

PREVISÃO DA CONCENTRAÇÃO DE MATERIAL PARTICULADO ATMOSFÉRICO NO CONDADO DE SURREY, REINO UNIDO PARA ATÉ 24H À FRENTE UTILIZANDO DIFERENTES MODELOS DE REDES NEURAS ARTIFICIAIS

Stephanie Lima Jorge Galvão¹; Erick Giovanni Sperandio Nascimento²

¹Bolsista Iniciação Científica – HPC FAPESB; stephanie.galvao23@gmail.com

²Centro Universitário SENAI CIMATEC; Salvador-BA; erick.sperandio@fieb.org.br

RESUMO

Os materiais particulados são poluentes atmosféricos com muitos efeitos adversos na saúde humana. Nesse sentido, a utilização de algoritmos de previsão surge como uma importante ferramenta para monitoramento e construção de medidas preventivas para redução da concentração desse componente. O objetivo desse trabalho foi comparar a performance de quatro diferentes modelos de redes neurais artificiais em prever a concentração de material particulado no ar do condado de Surrey, Reino Unido. Os dados foram coletados em duas estações de monitoramento próximas a dois parques da região: Stoke Park e Sutherland Park. As redes implementadas foram a multilayer perceptron, MLP, long short-term memory, LSTM, rede neural convolucional unidimensional, CNN1D, e um modelo híbrido com a junção da LSTM e da CNN1D e a eficácia de cada um em fazer as previsões foi avaliada por meio da utilização de métricas.

PALAVRAS-CHAVE: material particulado, poluição atmosférica, redes neurais artificiais, previsão.

1. INTRODUÇÃO

Materiais particulados consistem em uma mistura de partículas sólidas e líquidas suspensas no ar.¹ Eles são originados por fontes antropogênicas e não antropogênicas, e são classificados de acordo com o diâmetro de suas partículas e impactos na saúde humana. Os materiais particulados 2,5, em específico, que incluem partículas de até 2,5 μm , podem adentrar nos sistemas cardiorrespiratórios humanos e causar de problemas cardiorrespiratórios até câncer de pulmão,² sendo o principal grupo de risco as crianças.

A construção de modelos que realizem previsões da concentração dessas partículas horas à frente é essencial como fonte de monitoramento e para dar suporte a medidas de controle e ações preventivas de melhora da qualidade do ar e redução dos impactos na saúde humana. Assim, esse trabalho teve como objetivo construir e comparar o desempenho de 4 diferentes modelos de redes neurais artificiais na tarefa de prever a concentração do material particulado 2,5 (PM_{2,5}) para até 24h à frente para a região de Surrey, RU, utilizando como referência comparativa um modelo simples de Regressão Linear para os quatro modelos implementados, *multilayer perceptron* (MLP), *long short-term memory* (LSTM), rede neural convolucional unidimensional (CNN1D) e o modelo híbrido LSTM + CNN1D.

2. METODOLOGIA

Os dados utilizados nesse trabalho consistiram em dois grupos referentes a dois parques da região de Surrey: Stoke Park e Sutherland Park. Eles fazem parte do projeto europeu iSCAPE (*Improving the Smart Control of Air Pollution in Europe*) e estão disponibilizados publicamente no site do projeto. Os dados da região do Stoke Park foram coletados de fevereiro até setembro do ano de 2019, e os do Sutherland Park foram coletados de junho a outubro do mesmo ano. Ambos os conjuntos de dados possuem frequência de amostragem de um minuto e as variáveis medidas são: Bateria (%), Luz (Lux), Temperatura (°C), Umidade (%), Ruído (dBA), Pressão (kPa), PM 1,0 ($\mu\text{g}/\text{m}^3$), PM 2,5 ($\mu\text{g}/\text{m}^3$), PM 10 ($\mu\text{g}/\text{m}^3$), CO (mV), NO₂ (mV), O₃ (mV).

Os modelos de redes neurais artificiais trabalhados foram o MLP, LSTM, que corresponde a um tipo de rede neural recorrente, CNN unidimensional e um modelo híbrido da CNN + LSTM. A MLP é um dos tipos mais simples de rede neural artificial e abrange várias aplicações com topologias flexíveis e possuindo como parâmetros principais o número de camadas, a função de ativação de cada uma e o número de neurônios.³ A configuração mais adequada desses atributos para cada um dos problemas ocorre de modo empírico. Já a LSTM responde a um tipo de rede neural recorrente que trabalha com dados sequenciados e que foi criada com o objetivo de esquecer dependências à longo prazo. O seu diferencial com relação a MLP é que, além de possuir uma estrutura mais complexa, trabalha com memória. Por fim, a CNN corresponde a um tipo de rede neural artificial que aplica filtros nas entradas e possui um grande poder de aprendizado das relações espaciais e temporais dos dados⁴ e, conseqüentemente, tem capacidade de redimensioná-los e extrair novos

recursos. A abordagem híbrida busca potencializar os resultados das duas redes com um modelo mais robusto.

As configurações para cada um dos modelos das redes que foram implementadas podem ser vistas nas tabelas 1 a 4. Os dados disponíveis foram concatenados com objetivo de tornar o conjunto maior. Adicionou-se dados de latitude, longitude e altitude, além disso, os dados foram reamostrados através do cálculo da média de cada hora. Antes de aplicar à rede, todas as variáveis foram normalizadas, colocando-as sob a mesma referência para que todas tivessem o mesmo grau de importância. As variáveis de entrada das redes foram, portanto, 15, sendo elas: luz, temperatura, umidade, ruído externo, pressão, PM 2,5, hora, dia e mês, que foram transformadas em sinais periódicos de seno e cosseno, e os 3 dados adicionados na concatenação. A rede foram implementadas com 24 saídas, uma para cada hora à frente. Os dados de teste consistiram na amostragem e concatenação de dados de uma semana para cada mês de coleta e as semanas restantes foram concatenadas e utilizadas para treino, além disso 25% dos dados de treino foram separados para validação. A performance de cada um dos modelos foi avaliada via erro médio quadrático (MSE), raiz do erro médio quadrático (RMSE), coeficiente de correlação de Pearson (r) e fator de 2 (fac2).

Tabela 01 – Parâmetros da MLP

Camadas	Tipo	Neurônios	Função de Ativação
Entrada	N/A	15	N/A
1ª Camada	Dense	10	Sigmoide
2ª Camada	Dense	17	ReLu
Saída	Dense	24	Sigmoide

Tabela 02 – Parâmetros da LSTM

Camadas	Tipo	Neurônios	Função de Ativação
Entrada	N/A	15	N/A
1ª Camada	LSTM	32	Sigmoide
2ª Camada	Dropout (0,4)	N/A	N/A
3ª Camada	Dense	16	ReLu
Saída	Dense	24	Sigmoide

Tabela 03 – Parâmetros da CNN

Camadas	Tipo	Neurônios	Função de Ativação
Entrada	N/A	15	N/A
1ª Camada	CNN1D	64	Sigmoide
2ª Camada	CNN1D	32	ReLu
3ª Camada	MaxPooling 1D	N/A	N/A
4ª Camada	Dropout (0.4)	N/A	N/A
5ª Camada	Flatten	N/A	N/A
6ª Camada	Dense	16	ReLu
Saída	Dense	24	Sigmoide

Tabela 04 – Parâmetros da rede híbrida

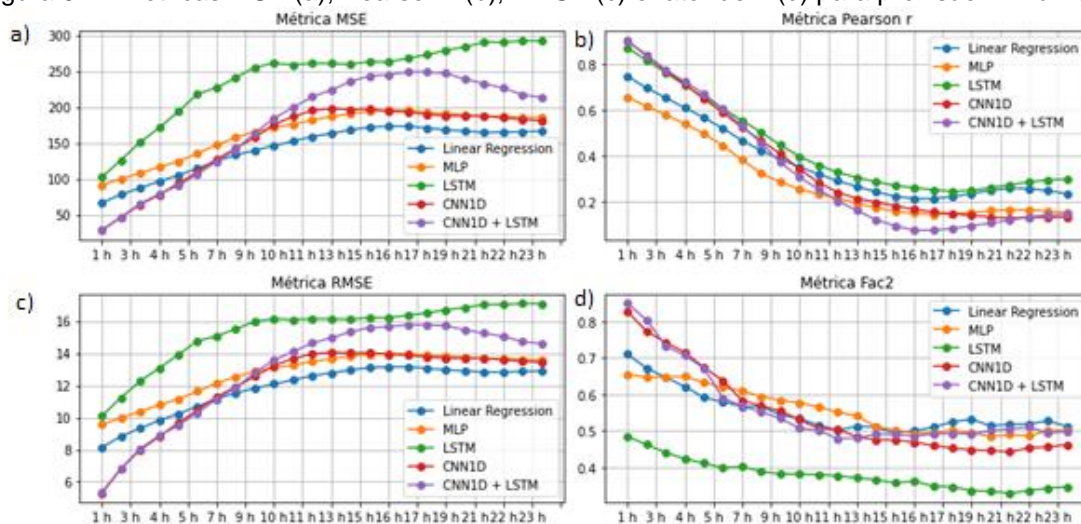
Camadas	Tipo	Neurônios	Função de Ativação
Entrada	N/A	15	N/A
1ª Camada	CNN1D	128	Sigmoide
2ª Camada	MaxPooling 1D	N/A	N/A
3ª Camada	LSTM	64	Sigmoide
4ª Camada	Dropout (0.4)	N/A	N/A
5ª Camada	Flatten	N/A	N/A
6ª Camada	Dense	31	ReLu
Saída	Dense	24	Sigmoide

3. RESULTADOS E DISCUSSÃO

Uma comparação entre as métricas das previsões para até 24h pode ser vista na figura 01. É importante ressaltar que os modelos de rede neural foram comparados com um modelo simples de regressão

linear, buscando validar a necessidade de aplicação de uma metodologia de rede neural profunda na solução desse problema.

Figura 01 – métricas MSE (a), Pearson r (b), RMSE (c) e fator de 2 (d) para previsão 24h à frente



Conforme pode ser visto na figura, a rede com pior comportamento do ponto de vista do MSE foi a LSTM. Já a CNN e a MLP possuem comportamentos semelhantes a partir do horizonte de previsão de 15 horas, contudo, para os instantes anteriores, a MLP apresenta pior desempenho, com erro maior. É importante notar que o modelo simples de regressão linear se destacou diante de todas as estratégias empregadas. Esse comportamento do MSE foi repetido nas outras métricas com exceção do coeficiente de Pearson em que a LSTM se mostrou melhor até que a regressão linear, contudo, os erros ainda apresentaram resultados elevados considerando todas as redes avaliadas.

4. CONSIDERAÇÕES FINAIS

Os modelos de rede analisados apresentaram performance razoável na tarefa de previsão apresentada, contudo com erros relativamente elevados, o que comprova a limitação da abordagem para esses dados, uma vez que não se distanciam muito do comportamento de uma regressão simples. Uma exploração maior e a utilização de outros dados disponíveis, assim como a avaliação de estruturas mais complexas de rede como *feature augmentation* e *wavelets* têm potencial de melhorar esses resultados para que possam ser utilizados como fontes confiáveis na adoção de ações preventivas relacionadas à poluição.

Agradecimentos

Agradecimento ao apoio do Centro de Referência em Inteligência Artificial, do Centro de Supercomputação para Inovação Industrial (CS2i) com a disponibilização do supercomputador OGUN e ao apoio financeiro da Fundação de Amparo à Pesquisa do Estado da Bahia (FAPESB) no desenvolvimento desse projeto.

5. REFERÊNCIAS

- World Health Organization, **Health effects of particulate matter, policy implications for countries in eastern Europe, Caucasus and central Asia**. World Health Organization, 2013.
- Chen, L. J., Ho, Y. H., Lee, H. C., Wu, H. C., Liu, H. M., Hsieh, H. H., Huang, Y. Te, & Lung, S. C. C.. **An Open Framework for Participatory PM2.5 Monitoring in Smart Cities**. IEEE Access, 2017.
- Alves, L., Sperandio Nascimento, E. G., & Martins Moreira, D. **Hourly tropospheric ozone concentration forecasting using deep learning**. WIT Transactions on Ecology and the Environment, 2019.
- Junior, A. S. R., Nascimento, E. G. S., & Moreira, D. M.). **Assessing recurrent and convolutional neural networks for tropospheric ozone forecasting in the region of Vitória, Brazil**. WIT Transactions on Ecology and the Environment, 2020.