

Revisão Bibliográfica Sistemática - Dispersão de Poluentes e Redes Neurais Artificiais

Systematic Bibliographic Review - Pollutant Dispersion and Artificial Neural Network

RESUMO

A preocupação mundial sobre o impacto causado pelos poluentes atmosféricos tanto na saúde humana quanto no meio ambiente vem gerando a necessidade de um melhor monitoramento da qualidade do ar em regiões com alto índice de emissão de poluentes. Além das formas convencionais de monitoramento da qualidade do ar, por meio de equipamentos que avaliam a qualidade do ar da região onde estão instalados, outras formas podem ser usadas: simulação de dispersão de poluentes e redes neurais artificiais. Este trabalho teve como objetivo fazer uma revisão bibliográfica sistemática sobre poluição atmosférica com a utilização de métodos de dispersão de poluentes e redes neurais artificiais. Houve uma prevalência de artigos que utilizaram apenas as redes neurais artificiais como método e 4 artigos que utilizaram ambos os métodos, de forma comparativa ou em conjunto. Apesar de ainda pouco explorado, a utilização simultânea de ambos os métodos aparenta ser uma alternativa promissora para a avaliação da qualidade do ar.

PALAVRAS-CHAVE: Poluição atmosférica. Métodos alternativos. Concentração de poluentes.

ABSTRACT

Worldwide concern about the impact of air pollutants on both human health and the environment has led to the need for better monitoring of air quality in regions with high levels of pollutant emissions. In addition to the conventional ways of monitoring air quality through equipment that assesses the air quality of the region where they are installed, other ways can be used: simulation of pollutant dispersion and artificial neural networks. This work aimed to make a systematic bibliographic review about air pollution using pollutant dispersion methods and artificial neural networks. There was a prevalence of articles that used only artificial neural networks as a method and 4 articles that used both methods, either comparatively or together. Although still little explored, the simultaneous use of both methods appears to be a promising alternative for air quality assessment.

KEYWORDS: Atmospheric pollution. Alternative methods. Pollutant concentration.

João Luiz Miranda Meyer
Joao_lmm@hotmail.com
Universidade Tecnológica Federal do Paraná,
Ponta Grossa, Paraná, Brasil

Yara de Souza Tadano
yaratadano@utfpr.edu.br
Universidade Tecnológica Federal do Paraná,
Ponta Grossa, Paraná, Brasil

Recebido: 19 ago. 2019.

Aprovado: 01 out. 2019.

Direito autoral: Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



INTRODUÇÃO

Segundo Carvalho (2016), o aumento da malha automotiva nos grandes centros urbanos vem gerando elevadas emissões de poluentes atmosféricos, resultando em problemas como: queda na qualidade do ar, aumento no número de casos de doenças respiratórias na população e intensificação do efeito estufa. Isso gera a necessidade de se quantificar esses poluentes, para que medidas públicas possam ser tomadas a fim de contornar o problema. Duas formas podem ser usadas para estimar a quantidade de poluentes presente no ar: simulação de dispersão ou Redes Neurais Artificiais (RNA), tendo finalidades distintas.

A simulação de dispersão faz uso de *softwares* em que são inseridos dados de entrada como: emissões de fontes poluidoras, topografia, dados meteorológicos, entre outros. Com isso, o *software* utilizará modelos matemáticos para simular e estimar a concentração de poluentes para uma determinada região de estudo. Assim, a simulação de dispersão é usada como uma forma de previsão temporal e espacial.

Já as Redes Neurais Artificiais (RNA) utilizam séries históricas de concentração de poluentes como entrada para fazer uma previsão de dados futuros, procurando um padrão a ser encontrado, podendo ser incluídos outros dados de entrada, como, por exemplo, dados meteorológicos. Essa estimativa futura encontrada pelas RNA, é utilizada para previsões, principalmente temporais.

Não se pode dizer que um método se sobressai perante ao outro, pois apesar de possuírem o mesmo objetivo de encontrar a concentração dos poluentes, as situações para que são analisados são distintas.

Portanto, para esses dois métodos, este trabalho procurou realizar uma revisão bibliográfica sistemática na literatura para analisar se existe uma interação entre os métodos ou são utilizados distintamente.

De acordo com Kitchenham e Charters (2007), a Revisão Bibliográfica Sistemática (RBS) pode ser definida como uma forma de analisar publicações de artigos a respeito de um determinado tema. O intuito é direcionar a procura de conhecimento em áreas que ainda não foram abordadas e evitar a repetição de assuntos abordados.

MATERIAIS E MÉTODOS

Na metodologia, serão apresentadas as bases de dados junto com palavras chaves utilizadas na pesquisa e, como foi feita a classificação dos artigos.

BASE DE DADOS

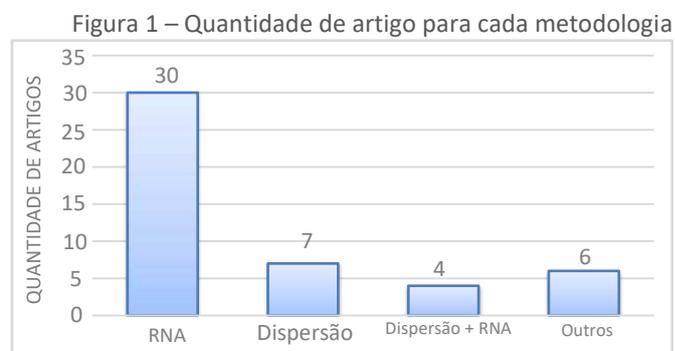
A pesquisa dos artigos foi realizada nas seguintes bases de dados: ScienceDirect, IEEE Xplore, Springer Link e ACM Digital Library. Em todas, as palavras chaves utilizadas foram: "artificial neural network" AND "atmospheric dispersion" AND "air pollution". O tempo de publicação não foi especificado, proporcionando todos os resultados existentes até hoje nas respectivas bases de dados.

CLASSIFICAÇÃO DOS ARTIGOS

Os artigos foram classificados em quatro classes. A sua classificação dependia da metodologia utilizada na pesquisa (Redes Neurais Artificiais, Dispersão, Redes Neurais Artificiais e Dispersão, Outros) que foi identificada por meio dos resumos disponíveis dos artigos, sendo excluídos aqueles que não se relacionassem de nenhuma forma com poluição atmosférica.

RESULTADOS E DISCUSSÕES

Após o término da pesquisa, e para um melhor entendimento dos resultados, foram criados gráficos que relacionassem a quantidade de artigos para cada classe considerada e por ano de publicação.



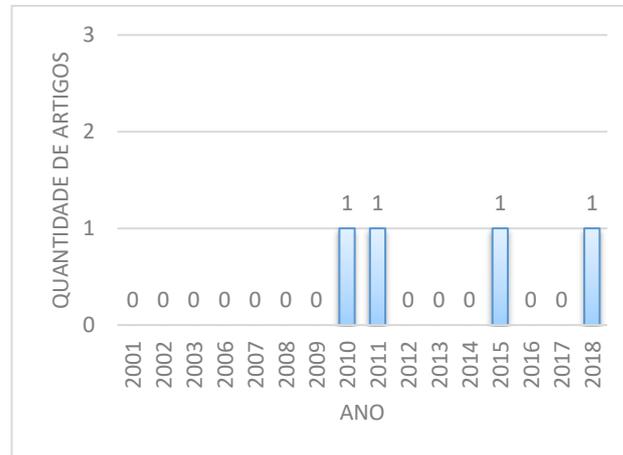
Fonte: autoria própria

A figura 1 mostra uma prevalência significativa de artigos relacionados com Redes Neurais Artificiais perante os outros. O intervalo de tempo de publicação dos artigos foi de 2001 até 2018, sendo que nem todos os anos houve publicação.

Como o intuito desta RBS é identificar como as RNA são utilizadas em estudos de simulação da dispersão, foram analisados os quatro artigos que utilizaram os

dois métodos simultaneamente. A figura 2 relaciona os artigos de RNA e dispersão com os anos de publicações.

Figura 2 - Quantidade de artigos usando RNA e dispersão durante os últimos anos



Fonte – autoria própria

O primeiro trabalho analisado foi de Cao, Roy e Andrews (2010), intitulado *Modelling the Concentration Distributions of Aerosol Puffs Using Artificial Neural Networks*. O objetivo foi comparar as concentrações de aerossóis em pequenas escalas de tempo usando RNA e dois modelos de pluma Gaussiana para condições meteorológicas diferentes. A RNA obteve resultados parecidos com os modelos de dispersão quando a atmosfera se encontrava em condições estáveis e resultados melhores quando em condições neutras e instáveis, para altas concentrações de aerossóis. No entanto, para regiões de menor concentração, as redes neurais não apresentaram resultados confiáveis. Os dados utilizados na RNA foram obtidos na cidade de Quebec, Canadá.

O segundo trabalho analisado foi de Cao et al. (2011), intitulado *Dispersion Coefficients for Gaussian Puff Models*. O artigo utilizou RNA e um modelo de regressão de múltiplas variáveis não linear para encontrar coeficientes de dispersão de aerossóis. Os dados de entrada para os modelos foram coletados durante uma semana em Quebec, Canadá. A rede neural apresentou previsões muito boas, com valores de coeficientes de dispersão muito próximos aos reais. Em seguida, esses dois métodos foram comparados com um modelo de dispersão que utilizava coeficientes de dispersão de Slade e COMBIC, que segundo o autor é um sofisticado modelo que utiliza distribuição Gaussiana. Ambos os modelos, tanto RNA quanto o modelo de regressão não linear, apresentaram melhores resultados de concentração de aerossóis quando comparado aos outros modelos de dispersão.

O terceiro trabalho foi de Ghazi, Dugdale e Khadir (2015), intitulado *Modelling PM₁₀ Crisis Peaks Using Multi-agent Based Simulation: Application to Annaba City, North-East Algeria*. O trabalho utilizou um modelo de dispersão junto com RNA, para prever a concentração de PM₁₀, integrado ao MAS (do inglês - *multi-agent system*). O MAS tem objetivo de controlar as fontes de emissão, auxiliando na redução de emissões de poluentes atmosféricos, evitando picos de poluição. Os dados utilizados foram de Annaba, Argélia. A simulação foi realizada para avaliar a eficiência no controle de picos de PM₁₀.

Por fim, o quarto trabalho de Wand et al. (2018), intitulado *The Air Contaminant Dispersion Prediction by the Integration of the Neural Network and AermodSystem*. O trabalho procurou utilizar simulações no *software* AERMOD a fim de obter dados que pudessem ser utilizados como entradas nas redes neurais e, assim, realizar previsões de poluentes. A utilização desse *software* surgiu devido à dificuldade de obtenção de dados meteorológicos, sendo essa, uma alternativa para contornar o problema e, se mostrando uma forma efetiva de previsão de poluentes.

CONCLUSÃO

Foi possível analisar a possibilidade da utilização conjunta das RNA e dispersão como métodos complementares. Na maioria das vezes, ao ser comparada com o método de dispersão, a RNA apresentou resultados mais próximos aos verdadeiros, mostrando ser uma ferramenta bastante eficiente, mas que seu uso deve ser analisado previamente, pois como visto no primeiro trabalho, para casos específicos, ela não apresentou resultados confiáveis. De acordo com os resultados da RBS, observou-se que o uso de RNA em conjunto com modelos de dispersão, ainda é uma metodologia pouco explorada. Normalmente, as RNA são uma boa alternativa para previsões futuras de concentração de poluentes, baseado em dados de concentração já existentes. Porém, para casos em que existam apenas informações referentes às fontes poluidoras, o método de dispersão é muito utilizado. Concluiu-se que a utilização dos métodos de forma conjunta mostrou ser uma maneira inteligente e eficiente de se estudar a dispersão de poluentes atmosféricos. Uma sugestão para trabalhos futuros seria uma atuação conjunta das redes neurais com os métodos de dispersão, parecido com o que foi feito no quarto artigo. Isso possibilitará previsões futuras de poluição para regiões em que não existe um banco de dados de concentração de poluentes devido à falta de recursos financeiros, muito comum em países em desenvolvimento, como o Brasil. Isso possibilitará que medidas públicas contra a poluição atmosférica possam ser tomadas e haja uma melhoria na qualidade do ar.

REFERÊNCIAS

CARVALHO, C.H. R. Emissões Relativas de Poluentes do Transporte Motorizado de Passageiros nos Grandes Centros Urbanos Brasileiros. INSTITUTO DE PESQUISA ECONOMICA APLICADA. ISSN 1415-4765. 2011. Disponível em: <<https://www.econstor.eu/bitstream/10419/91332/1/664398472.pdf>>. Acesso em: 10 jul. 2019.

KITCHENHAM, B.; CHARTERS, S. Guidelines for performing systematic literature reviews in software engineering. Technical Report EBSE 2007-001. Keele University and Durham University Joint Report, 2007.

CAO, X.; RAY, G.; ANDREWS, W.S. Modelling the Concentration Distributions of Aerosol Puffs Using Artificial Neural Networks (2010). Disponível em: <<https://doi.org/10.1007/s10546-010-9501-4>>. Acesso em: 18 jul. 2019.

CAO, X.; ROY, G.; HURLEY, W.J.; ANDREWS, W.S. Dispersion Coefficients for Gaussian Puff Models (2011). Disponível em: <<https://doi.org/10.1007/s10546-011-9595-3>>. Acesso em: 18 jul. 2019.

GHAZI S.; DUGDALE J.; KHADIR T. Modelling PM10 Crisis Peaks Using MultiagentBased Simulation: Application to Annaba City, North-East Algeria (2015). Disponível em: <https://doi.org/10.1007/978-3-319-24399-3_6>. Acesso em: 18 jul. 2019.

WANG, R.; CHEN, B.; WANG, Y.; ZHU, Z.; MA, L.; QIU, X. The Air Contaminant Dispersion Prediction by the Integration of the Neural Network and AermodSystem (2018). Disponível em: <<http://doi.org/10.1145/3284103.3284114>>. Acesso em: 18 jul. 2019.