

Predição de Velocidade de Ciclones Tropicais Utilizando Redes Neurais Convolutivas e Detecção de Movimento em Imagens

Matheus Luis Machado Sonogo¹, Alessandro Bof de Oliveira¹, Patricia Bof¹,
Dante Augusto Couto Barone²

¹Campus Alegrete – Universidade Federal do Pampa (UNIPAMPA)
Av. Tiaraju, 810 – Ibirapuitã – 97546-550 – Alegrete – RS – Brazil

{matheussonego.aluno, alessandrooliveira}@unipampa.edu.br

²Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS)
Caixa Postal 15.064 – 91.501-970 – Porto Alegre – RS – Brazil

pati.bof@gmail.com, barone@inf.ufrgs.br

Abstract. *With the scenario of climate change, the behavior of tropical cyclones has become increasingly unpredictable. Currently, several approaches have used convolutional neural networks (CNNs) with good results in predicting cyclone velocity. In this work, we propose a modification of the CNN-TC neural network model by incorporating motion detection preprocessing derived from temporally adjacent images. As a result, the proposed model achieved higher accuracy, yielding a root mean square error (RMSE) 7,55% lower than that of the original method. This outcome motivates us to develop more complex models that incorporate motion detection information.*

Resumo. *Com o cenário de mudanças climáticas, o comportamento dos ciclones tropicais tem se tornado mais imprevisível. Atualmente, existem diversas abordagens que utilizam redes neurais convolutivas (CNN) com bons resultados de predição de velocidade para os ciclones. O objetivo desse trabalho é propor uma modificação do modelo de Rede Neural CNN-TC, adicionando um pré-processamento de detecção de movimento, obtido de imagens adjacentes temporalmente. Como resultado, o modelo proposto teve melhor acurácia, obtendo um valor de raiz do erro médio quadrático (RMSE) 7,55% menor do que o método original. Esse resultado nos motiva a desenvolver modelos mais complexos com informações de detecção de movimento.*

1. Introdução

Ciclones tropicais são tempestades rotacionais formadas em regiões tropicais ou subtropicais. Com as mudanças climáticas, a predição de velocidades de vento sustentável dos ciclones tem se tornado ainda mais relevante e desafiadora, pois as características dos ciclones vêm se alterando ao longo do tempo [Deng et al. 2025]. Assim, torna-se fundamental desenvolver métodos mais precisos e ágeis para prever seu comportamento. Com os avanços da Inteligência Artificial, tornou-se possível aplicar redes neurais convolutivas (CNNs) para tarefas de regressão envolvendo imagens [LeCun et al. 1998], como é o caso da previsão de velocidade de ciclones. Existem diversos modelos para prever velocidade de ciclones tropicais através de imagens. O modelo CNN-TC proposto

por [Chen et al. 2018] não possui camadas de *Pooling* [LeCun et al. 1998] e *Dropout* [Srivastava et al. 2014] e obteve resultados satisfatórios na predição. Posteriormente, o modelo CNN-TC sofreu melhorias [Chen et al. 2019], onde foram adicionadas mais informações à rede neural, como região, dia do ano, horário, latitude e longitude. Também foi adicionada uma suavização no pós-processamento, o que fez com que o modelo alcançasse um RMSE de 8,79 nós. Outro modelo, o TCIENet [Zhang et al. 2019], usa duas CNNs em paralelo, em que são alimentadas duas imagens do mesmo ciclone com 30 minutos de diferença do momento em que foram capturadas. A intenção desse modelo é explorar diferenças temporais entre valores de elementos em imagens adjacentes, o que trouxe um resultado de RMSE de 9,97 nós.

2. Metodologia

Nesta seção vamos descrever a base de dados utilizada 2.1, modelo de rede neural utilizado 2.2 e nossa contribuição 2.3.

2.1. Base de dados

A base de dados TCIR [Chen et al. 2018] contém dados de ciclones obtidos nos anos de 2003 a 2017. Esses dados são constituídos de imagens de ciclones tropicais de todas as regiões da Terra obtidas de duas fontes diferentes: GridSat¹, que contém dados de ciclones desde 1981 e CMORPH², que inclui imagens de micro-ondas passiva de 2003 a 2016. A base de dados possui dados de 1285 ciclones com 70.501 imagens coletadas em 4 bandas diferentes, cada uma com 201 por 201 pixels, totalizando cerca de 45 GB. Os 4 canais presentes são: infravermelho (IR1), vapor de água (WV), luz visível (VIS) e micro-ondas passiva (PMW).

2.2. Modelo de rede neural profunda CNN-TC

O modelo CNN-TC proposto por [Chen et al. 2018] utiliza imagens de ciclones de 2003 a 2014 como dados de treinamento e de 2015 a 2016 como dados de validação. As imagens são rotacionadas em um ângulo aleatório para evitar *Overfitting*. Posteriormente, as imagens são recortadas de 201 x 201 pixels para 64 x 64 pixels, permanecendo apenas a parte central e mais importante do ciclone. Nesse modelo, somente as bandas de infravermelho (IR1) e micro-ondas passiva (PMW) são utilizadas, uma vez que a banda no visível (VIS) possui dados apenas durante o dia e a banda de vapor de água (WV) apresenta similaridade com a banda IR1, não contribuindo significativamente com mais informações. O modelo de rede neural convolutiva CNN-TC possui 4 camadas convolutivas e 3 camadas totalmente conectadas, sendo a última camada com apenas um neurônio de saída para a regressão do valor de intensidade do ciclone em nós. O modelo detalhado bem como a configuração dos hiperparâmetros podem ser obtidos em [Chen et al. 2018].

2.3. Contribuição: Adição de informação sobre quantidade de movimento no modelo

Nossa proposta consiste na adição de uma banda no pré-processamento com informação da detecção de movimento dos ciclones. Essa nova banda (Diff) é obtida através da

¹<https://essd.copernicus.org/articles/10/1417/2018/>

²<https://ipad.fas.usda.gov/cropexplorer/Definitions/cmorph.htm>

diferença de imagens adjacentes temporalmente na banda (IR1) do Infravermelho, ou seja, a diferença da imagem I^n e a imagem I^{n-1} , como mostra a equação 1:

$$\text{Diff}_i^n = \text{abs}(I_i^n - I_i^{n-1}), \quad (1)$$

onde n representa o índice temporal, i o índice do ciclone, e $\text{abs}(\cdot)$ é a função de módulo. Um exemplo de detecção de movimento pode ser visto na Figura 1. Dessa forma, além

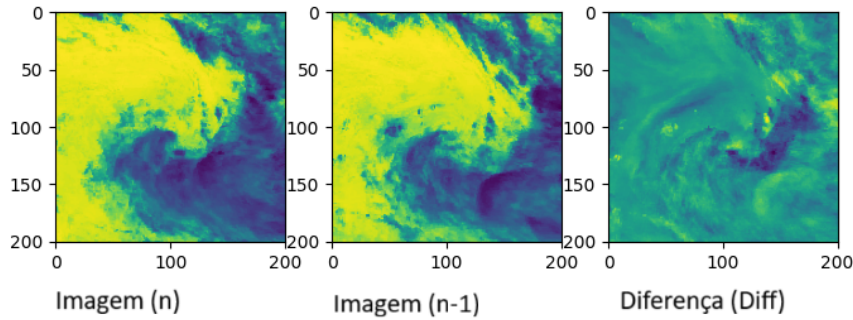


Figura 1. Exemplo de imagem de detecção de movimento no canal infravermelho obtida com a subtração de imagens temporalmente adjacentes.

de realizar o cálculo da detecção de movimento para imagens adjacentes na banda do infravermelho, essa imagem é adicionada como terceiro canal na composição de imagens que servem de entrada para a rede neural convolutiva sendo a dimensão anterior ($64 \times 64 \times 2$), passando para ($64 \times 64 \times 3$), adicionando mais uma camada de informação.

3. Resultados

Os modelos foram desenvolvidos na linguagem de programação Python [Foundation 2024] utilizando a biblioteca Keras [Chollet et al. 2015] e rodaram no ambiente computacional em nuvem Kaggle³ com uma placa de rede P100 da NVIDIA⁴. Implementando o modelo original, na época, 452 obteve-se o resultado de RMSE de 10,19 com 10 rotações. A melhoria proposta com a adição da camada de detecção de movimento fez com que o melhor resultado fosse obtido na época 292 com RMSE de 9,42. Ou seja, além da melhora do RMSE do modelo em 7,55%, o mesmo convergiu de forma mais rápida. A Tabela 1 faz a comparação dos resultados de RMSE de modelos da literatura com a nossa proposta. A nossa proposta teve resultado consideravelmente melhor que o modelo original, o que mostra a vantagem da adição da informação de detecção de movimento ao modelo CNN.

4. Conclusões

Neste trabalho foi realizada a modificação do modelo CNN-TC, originalmente proposto por [Chen et al. 2018], com o objetivo de melhorar a predição da velocidade de ciclones tropicais a partir de imagens de satélite. A principal modificação consistiu na adição de uma nova banda de imagem representando a diferença temporal entre imagens adjacentes,

³<https://www.kaggle.com/>

⁴<https://www.nvidia.com/pt-br/>

Tabela 1. Resultados comparativo dos modelos utilizando redes neurais convolutivas.

Modelo	Referência	RMSE (nós)
CNN-TC detecção de movimento	Modelo proposto	9,42
CNN-TC modelo base	[Chen et al. 2018]	10,19
CNN-TC com suavização	[Chen et al. 2019]	8,79
CNN com <i>Wavelets</i>	[Zhang et al. 2025]	8,98
TCIENet	[Zhang et al. 2021]	9,59

incorporando assim informações de detecção de movimento no processo de predição. Os resultados obtidos indicaram melhora significativa no desempenho do modelo, com redução do erro médio (RMSE) em relação ao modelo original da ordem de 7,55%.

Referências

- Chen, B., Chen, B.-F., and Lin, H.-T. (2018). Rotation-blended cnns on a new open dataset for tropical cyclone image-to-intensity regression. In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pages 90–99. ACM.
- Chen, B.-F., Chen, B., Lin, H.-T., and Elsberry, R. L. (2019). Estimating tropical cyclone intensity by satellite imagery utilizing convolutional neural networks. *Weather and Forecasting*, 34(2):447 – 465.
- Chollet, F. et al. (2015). Keras. <https://keras.io>.
- Deng, Z., Villarini, G., and Wang, Z. (2025). Climate change dominates over urbanization in tropical cyclone rainfall patterns. *Communications Earth & Environment*, 6(1):54.
- Foundation, P. S. (2024). Python language reference, version 3.x. <https://www.python.org/>.
- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1):1929–1958.
- Zhang, C.-J., Chen, M.-S., Ma, L.-M., and Lu, X.-Q. (2025). Deep learning and wavelet transform combined with multi-channel satellite images for tropical cyclone intensity estimation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*.
- Zhang, C.-J., Wang, X.-J., Ma, L.-M., and Lu, X.-Q. (2021). Tropical cyclone intensity classification and estimation using infrared satellite images with deep learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14:2070–2086.
- Zhang, R., Liu, Q., and Hang, R. (2019). Tropical cyclone intensity estimation using two-branch convolutional neural network from infrared and water vapor images. *IEEE Transactions on Geoscience and Remote Sensing*, 58(1):586–597.