

Modelo neural para previsão probabilística da precipitação

Otavio Medeiros Feitosa¹, Vinicio Lima Santos², Laiz Cristina Rodrigues Mello³, Bruna Larissa Rabelo dos Reis⁴, Saulo Ribeiro de Freitas⁵, Haroldo de Campos Velho⁶

¹ Instituto Nacional de Pesquisas Espaciais, Cachoeira Paulista/SP, Brasil

² Instituto Nacional de Pesquisas Espaciais, Cachoeira Paulista/SP, Brasil

³ Universidade de São Paulo, São Paulo/SP, Brasil

⁴ Instituto Nacional de Pesquisas Espaciais, Cachoeira Paulista/SP, Brasil

⁵ Instituto Nacional de Pesquisas Espaciais, São José dos Campos/SP, Brasil

⁶ Instituto Nacional de Pesquisas Espaciais, São José dos Campos/SP, Brasil

*otaviomf123@gmail.com

RESUMO

Prever a precipitação é de suma importância para diversas áreas da sociedade, a chuva, ou a falta dela, definem tomadas de decisões em setores econômicos, políticos e relacionados a recursos humanos. A previsão se torna ainda mais complicada quando elevamos para um domínio global, isso ocorre pois, nessa escala temos diferentes fatores físicos e dinâmicos que impactam na atmosfera forçados por diferentes regiões. Atualmente, existem diversos tipos de modelos numéricos para a previsão, porém, devido às limitações computacionais e sobre os conhecimentos físicos em relação a natureza caótica da atmosfera, temos uma imprecisão agregada nos resultados obtidos. Visando melhorar a precisão de modelos de precipitação global, foi elaborado um modelo de previsão probabilística utilizando redes neurais. Foram implementadas redes convolucionais, conv-transpostas e 3D-DenseUNet sobre os dados de precipitação coletados por estações do INMET para elaboração do modelo. Os resultados mostram um bom desempenho do modelo probabilístico, visto que o mesmo conseguiu manter tendência de aumento do erro com o tempo e obteve um melhor desempenho posicional de regiões de precipitação quando comparado a dados do ERA 5. Conclui-se que, mesmo em fase inicial de desenvolvimento, o modelo proposto foi capaz de reproduzir resultados semelhantes a modelos numéricos, com um baixo custo computacional e com significado para uso sinótico.

Palavras-Chave: Modelos probabilísticos, Chuva, conv-transpostas, 3D-DenseUNet, redes convolucionais.

1. INTRODUÇÃO

A precipitação é um fenômeno que possibilita o desenvolvimento em diversas áreas da sociedade, variando entre a produção de alimentos, energia, manutenção do ciclo hidrológico, prevenção de desastres, entre outras áreas. De acordo com Schardong (2014), citado por Bozzini (2020, p.100), os modelos climáticos e regionais são importantes

ferramentas de estudos para sistemas hídricos, sendo esses importantes peças nas tomadas de decisões.

A previsão da precipitação global configura-se como um grande desafio a ser enfrentado. Nos últimos anos, diferentes tecnologias e métodos voltaram-se a melhorar e auxiliar a modelagem numérica do tempo (estocástica), porém, devido aos erros numéricos, desconhecimento em áreas da natureza física da atmosfera somado à incerteza na qualidade das condições iniciais, se faz necessário explorar diferentes alternativas visando aumentar a precisão da previsão.

A implementação de redes neurais são capazes de alcançar um alto poder de generalização, uma boa habilidade para lidar com problemas relacionados a variáveis discretas (precipitação), onde a natureza puramente probabilística destaca-se (Ventura, 2005). Trabalhos como o de Dantas, Daniel, et al. (2016), Sousa, Rafaela et al. (2017), Anochi (2016), exploram essa ferramenta, através de diferentes estruturas, para a criação de modelos de previsão da precipitação, em diferentes escalas temporais e espaciais, conforme especificado nos objetivos de cada trabalho.

Neste trabalho utiliza-se a técnica de redes convolucionais e conv-transpostas. A Rede Neural Convolucional (RNC) foi introduzida por LeCun et al. (1989), em contraste com as redes neurais sem realimentação (*feed-forward*) clássicas com camadas totalmente conectadas, às RNC possuem a vantagem de serem conectadas a apenas um subconjunto de nós da camada anterior. Essa conectividade local possibilita a manipulação de dados, ou seja, possibilita trabalhar com dados que possuem uma dimensionalidade que muitas vezes é grande demais para redes neurais clássicas. Os dados utilizados (estações do INMET sobre o território brasileiro) neste trabalho encaixam-se como um problema a ser solucionado por essa estrutura (LeCun et al. 1989). O 3D-DenseUNet, (ferramenta utilizada) é ideal para o dados tridimensionais, visto que esse tipo de modelo trabalha de acordo com fatias de entradas volumétricas (ALALWAN, Nasser et al., 2021).

Autoencoders consistem em um tipo específico de redes neurais feedforward, cuja entrada é equivalente à saída. A entrada é comprimida em código de menor dimensão e, em seguida, reconstruem a saída dessa representação. O código é um “resumo” ou “compressão” compacto da entrada, também chamado de representação do espaço latente. Um *autoencoder* consiste em 3 componentes: codificador, código e decodificador. O codificador comprime a entrada e produz o código, o decodificador então reconstrói a entrada usando apenas esse código. Sinais puros só existem em teoria, no contexto de medições meteorológicas uma série

de erros podem ocorrer e comprometer as medições e no contexto de processamento de sinal, é muito provável que estes ‘erros’ associados a medições sejam considerados ruídos

2. METODOLOGIA

2.1 Dados de treinamento

As análises desenvolvidas pelo National Center for Atmospheric Research (NCEP) são implementadas nas análises do modelo global *Global Forecast System* (GFS). O conjunto de dados originalmente armazenados no Centro Nacional de Pesquisa Atmosférica (NCAR) tiveram início em em julho de 1976 e atualmente é atualizado continuamente de forma diária. Como parte de um projeto de pesquisa apoiado pela *National Science Foundation* (NSF), os dados do NCEP foram processados pelo NCAR e são oriundos do processamento diário às 00 UTC e 1200 UTC, interpolados para valores ausentes e em seguida calcula-se a média diária a partir deste conjunto de dados.

Após definir o conjunto de dados observados, os mesmos são implementados como dados de entrada do modelo, pois há a capacidade de utilização de forma operacional das variáveis descritas na tabela 1, possibilitando atualizações de forma diária. O espaçamento de grade do modelo é 2.5° e os dados utilizados para o conjunto de treinamento começam de forma diária desde o ano de 1982.

Tabela 1. Variáveis utilizadas para treinamento do modelo e entrada

Variável	Quantidade de níveis	Níveis de pressão(hpa)
Altura Geopotencial	12	1000, 850, 700, 500, 400, 300, 250, 200, 150, 100, 70, 50
Temperatura	12	1000, 850, 700, 500, 400, 300, 250, 200, 150, 100, 70, 50
Humidade Relativa	12	1000, 850, 700, 500, 400, 300, 250, 200, 150, 100, 70, 50
Vento Meridional (V)	12	1000, 850, 700, 500, 400, 300, 250, 200, 150, 100, 70, 50
Vento Zonal (U)	12	1000, 850, 700, 500, 400, 300, 250, 200, 150, 100, 70, 50
Água Precipitável	1	Superfície
Temperatura da superfície	1	Superfície
Pressão da superfície	1	Superfície

2.2 Dados de precipitação

O conjunto de dados de saída do modelo é definido pela reanálise do modelo global European Centre for Medium-Range Weather Forecasts (ECMWF) do ERA5 com um espaçamento de grade de 0.25° . Diante disso, utiliza-se o campo de precipitação total o qual combina a precipitação convectiva e não convectiva de 10 membros, com o intuito de obter-se a média dos membros, considerando um evento de precipitação valores acima de 1mm na soma dos eventos diários. Para a validação do modelo, os dados de todas as estações fornecidas pelo Instituto Nacional de Meteorologia (INMET) são utilizados com um período de 2015 a 2020, como mostra a figura 1.

Figura 1. Distribuição espacial das estações do INMET utilizadas na validação e cálculo de métricas entre os modelos entre 2015-2020 de forma diária para cada ponto próximo à estação.




2.3 Autoencoder

O *autoencoder*, como mostra a figura 2, é uma rede neural com 2 camadas ocultas na codificação/decodificação da informação. A função de ativação *ReLU* e escolha se deve às propriedades desta função para a minimização do erro. Na camada latente utiliza-se a função de ativação *Tanh*, a função *loss* é selecionada para o cálculo do erro médio

quadrático.

Figura 2. Esquemática da arquitetura utilizada para redução de dimensão da camada vertical atmosférica de 64 entradas para 16, 75% de redução de variáveis em relação à original.

Arquitetura utilizada para encodificar as informações da coluna vertical atmosférica



Esquemática da arquitetura neural utilizada para rede UNET-3D como conversão transposta 2D na camada de saída.


2.4 Função *loss* e hiperparâmetros

Para minimização do erro, a função objetiva Focal Loss é aplicada (função *loss*) foi a sendo uma versão da do Cross-Entropy Loss (CE) a qual busca corrigir o problema de desequilíbrio de classe, atribuindo mais pesos a exemplos difíceis ou mal classificados. Portanto, a escolha se deve ao problema da precipitação que não ocorre de forma uniforme e balanceada no planeta em todos os pontos de grade (YEUNG, et al., 2022).

2.5 Arquitetura da rede neural para previsão

A arquitetura escolhida consiste em uma rede do tipo UNET com convolução tridimensional com modificações das camadas finais utilizando convolução transposta bidimensional, a fim de expandir e garantir a mesma quantidade de pontos do conjunto de dados do ERA5- faz-se necessária para o ajuste de grades, pois o conjunto de entrada possui um espaçamento de grade de 2.5° e os dados de saída com um espaçamento de 0.25° , possuindo no total de 721×1440 pontos de grade na saída da rede.

Figura 3. Arquitetura escolhida para realização da previsão com entradas (à esquerda) de dados globais reduzidos no *autoencoder* com resolução de 2.5° de latitude, e a saída da rede a direita sendo amplificada para o tamanho correto da saída a 0.25° .



2.6 Métodos de avaliação

Para avaliação inicial do modelo, aplica-se o F1 score, o qual que combina a Precisão com o *Recall* e a área sob a curva (AUC abreviação em inglês) e origina-se a partir da *receiver operating characteristic curve*, advindos da matriz de confusão, amplamente utilizadas em classificação binária de eventos (Siblini, et al 2020).

3. RESULTADOS E DISCUSSÃO

3.1 Modelo-estações

Ao longo do tempo os resultados mostram oscilações no erro, porém, não há tendência de aumento do erro com o tempo (Figura 4 e 5). Nesse caso, observa-se a estacionariedade, visto que, essa oscilação pode ser atribuída a estações mais chuvosas no país, onde boa parte das estações se encontram, mostrando uma redução em ambos os modelos em relação à estação mais seca.

Figura 4. Comparação do F1 score que considera a precisão e o *recall*, entre modelo neural considerando valores de probabilidade acima ou igual 0.3 e a reanálise do ERA5 considerando valores de precipitação acumulados acima de 1mm/dia comparando com as observações das estações automáticas do INMET (figura 1).





Figura 5. Comparação do AUC que considera a área sob a curva ROC entre valores de probabilidade do modelo neural e a reanálise do ERA5 considerando valores de precipitação acumulados acima de 1mm/dia comparando com as observações das estações automáticas do INMET (figura 1).



3.2 Teste com ciclone bomba

No caso do ciclone bomba ocorrido entre o dia 30 de junho e primeiro de julho de 2020 (Gobato, Heidari, 2020), é possível, através dos resultados obtidos, comparar sua probabilidade de ocorrência na costa sul do Brasil. O modelo probabilístico (Figura 6a.), posicionou as áreas de precipitação, associadas ao evento, mais próximas quando comparado ao observado na Figura 7 (Precipitação estimada pelo IMERG/GPM). Os dados de reanálise do ERA 5, posicionam grande parte da precipitação sobre o continente (figura 6b). Destaca-se que, mesmo em um caso nunca observado pelo modelo neural, o mesmo foi capaz de generalizar, com bom desempenho, o posicionamento de áreas de precipitação em uma ciclogênese explosiva.

Figura 6. a) Previsão do modelo UNET com foco na América do sul, saída proporcional a probabilidade de precipitação > 1 mm/dia. b) Precipitação simulada pela reanálise do modelo ERA 5 utilizado a média de 10 membros, para precipitação total, referentes aos acumulados de precipitação diária do primeiro dia de julho de 2020





Figura 7. Precipitação estimada pelo IMERG/GPM *late run*, que combina diferentes canais de satélite e observações de pluviômetros e estima a precipitação, neste caso para o dia primeiro de julho.



4. CONCLUSÃO

O modelo neural, com o esquema apropriado que compreende as entradas de variáveis meteorológicas no espaço e no tempo, podem viabilizar previsões, com baixo custo

computacional, da probabilidade da ocorrência de precipitação dentro de um determinado intervalo. Técnicas para problemas não-balanceados e hiperparâmetros devem ser utilizados para obter um treinamento correto da rede neural.

Os resultados no tempo são satisfatórios nesta primeira análise diária de 5 anos sem tendência de aumento do erro com o tempo, apenas oscilações sazonais, porém outras métricas estatísticas serão calculadas para diferentes regiões, visando obter as limitações da técnicas para fenômenos específicos de precipitação regionais, assim compreender as limitações e vantagens do modelo perante a modelagem numérica.

A vantagem do presente trabalho frente aos modelos atuais numéricos é o tempo de processamento e a obtenção de resultados próximos a modelagem numérica (figura 4 e 5) e a capacidade de gerar análises que representam o ambiente sinótico de forma satisfatória (figura 6, 7) e bem próximos da reanálise do ERA 5 (figura 6b.) .

5. REFERÊNCIAS

BOZZINI, Pedro Ludovico; MÉLLO JÚNIOR, Arisvaldo Vieira. Previsões de Precipitação de Modelos Atmosféricos como Subsídio à Operação de Sistemas de Reservatórios. *Revista Brasileira de Meteorologia*, v. 35, p. 99-109, 2020.

SCHARDONG, A.; SIMONOVIC, S.P.; GARCIA, J.I.B. O possível efeito de mudanças climáticas e suas incertezas sobre afluências em sistemas de recursos hídricos. *REGA*, v. 11, n. 2, p. 53-65, 2014.

Dantas, Daniel, et al. "Uso de Redes Neurais Artificiais na previsão da precipitação de períodos chuvosos." *Revista Espinhaço* (2016).

DOS SANTOS SOUSA, Rafaela et al. Redes neurais artificiais aplicadas à previsão antecipada de precipitações na região central de Manaus. **IV Escola Regional de Informática Norte I**, p. 1-9, 2017

ANOCHI, Juliana Aparecida; DE CAMPOS VELHO, Haroldo Fraga. Previsão climática de precipitação para a região Sul por rede neural autoconfigurada. *Ciência e Natura*, v. 38, p. 98-104, 2016.

VENTURA, Erico S.; AMORIM, Cláudio A. Otimização da generalização de uma Rede Neural utilizando Algoritmos Genéticos.- Departamento de Ciências Exatas e da Terra, Universidade do Estado da Bahia, 2005.

Lecun, Y., Boser, B., Denker, J., S., Henderson, D., Howard, R., W., Hubbard, W., Jackel, L., D., 1989, "Backpropagation Applied to Handwritten Zip Code Recognition", National Severe Storms Laboratory.

ALALWAN, Nasser et al. Efficient 3D deep learning model for medical image semantic segmentation. *Alexandria Engineering Journal*, v. 60, n. 1, p. 1231-1239, 2021.

YEUNG, M.; SALA, E.; SCHÖNLIEB, C. B.; RUNDO, L. Unified Focal loss: Generalising Dice and cross entropy-based

XXI Encontro dos Alunos de Pós-Graduação em Meteorologia.

Instituto Nacional de Pesquisas Espaciais, 24 a 28 de outubro de 2022.



losses to handle class imbalanced medical image segmentation. **Computerized Medical Imaging and Graphics**, [S. L.], v. 95, n. November 2021, 2022. DOI: 10.1016/j.compmedimag.2021.102026.

ALALWAN, Nasser et al. Efficient 3D deep learning model for medical image semantic segmentation. **Alexandria Engineering Journal**, v. 60, n. 1, p. 1231-1239, 2021. GOBATO, Ricardo; HEIDARI, Alireza. Cyclone bomb hits southern brazil in 2020. **Journal of Atmospheric Science Research**, v. 3, n. 3, 2020.