XII WORKSHOP BRASILEIRO 2022
MICRO METEOROLOGIA
16 a 18 de novembro de 2022 | UFOPA | Santarém - PA | Brasil

MODELO DE TURBULÊNCIA ATMOSFÉRICA BASEADA EM REDES NEURAIS ARTIFICIAIS

Antonio V. Pereira Neto[1], Gutemberg B. França[1], Haroldo F. de Campos Velho[2]
Enver Ramirez[2] e Denis Eiras[2]

[1]Universidade Federal do Rio de Janeiro, UFRJ

[2]Instituto Nacional de Pesquisas Espaciais, INPE

Resumo

Uma parametrização de turbulência baseada em dados é apresentada. Uma rede neural do tipo supervisionada, perceptron de múltiplas camadas, é aplicada para emular um modelo de fechamento de primeira ordem no software WEKA. Os dados para configuração da rede neural são obtidos com execução da versão uni-dimensional do modelo de circulação atmosférica BAM (Brazilian global Atmospheric Model). Os resultados mostram um coeficiente de correlação de 96% entre a difusividade turbulenta obtida com a rede neural e a parametrização de turbulência de primeira ordem.
Palavras-chave: Turbulência atmosférica; parametrização por redes neurais; modelo BAM-1D.

Abstract

A data driven turbulence parameterization is presented. A supervised neural network of multi-layer perceptron is designed to emulate a first order closure turbulent parameterization with WEKA. The data used to configure the neural network are obtained by the execution of the atmospheric circulation model BAM (Brazilian global Atmospheric Model) – the 1D version. The results shown a 96% of correlation between the eddy diffusivity computed from neural network and the first order parameterization.
Keywords: Atmospheric turbulence; parameterization by neural network; BAM-1D model.

1. Introdução

A turbulência é uma ação permanente na parte na dinâmica da atmosfera mais próxima ao solo, numa região denominada de Camada Limite Planetária (CLP). A produção da turbulência está associada ao cisalhamento do vento ou transporte de energia térmica entre o solo e a atmosfera. Se a temperatura do solo estiver mais baixa do que a da atmosfera, ter-se-á um fluxo de calor da atmosfera para o solo, removendo energia da CLP, uma situação comumente encontrada durante o período noturno. O gradiente do número de Richardson pode ser usado para indicar o tipo de estabilidade da CLP.

Num escoamento turbulento, a hipótese de Reynolds considera que as propriedades do fluido

podem ser descritas como a soma entre um comportamento médio (similar ao que se encontra num escoamento laminar) adicionado a uma variação aleatória. Embora a média da variação aleatória possa ser considerada nula, a média do produto destas quantidades aleatórias não se anulam. De fato, as médias dos produtos das quantidades aleatórias são denominados *tensores de Reynolds*. Estes tensores são parametrizados para representar a turbulência nos códigos de simulação. A parametrização da turbulência tem sido investigada usando diferentes técnicas de fechamento (STULL, 1988; CAMPOS VELHO, 2010) e distintas ordens de fechamento, seja de primeira ordem (DEGRAZIA et al.,2000; HOLTSLAG-BOVILLE, 1993), ou ordens superiores (MELLOR-YAMADA,1982).

As redes neurais (RNs) estão sendo usadas com sucesso em muitas aplicações, inclusive na meteorologia. Se uma quantidade suficiente de dados estiver disponível, as RNs podem ser treinadas para descrever a evolução de processos não lineares (DUEBEN E BAUER, 2018). Este trabalho tem por objetivo desenvolver um modelo de rede neural para a difusão vertical turbulenta na CLP. A parametrização neural será comparada com a parametrização de primeira ordem de Holtslag-Boville (1993). Os dados para configuração da rede neural supervisionada são obtidos do modelo de circulação atmosférico global (FIGUEROA et al., 2016): BAM (Brazilian global Atmospheric Model), em versão 1D.

2. Materiais e Métodos

2.1 Àrea de estudo

A área de estudo localiza-se na cidade de Manacapuru-AM (Figura 1), aproximadamente a 66 km da capital Manaus, no sítio T3 (3,21297° S; 60,59805° W), sendo o ponto principal da coleta de dados do experimento como parte do projeto GoAmazon (do inglês, “Green Ocean Amazon”, Oceano Verde Amazônico), 2014/15 que se situa na Fazenda Exata. Martin et al. (2016).

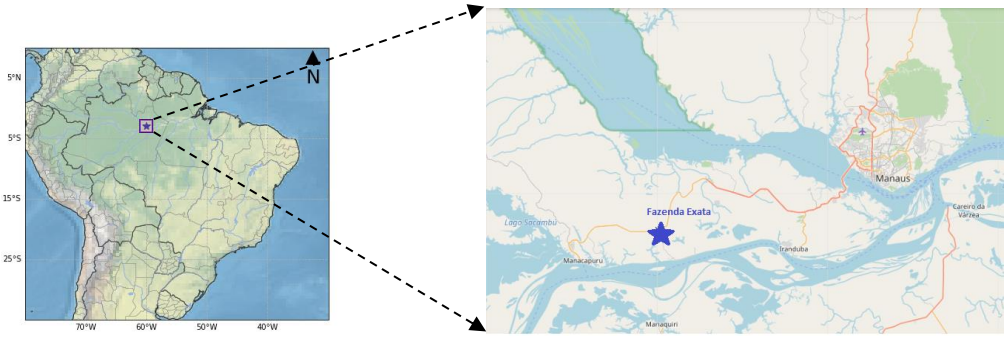


Figura 1 - Mapa da localização da fazenda Exata (Municipio de Manacapuru-AM)

2.2 Redes Neurais Artificiais

A rede neural artificial (RNA) é um ramo de estudo dentro da Inteligência Artificial, que aborda o funcionamento de uma estrutura computacional, composta por nós ou neurônios artificiais (Figura 2a) interconectados para formar a rede (Figura 2b) que se inspiram no funcionamento do cérebro humano.

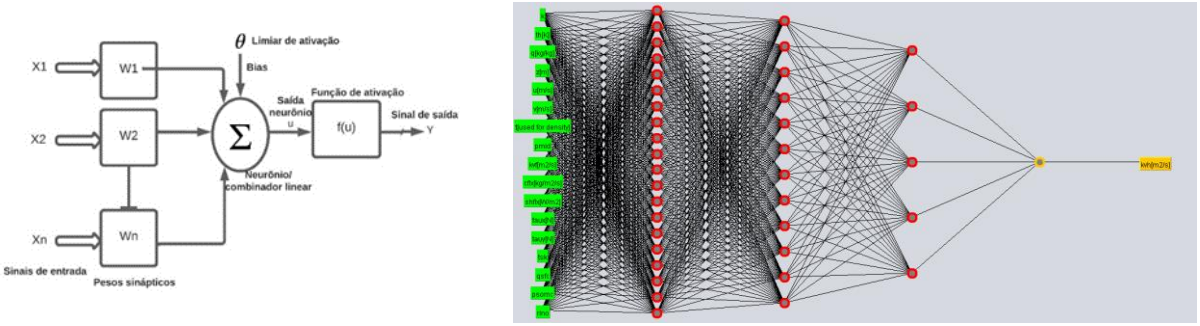


Figura 2 - a) Neurônio Perceptron; b) rede perceptron de multicamadas usada no trabalho.

Esses neurônios são capazes de reconhecer padrões a partir de um conjunto de dados, guardar valores na memória e aprimorar sua capacidade em um processo de aprendizagem devido a um processo de treinamento.

2.3 Software WEKA

O software Weka (HALL et al., 2009) consiste de uma coleção de algoritmos de aprendizado de máquina para tarefas de mineração de dados que podem ser aplicados diretamente a um conjunto de dados. Antes de aplicar o Weka é necessário cumprir (basicamente) três etapas: i) coleta de dados; ii) normalização dos dados; e, iii) configuração da rede neural.

O Weka deve ser configurado para realizar o treinamento com a rede Perceptron com Multicamadas (PMC). Entre as configurações de maior importância estão: topologia de rede, algoritmo de aprendizado (neste caso a escolha recaiu sobre o algoritmo de retropropagação) e função de ativação. A configuração inclui ainda a definição dos seguintes parâmetros: número de camadas ocultas; taxa de aprendizagem; impulso; tempo de treinamento; e conjunto de treino. Existem diversas metodologias para configurar uma rede podendo ser considerado uma “arte”. Inicialmente foram utilizados os padrões default do Weka, com taxa de aprendizado de 0,3; momento de 0,2 e com as épocas sendo allteradas para 5000.

3. Metodologia

A Figura 3 ilustra toda a metodologia do trabalho.

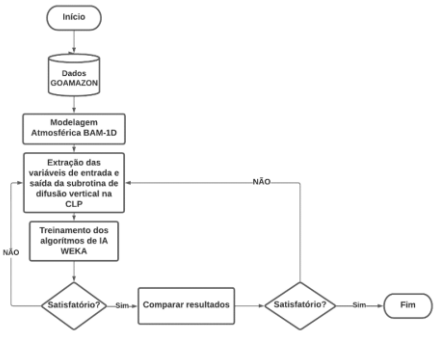


Figura 3 - Organograma com a metodologia do trabalho.

Os dados para a configuração da rede neural foram gerados a partir de uma simulação com o modelo BAM-1D para o ano de 2014. A partir daí, foram preparados os dados de entrada para o Weka com auxílio do ambiente Colab-Google utilizando programação na linguagem Python. Os

atributos de entrada e de saída da subrotina de HB são.

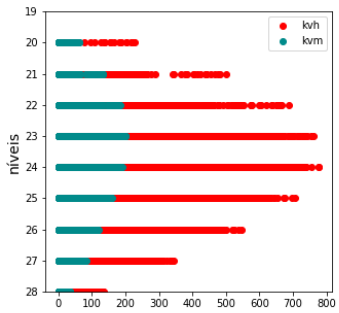
Entradas – Temperatura potencial (K), Umidade específica (kg/kg), Altura dos níveis (m), vento zonal (u), vento meridional (v), Temperatura (K), pressão entra níveis (pmid), difusividade molecular (m^2/s), fluxo sup. Constituinte ($kg/m^2/s$), fluxo sup. Calor (W/m^2), stress sup. u (N), stress sup. v (N) e umidade específica sup. e Número de Richardson.

Saídas – Difusividade de momento (m^2/s) e Difusividade de calor (m^2/s).

Uma vez que a etapa de preparação dos dados para o Weka é cumprida, a rede neural artificial pôde ser aplicada na tentativa de reproduzir a saída (ou alvo) utilizando o PMC, que é uma arquitetura feedforward de redes neurais artificiais, cuja configuração topológica é constituída de uma camada de entrada, uma ou mais camadas ocultas (intermediárias) e uma camada de saída.

4. Resultados

O BAM-1D tem implementado o esquema “Não local” para a difusão da temperatura, umidade e momentum na CLP, acima desta camada é usada a difusão “local” com um comprimento de escala de 30m para o cálculo. Na Figura 4 pode ser visto o perfil da difusão da temperatura (kvh) e momentum (kvm) extraídos do BAM-1D, cada ponto do gráfico indica o resultado para um nível dentro da CLP em um determinado passo de tempo (6 min para o BAM-1D) e para o ano 2014 (iniciando em 1 janeiro/14).



k (nível)	*z* (m)
20	2487,393
21	1926,716
22	1458,978
23	1073,511
24	758,927
25	504,287
26	299,785
27	136,660
28	19,349

Figura 4 – (a) Coeficientes de difusividade turbulenta de temperatura e quantidade de movimento (*momentum*); (b) Tabela das alturas dos níveis.

A avaliação da RNA foi feita usando as medidas de erro apropriadas para interpretar os resultados. O Weka fornece uma tabela (Tabela 2) de avaliação da adequação da RNA (coeficientes de correlação mais erros).

Analisando os valores da tabela 2 pode-se concluir que o coefiiciente de correlação R^2 é muito forte. Esta métrica mostra a relação entre o valor verdadeiro e o valor estimado de uma classificação, com isso esse valor varia estritamente entre −1 e 1. Quanto mais próximo de zero o valor, a relação é basicamente inexistente e quanto mais próximo aos extremos a relação é muito forte, sendo, no caso negativo, uma relação muito forte inversa.

Tabela 2 – Resultados do algorítmo MLP para kvh e kvm (5000 épocas).

Correlation coefficient	0.9667

Mean absolute error	2.458
Root mean squared error	5.9234
Relative absolute error	19.0226 %
Root relative squared error	30.1161 %

Correlation coefficient	0.9632
Mean absolute error	11.1007
Root mean squared error	25.4802
Relative absolute error	23.3141 %
Root relative squared error	34.6615 %

As outras métricas de avaliação indicam:

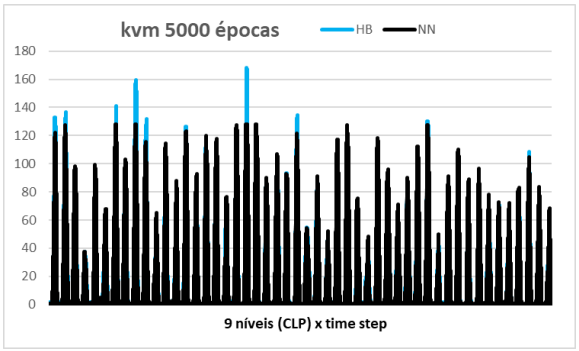
- MAE (Mean Absolute Error): não leva em conta se o erro foi superestimado ou subestimado, caracterizando-se por ser a média dos erros cometidos pelo modelo de previsão durante uma série de execuções.

- RSME (Root Mean Squared Error): Penaliza mais os erros maiores, permite avaliar a qualidade de um previsor em relação aos dados.

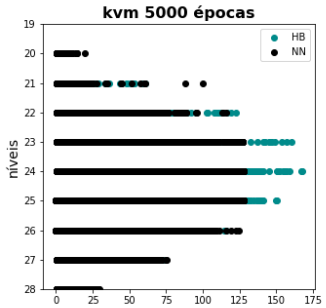
- RAE (Relative Absolute Error): É apenas o erro absoluto total, tendo o mesmo tipo de normalização do RSSE.

- RRSE (Root Relative Squared Error): refere-se a uma medida um pouco diferente, onde o cálculo do erro é feito em relação ao que teria sido um preditor simples utilizado. O preditor simples em questão é apenas a média dos valores reais dos dados, denotados por 1.

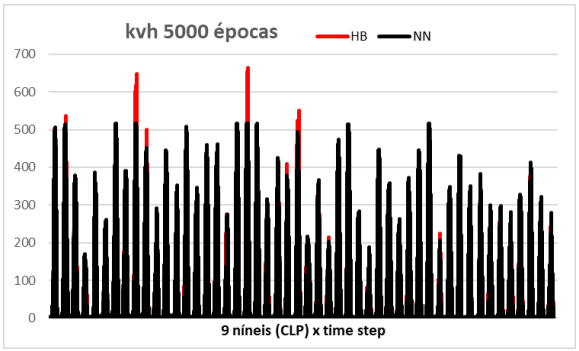
A comparação da difusividade turbulenta de temperatura e momento para o ano de 2014 fornece informação relevante. Nas Figuras 5a-d nota-se uma subestimativa da rede neural nos níveis mais altas, mas na superfície os valores da parametrização física e rede neural praticamente são coincidentes.



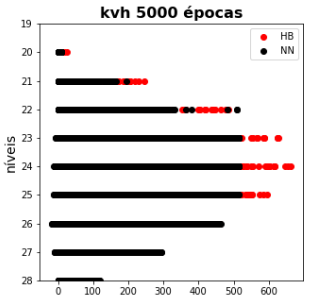
(a)



(b)



(c)



(d)

Figura 5 - a) e c) Coeficientes de difusividade turbulenta em cada passo de tempo (*time-step*) para quantidade de movimento (a) e temperatura (c); coeficientes de difusividade turbulenta mapeada em níveis (altura) no modelo BAM-1D.

5. Comentários Finais

A partir dos resultados apresentados, pode-se concluir que a determinação da difusão vertical da CLP a partir de uma rede neural artificial do tipo MLP apresenta uma correlação acima de 96% em relação a parametrização baseada em processos físicos e ajuste de curva como descrito por Holtslag-Boville (1993).

Previsões numéricas do tempo são códigos de computação intensiva, requerendo uso de supercomputadores. Neste trabalho, a rede neural supervisionada MLP foi configurada e treinada para emular a difusividade turbulenta da parametrização de primeira ordem de Holtslag-Boville (1993), que é uma das opções disponíveis para o modelo BAM (Figueroa et al., 2016). Porém, parametrização de ordem mais alta, como a de Mellor-Yamada (1982), também estão disponíveis, quem tem custo computacional significativamente maior. A aplicação de redes neurais nestes casos pode mitigar o custo de computação, melhorando o desempenho do código em sistemas de computação de alto desempenho.

Referências Bibliográficas

FIGUEROA, S. N.; BONATTI, J. P.; KUBOTA, P. Y.; GRELL, G. A.; MORRISON , H.; BARROS, S. R.; FERNANDEZ, J. P.; RAMIREZ, E.; SIQUEIRA, L.; LUZIA, G. et al. The Brazilian global atmospheric model (BAM): Performance for tropical rainfall forecasting and sensitivity to convective scheme and horizontal resolution, **Weather and Forecasting, v.** 31, p. 1547–1572, 2016.

DUEBEN, P. D.; BAUER, P. Challenges and design choices for global weather and climate models based on machine learning. **Geoscientific Model Development**, p. 3999-4009, 2018.

CAMPOS VELHO, H. F.: Modelagem Matemática em Turbulência Atmosférica. Sociedade Bbrasileira de Matemática Aplicada e Computacional (SBMAC): **Notas em Matemática Aplicada** - Nº. 48, 2010. (disponível em: https://proceedings.science/series/23/proceedings_non_indexed/53)

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I.H. The WEKA Data mining software: **An update. SIGKDD Explorations**, v.11, n.1, p. 10–18, 2009.

HOLTSLAG, A. A. M.; BOVILLE, B. A. Local versus nonlocal boundary-layer diffusion in a global climate model. **Journal of Climate, American Meteorological Society**, v. 6, n. 10, p. 1825–1842, 1993.

DEGRAZIA, G. A.; ANFOSSI, D.; CARVALHO, J. C.; MANGIA, C.; TIRABASSI, T; CAMPOS VELHO, H. F.; Turbulence parameterization for PBL dispersion models in all stability conditions. **Atmospheric Environment**, v. **34**, p. 3575-3583, 2000.

FIGUEROA, S. N.; BONATTI, J. P.; KUBOTA, P. Y.; GRELL, G. A.; MORRISON, H.; BARROS, S. R.; FERNANDEZ, J. P.; RAMIREZ, E.; SIQUEIRA, L.; LUZIA, G.; OTHERS: The Brazilian global atmospheric model (BAM): performance for tropical rainfall forecasting and sensitivity to convective scheme and horizontal resolution. **Weather and Forecasting**, **v**. 31, 1547–1572, 2016.

HOLTSLAG, A.; BOVILLE, B. A.; Local versus nonlocal boundary-layer diffusion in a global climate model. **Journal of Climate**, v. **6**, n. 10, 1825–1842, 1993. (disponível em: https://journals.ametsoc.org/view/journals/clim/6/10/1520-0442_1993_006_1825_lvnbld_2_0_co_2.xml).

MELLOR, G. L.; YAMADA, T;: Development of a turbulence closure model for geophysical fluid problems. **Reviews of Geophysical Physics and Space Physics**, v. **20**, 851-875,1982.

STULL, R. B.: An Introduction to Boundary Layer Meteorology. **Springer Science & Business Media**, 1988.