$RMSE\ (y,\hat{y}) = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}$

XI Simpósio Internacional de CLIMATOLOGIA
Clima, meio ambiente e desenvolvimento: o futuro da Amazônia
VII SIMCA
XI Simpósio Internacional de Climatologia & VII Seminário Internacional de Meteorologia e Climatologia do Amazonas
18 a 22 de agosto de 2025 | SUDAM – Belém – PA

Avaliação de uma nova ferramenta para o auxílio na tomada de decisão da escolha de cabeceira para pouso

Autores: Amanda Beck[1], Mario Paulo Alves Junior[1]
[1]Instituto de Controle do Espaço Aéreo (ICEA)

1.INTRODUÇÃO

O Instituto de Controle do Espaço Aéreo (ICEA) desenvolveu uma ferramenta de apoio ao controle e gerenciamento do tráfego aéreo denominada cabeceiras. A ferramenta cruza dados do WRF com a orientação das cabeceiras e sugere ao controlador a melhor opção com base na velocidade do vento. O aeroporto escolhido para estudo foi Santos Dumont (SBRJ) que possui um movimento de 73.687 pousos e decolagens de aeronaves anualmente, localizado na cidade do Rio de Janeiro, ao lado da Baía de Guanabara é cercado por morros, como o Morro da Urca e Pão de Açúcar. (IBGE, 2025; NIMER 1989). Esta configuração geográfica é influenciada particularmente por brisas marítimas (PIMENTEL et al., 2014 apud OLIVEIRA-JÚNIOR et al., 2017). O relevo acidentado no entorno e a pista curta, tornam-no um dos mais desafiadores aeroportos do país, sendo de suma importância para o controlador de tráfego aéreo considerar esses fatores para a escolha da pista ativa, que depende da direção e intensidade do vento de superfície.

2.METODOLOGIA

A ferramenta cabeceira fornece previsão de cabeceira em uso para aeródromos do Sistema de Controle do Espaço Aéreo (SISCEAB), esse resultado é obtido através do modelo WRF.

Foram utilizadas as métricas RMSE (Root Mean Squared Error) que caracteriza-se pelo erro quadrático médio e por sua raiz quadrada (CARMO C.R.S et al. 2023). Utilizada em modelos de previsão e regressão em meteorologia.

São utilizadas para avaliar o desempenho do modelo WRF na previsão das variáveis meteorológicas em modelos de previsão e regressão. O RMSE mede o erro quadrático médio entre os valores previstos pelo WRF e os valores observados. E MAPE (Mean Absolute Percentage Error), pela média dos erros percentuais absolutos.

$$\mathrm{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \qquad \mathrm{MAPE} = \frac{100\%}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right|$$

Na metodologia também foi utilizada a matriz de confusão, ou matriz de erro, uma métrica que analisa não só os acertos do modelo quanto também os falsos positivos.

	Dados Previstos	
Dados observados	Dado X	Dado Y
Dado X	Positivo Verdadeiro	Falso Positivo
Dado Y	Falso Positivo	Positivo Verdadeiro

Tabela 1**:** Matriz de confusão

3.RESULTADOS

Foram analisados os valores de RMSE e MAPE para velocidade e direção do vento, que são as variáveis utilizadas como preditoras na ferramenta cabeceiras.

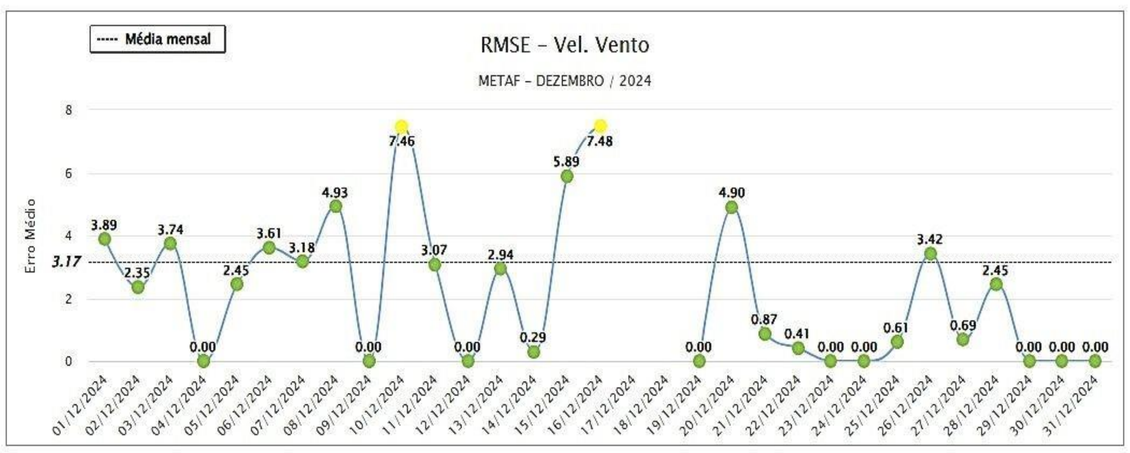

Figura 1 – Resultados de RMSE para a velocidade do vento

Além dos valores de RMSE e MAPE, foi analisada a distribuição de movimentos operacionais (pousos e decolagens) por cabeceira, com o objetivo de relacionar a predominância das operações com os dados de vento. Os resultados evidenciam que 74% das operações ocorreram pela cabeceira 20, que é mais utilizada historicamente no aeroporto Santos Dumont, conforme consta nos anuários estatísticos do DECEA, de 2012 em diante. Enquanto que 26% dos movimentos ocorreram pela cabeceira 02.

Direção observada	Direção prevista							
	E	N	NE	NO	O	S	SE	SO
E	8	4	3	0	4	3	2	4
N	16	12	5	19	6	11	11	6
NE	5	2	1	3	2	2	1	1
NO	14	18	4	5	5	3	9	3
O	2	0	0	2	2	1	0	0
S	41	9	12	10	3	44	93	6
SE	17	4	5	8	13	34	41	12

Tabela 2 – Matriz de Confusão

Seguindo a mesma metodologia de Franzini et al. 2024, sobre a previsão da configuração de pistas no Aeroporto de Congonhas utilizando técnicas de machine learning, foi conduzida uma análise direta para avaliar o desempenho do produto cabeceiras em duas classes de saída, uma direta contabilizando as duas cabeceiras e outra unicamente para a cabeceira 20. A acurácia geral foi 72%, na cabeceira 20 o acerto foi de 84%.

4.CONCLUSÕES

A partir dos resultados obtidos, pode-se perceber que a ferramenta Previsão de Cabeceira apresentou bom desempenho para o aeroporto Santos Dumont, com acurácia de 84 %, considerando a previsão da cabeceira 20, isso indica que o modelo identifica corretamente a maioria das situações em que a cabeceira 20 deve ser utilizada.

As métricas RMSE e MAPE apresentaram baixos valores na maior parte do período, com destaque para dias com erro nulo. A matriz de confusão confirmou a eficácia do modelo nas direções mais frequentes (S e SE). Melhorias são recomendadas para casos com menor acerto, especialmente com ventos de direções incomuns, como indicado na Tabela 2. Ajustes nas parametrizações físicas do modelo WRF podem aperfeiçoar o desempenho.

5.REFERÊNCIAS

BRASIL. Comando da Aeronáutica. Departamento de Controle do Espaço Aéreo. Portaria DECEA/DNOR1 n° 1.537, de 4 de novembro de 2024. Aprova a edição da instrução que dispõe sobre os Serviços de Tráfego Aéreo (ICA 100-37). Boletim do Comando da Aeronáutica, Rio de Janeiro, n. 211, 25 nov. 2024.

CARMO, C.R.S.;SILVA, J.R.M. Aprendizado de máquina e prestação de serviços de armazenamento de dados: métricas para análise e validação de algoritmos previsores. Uberlândia (BRA), 2023. Disponível em: https://revistas.fucamp.edu.br/index.php/getec/article/view/2895. Acesso em: 18 jun. 2025.

DECEA. Anuário estatístico de tráfego aéreo. Rio de janeiro (BRA), 2024. Disponível em: https://performance.decea.mil.br/performance-sisceab-app/produtos/?i=public&prod_part=anuario_estatistico. Acesso em: 23 jun. 2025.

FRANZINI, B. M.; DOMINGUES, T.; SILVA, I. M.; SILVA, P. E.; MELO, A. E.; FORSTER, C. H. Q.; LIMA, J. P. O.; MÁXIMO, M. R. O. A. Predicting runway configuration in the context of the Congonhas Airport using machine learning. Fortaleza (BRA), 2024. Disponível em: https://www.even3.com.br/ebook/xxi-sitraer-2024/904960-predicting-runway-configuration-in-the-context-of-the-congonhas-airport-using-machine-learning/. Acesso em: 23 jun. 2025.

ICEA. Previsão de Cabeceira. 2024. Disponível em: https://pesquisa.icea.decea.mil.br/cabeceira/. Acesso em: 09 jun. 2024.

NIMER. Climatologia do Brasil. Rio de Janeiro: IBGE, 1989. 421 p.

OLIVEIRA-JÚNIOR, J. F.; Terassi, P. M. de B.; Gois, G. de. Estudo da circulação dos ventos na Baía de Guanabara/RJ, entre 2003 e 2013.. Disponível em: https://doi.org/10.5380/abclima.v21i0.51492. Acesso em 09 jun. 2024.

STEHMAN, STEPHEN V. ,1997. «Selecting and interpreting measures of thematic classification accuracy». Remote Sensing of Environment 1: 77–89. doi:10.1016/S0034-4257(97)00083-7.

Realização: SBMET, UFPA, UFAM, UPEC
Patrocínio: Ministério da Ciência, Tecnologia e Inovação – Governo Federal – Brasil União e Reconstrução, CONFEA, CREA, MUTUA, CNPq
Apoio Institucional: SUDAM, UFPB, Embrapa Amazônia Oriental, UERJ, PPGGRD