

Previsão do Risco de Nevoeiro com Aprendizado Profundo: Estudo de Caso no Cais do Porto de Porto Alegre

Lucas dos Santos Azevedo¹, Rafael Manica², Eduardo Puhl²

¹Instituto de Pesquisas Hidráulicas – Universidade Federal do Rio Grande do Sul (UFRGS)
Caixa Postal 15.029 – 91501-970 – Porto Alegre – RS – Brazil Porto Alegre – RS – Brazil

lucas.azevedo@inf.ufrgs.br, manica@iph.ufrgs.br, eduardo.puhl@ufrgs.br

Abstract. This study proposes and validates a two-step pipeline for fog alert forecasting at the Porto Alegre harbor: (i) A multivariate LSTM (Network A) forecasts meteorological variables up to 100 h ahead, based on 318,000 records (REDEMET [SBPA/SBPK, 2003–2024] and local data); (ii) A binary LSTM (Network B) estimates, for each lead time, the probability of fog occurrence using the predictors generated by Network A. In 9,000 simulations, Network B achieved $AUC = 0.936$, $recall = 90\%$, and $accuracy = 82.52\%$ (7,131 true negatives, 477 true positives, 1,471 false positives, 41 false negatives), with false positives concentrated between 2–5 h under high relative humidity and weak winds in a class-imbalanced setting.

Resumo. Este trabalho propõe e valida um pipeline em duas etapas para previsão de alerta de nevoeiro no cais de Porto Alegre. (i) Uma LSTM multivariada (Rede A) prevê, até 100 h à frente, variáveis meteorológicas com base em 318.000 dados (REDEMET [SBPA/SBPK, 2003–2024] e locais); (ii) Uma LSTM binária (Rede B) estima, para cada lead, a probabilidade de nevoeiro usando os previsores gerados pela Rede A. Em 9.000 simulações, a Rede B alcançou $AUC = 0,936$, $recall = 90\%$ e acurácia = 82,52% (7.131 verdadeiros negativos, 477 verdadeiros positivos, 1.471 falsos positivos, 41 falsos negativos), com falsos positivos concentrados entre 2–5 h sob umidade relativa elevada e vento fraco em cenário desbalanceado.

1. Introdução

O impacto do nevoeiro sobre as operações hidroviárias e portuárias em Porto Alegre é significativo. A presença desse fenômeno constitui um dos desafios meteorológicos mais relevantes para o transporte hidroviário e portuário, modal de grande importância econômica no sul do Brasil. O nevoeiro, caracterizado pela presença de gotículas de água em suspensão que reduzem a visibilidade para menos de 1 km, apresenta comportamento fortemente dependente de processos microfísicos, termodinâmicos e da interação entre clima, relevo e dinâmica atmosférica [Gultepe et al. 2007, Silva 2012].

Porto Alegre e sua hidrovia localizam-se em uma região de transição climática, fortemente influenciada por sistemas subtropicais, pela presença de grandes corpos d'água (como o Rio Guaíba e a Lagoa dos Patos) e pelo regime de frentes frias e anticiclo-nes subtropicais [Lima 1982, Fedorova et al. 2019, Michelon 2023]. Estudos anteriores [Willett 1928, Piva 1999, Almeida 2008] mostraram que o nevoeiro em Porto Alegre é predominantemente de dois tipos: (i) *radiação*, originado por resfriamento noturno sob

céu claro e ventos fracos; e (ii) *advecção*, relacionado ao transporte de ar úmido sobre superfícies frias, frequentemente o Guaíba.

Em particular, o nevoeiro (visibilidade < 4.000 m; ventos < 5 m/s) tem sido associado a encalhes na hidrovia local [Michelon 2023, Scotta et al. 2025]. Motivado por esse contexto aplicado, este estudo investiga o uso de aprendizado profundo para previsão do risco de nevoeiro no cais do porto de Porto Alegre, com vistas a apoiar a gestão de riscos e a eficiência operacional.

2. Metodologia

Este estudo propõe um *pipeline* em duas etapas para previsão intradiária e alerta de nevoeiro no cais de Porto Alegre utilizando Redes Neurais Recorrentes do tipo *Long Short-Term Memory* (LSTM). Foram realizadas 9.000 simulações entre maio/2023 e abril/2024. Para avaliar os resultados, foram utilizadas métricas como acurácia média, *recall* médio, área sob a curva ROC (AUC), acurácia global e matriz de confusão (verdadeiros positivos e negativos, falsos positivos e negativos).

2.1. Rede A — LSTM multivariada para previsão dos previsores

A Rede A foi concebida para gerar, a cada ciclo, as 100 horas futuras das variáveis meteorológicas de interesse, contemplando direção e velocidade do vento (`dir_vel` e `vnt_vel`), pressão atmosférica ao nível da estação (`qnh`), umidade relativa (`ur`), ponto de orvalho (`po`) e temperatura do ar (`tt`). Para isso, utilizou-se um conjunto composto por 306.250 registros da API-REDEMET, referentes às estações SBPA e SBPK no período de 2003 a 2024, complementados por 12.589 medições *in loco* no cais do porto, coletadas entre 2021 e 2024. Os dados foram organizados em janelas de 100 *lags*, de modo que as entradas assumiram a forma de tensores (amostras, 100, features) com séries previamente normalizadas.

A arquitetura da rede foi estruturada com uma camada inicial LSTM de 256 unidades associada a um *dropout* de 0,2, seguida por um bloco de sete camadas LSTM empilhadas com 256 unidades cada, cada qual acompanhada de *dropout* de 0,1, resultando em uma saída densa linear que produz, para cada variável, vetores de 100 *leads*. O treinamento foi realizado com o otimizador Adam e a função de perda baseada no erro quadrático médio (MSE), com até 500 épocas. Para prevenir sobreajuste e assegurar estabilidade, foram empregados *callbacks* como *EarlyStopping*, *ReduceLROnPlateau* e *ModelCheckpoint*.

2.2. Rede B — Classificador de nevoeiro

A Rede B foi projetada para estimar, a cada horizonte $h \in \{1, \dots, 100\}$, a probabilidade de ocorrência de nevoeiro, definida como

$$p_{t+h} = \Pr(R = 1 \mid x_{t+h}),$$

em que o rótulo binário $R \in \{0, 1\}$ é estabelecido segundo a seguinte regra operacional:

$$R = \begin{cases} 1, & \text{se } (ur \geq 95\% \wedge \Delta T \leq 2^\circ\text{C} \wedge vnt_vel \leq 5 \text{ m/s}) \vee (Vis \leq 4000 \text{ m}) \vee (S = 1) \\ 0, & \text{caso contrário} \end{cases}$$

com $\Delta T = tt - po$ representando a diferença entre a temperatura do ar e o ponto de orvalho previstos pela Rede A. A entrada da Rede B foi composta por vetores de preditores previstos e derivados ($tt_h, po_h, ur_h, vnt_vel_h$), definidos por busca em grade de forma a maximizar a AUC.

A arquitetura final foi implementada com duas camadas LSTM de 128 células, sendo a primeira configurada para retornar sequências, seguidas de um *dropout* de 0,5 entre as camadas, culminando em uma camada densa com ativação sigmoide e um único neurônio para estimar a probabilidade de ocorrência. O treinamento utilizou a perda binária (*binary cross-entropy*), o otimizador Adam e ajuste de pesos de classe para lidar com desbalanceamento, em 60 épocas por *lead*. A avaliação baseou-se na métrica principal AUC-ROC, complementada por acurácia, matriz de confusão e *recall*. Quando necessário, o limiar τ foi calibrado por critérios como Youden-J ou custo-operacional, em vez de fixado rigidamente em 0,5.

2.3. Baselines, interpretabilidade e pipeline

Como referência, foram treinados modelos baseline (GLM/logística, MLP e *naive* de classe majoritária). A GLM serve de comparador interpretável (sinais e intervalos de confiança dos coeficientes), mas a decisão operacional adota a Rede B por desempenho agregado superior (AUC e *recall* por *lead*). Em produção, o *pipeline* executa: (i) a Rede A para prever 100 *leads* de *tt*, *ur*, *qnh*, *vnt_vel*, *vnt_dir* e *po*; (ii) o cálculo de ΔT e demais derivados; (iii) a Rede B para estimar p_{t+h} e classificar R_{t+h} conforme o limiar τ ; e (iv) a publicação das probabilidades/classes por *lead* e a consolidação de janelas de alto risco para apoio à decisão.

3. Resultados

Os resultados da Rede A mostram o padrão físico esperado de degradação com o horizonte: RMSE/MAE aumentam da lead 1 para a lead 100, mais claramente para a temperatura (p.ex. 2,56/1,97 °C para 4,84/3,74 °C) e o ponto de orvalho (de 2,26/1,73 °C para 4,43/3,50 °C). Já para a pressão, a degradação é mais contida (4,02/3,06 e 5,92/4,64 hPa), refletindo estabilidade barométrica; a umidade relativa quase dobra de valor (10,33/8,04% para 17,20/13,45%), bem como a velocidade do vento (de 2,75/2,21 para 4,00/2,88 nós), indicando persistência temporal. A direção do vento é a variável mais desafiadora, com erros altos em ambos os horizontes (124,81/92,52 → 135,47/109,62 graus), devido ao caráter angular e à variabilidade acentuada (mod 360°).

Em 9.000 simulações na Rede B, o classificador LSTM atingiu acurácia média de 82,52%, *recall* médio de 90% e AUC média de 0,936, com 7.131 verdadeiros negativos, 477 verdadeiros positivos, 1.471 falsos positivos e 41 falsos negativos. Na análise mensal (mai/2023–abr/2024), a acurácia global variou de 69,74% a 99,05%, o *recall* de 0,8889 a 1,0 e a AUC de 0,7988 a 0,9845, com acerto de 100% para nevoeiros densos, moderados e leves na maioria dos meses. Os falsos positivos concentraram-se na madrugada (2h–5h), sob $ur \geq 95\%$ e $vnt_vel \leq 5$ m/s, sem queda marcada de visibilidade; em visibilidades intermediárias (2–5 km), as taxas de erro oscilaram entre 2,381% e 60%, e em valores superiores a 8 km ocorreram erros pontuais (p.ex. 50% em out/2023), enquanto o *Fog-Alert* mostrou utilidade acima de 4 km.

A baixa incidência de falsos negativos (geralmente ≤ 8 /mês) indica alta sensibilidade a eventos críticos (Vis ≤ 1000 m), embora meses com poucos casos (p.ex., fev/2024:

3 verdadeiros positivos; dez/2023: 1 verdadeiro positivo) trazem maior incerteza. Em síntese, o modelo é robusto e operacionalmente confiável, com prioridade de melhorias na calibração de limiares (por sazonalidade/horário) para reduzir falsos positivos sem sacrificar a sensibilidade.

4. Conclusões

Conclui-se que a combinação entre uma LSTM multivariada ajustada localmente e um classificador binário dedicado possibilita a emissão de alertas de nevoeiro confiáveis para horizontes de curto e médio prazo. O modelo proposto apresenta desempenho robusto, alta sensibilidade a eventos críticos e aplicabilidade prática, oferecendo suporte às decisões operacionais no ambiente portuário de Porto Alegre.

Referências

- Almeida, L. A. F. (2008). Análise de frequência da ocorrência de nevoeiro no aeroporto internacional salgado filho – porto alegre/rs. Relatório de pesquisa, Instituto de Controle do Espaço Aéreo (ICEA).
- Fedorova, N., Levit, V., and Afonso, J. M. S. (2019). Estudo de baixa visibilidade no aeroporto de porto alegre: processos sinóticos e termodinâmicos. *Revista Ibero-Americana de Ciências Ambientais*, 10(6):131–145.
- Gultepe, I., Tardif, R., Michaelides, S. C., Cermak, J., Bott, A., Bendix, J., Müller, M. D., Pagowski, M., Hansen, B., Ellrod, G., Jacobs, W., Toth, G., and Cober, S. G. (2007). Fog research: A review of past achievements and future perspectives. *Bulletin of the American Meteorological Society*, 88(8):1111–1126.
- Lima, J. S. (1982). Método de previsão de ocorrência e de duração de nevoeiro em porto alegre: método objetivo. In *Congresso Brasileiro de Meteorologia (CBMET)*, Pelotas, Brasil.
- Michelon, C. R. (2023). Estudo de casos de acidentes de navegação na hidrovia do rio guaíba. Dissertação de mestrado, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre.
- Piva, E. D. (1999). Estudo de nevoeiros de radiação em porto alegre. *Revista Brasileira de Meteorologia*, 14(1):33–45.
- Scotta, F., Michelon, C. R., Puhl, E., Manica, R., Jr., E. E. T., Fick, C., Lenhard, C., Silva, T., and Nunes, J. C. R. (2025). Environmental causes of navigation accidents in the guaíba river waterway. *Brazilian Journal of Water Resources*. Aceito para publicação.
- Silva, A. O. (2012). Análise e previsão de visibilidade baixa no aeroporto de maceió. Dissertação de mestrado, Universidade Federal de Alagoas, Instituto de Ciências Atmosféricas, Maceió. Orient.: N. Fedorova; Coorient.: V. Levit.
- Willett, H. C. (1928). Fog and haze, their causes, distribution, and forecasting. *Monthly Weather Review*, 56(11):435–468.