

PREVISÃO CLIMÁTICA DE PRECIPITAÇÃO USANDO REDE NEURAL

Juliana A. ANOCHI¹, Sabrina B. M. SAMBATTI¹, Eduardo F. P. da LUZ¹, Haroldo F. de CAMPOS VELHO¹

Instituto Nacional de Pesquisas Espaciais - INPE – São José dos Campos São Paulo

RESUMO: Propõe-se um modelo empírico de previsão climática sazonal do campo de precipitação, que é uma das variáveis meteorológicas mais importantes. O método é baseado em redes neurais artificiais (RNA). Os dados para treinamento da rede são dados de reanálise do NCEP-NOAA. A arquitetura é obtida de forma automática: a topologia ótima é formulada como um problema de otimização. O Algoritmo de Colisão de Múltiplas Partículas (MPCA) é empregado para determinar uma arquitetura ótima para uma rede Perceptron de Múltiplas Camadas (PMC). A rede PMC foi configurada para o problema de previsão de precipitação sobre uma sub-região do Nordeste do Brasil.

ABSTRACT: An empirical climate model for seasonal precipitation field by artificial neural network (ANN) is proposed. The supervised ANN is trained from NOAA-NCEP reanalysis. For identifying the best topology for the ANN, the problem is formulated as an optimization problem. The optimum architecture for the Multilayer Perceptron (MLP) neural network is computed using the Multiple Particles Collision (MPCA). The MLP-NN was configured to the problem for climate prediction of precipitation over a subregion of Brazilian Northeastern.

1. INTRODUÇÃO

Devida a alta variabilidade espacial e temporal, precipitação é uma das variáveis que impõe maior desafio à previsão climática e de tempo. Técnicas novas podem e são empregadas para estimar e prever precipitação. Aqui, se apresentada previsão sazonal do campo de precipitação por uma rede neural supervisionada.

Um dos desafios no uso da técnica de redes neurais é a configuração da rede: quantas camadas escondidas devem ser empregadas? Qual o número de neurônios em cada camada escondida? Qual o valor da taxa de aprendizado? Estas e outras questões são temas de pesquisa na comunidade de redes neurais e também são obstáculos ao uso por um não especialista.

Aqui, o problema de se encontrar uma arquitetura ótima para a rede é formulado como um problema de otimização.

A solução do problema de otimização é endereçada pelo algoritmo de colisão de múltiplas partículas (MPCA) – ver Luz (2008), para determinar uma arquitetura ótima para uma rede Perceptron de Múltiplas Camadas (PMC). O MPCA é aplicado também para determinar os pesos das conexões da rede PMC.

Esta nova metodologia foi aplicada para o desenvolvimento de modelos empíricos de previsão climática sazonal, a partir de dados históricos de reanálise, da base de dados do National Oceanic & Atmospheric Administration (NOAA).

2. REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais são métodos computacionais cujo princípio de funcionamento é regido por um modelo matemático inspirado no funcionamento dos elementos básicos que formam a estrutura neural de organismos inteligentes, que adquirem conhecimento através de experiência. O comportamento inteligente resulta das interações entre as unidades de processamento, a partir de seu ambiente através de um processo de aprendizagem.

Computacionalmente, as RNA são sistemas paralelos distribuídos, compostos por neurônios ou unidades de processamento, que implementam funções matemáticas, normalmente não-lineares. Esses neurônios podem ser distribuídos em uma ou mais camadas interligadas por conexões (pesos sinápticos), os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede (Haykin, 2001).

Existem vários tipos de RNAs que diferem em arquitetura ou forma de treinamento. Para o problema de construção de modelo de previsão climática, como proposto neste trabalho, utilizou-se a rede Perceptron de Múltiplas Camadas (MLP) com treinamento supervisionado realizado pelo algoritmo de retropropagação do erro.

3. CONFIGURAÇÃO ARQUITETURA DA REDE NEURAL

Quando uma rede neural é aplicada para a resolução de um dado problema, a escolha de sua arquitetura é considerada crucial, pois pode influenciar significativamente seu desempenho. Se uma rede tiver sua arquitetura configurada com uma quantidade pequena de neurônios, pode não ser que não seja capaz de aprender os padrões apresentados, devido à quantidade insuficiente de parâmetros ajustáveis. Por outro lado, se tiver uma quantidade grande de neurônios, a rede pode conter excesso de parâmetros, apresentando dificuldades para generalização quando forem apresentados padrões ainda não vistos (Haykin, 2001).

Neste trabalho, a rede PMC é configurada automaticamente: a arquitetura ótima da rede é determinada como a minimização de uma função custo. Otimização é o processo de encontrar a melhor solução em um espaço de busca formado por diversas soluções possíveis.

A rede projetada para realizar a previsão climática sazonal é determinada pela solução do problema de otimização, onde cada ponto no espaço de busca representa uma arquitetura da rede. A função objetivo utilizada consiste na soma dos erros quadráticos de treinamento e de generalização multiplicado por um fator de penalização (Adenilson, 2011):

$$F_{obj} = penalty * \left(\frac{\rho_1 E_{trein} + \rho_2 E_{gener}}{\rho_1 + \rho_2} \right) \quad (1)$$

onde $\rho_1 = 1$ e $\rho_2 = 0.1$ (os mesmos valores propostos por Adenilson (2011)) e esses são parâmetros de ajuste que modificam a relevância atribuída aos erros de treinamento e generalização, respectivamente.

4. OTIMIZAÇÃO COM META-HEURÍSTICA

O algoritmo de colisão de múltiplas partículas (MPCA) é aplicado para encontrar a solução ótima para o funcional expresso na Eq. (1), ou seja, encontrar a arquitetura ótima para uma rede Perceptron de Múltiplas Camadas (MLP).

O algoritmo MPCA é um método de otimização estocástico baseado no conceito de aplicações de múltiplas partículas, viabilizadas através de ambientes computacionais de alto desempenho. Este é uma extensão do algoritmo de colisão de partículas proposto por Sacco (2005), o qual foi inspirado nos processos de viagem uma partícula em um reator nuclear, com ênfase nos comportamentos de espalhamento e absorção: se a partícula (solução candidata) atinge um núcleo com baixo valor da função objetivo é absorvida, caso contrário, uma partícula que atinge um núcleo com alto valor da função objetivo pode ser espalhada para outra região do espaço de busca. Assim, o espaço de busca do problema é amplamente percorrido e as regiões mais promissoras sejam exploradas através de eventos sucessivos de espalhamento e absorção.

5. RESULTADOS

Os resultados apresentados nesta seção levam em consideração a média de 10 experimentos com sementes geradoras de números aleatórios diferentes. Os parâmetros utilizados foram: 6 partículas; 6 processadores; 500 iterações. Para o critério de parada foi considerado o número máximo de avaliações da função objetivo.

O MPCA é usado para gerar um conjunto de soluções candidatas, as quais correspondem a uma arquitetura de rede neural. Em cada solução, a RNA é ativada e inicia-se o processo de treinamento até que o critério de parada seja satisfeito (erro desejado ou número total de épocas). O algoritmo calcula a função objetivo e define os parâmetros para a RNA. O processo se repete até que um critério de parada seja satisfeito.

Os dados utilizados nos experimentos foram coletados da base de dados de reanálise do NCEP/NOAA [<http://ww.ncep.noaa.gov>]: médias mensais de janeiro de 1998 a dezembro de 1999. A resolução espacial, em ambas as dimensões da grade é de 2.5° e resolução temporal (t) de 1 mês. Os experimentos foram realizados sobre uma sub-região do Nordeste do Brasil, entre as longitudes $[47^\circ\text{W}, 40^\circ\text{W}]$ e entre as latitudes $[0^\circ, -10^\circ\text{S}]$, para previsões climáticas sazonais da variável de precipitação. As variáveis meteorológicas são: vento zonal e meridional em 300 e 500 hPa, e campo de precipitação.

O algoritmo MPCA é empregado para determinar os melhores parâmetros para a rede (número de camada intermédia, número de neurônios em cada camada intermédia, taxa de aprendizagem,

constante momentum, função de ativação e conjunto de pesos). Os valores encontrados para estes parâmetros são apresentados na Tabela 1:

Tabela 1: Configuração arquitetura da rede neural

Parâmetro	MLP: MPCA	MLP: Ajuste Pesos	MLP: Empírica
Número de camada escondida	2	2	1
Número de neurônio na 1° camada escondida	9	9	6
Número de neurônio na 2° camada escondida	8	8	0
Número de neurônio na 3° camada escondida	0	0	0
Taxa de Aprendizagem	0.53	0.53	0.4
Constante momentum	0.2	0.2	0.6
Função de ativação	Tangente	Tangente	Logística
Erro quadrático médio	0.000076	0.000010	0.000048

Uma análise qualitativa dos resultados pode ser visualizada na Figura 1, a qual apresenta simultaneamente o resultado obtido no processo de previsão climática, usando a RNA configurada de forma empírica.

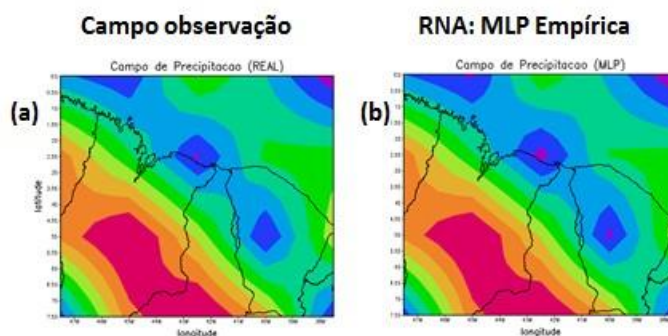


Figura 1: (a) Observado; (b) MLP configuração empírica.

Na Figura 2, são apresentados os resultados obtidos no processo de previsão climática, usando a RNA com sua arquitetura definida usando o MPCA e a rede neural com os pesos das conexões obtidos com o uso do MPCA.

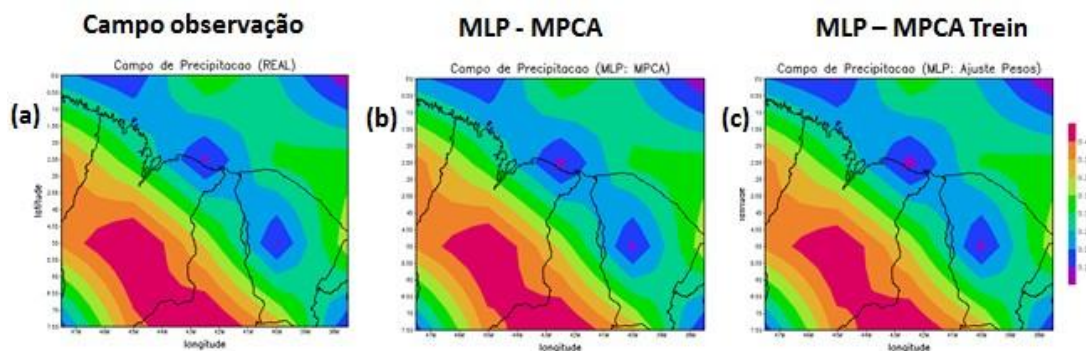


Figura 2: (a) Observado; (b) MLP configurada pelo MPCA; (c) MLP com pesos ajustados.

Analisando os mapas de erros entre as observações e a previsão das redes (Figura 3), observa-se que a MLP-empírica concentra os erros no oceano. Enquanto que a MLP-MPCA tem um erro menor na faixa no litoral, onde se concentra a maior parte da população da região. Além disso, os erros da MLP-MPCA estão melhores distribuídos, onde o erro concentra-se no intervalo [0–0.006] enquanto que o erro da MLP-empírica encontra-se no intervalo [0–0.01].




Figura 3: Diferença entre observação e RNA: (a) MLP-empírica; (b) MLP-MPCA; (c) MPCA-Treinamento.

5. CONCLUSÕES

Apresentamos um estudo que aborda uma aplicação de redes neurais para previsão sazonal. A configuração ótima da rede neural é determinada como uma solução de um problema de otimização. A arquitetura ótima da rede neural é calculada utilizando o algoritmo MPCA.

Os parâmetros de configuração da rede são obtidos tradicionalmente de forma empírica, com diversas tentativas de diferentes topologias, até serem obtidos resultados satisfatórios. O processo tem alto custo computacional e demanda tempo de um especialista. A principal vantagem da metodologia apresentada, para obter modelos de previsão usando RNA, é o uso do algoritmo otimização que reduz o tempo e a complexidade do problema.

REFERÊNCIAS

- CARVALHO, A., 2011. **Uso de redes neurais otimizadas para recuperação do perfil de concentração de gases traços atmosféricos a partir de dados de satélites**. Tese (Doutorado) Instituto Nacional de Pesquisas Espaciais, São José dos Campos - SP.
- HAYKIN, S., 2001. **Redes neurais princípios e práticas**. 2º ed. Porto Alegre: Bookman.
- LUZ, E., BECCENERI, J., VELHO, H.F., 2008. A new multi-particle collision algorithm for optimization in a high-performance environment. **Journal of Computational Interdisciplinary Sciences**, v. 1, p. 1-7.
- SACCO, W. F., OLIVEIRA, C. R. E. A., 2005. A new stochastic optimization algorithm based on a particle collision metaheuristic. In: **6th World Congress of Structural and Multidisciplinary Optimization**. Rio de Janeiro: WCSMO.