II Congresso Aeroespacial Brasileiro
De 16 a 19 de setembro

SIMULADOR DE RADAR METEOROLÓGICO USANDO REDES CONVOLUCIONAIS

Otavio Feitosa [a]; Laiz Mello [b]; Lucas Marten[c]; Vinicio Santos [d], Debora Simões [e]; Leonardo Calvetti [f]; Fabrício Harter [g]; João Carlos Viana [h]
[a] UFPEL, otaviomf123@gmail.com
[b] UFPEL, laiz.cristina.96@gmail.com
[c] UFPEL, lucasdmarten@gmail.com
[d] UFPEL, vlsantos5938@gmail.com
[e] UFPEL, debsimoes@gmail.com
[f] UFPEL, lcalvetti@gmail.com
[g] UFPEL, fpharter@gmail.com
[h] UFPEL, jcvianna@ufpel.edu.br

Resumo: *Utilizando rede convolucional, desenvolveu-se uma ferramenta que cria análises de intensidade de precipitação, análogo ao radar meteorológico (ou seja, um radar sintético), utilizando dados do satélite GOES-16 como entrada no modelo.*

Palavras-chave: *Simulador de radar, Nowcasting, Observação sintética, Redes Convolucionais, Deep Learning*

1. INTRODUÇÃO

O Brasil se encontra como o segundo país com a maior quantidades de aeroportos no mundo, conforme o Centro Brasileiro de Infraestrutura. Segundo a Agência Aeroespacial Brasileira (ANAC), o país possui 2.443 aeródromos espalhados por todo território nacional. O tráfego aéreo é de grande importância mundial, pois é responsável pelo transporte comercial e social, sendo indispensável a constante busca pela diminuição dos índices de acidentes aéreos. Devido à importância do mesmo, é indispensável a busca por métodos que ajudem de maneira direta ou indireta.

De acordo com a Organização Meteorológica Mundial (OMM), a previsão de curtíssimo prazo é realizada em um período de tempo entre 0 a 6 horas, sendo esta denominada nowcasting. Se caracteriza pela análise do estado atual da atmosfera com alta frequência temporal para prever o comportamento da atmosfera nas próximas horas ou minutos. O nowcasting é de grande relevância para os Sistemas Convectivos de Mesoescala (SCM), os quais são sistemas de nuvens que provocam um conjunto de tempestades que abrangem uma área de precipitação na ordem de 100 ou mais quilômetros em escala horizontal (MADDOX,1980). Os SCM são regiões que apresentam aglomerações de nuvens convectivas e precipitação estratiforme e parcialmente convectivas (Campos,2008), com duração mínima de 6 horas.

Júnior (2017) considera que com o aumento do custo dos combustíveis, é imprescindível o planejamento da navegação e a análise das variáveis meteorológicas são formas eficazes para definir rotas eficientes e econômicas. Contudo, eventos meteorológicos extremos como chuvas torrenciais e rajadas de vento interferem nas rotas na segurança das aeronaves, devendo ser analisadas de forma rápida e precisa. O nowcasting, associado ao uso de radares meteorológicos, contribui para o rastreamento do tipo de chuva e sua intensidade em curto espaço de tempo, proporcionando uma ferramenta essencial para determinar as condições meteorológicas para o planejamento do voo (Spirkovska et al.,2002).

O funcionamento do radar baseia-se nos fenômenos de espalhamento e reflexão, primordial para a detecção de nuvens, precipitação e classificação dos hidrometeoros. Uma das variáveis fornecidas pelo radar doppler, é o fator da refletividade, obtido pela razão entre a irradiância emitida pelo radar e a recebida por ele depois de retro espalhada pelos hidrometeoros presentes na atmosfera. A unidade utilizada é o dBZ, que é uma

Otavio Feitosa: otaviomf123@gmaill.com

escala logarítmica da refletividade. Os seus valores variam de normalmente de -10 a 60 e quanto maior o valor de refletividade, maiores são os diâmetros dos elementos presentes no volume medido e, consequentemente, maior será a intensidade de precipitação (Calvetti,2002). Contudo, a baixa cobertura de radares no Brasil reduz as possíveis áreas de utilização dessa fermenta.

O Sistema Meteorológico do Paraná (SIMEPAR) é uma das grandes referências do sistema de previsão e monitoramento no Brasil, fornecendo dados, previsões e produtos. O Estado do Paraná é monitorado através da utilização de estações pluviométricas é redes de radares do SIMEPAR (Campos 2008). Tal investimento evidencia que a região Sul do Brasil apresenta elementos favoráveis para a formação e manutenção dos SCM, devido a influência de sistemas de tempo de escala sinótica como Sistemas Frontais (SF) e Jatos de Baixos Níveis (JBN).

Assegurar o tráfego aéreo e reduzir os números de acidentes causados por eventos meteorológicos de curta duração, têm sido foco de inúmeros estudos que visam o desenvolvimento de ferramentas aplicáveis tanto o desenvolvimento de estudos que visam fornecer à indústria quanto aos centros de previsão, uma outra forma de assegurar o tráfego aéreo e reduzir os números de acidentes causados por eventos meteorológicos de curta duração. Uma das tendências, são algoritmos, que compõem um dos tipos de códigos chamados de Deep Learning, associados às Redes Neurais Convolucionais, de acordo com Heye (2017). Tais algoritmos, são adaptados para extrair o contexto espacial de cada pixel, a partir de dados de refletividade de radar. Quando informações que possam ser significativas são detectadas e combinadas com o rápido processamento e treinamento via GPU, os resultados são muito promissores do ponto de vista das previsões.

O desenvolvimento de estudos que visam fornecer a indústria ou centros de previsão, uma outra forma de assegurar o tráfego aéreo e reduzir os números de acidentes causados por eventos meteorológicos de curta duração, são algoritmos, que compõem um dos tipos de códigos chamados de Deep Learning, associados às Redes Neurais Convolucionais, de acordo com Heye (2017), são adaptadas para extrair o contexto espacial de cada pixel, com dados de refletividade de radar que possam ser significativos e combinado com o rápido processamento e treinamento via GPU, as previsões podem ser efetivas para a previsão.

Neste contexto, o presente trabalho visa contribuir com um modelo para a simulação do campo de refletividade, que pode ser obtida através de radares meteorológicos, utilizando dados do satélite GOES 16 como entrada do modelo, voltadas para regiões que não possuem radares meteorológicos. Realizou-se um estudo de caso ocorrido na cidade de Cascavel, no Paraná, no dia 10 de fevereiro de 2019, comparando os dados observados obtidos de radar meteorológico e com aqueles estimados pelo modelo que será desenvolvido neste trabalho.

2. METODOLOGIA

O modelo foi integralmente desenvolvido em linguagem Python. Este recurso, o qual proporciona uma plataforma computacional independente, habilitando o uso de todos os sistemas operacionais que suportem Python. Ademais, outro benefício do modelo é a livre aplicação sobre todo território nacional, incluindo boa parte do território marítimo, obtendo-se a estimativa da refletividade com pouca exigência computacional.

2.1 DADOS

Como entrada do modelo, utilizou-se dados no canal infravermelho do satélite geoestacionário GOES-16 (Schimit, 2017), nos seguintes comprimentos de onda: 6,2μm; 6,9μm; 7,3μm; 8,4μm; 9,6μm; 10,3μm; 11,2μm e 12,3μm. Para a saída do modelo, utilizou-se no treinamento dados de refletividade da rede americana de radar americana NEXRAD (|NEXRAD WSR-88D System) dos estados norte-americanos da Florida, Georgia e Alabama, disponibilizados pela National Oceanic and Atmospheric Administration (NOAA).Estes equipamentos possuem dupla polarização: uma tecnologia que permite distinguir os tipos de hidrometeoros (como chuva, granizo, neve, entre outros) e não-hidrometeoros (como aviões, aves e objetos suspensos),

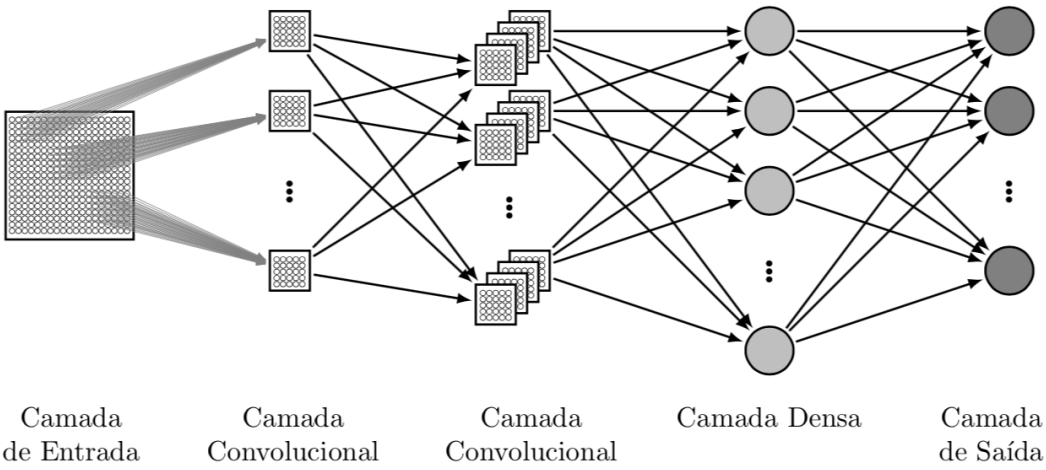
(Melnikov et al.,2006) esperando-se assim reduzir o erro na estimativa do modelo. O período utilizado no treinamento foi do mês de julho a dezembro de 2018 com uma frequência horária de uma hora, sendo este último mês os dados reservados ao conjunto de validação. No total fora processado aproximadamente 2 milhões de pares satélite-radar para o treinamento e cerca de 300 mil pares para validação do modelo.

2.2 REDE CONVOLUCIONAL

A Rede Neural Convolucional (RNC) foi introduzida pela primeira vez por LeCun et al. (1989), esquema de topologia é apresentada na Figura 1. Treinou-se a rede na linguagem Python com a utilização da plataforma Colab, disponibilizado pela Google, apresentando a vantagem do processamento dos dados sem a necessidade de um alto recurso computacional. Em contraste com as redes neurais sem realimentação (feed-forward) clássicas com camadas totalmente conectadas, às RNC são conectadas apenas a um subconjunto de nós da camada anterior. Essa conectividade local é útil para a manipulação de dados, os quais possuem uma dimensionalidade que muitas vezes é grande demais para redes neurais clássicas. Empregou-se o pacote Keras (Python Deep Learning library), que possui uma estrutura de código aberto escrita em Python.

A menor unidade de uma imagem é o pixel, as redes neurais convolucionais exploram esse fato, usando uma compensação, criando uma propensão de pixels mais próximos por estarem mais relacionados do que pixels distantes, criando a partir dessa lógica que inclui identificação e classificação de um conjunto de informações na matriz (Vargas et al., 2016), no caso deste conjunto de entrada, a partir dos dados de informações radiométricas do canal infravermelho do satélite geoestacionário GOES-16.

Figura 1: Exemplo de um esquema de topologia da RNC. Fonte: Rafael Sakurai Big Data Engineer at Tail and Editor at InfoQ Brazil



As camadas de entrada e de saída do modelo são essenciais para o aprendizado Deep Learning. Estas são chamadas de camadas convolucionais e camada densa. Na entrada, foram processados os dados do satélite GOES 16, e na saída, foram adicionados os dados da rede de radares NEXRAD. Os dados de radar e satélite foram transformados em um mapa de comum projeção e a capacidade de treinamento e o conjunto de validação foram analisados com os avanços das épocas que demonstrem resultados válidos.

Os dados foram divididos em duas partes: treinamento (ilustrado na figura 4) e teste. Para o treinamento, utilizou-se dados correspondentes a cinco meses, (tanto dos satélites quanto dos radares), já para os nos testes foram i utilizados dados de apenas um mês. O treinamento teve um intervalo de cinco5 meses, já o período de teste foi de 1um mês.

O conjunto de dados de treinamento seguiu o mesmo esquema apresentado na figura 1. Na camada de entrada foi utilizada os dados do canal janela do infravermelho do GOES- 16. Após o processamento mapeamento das imagens para uma resolução comum, foi combinado, como mostrado acima, é chamada de camada de entrada, a informação se propaga através da rede convolucional como mostrado a camada convolucional. Na saída da rede se encontra o alvo, referente a camada de saída no caso deste trabalho é referente aos dados simulados, ou sintéticos de radar que serão utilizados no treinamento.

2.3 VALIDAÇÃO

A validação do modelo partiu dos métodos básicos estatísticos, aplicando-se as seguintes equações:

$$Raiz\ do\ erro\ médio\ quadrático\ (REMQ) = \sqrt{\frac{1}{n}\sum(Y - \hat{Y})^2} \quad (1)$$

Onde N representa a quantidade de amostras avaliadas, Y a observação, e Ŷ o estimado pelo modelo. Calculou-se também o erro médio absoluto, descrito na equação 2:

$$Erro\ médio\ absoluto\ (EMA) = \frac{1}{N}\sum|Y - \hat{Y}| \quad (2)$$

Onde N representa a quantidade de amostras avaliadas, Y a observação, e Ŷ o estimado pelo modelo. Para complementar a análise estatística do modelo, foi estabelecido o coeficiente de correlação entre os dados observado e estimado, que descreve a associação o ou dependência entre as duas variáveis, onde os valores variam entre 0 e 1 e quanto mais próximo de 1, maior a associação.

2.4 RESULTADOS

No decurso do treinamento da rede, os valores do REMQ são demonstrados na tabela 1, obtido com 2000 épocas de treino, acompanhando a queda do erro para evitar o overfitting do modelo no conjunto de treinamento. A relação do medido-estimado determinou-se os valores como mostrado na tabela 1. Com o intuito de testar modelo, realizou-se uma análise dos dados de radar disponibilizados pelo SIMEPAR, este possui tecnologia de dupla polarização, possibilitando a distinção dos hidrometeoros, empregando somente valores de correlação (RHO) acima de 0.8, apresentados nas figuras a seguir.

Tabela 1: valores de erro e correlação calculados entre o modelo e conjunto de treinamento e validação

Raiz do erro médio quadrático no conjunto de treinamento	7,32
Raiz do erro médio quadrático no conjunto de validação	8,02

Tabela 2: valores de erro e correlação calculados entre estimado-observado

Raiz do erro médio quadrático	3,18
Erro médio absoluto	3,73
Coeficiente de correlação	0,82

Com o intuito de testar modelo, realizou-se uma análise dos dados de radar disponibilizados pelo SIMEPAR que possui tecnologia de dupla polarização, possibilitando a distinção dos hidrometeoros, empregando somente valores de correlação (RHO) acima de 0,8. Os resultados obtidos são demonstrados nas figuras de 5 a 11.

Figura 5: Resultados de refletividade obtidos em: A) refletividade observados no radar entre 3000-4000 m. B) Refletividade Estimativa do modelo, a partir dos dados referentes a 10/02/2019 às 9 UTC.

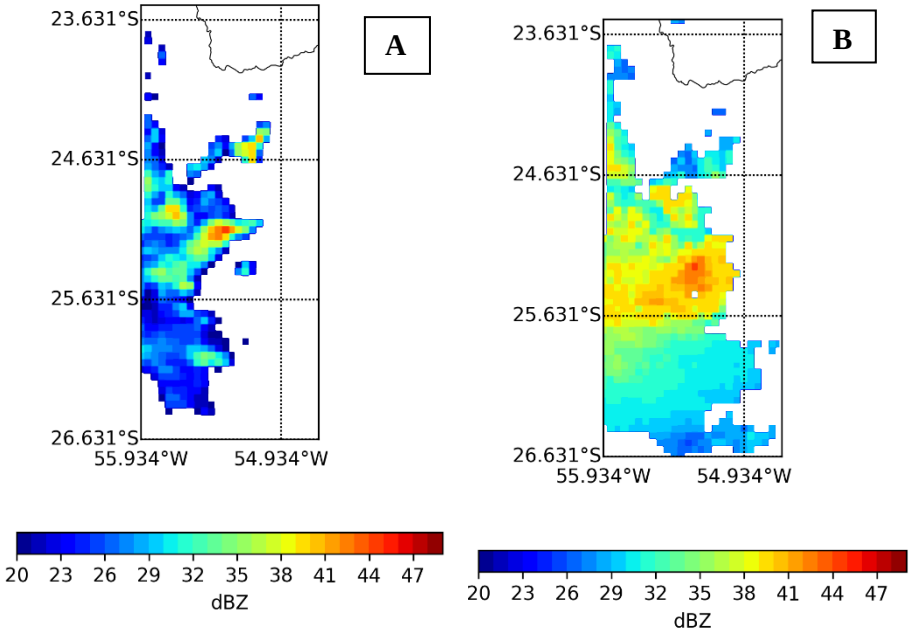


Figura 6: Resultados de refletividade obtidos em: A) refletividade observados no radar entre 3000-4000 m. B) Refletividade Estimativa do modelo, a partir dos dados referentes a 10/02/2019 às 10 UTC.

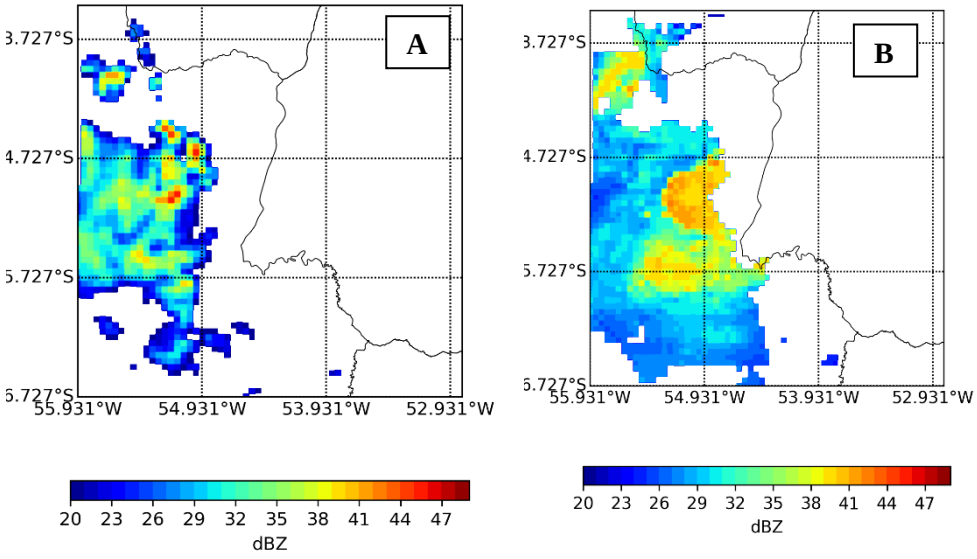


Figura 7: Resultados de refletividade obtidos em: A) refletividade observada no radar entre 3000-4000 m. B) Refletividade Estimativa do modelo, a partir dos dados referentes a 10/02/2019 às 11 UTC.

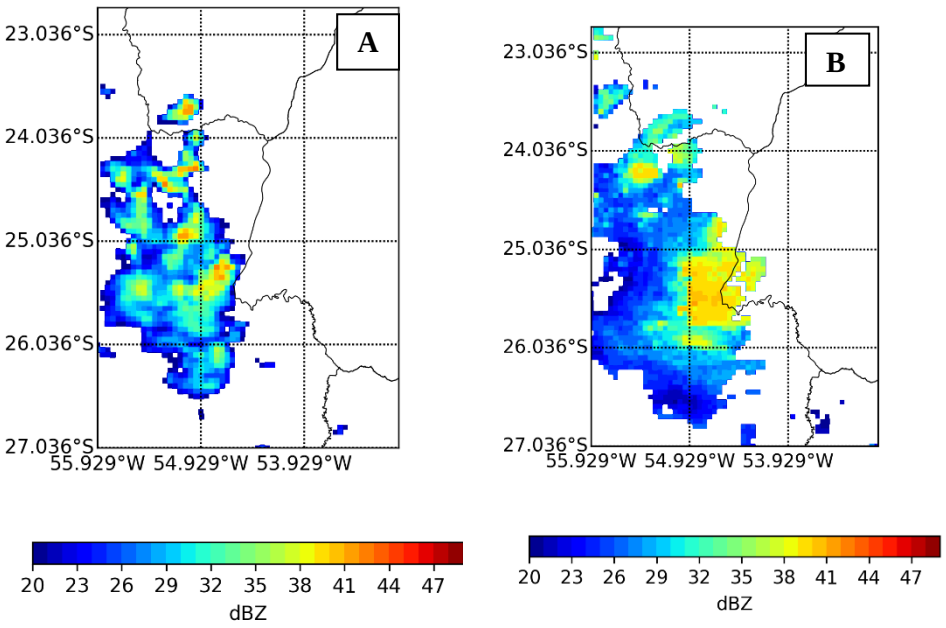


Figura 8: Resultados de refletividade obtidos em: A) refletividade observada no radar entre 3000-4000 m. B) Refletividade Estimativa do modelo, a partir dos dados referentes a 10/02/2019 às 12 UTC.

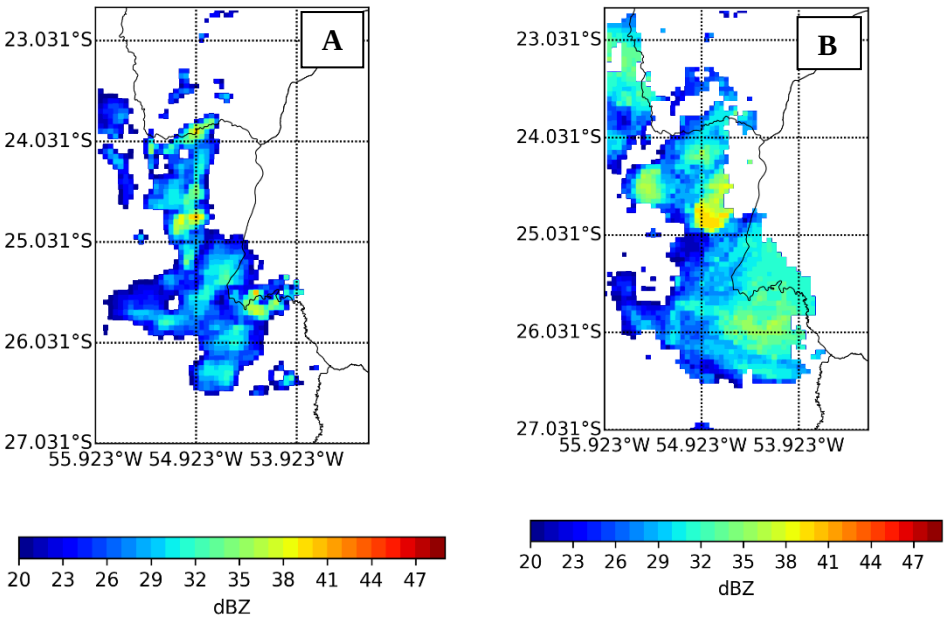


Figura 9: Resultados de refletividade obtidos em: A) refletividade observada no radar entre 3000-4000 m. B) Refletividade Estimativa do modelo, a partir dos dados referentes a 10/02/2019 às 13 UTC.

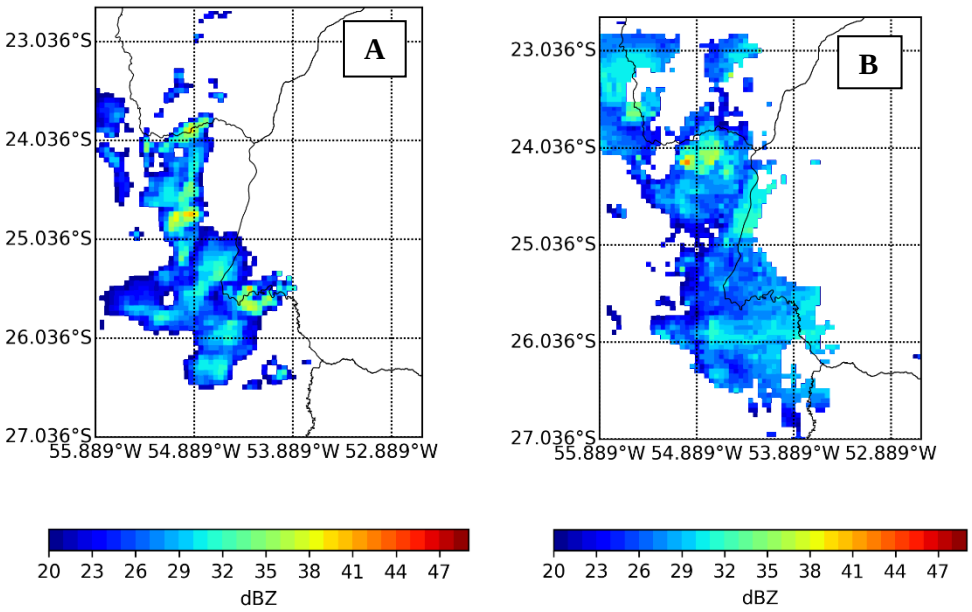


Figura 10: Resultados de refletividade obtidos em: A) refletividade observada no radar entre 3000-4000 m. B) Refletividade Estimativa do modelo, a partir dos dados referentes a 10/02/2019 às 14 UTC.

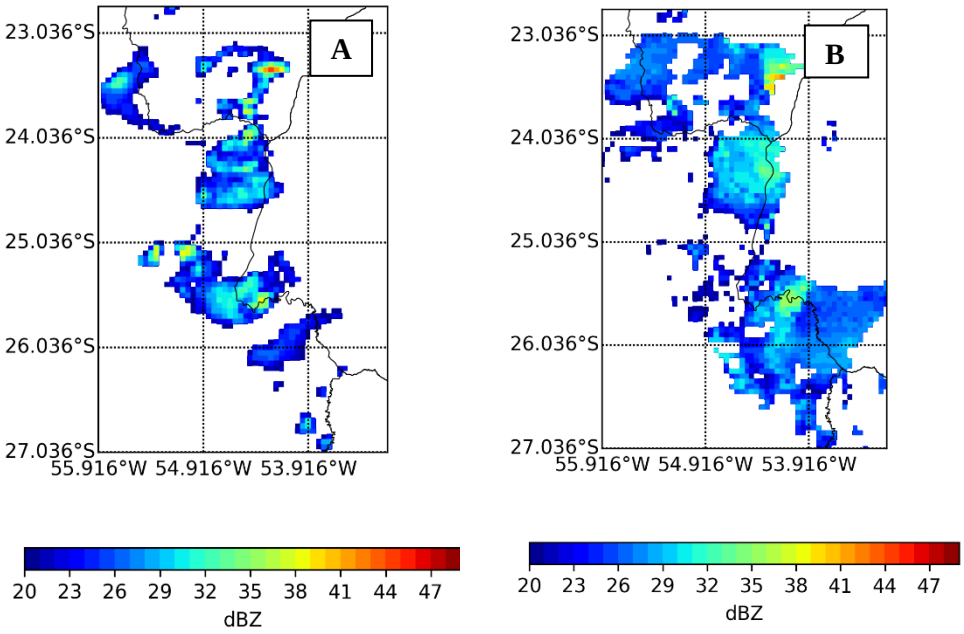
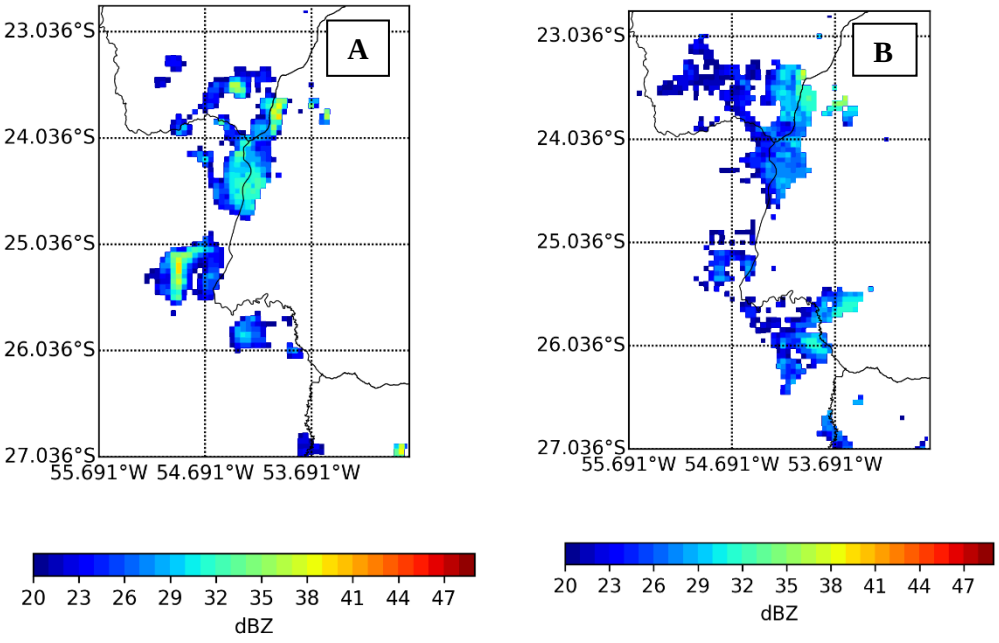


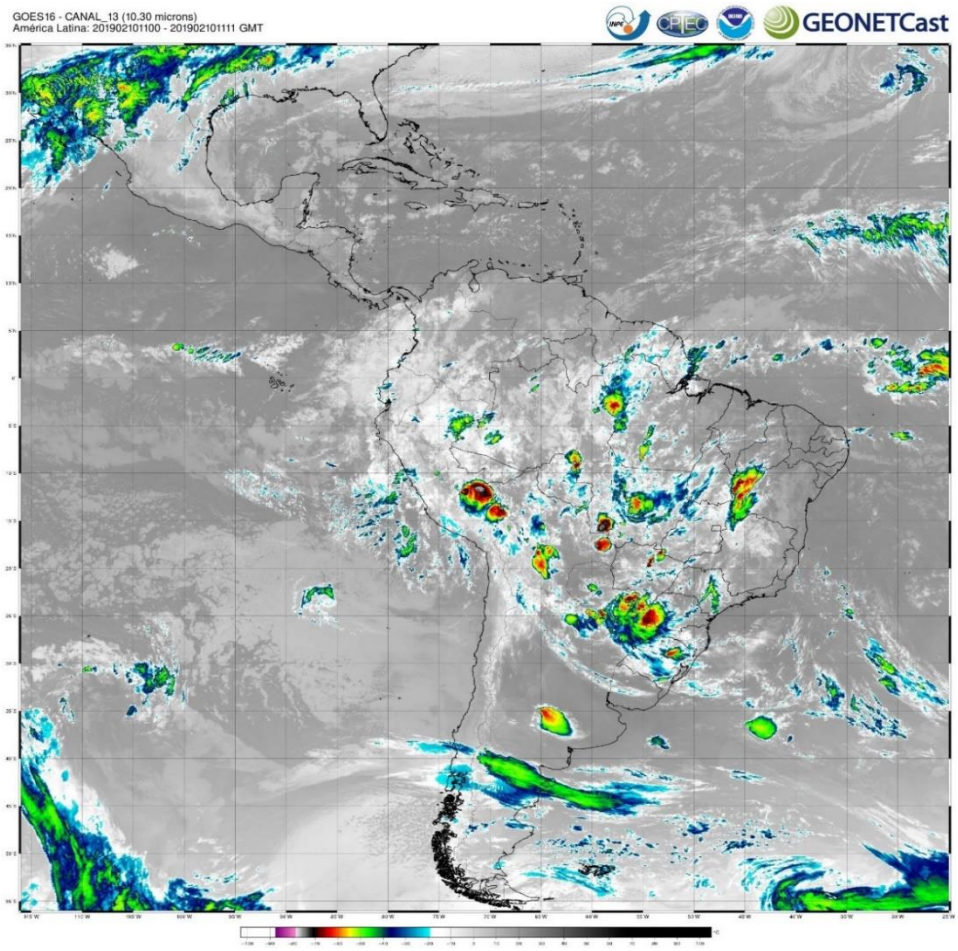
Figura 11: Resultados de refletividade obtidos em: A) refletividade observada no radar entre 3000-4000 m. B) Refletividade Estimativa do modelo, a partir dos dados referentes a 10/02/2019 às 15 UTC.



2.5 DISCUSSÕES

No dia 10/02/2019 às 00 UTC, parte do escoamento associado a Alta Subtropical do Atlântico Sul (ASAS) que adentra o continente deflete para sul, favorecendo o transporte de ar quente e úmido da Região Amazônica para a faixa entre o norte da Argentina e o Paraguai (CPTEC/INPE). Consequentemente, tem origem uma faixa em que são observadas intensas instabilidades na imagem de satélite (Figura 10) no horário das 11 UTC, no oeste do Paraná e Paraguai, onde constata-se é regiões com baixa temperatura de topo (<70°C) associadas a nuvens de grande desenvolvimento vertical.

Figura 10: imagem de satélite GOES-16 do dia 10 de fevereiro às 11 UTC do comprimento de onda 10.3μm (Canal 13)



Nas figuras 5 a 11, o modelo mostrou capaz de representar a trajetória do sistema meteorológico, com movimento predominantemente zonal, e a sua diminuição da intensidade com tempo. Para os valores de erro e correlação encontrados podem ser muito satisfatórios, dependendo a aplicação que serão utilizados, principalmente a relação entre o que está sendo estimado e medido pelo radar no evento. Apesar do modelo não representar os núcleos mais intensos com a mesma intensidade do observado, houve uma boa aproximação espacial entre os valores mais altos medidos pelo radar e a simulação de refletividade.

2.6 CONCLUSÕES

Os resultados obtidos pelo modelo sugerem que em neste caso este simulador pode fornecer informações que facilitam a tomada de decisões, tendo em vista a baixa densidade de radares no território nacional. As estimativas do modelo comparadas ao observado demonstram um produto inovador que pode ser implementado na área operacional auxiliando na prevenção de acidentes aéreos, melhorando a segurança e a economia de combustível nas rotas de voos.

Em trabalhos futuros, sugere-se a análise dos resultados do modelo em um número maior de casos de eventos meteorológicos e em regiões diferentes para melhorar a validação do trabalho proposto, explorando outros tipos de fenômenos atmosféricos que podem interferir na segurança de aeronaves.

7. AGRADECIMENTOS

Os autores agradecem ao MEC pela bolsa PET e ao SIMPAR pela disponibilidade dos dados.

8. REFERÊNCIAS

Cláudia R. J. Campos e Cristiano W. Eichholz, 2011, **"CARACTERÍSTICAS FÍSICAS DOS SISTEMAS CONVECTIVOS DE MESOESCALA QUE AFETAM O RIO GRANDE DO SUL NO PERÍODO DE 2004 A 2008"**, Revista Brasileira de Geofísica vol.29 no.2.

Força Aérea Brasileira, 2016, **Panoramas de Acidentes Aeronáuticos**.

Francisco J.Tapiador, J.Turk, Wal Petersen, Arthur Y.Hou, Eduardo García-Ortega, Luiz A.T.Machado, Carlos F. Angelis, Paola Salio, Chris Kidd, George J.Huffman, Manuel de Castro, 2011, **"Global precipitation measurement: Methods, datasets and applications"**.

Fujita, T. T., 1980.**" Downbursts and microbursts-An aviation hazard"**, USA,8aedição.

Kim,S., Hong,S., Joh,M., Song, S.,2017.**"DEEPRAIN:CONVLSTM NETWORK FOR PRECIPITATION PREDICTION USING MULTICHANNEL RADAR DATA"**, In Anais do 7th Internetional Workshop on Climate Informatics.Setembro 20-22.

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

Lecun,Y.,Boser,B.,Denker,J.,S.,Hwnderson,D.,Howard,R.,W.,Hubbard,W.,Jackel,L.,D.,1989.**"Backpropagation Applied to Handwritten Zip Code Recognition"**, In Institute of Tecnology

Leonardo Calvetti, Cesar Beneti, 2002, **"SISTEMA INTEGRADO DE ANÁLISE E VISUALIZAÇÃO DE DADOS DE RADAR METEOROLÓGICO DOPPLER"**

Melnikov,V.,M.,Ryzhkov,A.,V,.2006, **"Correlation Coefficients between Horizontally and Vertically Polarized Returns from Ground Clutter"**, In Journal of Atmospheric and Oceanic Technology.

Precipitation Nowcasting, 2017, **"Leveraging Deep Recurrent Convolutional Neural Networks"**
SIDNEI F. JUNIOR, 2017, "ADVERSIDADES METEOROLÓGICAS NOS CUSTOS E NA SEGURANÇA DE UMA EMPRESA AÉREA"- , Monografia.

Remi Barillec , Dan Cornford, 2009, **"Data assimilation for precipitation nowcasting using Bayesian inference"**, Neural Computing Research Group, Aston University, Birmingham, West Midland B4 7ET, UK.

Schimit,T.,J.,Griffith,P.,Gunshor,M.,M.,Daniels,J.,M.,Goodman,S.,J.,Lebair,W.,2017.**"A CLOSER LOOK AT THE ABI ON THE GOES-R SERIES"**,.Americal Meteorological Society.

Shi,X.,Gao,Z.,Lausen,L.,Wang,H.,Yeung,D.,2017, **"Deep Learning for Precipitation Nowcasting: A Benchmark and A New Model",** In 31st Conference on Neural Information Processing Systems.

Spirkovska,L.,Lodha,K.S..2002, **"Systems AWE: aviation weather data visualization environment",** In Computhers&Graphics.

Vargas, Carvalho,Vasconcelos, 2016, **"Um estudo sobre Redes Neurais Convolucionais e sua aplicação na detecção de pedestre"**, Instituto de Computação Universidade Federal Fluminense Niterói, Brasil.