



APLICAÇÃO DE DIFERENTES MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DA OCORRÊNCIA DE RAIOS NO ESTADO DA BAHIA

Mirella Lima Saraiva Araujo; Erick Giovanni Sperandio Nascimento²

¹ Bolsista HPC - FAPESB; e-mail: mirella.araujo@fbter.org.br

² Centro Universitário SENAI CIMATEC; Salvador-BA; e-mail: erick.sperandio@fieb.org.br

RESUMO

A ocorrência de raios tem potencial de causar fatalidades e prejuízos econômicos, portanto, a habilidade de prever a ocorrência desse evento natural é de grande importância. Deste modo, esse trabalho foi desenvolvido com objetivo de elaborar e analisar diferentes modelos de redes neurais capazes de prever a ocorrência de raios utilizando dados meteorológicos adquiridos através do *Global Data Assimilation System* (GDAS) para, primeiramente a região metropolitana de Salvador, e expandindo para o estado da Bahia, utilizando apenas as redes neurais que obtiveram melhor desempenho. Foram utilizados modelos de *multilayer perceptrons* (MLP), redes neurais convolucionais (CNN), redes neurais recorrentes *Long Short-Term Memory* (LSTM) e rede híbrida entre LSTM e CNN. A análise de métricas de erro e de correlação aponta que os melhores resultados foram obtidos pelas arquiteturas de MLP, seguidos pelas CNN, LSTM e híbrida, respectivamente. Conclui-se que a rede MLP foi a mais precisa, ainda havendo espaço para melhorias.

PALAVRAS-CHAVE: redes neurais, raios, multilayer perceptrons, previsão

1. INTRODUÇÃO

Raio é um fenômeno natural de descarga elétrica que ocorre com alta frequência em solo brasileiro e pode acarretar consequências desastrosas. Segundo o Grupo de Eletricidade Atmosférica (ELAT)¹ do Instituto Nacional de Pesquisas Espaciais (INPE) o Brasil é atingido por aproximadamente 77,8 milhões de raios por ano, causando uma média de 110 mortes e deixando o Brasil na sétima posição mundial em relação ao número de mortes causadas por raios, além de causarem mais de 1 bilhão de dólares em prejuízos.²

Nesse cenário, se torna relevante o estudo de técnicas capazes de prever a ocorrência desse fenômeno de forma cada vez mais precisa para um futuro próximo, possibilitando o alerta para que as pessoas possam tomar medidas preventivas e precatorias nas áreas de risco identificadas. Dessa forma, esse trabalho visa utilizar uma rede neural para possibilitar a previsão da ocorrência de raios para o período das próximas seis horas no estado da Bahia. Sendo realizado a partir da elaboração, análise e comparação de diferentes modelos de redes neurais utilizando dados da região metropolitana de Salvador, após avaliar os resultados obtidos nas métricas de correlação e erro, os modelos de redes que apresentaram melhor performance foram então aplicados para os dados de todo o estado.

As redes neurais baseiam-se nas estruturas biológicas responsáveis pelo aprendizado humano, sendo compostas por camadas de neurônios conectados que transmitem informação de um para o outro. Quando uma informação entra em um neurônio ela é multiplicada por um peso, esse resultado irá passar por uma função de ativação que definirá a informação que sairá para a entrada de outro neurônio. O aprendizado ocorre quando a rede ajusta os pesos para que a saída tenha o resultado próximo ao esperado.⁴

As redes neurais são altamente customizáveis, sendo necessário definir empiricamente a arquitetura mais apropriada para determinado problema. As redes MLP são as mais simples, construídas em múltiplas camadas, onde todos os neurônios de uma camada se conectam com todos os neurônios da camada seguinte, com a informação sendo transmitida sempre em uma direção.⁵ Diferentemente, as redes recorrentes possuem uma estrutura que permite que a saída de um neurônio, seja também a entrada nesse mesmo neurônio, ou no anterior, essa característica faz com que estas redes apresentem bons resultados com séries temporais. As redes convolucionais também trabalham com dados sequenciados, porém sua abordagem consiste na aplicação de filtros, chamados de kernels, para identificação de comportamentos similares ou diferentes em uma série temporal. A rede híbrida por tanto é uma combinação das duas redes descritas anteriormente.

2. METODOLOGIA

Este é um projeto de pesquisa experimental, onde dados meteorológicos foram utilizados em diferentes tipos de redes neurais, sendo elas: *multilayer perceptrons* (MLP); redes neurais convolucionais unidimensionais (CNN); redes neurais recorrentes *Long Short-Term Memory* (LSTM); e um modelo híbrido, com as redes CNN e LSTM para realizar a previsão de raios no período de seis horas de antecedência.

Neste caso, foram utilizadas como variáveis de entrada dados meteorológicos obtidos pelo *The Global Data Assimilation System (GDAS)*, que são dados utilizados operacionalmente para iniciar as previsões do *Global Forecast System (GFS)*³, pertencente ao *National Centers for Environmental Prediction (NCEP)*, para o período entre novembro de 2017 e novembro de 2018, juntamente com dados de incidência de raios disponibilizados pelo ELAT como alvo. Inicialmente os modelos foram criados somente com dados da região metropolitana de Salvador, com o intuito de agilizar o processo, para posteriormente então expandir apenas as redes neurais que obtiveram melhores resultados, com os dados de toda Bahia.

3. RESULTADOS E DISCUSSÃO

Para os treinamentos apenas na região metropolitana de Salvador, os dois melhores resultados foram obtidos em MLP. A primeira com 35 *hidden layers* com números decrescentes de neurônios, todas com função de ativação Unidade Linear Retificada (ReLU), uma camada de dropout e uma camada de saída com função de ativação sigmoid, referida como MLP 1. A segunda com 20 *hidden layers* com função de ativação ReLU, utilizando o Keras Tuner para definir a quantidade de neurônios para cada camada, a camada de saída com dois neurônios e função de ativação sigmoid, referida como MLP 2. Todas foram compiladas utilizando o otimizador Adam e o parâmetro de perda o *Binary-crossentropy*. A tabela 1 apresenta todas as métricas para avaliar a capacidade das redes neurais.

Tabela 1 - Métricas para modelos com dados da região metropolitana de Salvador.

| REDES | CLASSES | F1 | ROC AUC | PRC AUC | PRECISÃO | RECALL | ESPECIFICIDADE | ACURÁCIA |
|------------|---------|------|---------|---------|----------|--------|----------------|----------|
| MLP 1 | 0 | 0,97 | 0,97 | 0,99 | 0,98 | 0,95 | 0,92 | 0,94 |
| | 1 | 0,86 | 0,98 | 0,85 | 0,81 | 0,92 | 0,95 | 0,94 |
| | Média | 0,92 | 0,98 | 0,92 | 0,9 | 0,94 | 0,94 | 0,94 |
| MLP 2 | 0 | 0,96 | 0,98 | 1 | 0,99 | 0,92 | 0,98 | 0,93 |
| | 1 | 0,84 | 0,98 | 0,91 | 0,74 | 0,98 | 0,92 | 0,93 |
| | Média | 0,9 | 0,98 | 0,96 | 0,86 | 0,95 | 0,95 | 0,93 |
| LSTM | 0 | 0,92 | 0,66 | 0,85 | 0,85 | 1 | 0,32 | 0,86 |
| | 1 | 0,48 | 0,66 | 0,44 | 0,96 | 0,32 | 1 | 0,86 |
| | Média | 0,7 | 0,66 | 0,64 | 0,9 | 0,66 | 0,66 | 0,86 |
| CNN | 0 | 0,97 | 0,9 | 0,95 | 0,95 | 0,99 | 0,81 | 0,95 |
| | 1 | 0,87 | 0,9 | 0,81 | 0,95 | 0,81 | 0,99 | 0,95 |
| | Média | 0,92 | 0,9 | 0,88 | 0,95 | 0,9 | 0,9 | 0,95 |
| LSTM + CNN | 0 | 0,93 | 0,73 | 0,88 | 0,88 | 0,99 | 0,46 | 0,88 |
| | 1 | 0,62 | 0,73 | 0,54 | 0,92 | 0,46 | 0,99 | 0,88 |
| | Média | 0,78 | 0,73 | 0,71 | 0,9 | 0,72 | 0,72 | 0,88 |

Como é possível observar, o primeiro modelo obteve melhores valores de F1 score, precisão e especificidade para as previsões quando ocorreram raios, isso ocorre porque gera-se uma quantidade menor de falsos positivos. O segundo modelo apresentou melhores valores de *area under the precision recall curves* (PRC AUC) e recall, indicando que apesar de que a taxa de falsos positivos aumentou, o número de positivos verdadeiros também cresceu. Sendo assim, o segundo modelo mostrou-se mais eficiente, considerando que para prevenção de acidentes, é mais importante obter uma taxa mais alta de verdadeiros positivos, onde a maioria das ocorrências são de fato previstas, mesmo que aumente a ocorrência de falsos negativos.

A rede LSTM foi a que obteve os piores resultados em relação à sua capacidade de prever corretamente a ocorrência de raios, perceptível pelas métricas F1 score, PRC AUC e recall, por apresentarem valores baixos. A rede convolucional, por sua vez, obteve melhores resultados para estas métricas, porém ainda inferiores quando comparado com as MLP. Por último, a rede híbrida apesar de ter gerado resultados melhores que a LSTM, também não apresentou resultados satisfatórios, sendo inferior do que a uma rede puramente CNN, para o caso previsto neste estudo.

Em seguida, as duas arquiteturas MLP foram escolhidas para serem aplicadas em um dataset mais amplo contendo os dados de toda Bahia. Pode-se observar que ao aumentar a quantidade de dados,

ocorreu o overfitting, - evento que ocorre quando a rede neural memoriza os dados de treinamento em vez de aprender os padrões existentes - não conseguindo realizar previsões com boa eficiência. Desse modo, foi preciso criar um terceiro modelo (MLP 3,) contendo 10 *hidden layers* com funções de ativação ReLU e o uso do Keras Tuner para definir a quantidade de neurônios em cada camada, com adição de camadas de dropout a cada 2 *hidden layers*. Os resultados podem ser observados na tabela 2.

Tabela 2 - Métricas para os modelos com dados da Bahia

| REDES | CLASSES | F1 | ROC AUC | PRC AUC | PRECISÃO | RECALL | ESPECIFICIDADE | ACURÁCIA |
|-------|-----------|------|---------|---------|----------|--------|----------------|----------|
| MLP 1 | Sem raios | 0,93 | 0,95 | 0,99 | 0,94 | 0,93 | 0,76 | 0,89 |
| | Raios | 0,74 | 0,95 | 0,76 | 0,72 | 0,76 | 0,93 | 0,89 |
| | Média | 0,84 | 0,95 | 0,88 | 0,83 | 0,84 | 0,84 | 0,89 |
| MLP 2 | Sem raios | 0,95 | 0,96 | 0,99 | 0,95 | 0,94 | 0,81 | 0,92 |
| | Raios | 0,79 | 0,96 | 0,84 | 0,78 | 0,81 | 0,94 | 0,92 |
| | Média | 0,87 | 0,96 | 0,92 | 0,86 | 0,88 | 0,88 | 0,92 |
| MLP 3 | Sem raios | 0,94 | 0,97 | 0,99 | 0,98 | 0,9 | 0,93 | 0,9 |
| | Raios | 0,79 | 0,97 | 0,85 | 0,69 | 0,93 | 0,9 | 0,9 |
| | Média | 0,86 | 0,97 | 0,85 | 0,84 | 0,92 | 0,92 | 0,9 |

Os resultados mostram que há uma queda na eficiência da rede neural quando expandida para todo o território do estado, mas ainda demonstram resultados satisfatórios. O primeiro e o segundo modelo obtiveram comportamentos similares aos vistos anteriormente, enquanto o terceiro modelo reduz a precisão e aumenta o recall, tendo como resultado uma capacidade levemente maior do que o segundo modelo ao detectar a ocorrência de raios.

4. CONSIDERAÇÕES FINAIS

A utilização de redes neurais artificiais para previsão de descargas elétricas tem um grande potencial. As redes *multilayer perceptrons* apresentaram resultados satisfatórios para a previsão de raios nas próximas seis horas, porém ainda há espaço para ajustes e melhorias. Apesar das redes recorrentes, convolucionais e híbridas criadas não terem superado as redes MLP, em futuro trabalhos serão exploradas modificações nas arquiteturas e variações de parâmetros estas redes produzam melhores resultados.

Agradecimentos

Agradecimentos ao Centro de Referência em Inteligência Artificial, além do Centro de Supercomputação para Inovação Industrial (CS2i), ambos do SENAI CIMATEC por possibilitar essa pesquisa e a FAPESB pelo apoio financeiro essencial para a realização dessa pesquisa

5. REFERÊNCIAS

- ¹ ELAT, Levantamento inédito analisa as mortes por raios no Brasil e orienta como as pessoas devem se proteger. Inpe, 2020. Disponível em: <inpe.br/webelat/homepage/menu/noticias/release.php?id=80>. Acesso dia 24/03/2021.
- ² INPE. Inpe avalia prejuízos causados por raios, 2007. Disponível em: <inpe.br/noticias/noticia.php?Cod_Noticia=936>. Acesso dia 24/03/2021.
- ³ NATIONAL CENTERS FOR ENVIRONMENTAL PREDICTION/NATIONAL WEATHER SERVICE/NOAA/U.S. DEPARTMENT OF COMMERCE. **NCEP GFS 0.25 Degree Global Forecast Grids Historical Archive**. Research Data Archive at the National Center for Atmospheric Research, Computational and Information Systems Laboratory. 2015, atualizado diariamente. Disponível em: <<https://doi.org/10.5065/D65D8PWK>>. Acesso dia 26/01/2021.
- ⁴ NIELSEN, Michael A. **Neural networks and deep learning**. San Francisco, CA: Determination press, 2015.
- ⁵ SILVA, Caíque. **Redes Neurais aplicadas no reconhecimento de símbolos matemáticos manuscritos online**. São Paulo: Universidade de São Paulo, 2019.