

Modelo Neural para a Previsão de Ozônio na Baixa Atmosfera

Franco C. Degrazia¹, Haroldo F. de Campos Velho¹, José Demísio S. da Silva¹, Rosângela R. Cintra¹

¹Laboratório Associado de Computação e Matemática Aplicada - LAC
Instituto Nacional de Pesquisas Espaciais, INPE
12227-010, São José dos Campos, SP

1. Introdução

Concentrações elevadas de ozônio afetam a saúde humana, culturas agrícolas e danos à fauna e flora locais. Conseqüentemente, o rastreamento preciso do poluente tem se tornado uma tarefa vital para a realização de medidas mitigadoras. Modelos gaussianos, lagrangianos e eulerianos, são aplicados para modelar a dispersão de poluentes. Neste trabalho é sugerida uma abordagem fenomenológica para a avaliação da poluição do ar, denominada de estratégia de previsão da poluição do ar por redes neurais. A vantagem da modelagem neural é que ela não requer inventários de fontes de emissões, modelagem matemática de equações de transporte e difusão e/ou modelagem do terreno e cobertura vegetal. Modelos baseados em equações diferenciais de evolução são computacionalmente caros e requerem modelos constitutivos para representar as transformações químicas e a turbulência, por exemplo.

2. Modelo e metodologia

A localidade de estudo situa-se em São José dos Campos, cerca de 100 Km da cidade de São Paulo. O modelo neural tem como dados de entrada a temperatura da superfície e velocidade do vento, resultando na previsão pontual da concentração de ozônio. A rede foi treinada com dados do período: 17/julho/2007 a 29/julho/2007. Os dados experimentais meteorológicos e de concentração de ozônio foram obtidos da CETESB.

Na rede neural do tipo perceptron de múltiplas camadas (figura 1), cada unidade de entrada é conectada a todos os nós na camada seguinte, que pode ser uma camada escondida ou de saída.

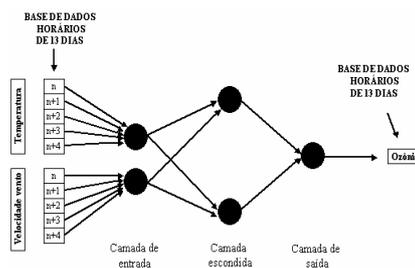


Figura 1: estrutura da rede sugerida por SHIGUEMORI et al. (2005).

Cada nó da rede estabelece um novo sinal, a partir de uma função de combinação não linear dos sinais de entrada. Esta função é chamada de função de ativação:

$$\varphi(X_i) = \frac{1}{1 + e^{-X_i}}, \quad \text{onde: } X_i = \sum w_{ij}u_j .$$

Os valores de w_{ij} são as conexões entre unidade j e unidade i , sendo u_j os sinais chegando à unidade i . O sinal gerado pela unidade i é enviado para todos os nós na camada seguinte ou registrada como uma saída quando atingida a camada de saída. Os pesos das conexões foram calculados usando o algoritmo de retropropagação (RUMELHART, HINTON e WILLIAMS, 1986), empregado para diminuir a diferença entre a saída da rede (concentração estimada pela rede) e os valores experimentais (ozônio medido). Após o treinamento com os pesos das conexões são fixos. O modelo neural foi executado para os seis dias posteriores ao treinamento.

3. Resultados e conclusões

Para observar a capacidade de previsão do modelo, valores de entrada de temperatura e velocidade do vento foram obtidos de duas fontes distintas para os dias subsequentes ao treinamento (dados não presentes no

período de treinamento). O modelo ETA (CPTEC) com resolução de 40 km de grade e a estação meteorológica da CETESB. A figura 2 mostra que mesmo com uma série temporal curta de dados para o treinamento, o modelo apresenta boa capacidade de previsão,

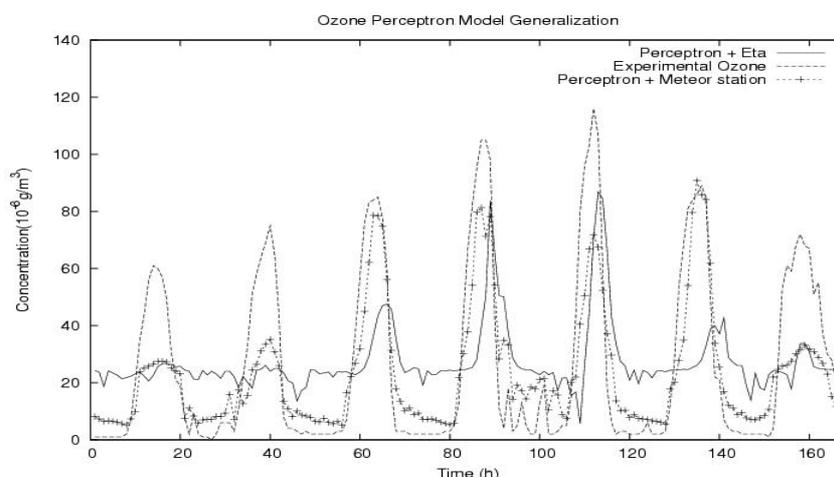


Figura 2: Generalização da concentração de ozônio.

As variáveis meteorológicas velocidade do vento e temperatura parecem representar satisfatoriamente o grande número de graus de liberdade implícitos na série temporal de ozônio. A correlação cruzada entre ozônio e temperatura é 0,68 e entre ozônio e velocidade do vento é 0,53. A correlação entre temperatura e ozônio pode ser explicada pela relação direta entre radiação solar e temperatura. Maior radiação solar implica no aumento de temperatura e aumento de reações fotoquímicas (formação de ozônio). Enquanto a correlação entre ozônio e velocidade do vento pode ser explicada pelo aumento da velocidade do vento durante as tardes, justamente os horários de maior concentração de ozônio.

O erro percentual médio foi utilizado como parâmetro de avaliação das previsões (PEREZ, TRIER E REYE, 2000). Os erros de previsão mostrado na figura 3a apresentam valores elevados nos horários noturnos, indicando que somente as variáveis meteorológicas escolhidas não são

suficientes para representar o comportamento da série temporal de ozônio durante a noite. Durante os horários de maior concentração a modelagem neural apresenta um satisfatório erro percentual (figura 3b). A diferença entre os dois erros médios deve-se a falha na previsão do modelo ETA (resolução da grade computacional é grosseira).

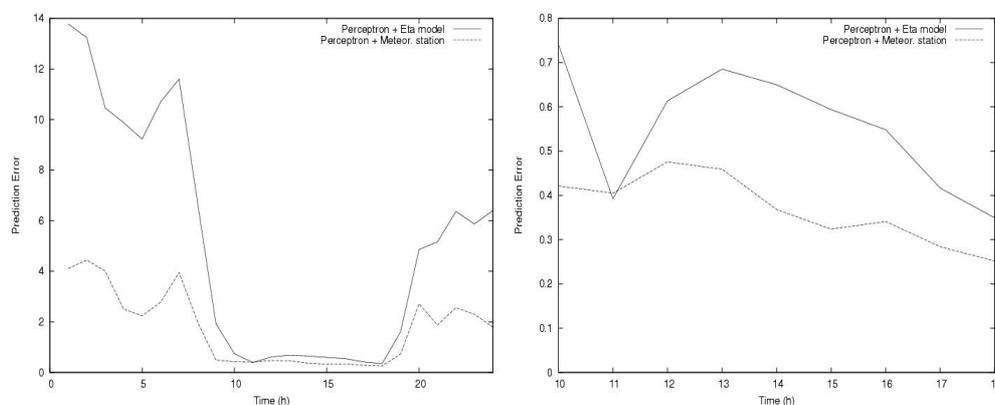


Figura 3: a) Erro percentual de previsão para as 24 horas, b) Erro percentual de previsão no período de maior concentração de ozônio.

O modelo neural apresentado mostrou boa previsão mesmo para uma pequena base de dados de treinamento. A simplicidade de implementação torna este modelo uma ferramenta promissora para a avaliação da poluição e emitir alertas. Na continuação deste trabalho, deve-se melhorar a modelagem noturna, atentando para a possibilidade de inclusão de novas variáveis. Ainda, uma base de dados maior tem de ser empregada.

Agradecimentos: Capes e CNPq pelo apoio financeiro, CPTEC pelos dados do modelo ETA e CETESB pelos dados de ozônio e meteorológicos.

Referências

- Rumelhart, D. E.; Hinton, G. E.; Williams, R. J. *Learning internal representations by error propagation. Parallel distributed processing*, The Mit Press: Cambridge, MA, London, 1986. p. 318-364.
- Shiguemori, E. H., Chiwiacowsky, L. D., Campos Velho, H. F., Silva, J. D. S. An Inverse vibration problem solved by an artificial neural network, *TEMA: Tendências em Matemática Aplicada e Computacional*, **6**(1), 163-175.
- Perez, P., Trier, A., Reye, J. (2000): Prediction of PM_{2,5} concentrations several hours in advance using neural networks in Santiago, Chile, *Atmospheric Environment*, **34**, 1189-1196.