



Utilização de Redes Neurais Convolucionais Recorrentes na previsão meteorológica de curto prazo (*nowcasting*) utilizando imagens de radar da cidade de Chapecó-SC

Recurrent Neural Networks in short-term weather forecast (*nowcasting*) using radar images in Chapecó-SC

F. C. Rossatto^{1*}; F. P. Härter²; E. H. Shiguemori³; L. Calvetti²

¹Instituto de Física e Matemática, UFPEL, 96160-000, Pelotas-RS, Brasil

²Faculdade de Meteorologia, UFPEL, 96160-000, Pelotas-RS, Brasil

³Instituto de Estudos Avançados, FAB, 12228-001, São José dos Campos-SP, Brasil

*felipe.rossatto@ufpel.edu.br

(Recebido em 08 de março de 2023; aceito em 16 de agosto de 2023)

Neste trabalho, propõe-se uma nova abordagem computacional que faz uso de Redes Neurais Convolucionais Recorrentes, na qual imagens de radar meteorológico são utilizadas para a previsão de propagação e intensidade de tempestades com até 3h de antecedência, conhecida como *nowcasting*. Para tal, utilizou-se imagens do radar meteorológico localizado na cidade de Chapecó-SC. Esses dados são públicos e estão disponíveis no site do Instituto de Pesquisas Espaciais do Brasil (INPE). Para isso, é proposta a avaliação do emprego de uma rede neural convolucional recorrente de aprendizagem espaço temporal chamada *PredRNN++*. Os resultados foram validados através de estudos de casos de tempestades ocorridas na região de cobertura do radar utilizado. Para avaliar a performance da rede neural, além de uma análise visual dos resultados, foram utilizadas as métricas *RMSE* e *SSIM*. Os resultados mostram que a *PredRNN++* foi capaz de simular o formato e local onde ocorreu o sistema meteorológico.

Palavras-chave: redes neurais recorrentes, meteorologia, radar.

In this work, a new computational approach is proposed that leverages Recurrent Convolutional Neural Networks, in which weather radar images are utilized for the prediction of the propagation and intensity of storms with up to 3 hours of anticipation, known as *nowcasting*. To achieve this, images from the weather radar located in the city of Chapecó-SC were used. These data are public and available on the website of the Brazilian National Institute for Space Research (INPE). To accomplish this, the utilization of a recurrent convolutional neural network with spatiotemporal learning, named *PredRNN++*, is suggested. The results were validated through case studies of storms that occurred within the coverage region of the utilized radar. To assess the performance of the neural network, in addition to a visual analysis of the results, Root Mean Square Error (RMSE) and Structural Similarity Index (SSIM) metrics were employed. The outcomes demonstrate that *PredRNN++* was capable of simulating the shape and location where the meteorological system occurred.

Keywords: recurrent neural networks, meteorology, radar.

1. INTRODUÇÃO

O aumento crescente da capacidade computacional, com destaque ao processamento das placas de vídeo (*GPUs*) modernas, a facilidade do acesso e o aumento de armazenamento de dados na última década, tem proporcionado grandes avanços em diversas áreas da computação científica, como descreve Zhu et al. (2017) [1] e Shi et al. (2015) [2].

Dentre as áreas referenciadas, a que mais tem se destacado é a Inteligência Artificial (IA). Isso se deve principalmente devido às novas abordagens de Redes Neurais Profundas, Redes Neurais Convolucionais e as Redes Neurais Convolucionais Recorrentes [3, 4].

As Redes Neurais Artificiais (RNA), embora tenham surgido para a academia na década de 1940 e tenham tido uma pequena expansão em décadas subsequentes com Linnainmaa (1976) [5], foi na década de 80 que Rumelhart e McClelland (1987) [6] apresentaram um modelo que viria

ser base das RNA até nos dias atuais. A partir disso, novos modelos foram propostos, ampliando ainda mais as aplicações nas diversas áreas do conhecimento.

É possível encontrar bases sólidas de RNA aplicadas em áreas como reconhecimento de voz [7], reconhecimento de imagens [8, 9], robótica [10, 11], economia [12, 13] medicina [14, 15], jogos de computadores [16, 17] e o setor de entretenimento [18].

Por outro lado, quando analisamos o estado da arte na meteorologia, a aplicação de inteligência artificial ainda não é tão explorada, como apresenta Salman et al. (2015) [19]. Além disso, analisando o contexto do Brasil, a quantidade de trabalhos acadêmicos na área é bem escassa quando comparamos com a comunidade científica internacional. Quando falamos de previsão meteorológica de curto prazo utilizando imagens de radares, temos poucos trabalhos, sendo o mais relevante o de Bonnet et al. (2020) [20].

Contextualizando a previsão numérica de tempo, destaca-se que os Modelos Numéricos de Previsão de Tempo atingem *skill correlation* superior a 97% de acerto na previsão de determinadas variáveis meteorológicas, na escala de fenômenos de milhares de quilômetros, que perduram por dias, tais como as frentes frias. Entretanto, a previsão de curto prazo (inferior a 3 horas) de fenômenos localizados, tais como tornados, são de difícil previsão. A previsão de tempo para 3 horas a frente, a partir de um estado inicial, é conhecida como *nowcasting* [21].

Como grande parte dos eventos meteorológicos extremos são formados dentro desse espaço de três horas, os modelos de previsão numérica clássicos não são suficientes para prevê-los de uma forma satisfatória. Nos últimos anos, vem se desenvolvendo técnicas de previsões meteorológicas que fazem uso de imagens de radares meteorológicos para buscar alternativas viáveis para o *nowcasting* e, conseqüentemente, melhorar a capacidade de previsão desse tipo de fenômeno atmosférico [22].

Analisando o estado da arte da área, dentre várias metodologias, as Redes Neurais Convolucionais Recorrentes (RNCR) que fazem uso de aprendizagem espaço temporal para a previsão de uma determinada sequência de imagens como o trabalho de Wang et al. (2018) [23], são as que vêm demonstrando resultados mais satisfatórios para o tipo de pesquisa desenvolvida nesse trabalho. Basicamente, uma rede com aprendizagem espaço temporal tem a capacidade de analisar sequências de dados, retirando características que fazem a sequência ser formada, obtendo assim, a capacidade de desenvolver uma previsão futura.

Levando em consideração o exposto, o objetivo principal deste trabalho é avaliar a aplicabilidade de Redes Neurais Convolucionais Recorrentes no campo da meteorologia, como uma alternativa aos modelos clássicos de previsão numérica de precipitação, fazendo uso de campos de refletividade obtidos por um radar meteorológico localizado na cidade de Chapecó-SC. O referido radar foi escolhido por apresentar uma boa quantidade de imagens com qualidade satisfatória, com um bom intervalo de tempo, possibilitando um melhor treinamento da Rede Neural (RN).

O principal motivo para a escolha deste tema foi saber que as técnicas recentes de aprendizado de máquina apresentam um potencial computacional imenso nos estudos dos processos atmosféricos e que possam se tornar uma alternativa muito interessante para o *nowcasting* no Brasil.

2. METODOLOGIA

As imagens de radar foram obtidas na página do INPE. No entanto, um passo importante é tratar estas imagens, cujo processo é obtido com uso de técnicas de pré-processamento para se adequarem ao formato necessário para serem utilizadas pela RNCR. Para este trabalho, foram selecionadas imagens obtidas pelo radar da cidade de Chapecó-SC (Figura 1), o qual apresenta uma altitude de 3 km, um alcance no raio de 250 km, nas coordenadas 27°02'52.7"S 52°36'13.3"W. As especificações do radar foram disponibilizadas pelo próprio INPE.



Figura 1: Raio de cobertura do radar de Chapecó-SC. Fonte: Google Maps (www.google.com.br/maps).

A rede neural escolhida para esse trabalho foi a *PredRNN++*, proposta inicialmente por Wang et al. (2018) [23], evolução da *PredRNN* original Wang et al. (2017) [24], a qual é uma Rede Neural Convolutiva Recorrente (RNCR) otimizada para previsão espaço-temporal. A rede neural utiliza dados de imagens sequenciais no tempo, tornando-se muito interessante no tipo de problema que se busca resolver, já que os dados de radares apresentam esse mesmo formato.

A *PredRNN++* conta com duas estruturas, uma delas é chamada de *Causal LSTM* e é utilizada para capturar dependências e variações complexas na sequência de dados (Figura 2). A outra, chamada de *gradient highway unit* (GHU), tem a função de manter os gradientes estáveis durante o treinamento da rede.

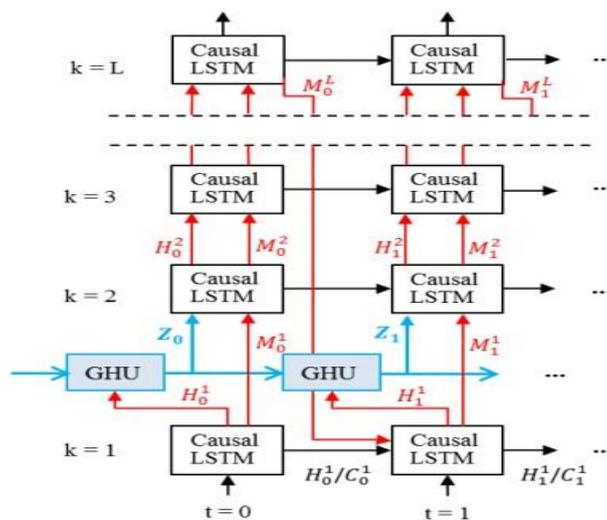


Figura 2: Arquitetura da rede *PredRNN++*. Adaptado de Wang et al. (2018) [23].

Ainda sobre a estrutura da rede neural representada na Figura 2, t representa o passo temporal em que a rede se encontra, k representa a k -ésima camada oculta do modelo, M_t^k e C_t^k representam, respectivamente, a memória espacial e a memória temporal, H_t^k a saída final da rede neural e Z_t o estado intermediário da rede fornecido pelo GHU. Além disso, as ligações azuis indicam as

unidades GHU, conectando o passo atual com as entradas anteriores e as ligações vermelhas mostram as ligações nas camadas profundas da rede [23].

Um passo importante no processo de utilização da RNCR é avaliar a qualidade da previsão. Nesse sentido, foram verificadas duas métricas, a RMSD ou RMSE (Raiz quadrada do desvio padrão/erro médio) [25] e a SSIM (Índice de similaridade estrutural) [26]. Ambas métricas, além de serem utilizadas nos testes originais da *PredRNN++*, são difundidas em outros modelos preditivos utilizando redes neurais.

O treinamento da rede neural foi realizado com 20.000 imagens de radares, que representam leituras de refletividade entre janeiro de 2020 e março de 2022. Essas imagens foram dispostas em 1.000 sequências de 20 imagens cada e foram divididas entre 800 sequências para treinamento da rede e 200 sequências para validação. Levando em consideração a estrutura da *PredRNN++*, essas 20 imagens dentro de uma sequência representam a entrada com 50 minutos no passado (10 imagens) e são utilizadas para prever 50 minutos no futuro (10 imagens). Cabe ressaltar que o radar utilizado registra leituras de 5 em 5 minutos e, por esse motivo, temos uma sequência com esse tempo específico. Exemplos destas imagens são ilustrados na Figura 3.

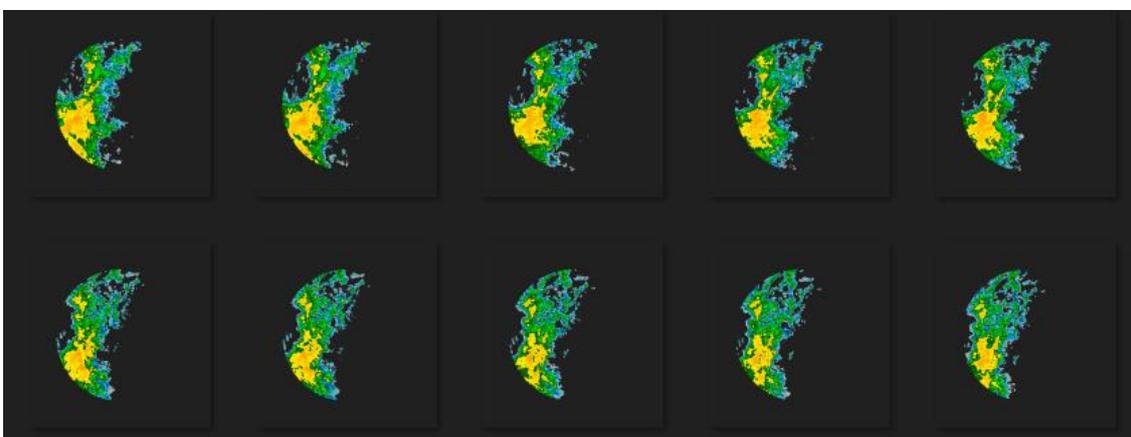


Figura 3: Exemplo de imagens (sem processamento) retiradas do radar. Fonte: Instituto Nacional de Pesquisas Espaciais [27].

De modo geral, as arquiteturas de redes neurais já definidas, como é o caso da *PredRNN++*, já possui topologia definida e, com isso, para as imagens do radar se adequarem a rede utilizada, foi necessário convertê-las para escala de cinza e redimensioná-las de 500x500 pixels para 64x64 pixels. Normalmente, a fase de treinamento das redes neurais convolucionais necessita de mais poder computacional que as redes neurais clássicas e, desta forma, o treinamento da rede neural foi realizado utilizando uma placa de vídeo *NVIDIA Tesla P100* disponibilizada pelo serviço de nuvem *Google Colab*. Como exemplo do tempo computacional necessário para este trabalho, o treinamento demorou aproximadamente 30 horas para ser finalizado. Após o treinamento para gerar um resultado (previsão), a rede neural levou, aproximadamente, 30 segundos.

2. RESULTADOS E DISCUSSÃO

Para demonstrar a capacidade preditiva da rede neural, foram selecionados três casos em que ocorreram tempestades severas na região de abrangência do radar. A seguir serão apresentadas as datas e breves descrições sobre os eventos citados.

1º Caso – Ocorrido no dia 21/06/2022, apresentou chuvas fortes, tempestade com granizo e ventos próximos de 70 km/h.

2º Caso – Nesse caso do dia 14/08/2020, aconteceram tornados com ventos acima de 100 km/h, tempestades de granizo e chuvas fortes.

3º Caso – O último caso utilizado foi o registro da passagem de um ciclone bomba pelo estado de Santa Catarina, no dia 03/06/2020. O ciclone bomba trouxe ventos acima de 100 km/h e chuvas fortes e mudanças drásticas na temperatura.

Em todos os casos utilizados nesse trabalho, a Defesa Civil do Estado de Santa Catarina, cuja cidade de Chapecó está localizada, declarou estado de emergência e contabilizou mais de 100 mil pessoas afetadas pelas tempestades. Todas as informações citadas sobre esses eventos, foram retiradas do site da própria Defesa Civil do Estado de Santa Catarina [28].

Cabe ressaltar que os três casos utilizados para testar a *PredRNN++* não fazem parte do conjunto de treinamento nem do conjunto de teste. Portanto, com o objetivo de verificar a generalização da rede neural, as previsões são realizadas com dados que não foram apresentados a mesma anteriormente.

As Figuras 4, 5 e 6 representam a saída da rede *PredRNN++* com os resultados da previsão. A primeira linha representa os dados de entrada (... , t-10, t-15, t), a segunda linha representa a verdade terrestre e a terceira linha representa a previsão gerada pela rede (previsão em t+5, t+10, t+15, ...).

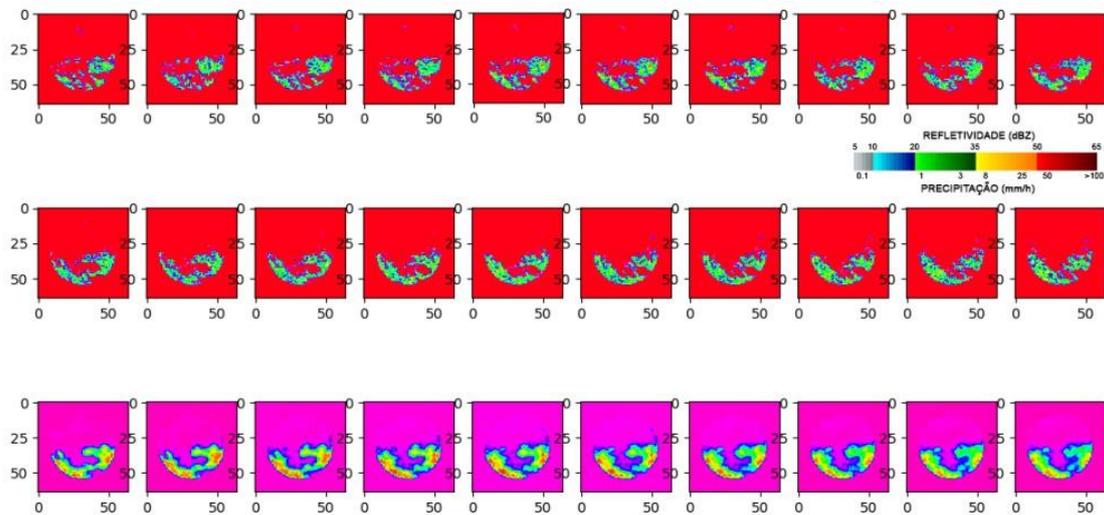


Figura 4: Saída da rede neural do 1º caso.

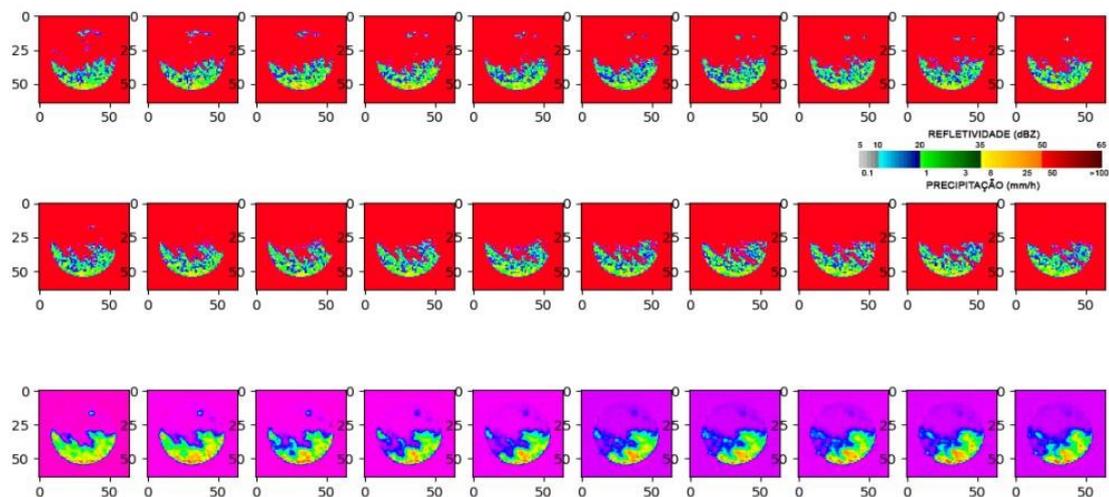


Figura 5: Saída da rede neural do 2º caso.

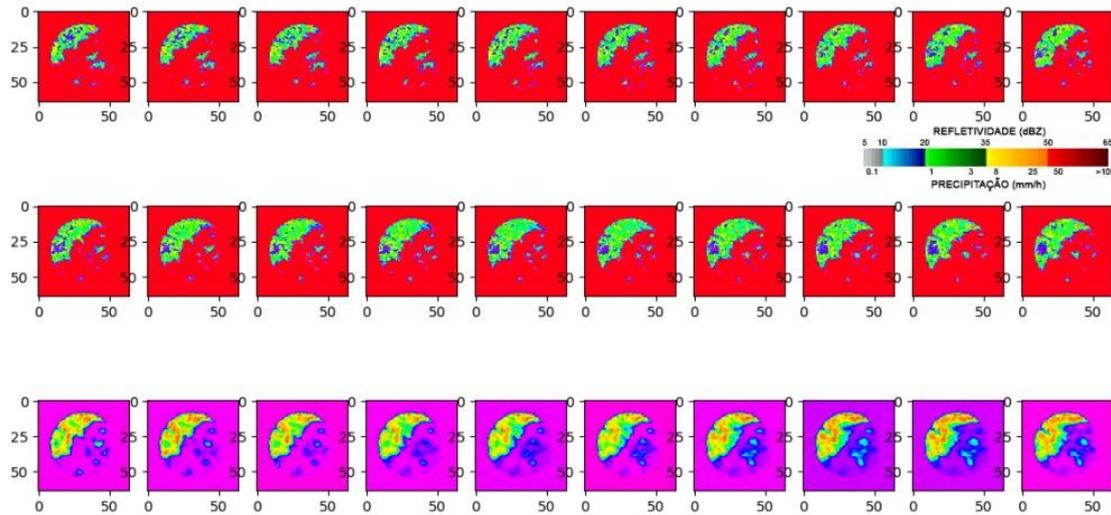


Figura 6: Saída da rede neural do 3º caso.

Numa análise subjetiva dos resultados obtidos, é possível observar que a PredRNN++ simula a localização e o formato do sistema meteorológico nos três casos apresentados. Porém, os níveis de intensidade de refletividade previstos (analisando pela escala) superestimam a verdade terrestre.

Usando as métricas estatísticas para avaliação do modelo, obtém-se os seguintes resultados na Tabela 1:

Tabela 1: Resultados das métricas avaliativas.

1º Caso					
Tempo	t+5	t+10	t+15	t+20	t+25
RMSE	0,1448	0,1489	0,1503	0,156	0,1597
SSIM	0,8034	0,8012	0,8004	0,7876	0,7825
Tempo	t+30	t+35	t+40	t+45	t+50
RMSE	0,162	0,1678	0,1744	0,1776	0,1812
SSIM	0,7784	0,7761	0,773	0,7644	0,7635
2º Caso					
Tempo	t+5	t+10	t+15	t+20	t+25
RMSE	0,1478	0,1491	0,1508	0,1566	0,1604
SSIM	0,8110	0,8089	0,7994	0,7957	0,7771
Tempo	t+30	t+35	t+40	t+45	t+50
RMSE	0,1604	0,1715	0,1764	0,1766	0,1791
SSIM	0,7732	0,7688	0,7622	0,7609	0,7587
3º Caso					
Tempo	t+5	t+10	t+15	t+20	t+25
RMSE	0,1578	0,1610	0,1638	0,1683	0,1704
SSIM	0,7984	0,7952	0,7920	0,7894	0,7833
Tempo	t+30	t+35	t+40	t+45	t+50
RMSE	0,1722	0,1767	0,1780	0,1784	0,1799
SSIM	0,7809	0,7742	0,7721	0,7631	0,7608

Para questão de análise, o SSIM mede o índice de similaridade de duas imagens dadas onde, quanto mais próximo de 1 é o resultado, mais parecidas elas são. Já o RMSE calcula a raiz quadrática média dos erros entre valores da verdade terrestre e as previsões. Quanto mais próximo de zero é esse valor, melhor é a qualidade da previsão. Os resultados mostram-se coerentes à medida que os erros aumentam com o aumento do horizonte de previsão.

4. CONCLUSÃO

A previsibilidade das condições meteorológicas sempre foi um fator crucial dentro de qualquer sociedade moderna e, mais do que isso, aperfeiçoar a capacidade de prever fenômenos meteorológicos extremos (tempestades, inundações, ventos fortes, etc) é uma característica importante para evitar não só perdas materiais como perdas de vidas humanas causadas por esses fenômenos.

Levando isso em consideração, acredita-se que os resultados apresentados neste trabalho demonstram que as Redes Neurais Convolucionais Recorrentes possam ser grandes aliadas na previsão de eventos meteorológicos extremos e auxiliar na prevenção de possíveis perdas causadas pelos mesmos. Embora seja uma área relativamente pouco explorada no Brasil, a rede neural apresentada, demonstrou resultados promissores utilizando os dados disponibilizados.

Em trabalhos futuros, pretende-se avaliar o desempenho deste modelo neural em estudos de caso que causaram danos em torres de transmissão de energia elétrica, enriquecer a avaliação dos resultados através de tabela de contingência e tornar o método operacional para a previsão de *nowcasting*.

5. REFERÊNCIAS BIBLIOGRÁFICAS

1. Zhu XX, Tuia D, Mou L, Xia G-S, Zhang L, Xu F, et al. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geosci Remote Sens Mag.* 2017 Dec;5(4):8-36. doi: 10.1109/MGRS.2017.2762307
2. Shi X, Chen Z, Wang H, Yeung D-Y, Wong W, Woo W. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *NIP'15: Proceedings of the 28th International Conference on Neural Information Processing Systems.* 2015 Sep;1:802-10. doi: 10.5555/2969239.2969329
3. Wani MA, Farooq AB, Saduf A, Asif IK. *Advances in deep learning.* Singapore: Springer Singapore; 2020.
4. Antonio Aceves-Fernandez M, editor. *Advances and applications in deep learning.* Croatia: IntechOpen; 2020. doi: 10.5772/intechopen.87786
5. Linnainmaa S. Taylor expansion of the accumulated rounding error. *BIT.* 1976 Jun;16(2):146-60. doi: 10.1007/BF01931367
6. Rumelhart DE, McClelland JL. Learning internal representations by error propagation. *IEEE Xplore. MITP.* 1987:318-62.
7. Tandel NH, Prajapati HB, Dabhi VK. Voice recognition and voice comparison using machine learning techniques: A survey. *IEEE ICACCS.* 2020 Mar:459-65. doi: 10.1109/ICACCS48705.2020.9074184
8. Traore BB, Kamsu-Foguem B, Tangara F. Deep convolution neural network for image recognition. *Ecol Inform.* 2018 Nov; 48:257-68. doi: 10.1016/j.ecoinf.2018.10.002
9. Chauhan R, Ghanshala KK, Joshi RC. Convolutional Neural Network (CNN) for image detection and recognition. *IEEE Xplore.* 2018 Dec;278-82. doi: 10.1109/ICSCCC.2018
10. Sünderhauf N, Brock O, Scheirer W, Hadsell R, Fox D, Leitner J, et al. The limits and potentials of deep learning for robotics. *Int J Rob Res.* 2018 Apr;37(4-5):405-20. doi: 10.1177/02783649187707
11. Miyajima R. Deep learning triggers a new era in industrial robotics. *IEEE Multimedia.* 2017;24:91-6. doi: 10.1109/MMUL.2017.4031311
12. Huang J, Chai J, Cho, S. Deep learning in finance and banking: A literature review and classification. *Frontiers of Business Research in China.* 2020;14(1):1-24. doi: 10.1186/s11782-020-00082-6
13. Hiransha M, Gopalakrishnan EA, Vijay KM, Soman KP. NSE Stock Market Prediction Using Deep-Learning Models. *Procedia Computer Science.* 2018;132:1351-62. doi: 10.1016/j.procs.2018.05.050
14. Wang F, Casalino LP, Khullar D. Deep learning in medicine—promise, progress, and challenges. *JAMA Intern Med.* 2019 Mar 1;179(3):293. doi: 10.1001/jamainternmed.2018.7117

15. Krittanawong C, Johnson KW, Rosenson RS, Wang Z, Aydar M, Baber U, et al. Deep learning for cardiovascular medicine: A practical primer. *Eur Heart J*. 2019 Feb 27;40(25):2058-73. doi: 10.1093/eurheartj/ehz056
16. Justesen N, Bontrager P, Togelius J, Risi S. Deep learning for video game playing. *IEEE Transactions on Games*. 2019;12(1):1-20. doi: 10.48550/arXiv.1708.07902
17. Skinner G, Walmsley T. Artificial intelligence and deep learning in video games a brief review. *IEEE 4th International Conference on Computer and Communication Systems*. 2019;404-8. doi: 10.1109/CCOMS.2019.8821783
18. Lund J, Ng Y-K. Movie recommendations using the deep learning approach. *IEEE 2018 International Conference on Information Reuse and Integration (IRI)*. 2018 Jul;47-54. doi: 10.1109/IRI.2018.00015
19. Salman AG, Kanigoro B, Heryadi Y. Weather forecasting using deep learning techniques. *IEEE 2015 International Conference on Advanced Computer Science and Information Systems (ICACSIS)*. 2015 Oct;281-285. doi: 10.1109/ICACSIS.2015.7415154
20. Bonnet SM, Evsukoff A, Morales Rodriguez CA. Precipitation Nowcasting with weather radar images and deep learning in São Paulo, Brasil. *Atmosphere*. 2020 Oct 27;11(11):1157. doi: 10.3390/atmos11111157
21. Browning KA, Collier CG. Nowcasting of precipitation systems. *Rev Geophys*. 1989;27(3):345.
22. Camporeale E. The challenge of machine learning in space weather: Nowcasting and forecasting. *Space Weather*. 2019 Aug;17(8):1166-207. doi: 10.48550/arXiv.1903.05192
23. Wang Y, Gao Z, Long M, Wang J, Yu PS. PredRNN++: Towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning. *Proceedings of Machine Learning Research*. 2018 Nov;80:5123-32.
24. Wang Y, Long M, Wang J, Gao Z, Yu PS. PredRNN: Recurrent neural networks for predictive learning using spatiotemporal LSTMs. In: Guyon I, Von Luxburg U, Bengio S, Wallach H, Fergus R, Vishwanathan S, et al, editors. *Advances in Neural Information Processing Systems 30*. California (US): Curran Associates; 2017. p.879-88.
25. Hyndman RJ, Koehler AB. Another look at measures of forecast accuracy. *Int J Forecast*. 2006 Oct;22(4):679-88. doi: 10.1016/j.ijforecast.2006.03.001
26. Wang Z, Bovik AC, Sheikh HR, Simoncelli EP. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*. 2004 Apr;13(4):600-12. doi: 10.1109/TIP.2003.819861
27. Instituto Nacional de Pesquisas Espaciais [INPE; Internet]. Disponível em: <https://www.gov.br/inpe/pt-br>
28. Defesa Civil de SC – DC [Internet]. Disponível em: <https://www.defesacivil.sc.gov.br/>