o evento ocorrido no dia 17 de março de 2015.

Tempo observado	Modelo	Saída obtida		
		FF	FR	Neg
10 minutos	Cash et al. (2014)	1	-	0
10 minutos	Kruparova et al. (2013)	1	-	0
20 minutos	Vorotnikov et al. (2008)	0	-	1
17 minutos	Lumme et al. (2019)	0	0	1
20 minutos	* Inception V3	70,4%	23,2%	6,4%
30 minutos	* VGG19	92,8%	6,9%	0,3%
1 hora	* VGG16	99,9%	<0,1%	<0,1%
2 horas	* Painters	99,7%	0,2%	0,1%

A primeira coluna identifica a janela de tempo utilizado em cada caso, enquanto que a segunda referencia os modelos e técnicas tradicionais ao mesmo tempo que identifica qual rede neural pré-treinada foi escolhida para cada padrão de tempo observado utilizado nesta pesquisa. As linhas com * identificam quais itens foram desenvolvidos no trabalho. As três últimas colunas exibem os resultados obtidos para cada saída dos modelos para essa amostra. O símbolo - identifica saídas inexistentes em determinados modelos.

Para este evento específico, foi possível identificar corretamente a onda de choque interplanetária com uma certeza média de $90,7\% \pm 14,47\%$, através da abordagem desenvolvida, com uma leve incerteza para a rede neural que utiliza 20 minutos de dados. Isso indica uma alta taxa de assertividade em comparação às técnicas tradicionais que foram utilizadas nos trabalhos listados na Tabela 5.4.

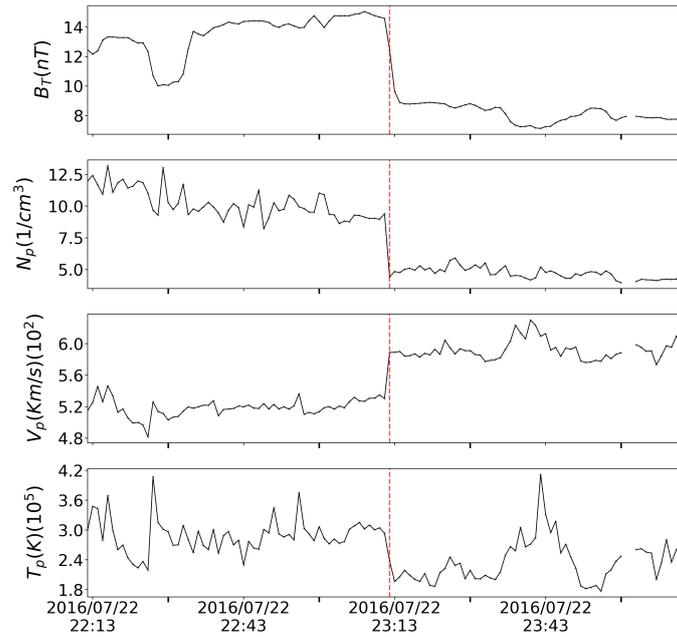
5.1.4.2 Evento de 22 de julho de 2016

No dia 22 de julho de 2016, uma onda de choque interplanetária do tipo reversa rápida pode ser observada pelas perturbações, no vento solar e no campo magnético interplanetário, captadas pelos sensores do satélite STEREO-A, às 23:12 UT. As perturbações geradas pelo choque IP podem ser visualizadas na Figura 5.4, onde os parâmetros do vento solar variaram de 530 para 589 km/s para a velocidade dos prótons, de 9,4 para 4,8/cm³ para a densidade de prótons do plasma solar. Ao mesmo tempo, a temperatura dos prótons e a magnitude do campo magnético interplanetário caíram de $2,93 \times 10^5$ para $1,96 \times 10^5$ K e de 14,6 para 9,7 nT, respectivamente.

Neste caso, por se tratar de uma onda de choque interplanetária do tipo reversa rápida, algumas das técnicas tradicionais não puderam ser aplicadas para sua detecção, por apenas identificarem eventos do tipo frontal rápida. A Tabela 5.5, por

esta razão, apresenta a comparação dos resultados obtidos através da abordagem desenvolvida no presente trabalho. Foi utilizando um único algoritmo tradicional apresentado em Lumme et al. (2019), capaz de identificar e classificar ondas de choque do tipo FR.

Figura 5.4 - Onda de choque interplanetária reversa rápida, detectada pelo satélite STEREO-A, às 23:12 UT do dia 22 de julho de 2016.



Exemplo de um evento reverso rápido com dados *in-situ* do satélite STEREO-A, às 23h12 UT do dia 22 de julho de 2016, gerada para entrada da rede de detecção, com total de 2 horas de dados observados. Os painéis, dispostos de cima para baixo, representam os parâmetros da magnitude do campo magnético interplanetário ($B[nT]$), densidade dos prótons ($N_p[1/cm^3]$), velocidade do vento solar ($V[km/s]$), em escala de 10^2 , e temperatura dos prótons ($T_p[^\circ K]$), em escala de 10^5 .

Tabela 5.5 - Modelos utilizados e saídas obtidas para o evento ocorrido no dia 22 de julho de 2016.

Tempo observado	Modelo	Saída obtida		
		FF	FR	Neg
17 minutos	Lumme et al. (2019)	0	1	0
20 minutos	* Inception V3	0,4%	99,3%	0,3%
30 minutos	* VGG19	0,9%	99,0%	0,1%
1 hora	* VGG16	2,9%	97,0%	0,1%
2 horas	* Painters	5,8%	83,0%	11,2%

A primeira coluna identifica o padrão total de tempo utilizado em cada caso, enquanto que a segunda referencia os modelos e as técnicas tradicionais ao mesmo tempo que identifica qual rede neural pré-treinada foi escolhida para cada padrão de tempo observado utilizado nesta pesquisa. As linhas com * identificam quais itens foram desenvolvidos aqui. As três últimas colunas exibem os resultados obtidos para cada saída dos modelos para essa amostra.

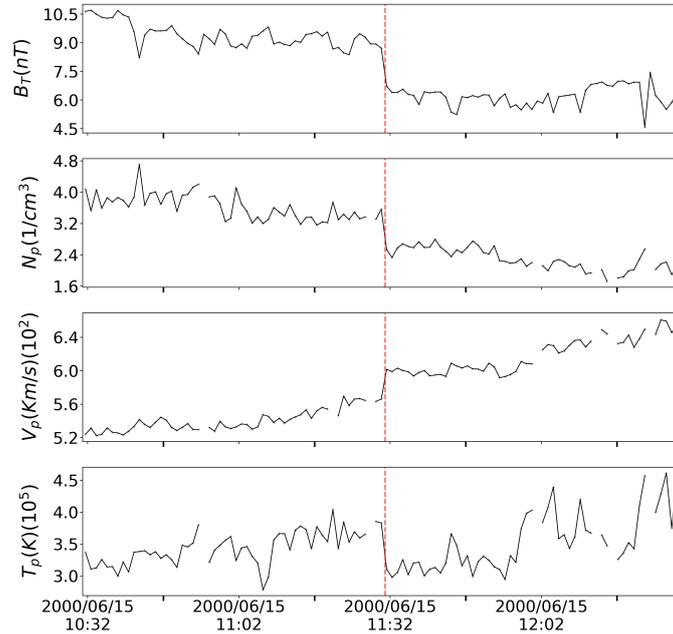
Para esse estudo de caso, foi possível identificar corretamente a onda de choque interplanetária com uma certeza média de $94\% \pm 7,15\%$, pela abordagem desenvolvida. Indicando, novamente, uma capacidade na identificação e classificação das estruturas observadas.

5.1.4.3 Evento de 15 de junho de 2000

No dia 15 de junho de 2000, uma onda de choque interplanetária do tipo reversa rápida pode ser observada pelas perturbações, no vento solar e no campo magnético interplanetário, captadas pelos sensores do satélite ACE, às 11:31 UT. As perturbações geradas pelo choque IP podem ser visualizadas na Figura 5.5, onde os parâmetros do vento solar variaram de 560 para 600 km/s para a velocidade dos prótons, de 3,4 para 2,6/cm³ para a densidade de prótons do plasma solar. Ao mesmo tempo, a temperatura dos prótons e a magnitude do campo magnético interplanetário caíram de $3,7 \times 10^5$ para $3,15 \times 10^5$ K e de 9,0 para 6,3 nT, respectivamente.

Assim, como no caso de estudo anterior, por se tratar de uma onda de choque interplanetária do tipo reversa rápida, algumas das técnicas tradicionais não puderam ser aplicadas para sua detecção, por apenas identificarem eventos do tipo frontal rápida. A Tabela 5.6, por esta razão, apresenta a comparação dos resultados obtidos através da abordagem desenvolvida no presente trabalho, apenas com um único algoritmo tradicional, sendo o apresentado em Lumme et al. (2019), capaz de identificar e classificar ondas de choque do tipo FR.

Figura 5.5 - Onda de choque interplanetária reversa rápida, detectada pelo satélite ACE, às 11:31 UT do dia 15 de junho de 2000.



Exemplo de um evento reverso rápido com dados *in-situ* do satélite ACE, às 11h31 UT do dia 15 de junho de 2000, gerada para entrada da rede de detecção, com total de 2 horas de dados observados. Os painéis, dispostos de cima para baixo, representam os parâmetros da magnitude do campo magnético interplanetário ($B[nT]$), densidade dos prótons ($N_p[1/cm^3]$), velocidade do vento solar ($V[km/s]$), em escala de 10^2 , e temperatura dos prótons ($T_p[^\circ K]$), em escala de 10^5 .

Tabela 5.6 - Modelos utilizados e saídas obtidas para o evento ocorrido no dia 15 de junho de 2000.

Tempo observado	Modelo	Saída obtida		
		FF	FR	Neg
17 minutos	Lumme et al. (2019)	0	1	0
20 minutos	* Inception V3	0,3%	99,3%	0,4%
30 minutos	* VGG19	4,9%	49,4%	45,7%
1 hora	* VGG16	0,2%	0,1%	99,7%
2 horas	* Painters	21,8%	24,7%	53,5%

A primeira coluna identifica o padrão total de tempo utilizado em cada caso, enquanto que a segunda referencia os modelos e técnicas tradicionais, ao mesmo tempo que identifica qual rede neural pré-treinada foi escolhida para cada padrão de tempo observado utilizado nesta pesquisa. As linhas com * identificam quais itens foram desenvolvidos no presente trabalho. As três últimas colunas exibem os resultados obtidos para cada saída dos modelos para essa amostra.

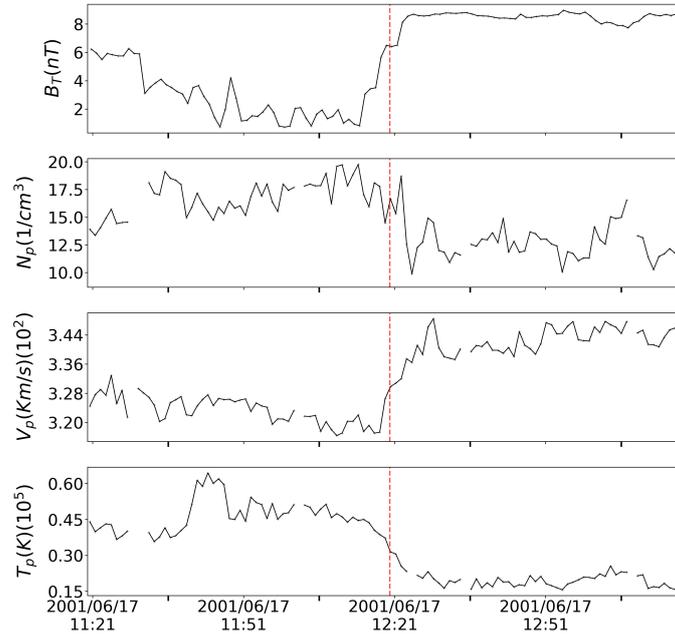
Neste estudo de caso, as redes neurais artificiais que recebem uma maior quantidade de dados apresentam uma deficiência na assertividade, classificando o evento como uma amostra negativa, ou seja, sem a presença de uma onda de choque. De forma geral, recebendo uma certeza média de apenas 43,37% de que a amostra é uma estrutura do tipo reversa rápida. As redes neurais que observam um período de tempo maior, possivelmente, tiveram suas saídas afetadas pelo parâmetro da temperatura do vento solar, que retornou a um estado de perturbação semelhante ao anterior à passagem da onda de choque pelo satélite.

5.1.4.4 Evento de 17 de junho de 2001

No dia 17 de junho de 2001, uma onda de choque interplanetária do tipo reversa lenta foi observada pelas perturbações, no vento solar e no campo magnético interplanetário, captadas pelos sensores do satélite ACE, às 12:20 UT. As perturbações geradas pelo choque IP podem ser visualizadas na Figura 5.6, onde os parâmetros referentes à velocidade do vento solar e o campo magnético interplanetário aumentaram de 320 para 339 km/s e de 2,35 para 8,3 nT, respectivamente. Enquanto que, a temperatura dos prótons e a densidade do plasma do vento solar diminuíram de $0,43 \times 10^5$ para $0,22 \times 10^5$ K e de 17,5 para 13,7/cm³, respectivamente.

Neste exemplo, por se tratar de uma amostra do tipo SR, ao qual nenhuma das arquiteturas de redes neurais ou das técnicas tradicionais, foi treinada para classificar, serão levadas em conta apenas as saídas das redes neurais, de forma a observar os padrões de saídas obtidos. A Tabela 5.7, por esta razão, apresenta apenas a comparação dos resultados obtidos através da abordagem desenvolvida no presente trabalho.

Figura 5.6 - Onda de choque interplanetária reversa lenta, detectada pelo satélite ACE, às 12:20 UT do dia 17 de junho de 2001.



Exemplo de um evento reverso lento com dados *in-situ* do satélite ACE, às 12h20 UT do dia 17 de junho de 2001, gerada para entrada da rede de detecção, com total de 2 horas de dados observados. Os painéis, dispostos de cima para baixo, representam os parâmetros da magnitude do campo magnético interplanetário ($B[nT]$), densidade dos prótons ($N_p[1/cm^3]$), velocidade do vento solar ($V[km/s]$), em escala de 10^2 , e temperatura dos prótons ($T_p[^\circ K]$), em escala de 10^5 .

Apesar de as redes neurais não terem sido treinadas para identificar ondas de choque interplanetárias do tipo SR, neste estudo de caso, foi possível observar que as respostas obtidas pelas arquiteturas foram expressivamente classificadas como reversas rápidas. A assertividade média de 95,7% indica que a amostra pertence à classe de ondas de choque interplanetária reversas rápidas, provavelmente devido à propriedade relacionada à queda brusca nos parâmetros do plasma solar, densidade e temperatura, juntamente com o aumento observado para a velocidade do vento solar, característica comum a todos os tipos de onda de choque interplanetária.

Tabela 5.7 - Modelos utilizados e saídas obtidas para o evento ocorrido no dia 22 de julho de 2016.

Tempo observado	Modelo	Saída obtida		
		FF	FR	Neg
20 minutos	* Inception V3	0,3%	99,3%	0,4%
30 minutos	* VGG19	1,3%	97,1%	1,6%
1 hora	* VGG16	0,3%	99,6%	0,1%
2 horas	* Painters	7,1%	86,9%	6,0%

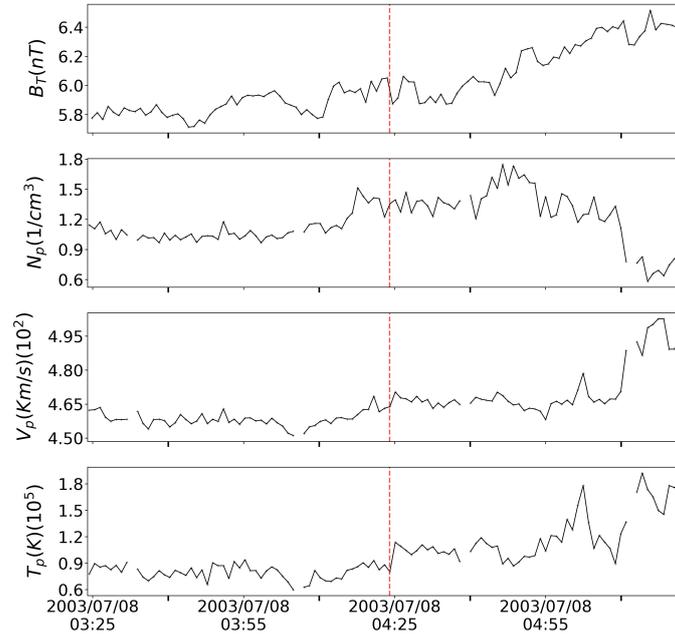
A primeira coluna identifica a janela de tempo utilizada em cada caso, enquanto que a segunda coluna identifica qual rede neural pré-treinada foi escolhida para cada padrão de tempo observado utilizado nesta pesquisa. As três últimas colunas exibem os resultados obtidos para cada saída dos modelos para essa amostra.

5.1.4.5 Caso de estudo para o dia 08 de julho de 2003

No dia 08 de julho de 2003, entre às 03h24 e 05h24 UT, conforme observado na Figura 5.7, nenhum tipo de perturbação identifica a passagem de uma onda de choque interplanetária a partir dos dados, *in-situ*, dos sensores do satélite ACE. As séries temporais entre o período considerado podem ser visualizadas na Figura 5.7 onde, contudo, para essa amostra de estudo de caso, é possível observar uma perturbação nos parâmetros, havendo uma queda na densidade de prótons do vento solar, e um aumento para a velocidade do vento solar, temperatura do plasma solar e para a magnitude do campo magnético interplanetário.

Pode-se visualizar, por meio da Tabela 5.8, que realiza a comparação entre os resultados obtidos pelas técnicas tradicionais e os resultados obtidos pela nossa abordagem, uma acurácia de 99,9% para as arquiteturas que utilizam até 1 hora de dados. No entanto, foi identificado um alarme falso para a rede neural que utiliza 2 horas de dados das séries temporais, ocorrido provavelmente pela presença de uma perturbação, que pode ser visualizada no canto esquerdo dos painéis. Essa perturbação resultou em um aumento nos parâmetros referentes à magnitude do IMF, velocidade do vento solar e temperatura dos prótons do plasma solar, juntamente com uma queda na densidade de prótons no vento solar.

Figura 5.7 - Exemplo de um caso sem a presença de uma onda de choque interplanetária, no dia 08 de julho de 2003.



Durante o período de 03h24 e 05h24, não é possível observar a presença de uma onda de choque interplanetária, no dados do satélite ACE. Os painéis, dispostos de cima para baixo, representam os parâmetros da magnitude do campo magnético interplanetário ($B[nT]$), densidade dos prótons ($N_p[1/cm^3]$), velocidade do vento solar ($V[km/s]$), em escala de 10^2 , e temperatura dos prótons ($T_p[^\circ K]$), em escala de 10^5 .

Tabela 5.8 - Comparação das saídas obtidas para o período observado no dia 08 de julho de 2003.

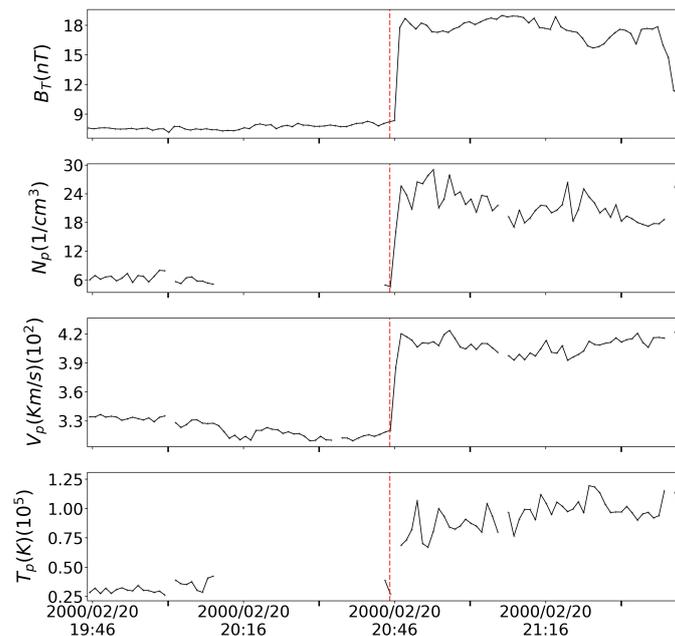
Tempo observado	Modelo	Saída obtida		
		FF	FR	Neg
10 minutos	Cash et al. (2014)	0	-	1
10 minutos	Kruparova et al. (2013)	0	-	1
20 minutos	Vorotnikov et al. (2008)	0	-	1
17 minutos	Lumme et al. (2019)	0	0	1
20 minutos	* Inception V3	<0,1%	<0,1%	99,9%
30 minutos	* VGG19	<0,1%	<0,1%	99,9%
1 hora	* VGG16	<0,1%	<0,1%	99,9%
2 horas	* Painters	97,6%	0,3%	2,1%

A primeira coluna identifica o padrão total de tempo utilizado em cada caso, enquanto que a segunda referencia as pesquisas para os modelos e técnicas tradicionais, ao mesmo tempo que identifica qual rede neural pré-treinada foi escolhida para cada padrão de tempo observado utilizado nesta pesquisa. As linhas com * identificam quais itens foram desenvolvidos no presente trabalho. As três últimas colunas exibem os resultados obtidos para cada saída dos modelos para essa amostra.

5.1.4.6 Evento de 20 de fevereiro de 2000

No dia 20 de fevereiro de 2000, uma onda de choque interplanetária do tipo frontal rápida pode ser observada pelas perturbações no vento solar e no campo magnético interplanetário, de acordo com as medidas feitas pelos sensores do satélite STEREO-A, às 23:12 UT. As perturbações geradas pelo choque IP podem ser visualizadas na Figura 5.8, onde os parâmetros do vento solar variaram de 313 para 413 km/s, para a velocidade dos prótons do vento solar; de 8 para 17,8 nT, para a magnitude do campo magnético interplanetário. Enquanto que, para a densidade de prótons do plasma solar, houve um aumento de 4,9 para 22 cm³; e, para a temperatura dos prótons, houve um aumento de $0,388 \times 10^5$ para $0,83 \times 10^5$ K. Notou-se que, para os atributos de densidade e temperatura, o período observado pela série temporal contém uma alta taxa de dados faltantes.

Figura 5.8 - Onda de choque interplanetária frontal rápida, detectada pelo satélite ACE, às 20:45 UT do dia 20 de fevereiro de 2000.



Amostra de um evento frontal rápido, gerada para entrada da rede de detecção, com total de 2 horas de dados observados. Os painéis, dispostos de cima para baixo, representam os parâmetros da magnitude do campo magnético interplanetário ($B[nT]$), densidade dos prótons ($N_p[1/cm^3]$), velocidade do vento solar ($V[km/s]$), em escala de 10^2 , e temperatura dos prótons ($T_p[^\circ K]$), em escala de 10^5 . A linha vertical tracejada indica o momento em que a onda de choque interplanetária atingiu o satélite. Nota-se, para esse caso de estudo, uma grande quantidade de *gaps*, ou seja, de dados faltantes para os atributos referentes à densidade e à temperatura do vento solar.

A Tabela 5.9 realiza a comparação entre os resultados obtidos pelas técnicas tradicionais e os resultados obtidos pela nova abordagem. É possível observar, por meio dos resultados apresentados, como a presença de dados faltantes gera falhas na detecção por meio das técnicas tradicionais, fato este que não é observado para a abordagem utilizando redes neurais. Para a abordagem descrita em Vorotnikov et al. (2008), os dados faltantes contribuíram para que houvesse uma falha no algoritmo, uma vez que não existiam os dados necessários para sua execução. Dessa forma, não foi possível avaliar seu resultado para este caso de estudo específico.

Tabela 5.9 - Modelos e saídas obtidas para o evento ocorrido no dia 20 de fevereiro de 2000.

Tempo observado	Modelo	Saída obtida		
		FF	FR	Neg
10 minutos	Cash et al. (2014)	1	-	0
10 minutos	Kruparova et al. (2013)	1	-	0
17 minutos	Lumme et al. (2019)	0	0	1
20 minutos	* Inception V3	99,8%	0,1%	0,1%
30 minutos	* VGG19	97,4%	2,5%	0,1%
1 hora	* VGG16	99,9%	<0,1%	<0,1%
2 horas	* Painters	98,9%	0,9%	0,2%

A primeira coluna identifica a janela de tempo utilizado em cada caso, enquanto que a segunda referencia os modelos e técnicas tradicionais ao mesmo tempo que identifica qual rede neural pré-treinada foi escolhida para cada padrão de tempo observado utilizado nesta pesquisa. As linhas com * identificam quais itens foram desenvolvidos no trabalho. As três últimas colunas exibem os resultados obtidos para cada saída dos modelos para essa amostra. O símbolo - identifica saídas inexistentes em determinados modelos.

Para este evento específico, foi possível identificar corretamente a onda de choque interplanetária com uma certeza média de $99\% \pm 1\%$, através da abordagem desenvolvida. Isso indica uma alta taxa de assertividade em comparação às técnicas tradicionais que foram utilizadas nos trabalhos listados na Tabela 5.9. É importante ressaltar que não houve interferência na capacidade de detecção da onda de choque mesmo na existência de dados faltantes.

5.2 Resultados das redes para previsão do tempo de chegada das estruturas

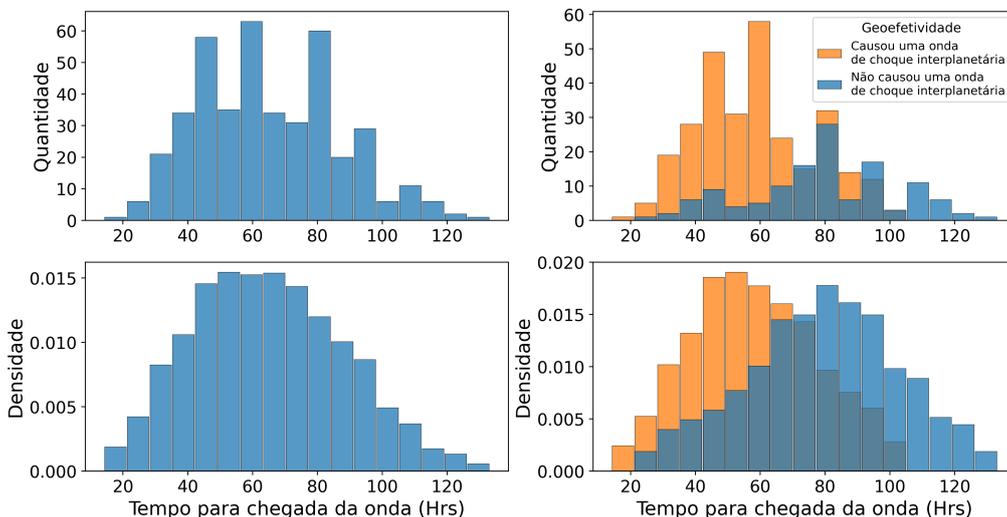
Nesta seção, estão descritos os resultados obtidos pelas técnicas, algoritmos e metodologias aplicadas nos dados utilizados para a previsão do tempo de chegada das ondas de choque interplanetárias e das estruturas solares que as guiam.

5.2.1 Suavização da distribuição para balanceamento.

A razão que justifica a necessidade de uma suavização é o desbalanceamento do conjunto de dados. Originalmente, o conjunto utilizado contém maior quantidade de amostras entre os valores compreendidos entre $58,5 \pm 18$ horas, para a propagação das estruturas até o ambiente terrestre, para estruturas acompanhadas de ondas de choque interplanetária e 77 ± 22 horas para estruturas que não guiaram ondas de choque interplanetárias.

Na Figura 5.9, é possível observar a comparação entre a distribuição empírica com o comportamento da distribuição suavizada das amostras, para um espaço de atributo contínuo, referente ao tempo de chegada das estruturas em ambiente próximo à Terra.

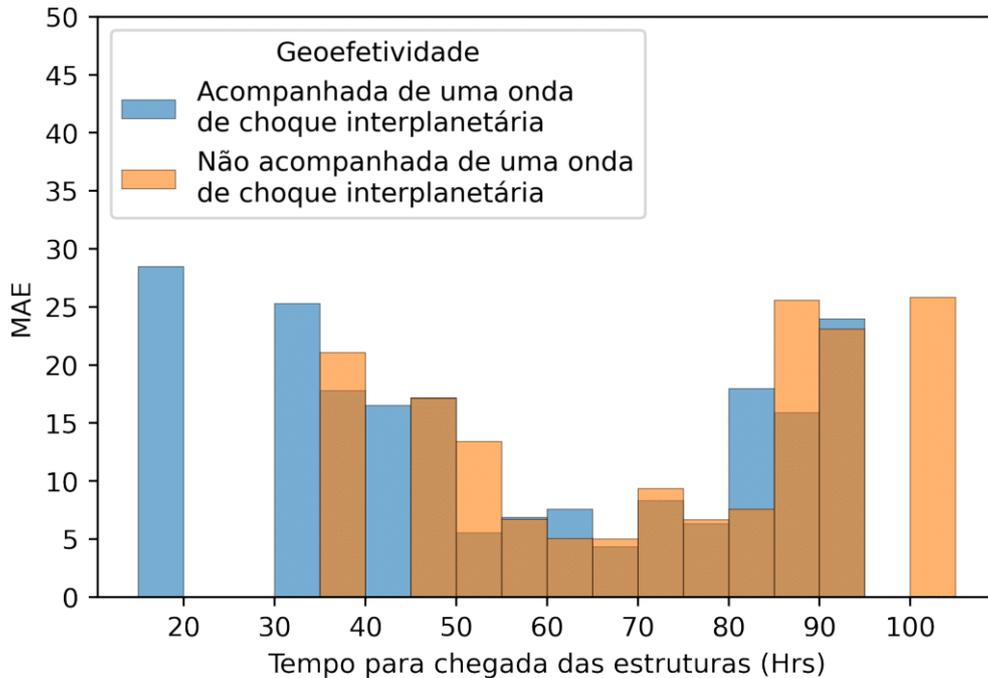
Figura 5.9 - Comparação da distribuição empírica com distribuição suavizada.



A comparação entre a distribuição empírica, mostrada nos painéis superiores, e a distribuição suavizada com o algoritmo LDS, apresentada nos painéis inferiores, permite analisar a suavização do conjunto de dados como um todo (painéis à esquerda) e por geofetividade (painéis à direita). A densidade identificada pelo algoritmo LDS facilita a identificação dos espaços contínuos majoritários e minoritários. Nesse contexto, a informação da densidade é inversamente proporcional ao peso atribuído a cada amostra pertencente a cada espaço de atributo identificado.

O treinamento de uma rede utilizando o comportamento original do conjunto gerou uma tendência nos valores majoritários, como identificado na Figura 5.10. Tal comportamento é destacado pela existência de erros menores dentro do espaço de atributos que compreendem os tempos de propagação mais comuns.

Figura 5.10 - Distribuição dos erros, sem aplicação do LDS, para o conjunto de teste.



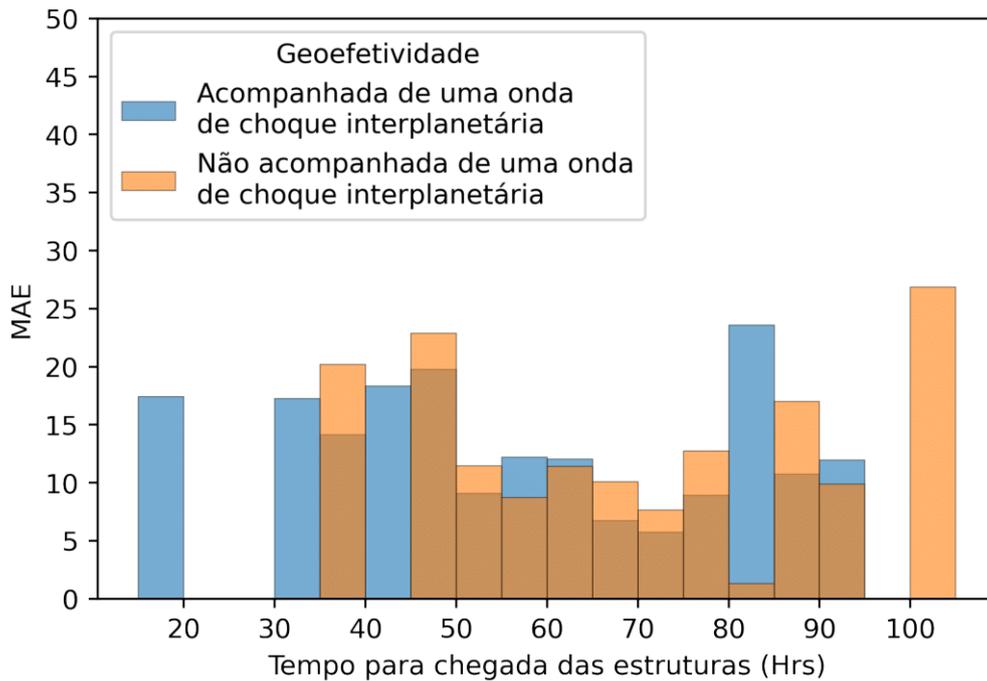
Distribuição dos erros em torno do tempo esperado para a chegada das estruturas, obtendo uma média de erro menor dentro do espaço de atributo majoritário. As barras azuis identificam as amostras de CMEs que guiaram ondas de choque, ao mesmo tempo que as barras laranjas designam as estruturas que não guiaram ondas de choque interplanetárias.

5.2.2 Treinamento e generalização

Separando os conjuntos de treinamento e teste com base nos eventos originais, sendo utilizados 25% dos eventos catalogados para a generalização das redes neurais. Por outro lado, o conjunto de validação recebeu 20% do conjunto de treinamento.

O comportamento com resultados tendenciosos entre os valores médios do tempo de propagação foi modificado após a aplicação de amostras com diferentes pesos, pela técnica LDS, conforme observado na Figura 5.11.

Figura 5.11 - Distribuição dos erros, com aplicação do algoritmo LDS, para o conjunto de teste.



Distribuição dos erros em torno do tempo esperado para chegada das estruturas, onde os erros médios são relativamente semelhantes. As barras azuis identificam as amostras de CMEs que guiaram ondas de choque, ao mesmo tempo que as barras laranjas designam as estruturas que não guiaram ondas de choque interplanetárias. Note que as estruturas não acompanhadas de choque apresentam um tempo de propagação maior.

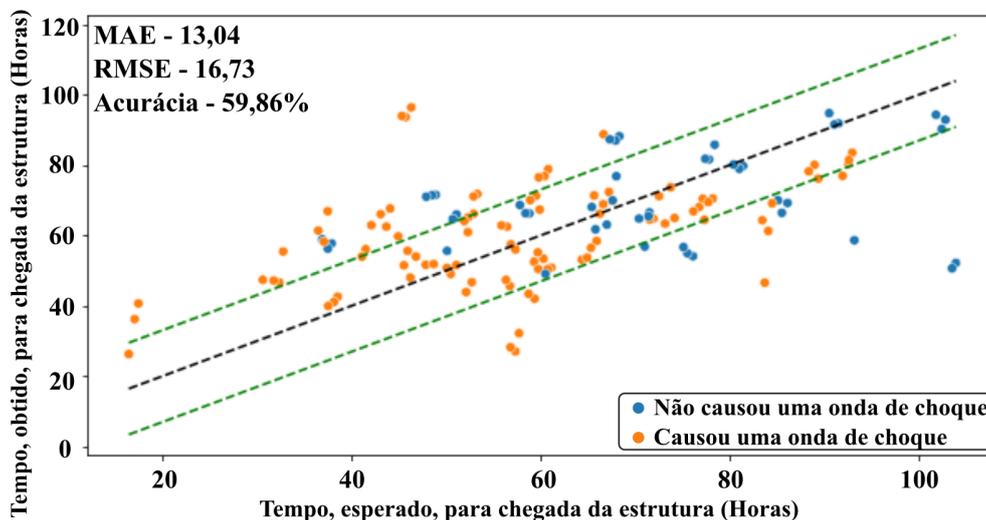
Como resultados finais, foram testadas várias arquiteturas, com resultados levemente satisfatórios, com erros médios de $13,51 \pm 0,69$ horas e uma acurácia média de $56,57 \pm 3,01\%$. A Tabela 5.10 identifica os resultados obtidos durante os testes de diferentes arquiteturas, de redes neurais convolucionais profundas, sendo possível, também, observar em outras abordagens resultados semelhantes ou até mesmo com taxas de erro menores, como indicado na Tabela 5.11.

Tabela 5.10 - Comparação dos resultados entre as diferentes arquiteturas testadas para obtenção dos resultados.

Arquitetura base	MAE	Acurácia
Inception V3	13,14 ± 0,57	58 ± 2,48%
Resnet50 V2	13,32 ± 0,78	55,35 ± 3,32%
Wang et al. (2019)	14,54 ± 0,64	54,46 ± 0,33%
Nossa arquitetura	13,91 ± 0,56	55,92 ± 3,1%

Detalhamento dos resultados obtidos para os testes de arquiteturas para obtenção dos resultados referentes à previsão do tempo de chegada das estruturas magnéticas. Os testes, utilizando como base as arquiteturas *InceptionV3* e *Resnet50 V2*, extraíram os atributos utilizando essas respectivas redes pré-treinadas para depois aplicar as saídas desse estágio como entradas para camadas totalmente conectadas que realizaram o reconhecimento de padrões e obtiveram uma saída referente ao tempo de propagação até o ambiente próximo à Terra. De forma semelhante ocorreu com as demais arquiteturas, onde foi aplicada uma adaptação para a arquitetura demonstrada em Wang et al. (2019), modificando a quantidade de sinais de entrada da arquitetura, por fim, a arquitetura desenvolvida especificamente pela nossa abordagem, descrita na Seção 4.5.2.2, onde os pesos foram inicializados aleatoriamente. Todos os pesos de cada arquitetura foram treinados com o subconjunto de treinamento dos dados descritos em 4.2.

Figura 5.12 - Comparação dos resultados obtidos com os valores esperados para o conjunto de teste.



Avaliação dos resultados obtidos pela rede neural treinada, com aplicação do algoritmo LDS, a fim de diminuir a diferença de erro entre os espaços de valores majoritários e minoritários referente ao tempo de chegada da estrutura, como descrito na Figura 5.11. A taxa de erro compreende um valor absoluto de 13,04 horas, indicado pelas linhas verdes tracejadas. A linha preta tracejada indica os valores ideais.

Tabela 5.11 - Comparação dos resultados entre modelos desenvolvidos anteriormente e o novo modelo.

Modelo	MAE	Acurácia
CAT-PUMA	5,9	54%
Wang et al. (2019)	12,4	-
Feng e Ye (2021)	5,8	60,7%
Arquitetura treinada	13,03	59,86%

Considerando individualmente uma previsão para cada amostra, o erro gerado torna-se simplesmente a diferença entre o tempo de propagação obtido pelo modelo e o valor esperado, a fim de apresentar alguns exemplos específicos, obtidos para algumas amostras do conjunto de teste, a Tabela 5.12 mostra os valores de erros obtidos para alguns casos específicos utilizados para a generalização da abordagem. Além de comparar com o resultado obtido com o modelo Cat-Puma (LIU et al., 2018), que obteve um valor de MAE de 5,9 horas.

Tabela 5.12 - Resultados obtidos para algumas amostras do conjunto de teste para o problema de previsão.

Data CME	Data Saída	Modelo	Erro (Horas)
1997/09/28 01:08	1997/10/01 00:59	Cat-Puma	6,5
		Nosso modelo	-0,1
2001/10/25 15:26	2001/10/28 03:13	Cat-Puma	3,6
		Nosso modelo	-1,75
2003/10/29 20:54	2003/10/30 16:19	Cat-Puma	31,2
		Nosso modelo	23,91
2011/08/08 18:12	2011/08/11 20:00	Cat-Puma	-15,2
		Nosso modelo	-0,77
2013/10/25 15:12	2013/10/29 09:33	Cat-Puma	4,85
		Nosso modelo	-15,86
2015/03/15 01:48	2015/03/17 04:00	Cat-Puma	8,0
		Nosso modelo	10,06

6 CONCLUSÕES

Neste trabalho, foi analisada a capacidade de reconhecimento de padrões diante da utilização de redes CNN profundas em aplicações voltadas às previsões do Clima Espacial.

As análises realizadas anteriormente comprovam a relação entre os parâmetros da velocidade do vento solar, da temperatura do plasma solar, da densidade do plasma solar e do campo magnético interplanetário, durante a ocorrência de descontinuidade gerada por estruturas magnéticas derivadas da atividade solar. Outras análises, por sua vez, indicam que a velocidade inicial das estruturas que guiam eventos como ondas de choque interplanetários, bem como a propagação das mesmas no espaço interplanetário, são atributos e informações úteis para indicar ou prever o tempo necessário para que as estruturas atinjam uma distância de 1 UA.

6.1 Classificação geral das redes

Tomando como base os efeitos ocasionados por estruturas de origem solar, pode-se avaliar as redes de detecção e classificação de forma geral com base na taxa de detecção e na taxa de falsos alarmes. Com isso em mente, é possível dizer que as redes aqui desenvolvidas obtiveram uma grande melhora em comparação com modelos tradicionais, com uma média de 91% para a taxa de detecção e cerca de 5% de alarmes falsos.

Enquanto que, para os resultados referentes à previsão do tempo de chegada, não foi possível atingir valores adequados para a aplicação do modelo como metodologia de previsão. Com o uso de algoritmos para o pré-processamento das imagens, foi possível proporcionar a remoção de ruídos nas imagens utilizadas para o treinamento e generalização das redes neurais. De forma que se esperava que isso auxiliasse no reconhecimento de padrões existentes e gerados somente nas estruturas observadas, ou seja, para a visualização da propagação inicial das CMEs. Além disso, foi aplicada a técnica LDS, onde a partir de sua aplicação, viabilizou-se uma melhor descrição dos atributos para um problema de regressão com um conjunto de dados desbalanceado.

Apesar dos avanços obtidos com o tratamento dos dados, as arquiteturas desenvolvidas nesta pesquisa para a previsão do tempo de chegada das estruturas em ambiente próximo à Terra obtiveram uma taxa de erro absoluto em torno de 13,51 horas, com aproximadamente 56,6% das amostras dentro deste intervalo de erro.

6.2 Considerações finais

As abordagens utilizando aprendizado de máquina, como as desenvolvidas nesta pesquisa, possibilitam a adesão de uma metodologia com baixo custo computacional para a ativação, ou seja, para a implementação e utilização das ferramentas de inteligência artificial utilizadas e desenvolvidas, possibilitando a detecção, estudo e análises da propagação das estruturas magnéticas no clima espacial.

A pesquisa realizada apresentou avanços significativos na detecção e previsão de ondas de choque interplanetárias, destacando a importância de continuar explorando novos dados e adotando abordagens inovadoras. A melhoria contínua desses métodos não apenas aprimora a capacidade de prever eventos climáticos espaciais, mas também tem um impacto direto na proteção de infraestruturas críticas, como redes elétricas e sistemas de comunicação, diante dos efeitos potencialmente devastadores das tempestades solares.

Para pesquisas e trabalhos futuros, sugere-se a aplicação de novos dados que possam contribuir na busca por relações das estruturas que guiam as ondas de choque. As velocidades de expansão das CMEs no campo de visão do coronógrafo, ou outros atributos como as séries temporais de eventos como SEPs, precursores de estruturas como CMEs e ondas de choque interplanetárias, além da associação com *flares* solares, podem contribuir para melhorar a previsão do tempo de chegada. Os *flares* são estruturas que emitem uma enorme quantidade de raios-X que acompanham a velocidade da luz e, conseqüentemente, podem ser monitorados 8 minutos após seu surgimento, estão intrinsecamente relacionados com as CMEs, mas não sendo necessariamente a fonte ou consequência da mesma, além do estudo de abordagens que utilizem modelos *Physics Informed Neural Networks*, possibilitando a incorporação de equações diferenciais relacionadas com os processos e dinâmicas do clima espacial.

Essa linha de pesquisa continua a desempenhar um papel fundamental na compreensão e na mitigação dos riscos associados ao clima espacial, contribuindo para a segurança e a resiliência de nossa sociedade frente aos desafios do ambiente espacial.

REFERÊNCIAS BIBLIOGRÁFICAS

ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVDO, E.; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; GOODFELLOW, I.; HARP, A.; IRVING, G.; ISARD, M.; JIA, Y.; JOZEFOWICZ, R.; KAISER, L.; KUDLUR, M.; LEVENBERG, J.; MANÉ, D.; MONGA, R.; MOORE, S.; MURRAY, D.; OLAH, C.; SCHUSTER, M.; SHLENS, J.; STEINER, B.; SUTSKEVER, I.; TALWAR, K.; TUCKER, P.; VANHOUCHE, V.; VASUDEVAN, V.; VIÉGAS, F.; VINYALS, O.; WARDEN, P.; WATTENBERG, M.; WICKE, M.; YU, Y.; ZHENG, X. **TensorFlow: large-scale machine learning on heterogeneous systems**. 2015. Software available from tensorflow.org. Disponível em: <<<https://www.tensorflow.org/>>>. 40

ALLEN, R.; JIAN, L.; VINES, S.; BALE, S.; CASE, A.; HILL, M.; JOYCE, C.; KASPER, J.; KORRECK, K.; MALASPINA, D.; MCCOMAS, D.; MCNUTT, R.; MÖSTL, C.; ODSTRCIL, D.; RAOUAFI, N. E.; SCHWADRON, N.; STEVENS, M. A living catalog of stream interaction regions in the parker solar probe era. **Astronomy & Astrophysics**, v. 650, 12 2020. 2

ALOM, M. Z.; TAHA, T.; YAKOPCIC, C.; WESTBERG, S.; SIDIKE, P.; NASRIN, M.; HASAN, M.; ESSEN, B. V.; AWWAL, A.; ASARI, V. A state-of-the-art survey on deep learning theory and architectures. **Electronics**, v. 8, p. 292, 03 2019. 31

BAKER, D. N. Introduction to space weather. In: SCHERER, K.; FICHTNER, H.; HEBER, B.; MALL, U. (Ed.). **Space weather: the physics behind a slogan**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004. p. 3–20. ISBN 978-3-540-31534-6. Disponível em: <<https://doi.org/10.1007/978-3-540-31534-6_1>>. 1

BALOGH, A.; MARSDEN, R. G.; SMITH, E. J. **The heliosphere near solar minimum. The Ulysses perspective**. [S.l.: s.n.], 2001. 1

BANACHEWICZ, K.; MASSARON, L.; GOLDBLOOM, A. **The kaggle book: data analysis and machine learning for competitive data science**. Packt Publishing, 2022. (Expert insight). ISBN 9781801817479. Disponível em: <<<https://books.google.com.br/books?id=Cy-nzgEACAAJ>>>. 32

BARTELS, J. The standardized index ks, and the planetary index kp. **Office, Paris**, v. 12 (b), p. 97–120, 1949. 17

BAUMANN, C.; MCCLOSKEY, A. Timing of the solar wind propagation delay between 11 and earth based on machine learning. **Journal of Space Weather and Space Climate**, v. 11, 06 2021. 9, 10, 40

BRADSKI, G. The OpenCV Library. **Dr. Dobb's Journal of Software Tools**, 2000. 40

BRAGA, C. R.; VOURLIDAS, A.; STENBORG, G.; LAGO, A. D.; MENDONÇA, R. R. S. d.; ECHER, E. Predicting the time of arrival of coronal mass ejections at earth from heliospheric imaging observations. **Journal of Geophysical Research: Space Physics**, v. 125, n. 9, p. e2020JA027885, 2020. E2020JA027885 10.1029/2020JA027885. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2020JA027885>>>. 4, 8

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 2001. Disponível em: <<<https://api.semanticscholar.org/CorpusID:89141>>>. 10

BRUECKNER, G. E. The behaviour of the outer solar corona ($3 R_{sun}$ to $10 R_{sun}$) during a large solar flare observed from OSO-7 in white light. In: NEWKIRK, G. A. (Ed.). **Coronal disturbances**. [S.l.: s.n.], 1974. v. 57, p. 333–334. 1

BRUECKNER, G. E.; DELABOUDINIÈRE, J. P.; HOWARD, R. A.; PASWATERS, S. E.; CYR, O. C. S.; SCHWENN, R.; LAMY, P.; SIMNETT, G. M.; THOMPSON, B.; WANG, D. Geomagnetic storms caused by coronal mass ejections (CMEs): March 1996 through June 1997. **Geophysical Research Letters**, v. 25, n. 15, p. 3019–3022, ago. 1998. 16

BRUECKNER, G. E.; HOWARD, R. A.; KOOMEN, M. J.; KORENDYKE, C. M.; MICHELS, D. J.; MOSES, J. D.; SOCKER, D. G.; DERE, K. P.; LAMY, P. L.; LLEBARIA, A.; BOUT, M. V.; SCHWENN, R.; SIMNETT, G. M.; BEDFORD, D. K.; EYLES, C. J. The Large Angle Spectroscopic Coronagraph (LASCO). **Solar Physics**, v. 162, n. 1-2, p. 357–402, dez. 1995. 11

BURLAGA, L.; SITTNER, E.; MARIANI, F.; SCHWENN, R. Magnetic loop behind an interplanetary shock: Voyager, Helios, and IMP 8 observations. **Journal of Geophysical Research**, v. 86, n. A8, p. 6673–6684, ago. 1981. 33

BURTON, R. K.; MCPHERRON, R. L.; RUSSELL, C. T. An empirical relationship between interplanetary conditions and Dst. **Journal of Geophysical Research**, v. 80, n. 31, p. 4204–4214, nov. 1975. 17

CAMPOREALE, E. The challenge of machine learning in space weather: Nowcasting and forecasting. **Space Weather**, v. 17, n. 8, p. 1166–1207, 2019. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2018SW002061>>>. 4, 5, 9, 25

CASH, M. D.; WROBEL, J. S.; COSENTINO, K. C.; REINARD, A. A. Characterizing interplanetary shocks for development and optimization of an automated solar wind shock detection algorithm. **Journal of Geophysical Research: Space Physics**, v. 119, n. 6, p. 4210–4222, 2014. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2014JA019800>>>. 4, 7, 64, 65, 67, 74, 76

CHOLLET, F. et al. **Keras**. 2015. Disponível em: <<<https://keras.io>>>. 40

COHEN, C.; MEWALDT, R.; SMITH, C.; SKOUG, R.; HO, G.; SZABO, A. Energetic particle responses to interplanetary shocks observed by ace. In: INTERNATIONAL COSMIC RAY CONFERENCE, 29., 2005. **Proceedings...** Pune, 2005. p. 327–330. 9

COSTA, J. E. R.; NARDIN, C. M. Em que escala os efeitos do clima espacial afetam a sociedade. In: WORKSHOP DO PROGRAMA DE CLIMA ESPACIAL DO INPE COM USUÁRIOS, 1., 2011. **Anais...** São José dos Campos, 2011. Disponível em: <<<https://www2.inpe.br/climaespacial/workshop2011usuarios/files/embraceUsu2011Efeitos.pdf>>>. 19

DAGLIS, I.; BAKER, D. N.; DALY, E.; KAPPENMAN, J. G.; PANASYUK, M. Effects of space weather on technology infrastructure. **Space Weather**, v. 2, n. 2, 2004. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2003SW000044>>>. 1

DEMŠAR, J.; CURK, T.; ERJAVEC, A.; GORUP, Č.; HOČEVAR, T.; MILUTINOVIČ, M.; MOŽINA, M.; POLAJNAR, M.; TOPLAK, M.; STARIČ, A.; ŠTAJDOHAR, M.; UMEK, L.; ŽAGAR, L.; ŽBONTAR, J.; ŽITNIK, M.; ZUPAN, B. Orange: data mining toolbox in python. **Journal of Machine Learning Research**, v. 14, p. 2349–2353, 2013. Disponível em: <<<http://jmlr.org/papers/v14/demsar13a.html>>>. 40

DESAI, M.; GIACALONE, J. Large gradual solar energetic particle events. **Living Reviews in Solar Physics**, v. 13, n. 1, p. 3, set. 2016. 1

DOBRIJEVIC, D. **Coronal mass ejections: what are they and how do they form?** 2022. Disponível em: <<<https://www.space.com/coronal-mass-ejections-cme>>>. 40

DUNGEY, J. W. Interplanetary magnetic field and the auroral zones. **Physical Review Letters**, v. 6, p. 47–48, Jan 1961. Disponível em: <<<https://link.aps.org/doi/10.1103/PhysRevLett.6.47>>>. 1, 3, 15

ECHER, E.; ALVES, M. Ondas de choque não colisionais no espaço interplanetário. **Revista Brasileira de Ensino de Física**, v. 28, 01 2006. 2, 3, 16, 33

ECHER, E.; GONZALEZ, W. Geoeffectiveness of interplanetary shocks, magnetic clouds, sector boundary crossings and their combined occurrence. **Geophysical Research Letters**, v. 310, 05 2004. 16

ECHER, E.; GONZALEZ, W.; A, V.; LAGO, A. D.; GUARNIERI, F.; PRESTES, A.; C, G.; J, S. Interplanetary shock parameters during solar activity maximum (2000) and minimum (1995-1996). **Brazilian Journal of Physics**, v. 33, 03 2003. 3, 20, 33

ECHER, E.; GONZALEZ, W. D.; ALVES, M. V. On the geomagnetic effects of solar wind interplanetary magnetic structures. **Space Weather**, v. 4, n. 6, 2006. 16

ECHER, E.; LUCAS, A. d.; HAJRA, R.; FRANCO, A. M. d. S.; BOLZAN, M. J.; NASCIMENTO, L. E. S. d. Geomagnetic activity following interplanetary shocks in solar cycles 23 and 24. **Brazilian Journal of Physics**, v. 53, n. 3, p. 79, 2023. 4

FENG, X.; YE, Y. Joint geoeffectiveness and arrival time prediction of cmes by a unified deep learning framework. **Remote Sensing**, v. 13, 08 2021. 4, 9, 11, 40, 56, 81

FENG, X. S.; ZHANG, Y.; YANG, L. P.; WU, S. T.; DRYER, M. An operational method for shock arrival time prediction by one-dimensional cese-hd solar wind model. **Journal of Geophysical Research: Space Physics**, v. 114, n. A10, 2009. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2009JA014385>>>. 8

FENG, Y.; ZHENG, J.; QIN, M.; BAI, C.; ZHANG, J. 3d octave and 2d vanilla mixed convolutional neural network for hyperspectral image classification with limited samples. **Remote Sensing**, v. 13, n. 21, 2021. ISSN 2072-4292. Disponível em: <<<https://www.mdpi.com/2072-4292/13/21/4407>>>. 29

FRASSATI, F.; LAURENZA, M.; BEMPORAD, A.; WEST, M. J.; MANCUSO, S.; SUSINO, R.; ALBERTI, T.; ROMANO, P. Acceleration of solar energetic particles through cme-driven shock and streamer interaction. **The Astrophysical Journal**, v. 926, n. 2, p. 227, feb 2022. Disponível em: <<<https://dx.doi.org/10.3847/1538-4357/ac460e>>>. 1

GEORGE MASON UNIVERSITY (GMU). **GMU CME/ICME List**. 2018. Disponível em: <<http://solar.gmu.edu/heliophysics/index.php/GMU_CME/ICME_List>>. 41

GODDARD SPACE FLIGHT CENTER (GSFC). **List of shock-driving ICMEs during the solar cycle 23**. 2021. Disponível em: <<https://cdaw.gsfc.nasa.gov/meetings/2010_fluxrope/LWS_CDAW2010_ICMEtbl.html>>. 41

GONZALEZ, W.; JOSELYN, J.-A.; KAMIDE, Y.; KROEHL, H. W.; ROSTOKER, G.; TSURUTANI, B.; VASYLIUNAS, V. What is a geomagnetic storm? **Journal of Geophysical Research: Space Physics**, v. 99, n. A4, p. 5771–5792, 1994. 15, 16, 17

GONZALEZ, W. D.; ECHER, E.; TSURUTANI, B. T.; GONZALEZ, A. L. C.; LAGO, A. D. Interplanetary origin of intense, superintense and extreme geomagnetic storms. **Space Science Reviews**, v. 158, n. 1, p. 69–89, jan 2011. 16

GONZALEZ, W. D.; TSURUTANI, B. T.; GONZALEZ, A. L. C. Interplanetary origin of geomagnetic storms. **Space Science Reviews**, v. 88, p. 529–562, abr. 1999. 16, 33, 34

- GOOD, S.; FORSYTH, R. Interplanetary coronal mass ejections observed by messenger and venus express. **Solar Physics**, v. 291, 01 2016. 32
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>. 5, 22, 25, 27, 28, 29, 44
- GOPALSWAMY, N. A global picture of CMEs in the inner heliosphere. In: POLETTI, G.; SUESS, S. T. (Ed.). **The Sun and the heliosphere as an integrated system**. [S.l.: s.n.], 2004. (Astrophysics and Space Science Library, v. 317), p. 201. 1
- GOPALSWAMY, N.; LARA, A.; LEPPING, R. P.; KAISER, M. L.; BERDICHEVSKY, D.; CYR, O. C. S. Interplanetary acceleration of coronal mass ejections. **Geophysical Research Letters**, v. 27, n. 2, p. 145–148, jan. 2000. 8
- GOPALSWAMY, N.; LARA, A.; MANOHARAN, P.; HOWARD, R. An empirical model to predict the 1-au arrival of interplanetary shocks. **Advances in Space Research**, v. 36, n. 12, p. 2289–2294, 2005. ISSN 0273-1177. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0273117705004588>>>. 8
- GOPALSWAMY, N.; LARA, A.; YASHIRO, S.; KAISER, M. L.; HOWARD, R. A. Predicting the 1-au arrival times of coronal mass ejections. **Journal of Geophysical Research: Space Physics**, v. 106, n. A12, p. 29207–29217, 2001. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2001JA000177>>>. 4, 8
- GOPALSWAMY, N.; YASHIRO, S.; AKIYAMA, S. Geoeffectiveness of halo coronal mass ejections. **Journal of Geophysical Research (Space Physics)**, v. 112, n. A6, p. A06112, jun. 2007. 14
- GOSLING, J. T. Coronal mass ejections: an overview. **Geophysical Monograph Series**, v. 99, p. 9–16, jan. 1997. 1
- GOSLING, J. T.; BAME, S. J.; MCCOMAS, D. J.; PHILLIPS, J. L. Coronal mass ejections and large geomagnetic storms. **Geophysical Research Letters**, v. 17, n. 7, p. 901–904, jun. 1990. 16
- GOSLING, J. T.; HILDNER, E.; MACQUEEN, R. M.; MUNRO, R. H.; POLAND, A. I.; ROSS, C. L. Mass ejections from the Sun: a view from Skylab. **Journal of Geophysical Research**, v. 79, n. 31, p. 4581, nov. 1974. 1
- GOSLING, J. T.; PIZZO, V. J. Formation and evolution of corotating interaction regions and their three dimensional structure. **Space Science Reviews**, v. 89, p. 21–52, jul. 1999. 16
- HAPGOOD, M. Societal and economic importance of space weather. In: CAMPOREALE, E.; WING, S.; JOHNSON, J. R. (Ed.). **Machine learning techniques for space weather**. Elsevier, 2018. p. 3–26. ISBN 978-0-12-811788-0. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/B9780128117880000019>>>. 1, 37

HARRIS, C. R.; MILLMAN, K. J.; WALT, S. J. van der; GOMMERS, R.; VIRTANEN, P.; COURNAPEAU, D.; WIESER, E.; TAYLOR, J.; BERG, S.; SMITH, N. J.; KERN, R.; PICUS, M.; HOYER, S.; KERKWIJK, M. H. van; BRETT, M.; HALDANE, A.; RÍO, J. F. del; WIEBE, M.; PETERSON, P.; GÉRARD-MARCHANT, P.; SHEPPARD, K.; REDDY, T.; WECKESSER, W.; ABBASI, H.; GOHLKE, C.; OLIPHANT, T. E. Array programming with NumPy. **Nature**, v. 585, n. 7825, p. 357–362, set. 2020. Disponível em: <<<https://doi.org/10.1038/s41586-020-2649-2>>>. 40

HATHAWAY, D. H. The solar cycle. **Living Reviews in Solar Physics**, v. 12, n. 1, p. 4, set. 2015. 13

HAVARD DATAVERSE. **Near-Earth interplanetary coronal mass ejections since January 1996**. 2024. Disponível em: <<<https://doi.org/10.7910/DVN/C2MHTH>>>. 41

HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001. ISBN 9788577800865. 5, 22, 23, 24, 25, 26, 27

HE, K.; ZHANG, X.; REN, S.; SUN, J. Identity mappings in deep residual networks. **Computing Research Repository**, abs/1603.05027, 2016. Disponível em: <<<http://arxiv.org/abs/1603.05027>>>. 32

HE, Z.; LIN, D.; LAU, T.; WU, M. Gradient boosting machine: a survey. **ArXiv**, abs/1908.06951, 2019. Disponível em: <<<https://api.semanticscholar.org/CorpusID:201070042>>>. 10

HESSE, M.; CASSAK, P. A. Magnetic reconnection in the space sciences: past, present, and future. **Journal of Geophysical Research: Space Physics**, v. 125, n. 2, p. e2018JA025935, 2020. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2018JA025935>>>. 14

HOSNA, A.; MERRY, E.; GYALMO, J.; ALOM, Z.; AUNG, Z.; AZIM, M. Transfer learning: a friendly introduction. **Journal of Big Data**, v. 9, 10 2022. 31

HUNDHAUSEN, A. J. **Coronal expansion and solar wind**. Heidelberg: Springer, 1972. ISBN 9783642654145. 1

_____. Coronal mass ejections. In: **Cosmic winds and the heliosphere**. Tucson: University of Arizona Press, 1997. p. 259–296. 1

HUNDHAUSEN, A. J.; SAWYER, C. B.; HOUSE, L.; ILLING, R. M. E.; WAGNER, W. J. Coronal mass ejections observed during the solar maximum mission: latitude distribution and rate of occurrence. **Journal of Geophysical Research: Space Physics**, v. 89, n. A5, p. 2639–2646, 1984. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/JA089iA05p02639>>>. 1, 14

HUNTER, J. D. Matplotlib: a 2d graphics environment. **Computing in Science & Engineering**, v. 9, n. 3, p. 90–95, 2007. 40

IANDOLA, F. N.; HAN, S.; MOSKEWICZ, M. W.; ASHRAF, K.; DALLY, W. J.; KEUTZER, K. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size. **arXiv e-prints**, p. arXiv:1602.07360, fev. 2016. 31

ILENIC, N. **Painter by numbers competition on Kaggle**. GitHub, 2016. Disponível em: <<<https://github.com/inejc/painters>>>. 32

INSTITUTO PUSHKOV DE MAGNETISMO TERRESTRE, IONOSFERA E PROPAGAÇÃO DE ONDAS DE RÁDIO (IZMIRAN). **Catalogue of the Forbush-effects and interplanetary disturbances**. 2021. Disponível em: <<<http://spaceweather.izmiran.ru/eng/dbs.html>>>. 41

IRELAND, J.; HUGHITT, K.; MÜLLER, D.; DIMITOGLU, G.; SCHMIEDEL, P.; FLECK, B. The helioviewer project: discovery for everyone everywhere. In: AAS/SOLAR PHYSICS MEETING, 2009. **Proceedings...** [S.l.]: AAS, 2009. 49

JI, S.; ZHANG, C.; XU, A.; SHI, Y.; DUAN, Y. 3d convolutional neural networks for crop classification with multi-temporal remote sensing images. **Remote Sensing**, v. 10, n. 1, 2018. ISSN 2072-4292. Disponível em: <<<https://www.mdpi.com/2072-4292/10/1/75>>>. 29

JOHNSON, J.; KHOSHGOFTAAR, T. Survey on deep learning with class imbalance. **Journal of Big Data**, v. 6, p. 27, 03 2019. 43

KAHLER, S. W. Solar flares and coronal mass ejections. **Annual Review of Astronomy and Astrophysics**, v. 30, p. 113–141, jan. 1992. 1

KATAOKA, R. Technological vulnerability and statistics. In: KATAOKA, R. (Ed.). **Extreme space weather**. Elsevier, 2022. p. 65–92. ISBN 978-0-12-822537-0. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/B9780128225370000028>>>. 14

KILPUA, E. K. J.; ISAVNIN, A.; VOURLIDAS, A.; KOSKINEN, H. E. J.; RODRIGUEZ, L. On the relationship between interplanetary coronal mass ejections and magnetic clouds. **Annales Geophysicae**, v. 31, n. 7, p. 1251–1265, jul. 2013. 33

KILPUA, E. K. J.; LUMME, E.; ANDREEOVA, K.; ISAVNIN, A.; KOSKINEN, H. E. J. Properties and drivers of fast interplanetary shocks near the orbit of the earth (1995–2013). **Journal of Geophysical Research: Space Physics**, v. 120, n. 6, p. 4112–4125, 2015. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2015JA021138>>>. 4

KOHL, J.; CRANMER, S. **Coronal holes and solar wind acceleration**. [S.l.]: Springer Science & Business Media, 1999. 1

- KRUPAROVA, O.; MAKSIMOVIC, M.; ŠAFRÁNKOVÁ, J.; NĚMEČEK, Z.; SANTOLIK, O.; KRUPAR, V. Automated interplanetary shock detection and its application to wind observations. **Journal of Geophysical Research: Space Physics**, v. 118, n. 8, p. 4793–4803, 2013. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/jgra.50468>>>. 4, 7, 65, 67, 74, 76
- LANZEROTTI, L. J. Space weather effects on technologies. **Space Weather**, v. 125, p. 11–22, 2001. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/GM125p0011>>>. 1
- LIU, J.; YE, Y.; SHEN, C.; WANG, Y.; ERDÉLYI, R. A new tool for cme arrival time prediction using machine learning algorithms: cat-puma. **Astrophysical Journal**, v. 855, p. 209, 03 2018. 4, 9, 10, 81
- LOW, B. C. Coronal mass ejections, magnetic flux ropes, and solar magnetism. **Journal of Geophysical Research**, v. 106, n. A11, p. 25141–25164, nov. 2001. 1
- LUCAS, A.; ALARCON, W. D. G.; ECHER, E.; GUARNIERI, F. L.; LAGO, A. D.; SILVA, M. R. d.; VIEIRA, L. E. A.; SARAIVA, A. C. V. Estruturas interplanetárias causando supertempestades e tempestades magnéticas intensas. **Revista UNIVAP**, v. 13, n. 24, p. 2114–2117, 2006. ISSN 1517-3275. 16, 33
- LUCAS, A.; GONZALEZ, W.; ECHER, E.; GUARNIERI, F.; LAGO, A. D.; SILVA, M.; VIEIRA, L.; SCHUCH, N. Energy balance during intense and super-intense magnetic storms using an akasofu ϵ parameter corrected by the solar wind dynamic pressure. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 69, p. 1851–1863, 11 2007. 3
- LUCAS, A.; SCHWENN, R.; LAGO, A. D.; MARSCH, E.; GONZALEZ, A. L. C. Interplanetary shock wave extent in the inner heliosphere as observed by multiple spacecraft. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 73, n. 10, p. 1281–1292, jun. 2011. 20
- LUMME, E.; KILPUA, E. K. J.; ISAVNIN, A.; ANDREEOVA, K. **Database of heliospheric shock waves**: method documentation. 10 2019. Disponível em: <<<http://www.ipshocks.fi/documentation>>>. 21, 67, 68, 69, 70, 74, 76
- MAKELA, P.; GOPALSWAMY, N.; XIE, H.; YASHIRO, S. Energetic storm particle events in coronal mass ejection–driven shocks. **Journal of Geophysical Research**, v. 116, 08 2011. 9
- MANOHARAN, P. K.; GOPALSWAMY, N.; YASHIRO, S.; LARA, A.; MICHALEK, G.; HOWARD, R. A. Influence of coronal mass ejection interaction on propagation of interplanetary shocks. **Journal of Geophysical Research: Space Physics**, v. 109, n. A6, 2004. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2003JA010300>>>. 9
- MARSCH, E. Kinetic physics of the solar corona and solar wind. **Living Reviews in Solar Physics**, v. 3, n. 1, p. 1, jul. 2006. 1

MARSCH, E.; AXFORD, W. I.; MCKENZIE, J. F. Solar wind. In: DWIVEDI, B. N.; PARKER, F. E. N. (Ed.). **Dynamic Sun**. [S.l.: s.n.], 2003. p. 374–402. 1

MATZKA, J.; STOLLE, C.; YAMAZAKI, Y.; BRONKALLA, O.; MORSCHHAUSER, A. The geomagnetic kp index and derived indices of geomagnetic activity. **Space Weather**, v. 19, n. 5, p. e2020SW002641, maio 2021. 17

MCKINNEY, W. Data structures for statistical computing in python. In: WALT, S.; MILLMAN, J. (Ed.). **Proceedings of the 9th Python in Science Conference**. [S.l.: s.n.], 2010. p. 51 – 56. 40

MEDEIROS, L. **Inteligência artificial aplicada: uma abordagem introdutória**. [S.l.]: Intersaberes, 2018. ISBN 9788559728002. 5, 23, 27

MENDEZ, B.; PETICOLAS, L.; HAUCK, K. **Solar flares and coronal mass ejections**. 2004. Disponível em: <<https://www.nasa.gov/audience/foreducators/9-12/features/F_Dangers_of_Solar_Flares_and_CME.html>>. 40

MINTA, F.; NOZAWA, S.; KOZAREV, K.; ELSAID, A.; MAHROUS, A. Forecasting the transit times of earth-directed halo cmes using artificial neural network: a case study application with gcs forward-modeling technique. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 247, p. 106080, 2023. ISSN 1364-6826. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S1364682623000780>>>. 10

MUMFORD, S. J.; FREIJ, N.; CHRISTE, S. D.; IRELAND, J.; MAYER, F.; HUGHITT, V. K.; SHIH, A. Y.; RYAN, D. F.; LIEDTKE, S.; PÉREZ-SUÁREZ, D.; CHAKRABORTY, P.; VISHNUNARAYAN, K.; INGLIS, A. R.; PATTNAIK, P.; SIPOCZ, B. M.; SHARMA, R.; LEONARD, A.; STANSBY, D.; HEWETT, R. J.; HAMILTON, A.; HAYES, L. A.; PANDA, A.; EARNSHAW, M.; CHOUDHARY, N.; KUMAR, A.; CHANDA, P.; HAQUE; KIRK, M. S. F.; MUELLER, M.; KONGE, S.; SRIVASTAVA, R.; JAIN, Y. R.; BENNETT, S.; BARUAH, A. K.; BARNES, W. T.; CHARLTON, M. C.; MALONEY, S. A.; CHORLEY, N.; HIMANSHU; MODI, S.; MASON, J.; NAMAN; ROZO, J. I. C.; MANLEY, L.; CHATTERJEE, A.; EVANS, J. G.; MALOCHA, M.; BOBRA, M. G.; GHOSH, S.; AIRMANSMITH; STAŃCZAK, D.; VISSCHER, R. D.; VERMA, S.; AGRAWAL, A.; BUDDHIKA, D.; SHARMA, S.; PARK, J.; BATES, M. W.; GOEL, D.; TAYLOR, G.; CETUŠIĆ, G.; JACOB; INCHAURRANDIETA, M.; DACIE, S.; DUBEY, S.; SHARMA, D.; BRAY, E.; RIDEOUT, J. R.; ZAHNIY, S.; MÉSZÁROS, T.; BOSE, A.; CHICRALA, A.; ANKIT; GUENNOU, C.; D'AVELLA, D.; WILLIAMS, D.; BALLEW, J. H.; MURPHY, N.; LODHA, P.; ROBITAILLE, T. P.; KRISHAN, Y.; HILL, A.; EIGENBROT, A. D.; MAMPAEY, B.; WIEDEMANN, B. M.; MOLINA, C.; KEŞKEK, D.; HABIB, I.; LETTS, J.; BAZÁN, J.; ARBOLANTE, Q.; GOMILLION, R.; KOTHARI, Y.; SHARMA, Y.; STEVENS, A. L.; PRICE-WHELAN, A. M.; MEHROTRA, A.; KUSTOV, A.; STONE, B.; DANG, T. K.; ARIAS, E.; DOVER, F. M.; VERSTRINGE, F.; KUMAR, G.; MATHUR, H.; BABUSCHKIN, I.; WIMBISH, J. C.;

BUITRAGO-CASAS, J. C.; KRISHNA, K.; HIWARE, K.; MANGAONKAR, M. D.; MENDERO, M.; SCHOENTGEN, M.; GYENGE, N.; STREICHER, O.; MEKALA, R. S. R.; MISHRA, R. K.; SRIKANTH, S.; JAIN, S.; YADAV, T.; WILKINSON, T. D.; PEREIRA, T. M. D.; AGRAWAL, Y.; JAMESCALIXTO; YASINTODA; MURRAY, S. A. SunPy: a Python package for Solar Physics. **The Journal of Open Source Software**, v. 5, n. 46, p. 1832, fev. 2020. 40

NIELSEN, M. **Neural networks and deep learning**. Determination Press, 2015. Disponível em: <<<http://neuralnetworksanddeeplearning.com/>>>. 5, 23, 26, 55

NÚÑEZ, M.; NIEVES-CHINCHILLA, T.; PULKKINEN, A. Prediction of shock arrival times from cme and flare data. **Space Weather**, v. 14, n. 8, p. 544–562, 2016. Disponível em: <<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2016SW001361>>>. 7

O'CALLAGHAN, J. How to predict solar flares before they hit. **New scientist (1971)**, v. 247, n. 3294, p. 19–19, 2020. ISSN 0262-4079. 14

OGILVIE, K.; DESCH, M. The wind spacecraft and its early scientific results. **Advances in Space Research**, v. 20, n. 4, p. 559–568, 1997. ISSN 0273-1177. Results of the IASTP Program. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0273117797004390>>>. 7

OLIVEIRA, D.; SILVEIRA, M. Clima espacial e choques interplanetários (space weather and interplanetary shocks). **Revista Brasileira de Ensino de Física**, v. 38, 03 2016. 2, 3, 4, 14, 15

OLIVEIRA, D. M. Magnetohydrodynamic shocks in the interplanetary space: a theoretical review. **Brazilian Journal of Physics**, v. 47, n. 1, p. 81–95, fev. 2017. 16

PAGOT, E.; LAMY, P.; LLEBARIA, A.; BOCLET, B. Automated processing of lasco coronal images: spurious point-source-filtering and missing-blocks correction. **Solar Physics**, v. 289, 04 2014. 50

PANT, V.; MAJUMDAR, S.; PATEL, R.; CHAUHAN, A.; BANERJEE, D.; GOPALSWAMY, N. Investigating width distribution of slow and fast CMEs in solar cycles 23 and 24. **Frontiers in Astronomy and Space Sciences**, v. 8, p. 73, maio 2021. 15

PRIEST, E. **Magnetohydrodynamics of the Sun**. Cambridge: Cambridge University Press, 2014. 13

RAWAT, R.; ECHER, E.; GONZALEZ, W. How different are the solar wind-interplanetary conditions and the consequent geomagnetic activity during the ascending and early descending phases of the solar cycles 23 and 24? **Journal of Geophysical Research: Space Physics**, v. 123, 08 2018. 65

REAMES, D. V. Solar energetic particle variations. **Advances in Space Research**, v. 34, n. 2, p. 381–390, jan. 2004. 9

_____. The two sources of solar energetic particles. **Space Science Reviews**, v. 175, n. 1-4, p. 53–92, jun. 2013. 1

SANTIAGO, V. **Deep neural networks: How to define?** 05 2021. Disponible en: <<<https://towardsdatascience.com/deep-neural-networks-how-to-define-73d87bf36421>>>. 29, 30

SCHWENN, R. Relationship of coronal transients to interplanetary shocks - 3d aspects. **Space Science Reviews**, v. 44, n. 1-2, p. 139–168, jun. 1986. 1

_____. Large-scale structure of the interplanetary medium. In: SCHWENN, R.; MARSCH, E. (Ed.). **Physics of the inner heliosphere I**. [S.l.: s.n.], 1990. p. 99. 2

_____. An essay on terminology, myths, - and known facts: Solar transient - flare - cme - driver gas - piston - bde - magnetic cloud - shock wave - geomagnetic storm. **Astrophysics and Space Science**, v. 243, p. 187–193, 1996. 1

_____. Space weather: the solar perspective. **Living Reviews in Solar Physics**, v. 3, 08 2006. 1, 2, 9, 14, 15, 16, 19

SCHWENN, R.; LAGO, A.; HUTTUNEN, E.; GONZALEZ, W. D. The association of coronal mass ejections with their effects near the Earth. **Annales Geophysicae**, v. 23, n. 3, p. 1033–1059, mar. 2005. 8

SCHWENN, R.; MARSCH, E. **Physics of the inner heliosphere I. large-scale phenomena**. [S.l.: s.n.], 1990. 1

_____. **Physics of the inner heliosphere II. particles, waves and turbulence**. [S.l.: s.n.], 1991. 1

SHARIFF, N. N. M.; HAMIDI, Z.; ZAINOL, N. Analysis of slow partial halo cme events with velocity of 100-200 km/s: an observation through callisto system. In: INTERNATIONAL CONFERENCE ON INDUSTRIAL ENGINEERING, MANAGEMENT SCIENCE AND APPLICATION, 2017. **Proceedings...** [S.l.], 2017. 32

SHETTY, S.; SIDDIQA, A. Deep learning algorithms and applications in computer vision. **International Journal of Computer Sciences and Engineering**, v. 7, p. 195–201, 07 2019. 5

SHNEIDER, C.; HU, A.; TIWARI, A. K.; BOBRA, M. G.; BATTAMS, K.; TEUNISSEN, J.; CAMPOREALE, E. A machine-learning-ready dataset prepared from the solar and heliospheric observatory mission. **ArXiv**, abs/2108.06394, 2021. 20

- SIEBERT, M.; MEYER, J. **The upper atmosphere: geomagnetic activity indices**. [S.l.]: Springer, Berlin Heidelberg, 1996. 17
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **ArXiv e-prints**, p. arXiv:1409.1556, set. 2014. 31
- SISCOE, G. The space-weather enterprise: past, present, and future. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 62, p. 1223–1232, 09 2000. 1
- SRIVASTAVA, N.; SCHWENN, R. The origin of the solar wind: an overview. In: **THE OUTER HELIOSPHERE: BEYOND THE PLANETS**, 2000. **Proceedings...** Katlenburg-Lindau, 2000. p. 12–40. 1
- STONE, E. C.; FRANDBSEN, A. M.; MEWALDT, R. A.; CHRISTIAN, E. R.; MARGOLIES, D.; ORMES, J. F.; SNOW, F. The advanced composition explorer. **Space Science Reviews**, v. 86, p. 1–22, jul. 1998. 7
- SUGIURA, M.; KERTZ, W.; PRICE, A.; STONE, D. **Hourly values of equatorial Dst for the IGY**. [S.l.]: Pergamon Press, 1964. 17
- SZABO, A. Nasa wind satellite (1994). In: PELTON, J. N.; ALLAHDADI, F. (Ed.). **Handbook of cosmic hazards and planetary defense**. Cham: Springer International Publishing, 2015. p. 141–157. ISBN 978-3-319-03952-7. Disponível em: <<https://doi.org/10.1007/978-3-319-03952-7_13>>. 38
- SZEGEDY, C.; VANHOUCHE, V.; IOFFE, S.; SHLENS, J.; WOJNA, Z. Rethinking the inception architecture for computer vision. **Computing Research Repository**, p. 2818–2826, 2015. Disponível em: <<<http://arxiv.org/abs/1512.00567>>>. 5, 31, 56
- TSURUTANI, B. T.; LAKHINA, G. S.; HAJRA, R. The physics of space weather/solar-terrestrial physics (stp): what we know now and what the current and future challenges are. **Nonlinear Processes in Geophysics**, v. 27, n. 1, p. 75–119, 2020. Disponível em: <<<https://npg.copernicus.org/articles/27/75/2020/>>>. 17, 20
- TURCHENKO, V.; DEMCHUK, V.; SACHENKO, A. Interplanetary shock arrival time prediction using multi-layer perceptron. In: **WORKSHOP ON INTELLIGENT DATA ACQUISITION AND ADVANCED COMPUTING SYSTEMS: TECHNOLOGY AND APPLICATIONS**, 4., 2007. **Proceedings...** [S.l.]: IEEE, 2007. p. 185–190. ISBN 978-1-4244-1347-8. 9
- UNIVERSITY OF SCIENCE AND TECHNOLOGY OF CHINA (USTC). **List of interplanetary coronal mass ejections**. 2016. Disponível em: <<https://space.ustc.edu.cn/dreams/wind_icmes/>>. 41
- VANDEGRIFF, J.; WAGSTAFF, K.; HO, G.; PLAUGER, J. Forecasting space weather: predicting interplanetary shocks using neural networks. **Advances in Space Research**, v. 36, n. 12, p. 2323–2327, 2005. ISSN 0273-1177. Space Weather. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0273117705004540>>>. 9

VARGAS, V. W. de; ARANDA, J. A. S.; COSTA, R. dos S.; PEREIRA, P. R. da S.; BARBOSA, J. L. V. Imbalanced data preprocessing techniques for machine learning: a systematic mapping study. **Knowledge and Information Systems**, v. 65, p. 31 – 57, 2022. Disponível em:

<<<https://api.semanticscholar.org/CorpusID:253459320>>>. 43

VOROTNIKOV, V.; SMITH, C.; HU, Q.; SZABO, A.; SKOUG, R.; COHEN, C. Automated shock detection and analysis algorithm for space weather application. **Space Weather-the International Journal of Research and Applications - SPACE WEATHER**, v. 6, 03 2008. 4, 7, 16, 65, 67, 74, 76

WANG, Y.; LIU, J.; JIANG, Y.; ERDÉLYI, R. Cme arrival time prediction using convolutional neural network. **The Astrophysical Journal**, v. 881, p. 15, 08 2019. 4, 9, 11, 56, 80, 81

WEBB, D. F.; CROOKER, N. U.; PLUNKETT, S. P.; CYR, O. C. S. The solar sources of geoeffective structures. **Space Weather**, p. 123–141, 2001. Disponível em:

<<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/GM125p0123>>>. 1, 3, 15, 40

WILSON, D. L. Asymptotic properties of nearest neighbor rules using edited data. **IEEE Transactions on Systems, Man, and Cybernetics**, n. 3, p. 408–421, 1972. 44

WU, C.-C.; LIOU, K.; LEPPING, R.; HUTTING, L.; PLUNKETT, S.; HOWARD, R.; SOCKER, D. The first super geomagnetic storm of solar cycle 24: “the st. patrick’s day event (17 march 2015)”. **Earth, Planets and Space**, v. 68, 12 2016. 65

XIE, H.; OFMAN, L.; LAWRENCE, G. Cone model for halo cmes: application to space weather forecasting. **Journal of Geophysical Research: Space Physics**, v. 109, n. A3, 2004. Disponível em:

<<<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2003JA010226>>>. 11

YANG, Y.; ZHA, K.; CHEN, Y.-C.; WANG, H.; KATABI, D. Delving into deep imbalanced regression. **ArXiv**, 2021. International Conference on Machine Learning (ICML). 45

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? **Advances in Neural Information Processing Systems (NIPS)**, v. 27, 11 2014. 31

ZHANG, C.-B.; JIANG, P.-T.; HOU, Q.; WEI, Y.; HAN, Q.; LI, Z.; CHENG, M.-M. Delving deep into label smoothing. **IEEE Transactions on Image Processing**, v. 30, p. 5984–5996, 2021. 44

ZHAO, X.; DRYER, M. Current status of cme/shock arrival time prediction. **Space Weather**, v. 12, n. 7, p. 448–469, 2014. 9

ZIRKER, J. B. Coronal holes and high-speed wind streams. **Reviews of Geophysics**, v. 15, n. 3, p. 257–269, 1977. 1