



ConBRepro

X CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



02 a 04
de dezembro 2020

Refletividade de Radar Gerada a Partir de Dados de Descargas Elétricas Atmosféricas

Camila de Oliveira

Programa de Pós-Graduação em Métodos Numéricos para Engenharia, UFPR

Sergio Scheer

Programa de Pós-Graduação em Métodos Numéricos para Engenharia, UFPR

Mauren Lucila Marques de Moraes Micalichen

Setor de Educação Profissional e Tecnológica - SEPT, UFPR

Nicole Amanda Rozin Hervis

Setor de Educação Profissional e Tecnológica - SEPT, UFPR

Cesar Beneti

SIMEPAR

Resumo: A refletividade de radar permite o monitoramento de tempestades, isto é, a identificação, seu acompanhamento e previsão no curto prazo, o que auxilia na tomada de decisões e medidas operacionais, mitigando possíveis danos. Porém os dados de radar nem sempre estão disponíveis, devido à falhas ou mesmo regiões que não estão no alcance do radar. Tempestades podem ser caracterizadas por chuvas e descargas elétricas. A relação entre precipitação convectiva e atividade de raio pode ser usada como um indicador do regime de chuvas. Além disso, um melhor conhecimento da fenomenologia local da tempestade pode ser muito útil para avaliar as tarefas de vigilância meteorológica. Esse trabalho utiliza a rede neural perceptron multicamadas para estimar refletividade de radar a partir de descargas elétricas atmosféricas. Os resultados obtidos fornecem uma boa estimativa da localização e formato das tempestades.

Palavras-chave: Refletividade, Descargas Elétricas, MLP.

Radar Reflectivity Generated from Lightning Data

Abstract: Radar reflectivity allows the monitoring of storms, that is, the identification, their monitoring and forecast in the short term, which helps in making decisions and operational measures, mitigating possible damage. However, radar data is not always available, due to faults or even regions that are not in the radar's range. Storms can be characterized by rain and lightning. The relationship between convective precipitation and lightning activity can be used as an indicator of the rainfall regime. In addition, a better understanding of the local phenomenology of the storm can be very useful to assess meteorological surveillance tasks. This work uses the multilayer perceptron neural network to estimate radar reflectivity from lightning data. The results obtained provide a good estimate of the location and shape of the storms.

Keywords: Reflectivity, Lightning Data, MLP.

1. Introdução

A meteorologia busca compreender de forma abrangente os fenômenos atmosféricos que são presenciados no cotidiano. As aplicações da meteorologia são bastante amplas e a previsão do tempo influencia o cotidiano de toda a sociedade.

Eventos de vendavais, granizos e tornados, ainda que relativamente raros em comparação com outros sistemas meteorológicos (como chuvas frontais), representam ameaça potencial para atividades importantes como por exemplo defesa civil, aviação, agricultura e transmissão e distribuição de energia elétrica. Assim, o fato de serem eventos relativamente raros não implica em darmos menos atenção ao estudo destes sistemas e ao treinamento de pessoal operacional visando a previsão dos mesmos (NASCIMENTO, 2005).

Estudar a estrutura dessas tempestades severas ajuda a identificar as condições favoráveis para a sua formação, podendo-se assim, com antecedência de várias horas, vincular alertas e antecipar a adoção de estratégias que eliminem ou minimizem o impacto negativo destes fenômenos meteorológicos.

A estrutura tridimensional de uma tempestade pode ser observada utilizando o radar meteorológico. O radar é uma das tecnologias mais precisas e utilizadas dentro da meteorologia, sendo capaz de prover informações complexas sobre as dimensões horizontal e vertical da precipitação. Quando utilizado em conjunto com um experimento de medição de taxa de precipitação, permite o levantamento adequado do comportamento local da chuva (OLIVEIRA, 2014).

As tempestades severas muitas vezes são acompanhadas por descargas elétricas atmosféricas, esses dados são coletados em tempo real e estão disponíveis em todo o território nacional, seja com sistemas de detecção terrestre, ou do espaço.

A refletividade de radar permite o *Nowcasting* de tempestades, isto é, a identificação, seu acompanhamento e previsão no curto prazo, o que auxilia na tomada de decisões e medidas operacionais, mitigando possíveis danos.

Dessa forma, objetiva-se desenvolver um modelo de estimativa da refletividade de radar, com base nos dados de descarga atmosférica de diferentes sistemas de detecção. Visto que esse produto pode contribuir para o *Nowcasting* em intervalos de tempo menores e permite sua ampliação para outras regiões.

2. Conceitos Meteorológicos

O estudo das condições meteorológicas é um objetivo do ramo da ciência denominada meteorologia. Os fenômenos meteorológicos são estudados a partir das observações, experiências e métodos científicos de análise. A observação meteorológica é uma avaliação ou uma medida de um ou vários parâmetros meteorológicos.

As observações são sensoriais quando são adquiridas por um observador sem ajuda de instrumentos de medição, e instrumentais, em geral chamadas medições meteorológicas, quando são realizadas com instrumentos meteorológicos (INMET, 2020).

Um desses instrumentos de medição é o radar meteorológico, que possibilita o monitoramento em tempo real de uma ampla área com alta resolução espacial e temporal e permite observar a estrutura tridimensional do sistema que deu origem à precipitação.

Medições meteorológicas permitem conhecer as características e variações dos elementos atmosféricos, os quais constituem os dados básicos para confecção de cartas de previsão do tempo, para conhecimento do clima, para o estudo de leis gerais que regem os fenômenos meteorológicos, entre outros. Essas medições são utilizadas também como condições iniciais para a previsão numérica do tempo, que baseia-se num

conjunto de equações que traduzem leis da física para descrever o comportamento hidrodinâmico da atmosfera.

A seguir são apresentados alguns fundamentos básicos sobre radar aplicado à meteorologia.


2.1 Radar Meteorológico

Radars são dispositivos que permitem detectar objetos a longas distâncias. Um radar meteorológico consiste basicamente de quatro componentes principais: um transmissor para gerar um sinal de alta frequência, uma antena para enviar o sinal e receber o eco de volta do alvo, um receptor para detectar e amplificar o sinal, e algum tipo de sistema de exibição para permitir que se veja o que o radar detectou (RINEHART, 2004).

A antena do radar meteorológico emite pulsos de energia eletromagnética em intervalos de tempo regulares, concentrados em um feixe de pequena abertura. Os alvos iluminados pelo feixe do radar podem absorver parte desta energia e irradiá-la em diversas direções. A fração da energia que retorna ao radar é medida pelo receptor e, conhecendo-se o intervalo de tempo t entre a emissão e o retorno do eco, é possível determinar a distância r do alvo (QUEIROZ, 2009).

Normalmente, a coleta de dados de radar se dá através da rotação da antena em torno de um eixo vertical com uma sequência pré-programada de varreduras azimutais em 360° . Um volume de varredura corresponde a uma sequência completa de várias varreduras azimutais com diferentes elevações da antena, como mostrado na Figura 1.

Figura 1 – Esquema de varredura volumétrica de um radar meteorológico



Fonte: SELUZNIAK (2016)

Esses dados possuem coordenadas esféricas com três graus de liberdade (r, θ, φ), onde r é a distância do alvo até o radar (slant range), θ é o ângulo de azimute em relação ao norte e, φ é o ângulo de elevação da antena em relação ao horizonte.

Uma das variáveis obtidas pelo radar é a refletividade (z), a qual será utilizada neste trabalho. Ela é o fator entre as ondas eletromagnéticas emitidas e as que voltam para o radar, depois de passarem por uma nuvem e serem irradiadas em todas as direções pelas gotas de chuva. Quanto maior o valor da refletividade, maiores são os diâmetros das gotas presentes, e maior será a intensidade da precipitação.

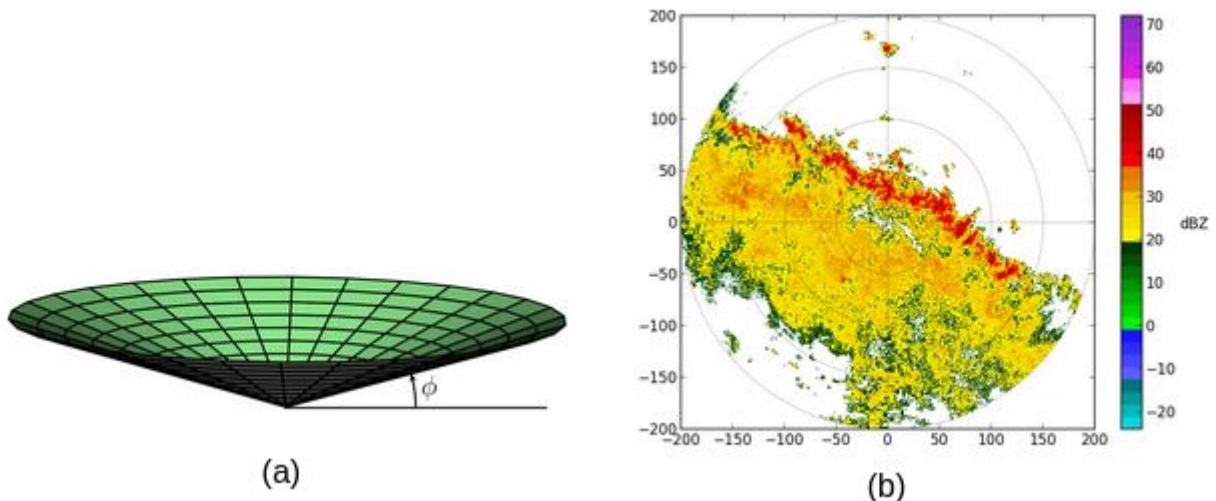
2.1.1 Produtos do Radar

Os dados em formato numérico obtidos pelo radar podem ser convertidos em imagens, chamadas de produtos do radar. Esses produtos podem ser visualizados de diferentes modos. Dois produtos que serão utilizados no trabalho são o PPI e o Zmax.

O PPI (Plan Position Indicator) é o produto gerado de uma varredura em azimute. Ele representa a projeção, no plano horizontal, dos dados dos ecos recebidos em um ângulo de elevação constante. Esses dados em coordenadas esféricas são transformados para coordenadas cartesianas e então, são plotados com o centro da imagem indicando a localização do radar.

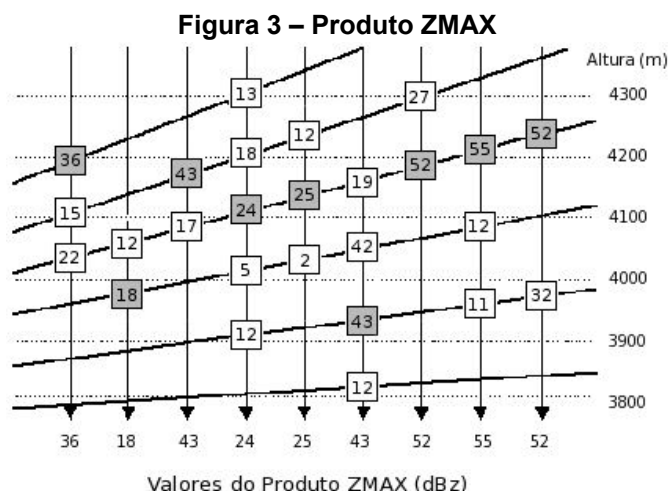
A Figura 2(a) apresenta uma varredura em azimute do radar com um determinado ângulo de elevação ϕ constante e a Figura 2(b) mostra o PPI da variável refletividade obtida pelo radar através desta varredura em azimute. As cores quentes representam valores de refletividade mais elevados, enquanto que cores frias representam valores mais baixos.

Figura 2 – Em (a) tem-se um exemplo de varredura do radar com elevação ϕ da antena constante e em (b) o PPI obtido da variável refletividade desta varredura



Fonte: OLIVEIRA (2014)

O produto Zmax indica o maior valor de refletividade encontrado em cada coluna do volume de varredura. Ou seja, para cada posição (r, θ) dos dados do radar, encontra-se o maior valor de refletividade em todas as elevações do volume de varredura, como ilustrado na Figura 3.



Fonte: METEOPT (2013)

2.2 Descargas Eléctricas Atmosféricas

Descargas atmosféricas, também chamadas de raios, são descargas elétricas de grande extensão (alguns quilômetros) e de grande intensidade (picos de intensidade de corrente acima de um quiloampere), que ocorrem devido ao acúmulo de cargas elétricas em

regiões localizadas da atmosfera, em geral dentro de tempestades. A descarga inicia quando o campo elétrico produzido por estas cargas excede a capacidade isolante, também conhecida como rigidez dielétrica, do ar em um dado local na atmosfera, que pode ser dentro da nuvem ou próximo ao solo. Quebrada a rigidez, tem início um rápido movimento de elétrons de uma região de cargas negativas para uma região de cargas positivas. Existem diversos tipos de descargas, classificadas em função do local onde se originam e do local onde terminam (INPE, 2020).

O Brasil, devido à sua grande extensão territorial e pelo fato de estar localizado em uma região predominantemente tropical, é um dos países de maior ocorrência de descargas do planeta. Descargas elétricas atmosféricas podem provocar colapsos ou desligamentos na rede de distribuição de energia elétrica, incêndios, acidentes na aviação e em embarcações marítimas, danos aos sistemas de telefonia e de telecomunicações podendo, inclusive, provocar mortes de seres humanos e de animais (LIMA, 2009).

As DEA podem ser divididas em duas categorias principais determinadas com relação ao local onde ocorrem:

- Nuvem-Solo (NS): conectam o solo com a nuvem;
- Nuvem-Nuvem (NN): a descarga se propaga entre duas ou mais nuvens ou dentro da própria nuvem.

As descargas nuvem-nuvem são as que ocorrem com mais frequência, pois neste caso cargas opostas estão mais próximas do que em qualquer outro tipo de descarga e também pelo fato de que a densidade do ar é menor a medida que a altura vai aumentando, diminuindo assim a capacidade isolante do ar (KLEINA, 2015).

Mesmo ocorrendo com com menos frequência, as descargas nuvem-solo são de maior interesse de estudo, pois, podem provocar diversos tipos de destruição. Apesar desse tipo de descarga parecer contínua, geralmente é composta por múltiplas descargas, chamadas de descargas de retorno (ou *return strokes*, em inglês). Esse conjunto de descargas que ocorrem de forma organizada, em intervalos de tempo muito curtos, são chamados de *flash*.

3. Inteligência Artificial

A Inteligência Artificial é um campo que usa técnicas de programação que procuram, por intermédio de máquinas, resolver problemas do mesmo modo que um ser humano os resolveria.

Ela é responsável pelo estudo e desenvolvimento de rotinas computacionais, envolvendo pesquisas relacionadas à aprendizagem e evolução computacional, sistemas especialistas, sistemas de suporte à tomada de decisão, agentes computacionais inteligentes, entre outras áreas.

3.1 Aprendizagem de Máquina

O Aprendizado de Máquina (AM) é considerada um subcampo da Inteligência Artificial. Ele é baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana.

Os algoritmos de AM podem ser usados para classificação binária e multiclasse, extração de características, regressão, criação de regras de associação, reconhecimento de padrão, compreensão e ou detecção de valores atípicos, sendo usada desde diagnósticos médicos a ajustes de funções (ALOAYDIN, 2010).

Os algoritmos de AM podem ser divididos em dois tipos principais de tarefas: supervisionada e não-supervisionada.

O aprendizado supervisionado é realizado por meio de um supervisor externo, que fornece ao sistema as entradas juntamente com os valores de saída desejados. A ideia é que, a partir da amostra apresentada, o sistema seja capaz de construir um classificador para rotular novos dados, desconhecidos até então (LORENA; CARVALHO, 2007).

Problemas de aprendizagem supervisionados são classificados em problemas de classificação, onde o único recurso é nominal ou discreto e regressão, em que a saída ou previsão é contínua. Na classificação o objetivo é prever os resultados a um único rótulo discreto, tentando mapear as variáveis de entrada em categorias distintas. Já a regressão consiste em prever um valor contínuo em vez de um rótulo discreto: por exemplo, prever a temperatura de amanhã, a partir de dados meteorológicos; ou prever o tempo que um projeto de software levará para concluir, dadas suas especificações (CHOLLET, 2017).

O aprendizado não-supervisionado é realizado quando, para cada exemplo, apenas os atributos de entrada estão disponíveis. Essas técnicas de aprendizado são utilizadas quando o objetivo for encontrar em um conjunto de dados padrões ou tendências (aglomerados) que auxiliem o entendimento desses dados (SOUTO et al., 2003).


Neste trabalho será utilizado o aprendizado supervisionado a partir do método de regressão MLP, que será descrito melhor a seguir.

3.2 Perceptron Multicamadas (MLP)

Os perceptrons multicamadas ou MLPs se caracterizam pela presença de uma ou mais camadas intermediárias ou escondidas (camadas em que os neurônios são efetivamente unidades processadoras, mas não correspondem à camada de saída). Adicionando-se uma ou mais camadas intermediárias, aumenta-se o poder computacional de processamento não-linear e armazenagem da rede. Em uma única camada oculta, suficientemente grande, é possível representar, com exatidão, qualquer função contínua das entradas. O conjunto de saídas dos neurônios de cada camada da rede é utilizada como entrada para a camada seguinte (DUARTE, 2009).

Na Figura 4 pode-se observar a rede Perceptron multicamadas, constituída de várias camadas em grafos, de forma que o sinal parte para um único sentido e cada nó tem uma função de ativação não linear.

Figura 4 – MLP com entrada, processamento de dados e sentido de saídas



Fonte: SOUZA (2020)

O treinamento de uma rede MLP insere-se no contexto de aprendizado de máquina supervisionado, em que cada amostra de dados utilizada apresenta um rótulo informando a saída.

4. Metodologia

4.1 Dados

Os dados necessários para o desenvolvimento do trabalho foram disponibilizados pelo Sistema de Tecnologia e Monitoramento Ambiental do Paraná (SIMEPAR).

São utilizadas duas fontes de dados: descargas elétricas atmosféricas provindas de detecção de superfície Rindat e dados de radar meteorológico obtidos pelo radar localizado no município de Cascavel -- PR.

O estudo limita-se a região do radar meteorológico com alcance de 240 km e os dados são avaliados em uma grade com espaçamento horizontal e vertical de aproximadamente 2 km.

Os atributos são construídos por ponto de grade, com as seguintes informações: número de descargas, quantidade de descargas nuvem-nuvem, quantidade de descargas nuvem-solo, mês e hora de ocorrência.

Enquanto isso, os rótulos são obtidos pelo produto Z_{max} que representa o maior valor de refletividade em todas as elevações do volume de varredura do radar.

Dessa forma, o problema é do tipo Regressão, visto que deseja-se estimar um valor contínuo e, optou-se por aplicar o método MLP.

Para o treinamento e validação da rede, foram selecionados dados de tempestades que ocorreram no ano de 2019, na área do radar de Cascavel, totalizando 7521 arquivos de radar. Para os dados de teste, foram selecionadas algumas tempestades que ocorreram no ano de 2020, também na mesma área, totalizando 356 arquivos.

4.2 Avaliação dos Resultados

Para a avaliação dos resultados gerados pela MLP, foram utilizadas as seguintes métricas:

$$\text{BIAS} = \frac{\sum_{i=1}^n (y_i - x_i)}{n}, \quad (1)$$

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

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (3)$$

Foi utilizado também o coeficiente de determinação (R^2).

5. Resultados

Para a aplicação da rede MLP foi utilizada a linguagem de programação Python, com o pacote scikit-learn. Esse pacote possui a função `sklearn.neural_network.MLPRegressor`, utilizados para problemas de regressão.

Os parâmetros da função utilizados foram:

- `hidden_layer_sizes`: 10, 100, 200
- `activation`: identity, logistic, tanh, relu;
- `solver`: lbfgs, sgd, adam;

- batch_size: 100, 500, 1000
- learning_rate: constant, invscaling, adaptive.

Todas as combinações dos parâmetros foram testadas. E os parâmetros que apresentaram melhor resultado são:

- hidden_layer_sizes: 100;
- activation: tanh;
- solver: adam;
- batch_size: 100;
- learning_rate: constant.

A Tabela 1 mostra os valores obtidos com dados de teste para as métricas apresentadas em 4.2.

Tabela 1 - Métricas obtidas com os dados de teste.

Métrica	Valores
BIAS	0,36
MAE	6,48
RMSE	7,98
R ²	0,12

O BIAS positivo indica que o valor de refletividade está sendo superestimado pelo modelo. As Figuras 5 a 7 mostram a comparação a refletividade observada, na coluna da esquerda, e os dados previstos, na coluna da direita, para alguns instante de tempo do conjunto de teste.

Figura 5 – Comparação entre refletividade observada e refletividade prevista para os dia 25/06/2020 às 14:44

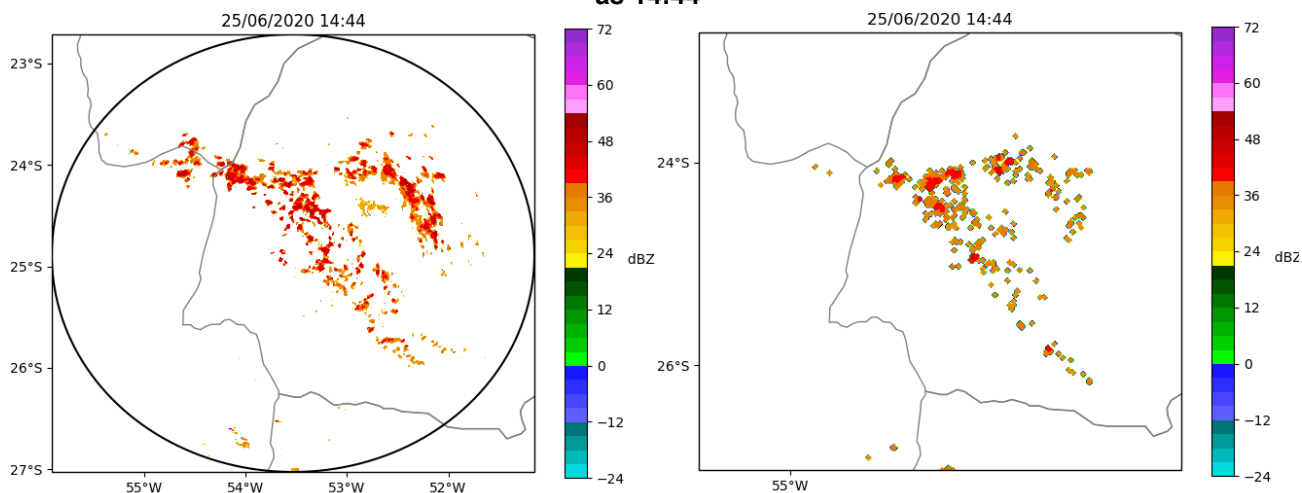


Figura 6 – Comparação entre refletividade observada e refletividade prevista para os dia 25/06/2020 às 17:24





Figura 7 – Comparação entre refletividade observada e refletividade prevista para os dia 30/06/2020 às 14:54



6. Conclusões

Os resultados obtidos pela rede MLP fornecem uma boa estimativa das regiões com tempestades, inclusive o formato das mesmas.

Nos dados previstos é possível observar falhas na extensão da tempestade. Essas falhas mostram que, para trabalhos futuros, deve-se obter mais características que possam melhorar a reconstrução de refletividade.

Referências

ALPAYDIN, E. **Introduction to Machine Learning**. The MIT Press, 2ª edição, 2010.

CHOLLET, F. **Deep Learning with Python**. Manning Publications Company, 2017.

DUARTE, V. A. R. **MP-DRAUGHTS - Um Sistema Multiagente de Aprendizagem Automática para Damas Baseado em Redes Neurais de Kohonen e Perceptron Multicamadas**. Uberlândia, 2009. Dissertação (Mestrado) - Universidade Federal de Uberlândia.

INMET. **Instituto nacional de meteorologia**. Disponível em: <<https://portal.inmet.gov.br/>> Acesso em: 01 de out. 2020.

INPE. **Instituto Nacional de Pesquisas Espaciais**. Disponível em: <<http://www.inmet.gov.br>>. Acesso em: 20 de jan. 2020.

KLEINA, M. **Identificação, Monitoramento e Previsão de Tempestades Elétricas**. Curitiba, 2015. Tese (Doutorado) — Universidade Federal do Paraná.

LIMA, K. C.; GOMES, R. G. Detecção de descargas elétricas atmosféricas em sistemas convectivos com dados do SIMEPAR. **Revista Brasileira de Geofísica**, v. 27, p. 5–16, 2009.

LORENA, A. C.; CARVALHO, A. C. P. L. F. D. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, vol. 14, pp. 43, 2007.

METEOPT. **Fórum de meteorologia**. Disponível em: <<http://www.meteopt.com/>>. Acesso em: 07 de nov. 2013.

NASCIMENTO, E. D. L. Previsão de tempestades severas utilizando-se parâmetros convectivos e modelos de mesoescala: Uma estratégia operacional adotável no Brasil?. **Revista Brasileira de Meteorologia**, vol. 20, n. 1, pp. 121–140, 2005.

OLIVEIRA, C. D. **Identificação e correção da banda brilhante em dados de radar meteorológico**. Curitiba, 2014. Dissertação (Mestrado) - Universidade Federal do Paraná.

QUEIROZ, A. P. D. **Monitoramento e previsão imediata de tempestades severas usando dados de radar**. 2009. Dissertação (Mestrado) - Curso de Pós-Graduação em Meteorologia, Instituto Nacional de Pesquisas Espaciais.

RINEHART, R. E. **Radar for meteorologists**. Rinehart Publications, Nevada, United States of America, 4 edição, 2004.

SELUZNIAK, R. H. L. **Controle de qualidade de dados de radar polarimétrico com apoio de visualizador interativo de dados**. Curitiba, 2016. Dissertação (Mestrado) - Universidade Federal do Paraná.

SOUTO, M. C. P. D., LORENA, A. C., DELBEM, A. C. B., & CARVALHO, A. C. P. L. F. D. Técnicas de aprendizado de máquina para problemas de biologia molecular. In: XXIII CONGRESSO DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO, pp. 103–152, 2003.

SOUZA, J. R.; ANTUNES, J. F.; OLIVEIRA, I. A.; LEITE, J. C. R.; SOUZA, T. M. S. M.; SANTOS, T. G. S. Python e predição de dados usando redes neurais multicamadas. **Brasiliam Journal of Development**. Curitiba, v. 6, n. 7, p. 54181- 54185, 2020.