

Classificação Automática de Dermatoses a partir de Modelos Matemáticos de Redes Neurais Artificiais

Thaise Dias

Universidade Federal do Pará
Instituto de Ciências Exatas e Naturais

thaise.paes@itec.ufpa.br



Resumo

A detecção automática de doenças eritemato-descamativas (ESD) auxilia a tomada de decisões do profissional médico no diagnóstico. Uma Rede Neural Artificial (RNA) do tipo Perceptron de Múltiplas Camadas (MLP) é desenvolvida para realizar a classificação de seis diferentes tipos de dermatoses.

Introdução

Doenças eritemato-escamosas são dermatoses não alérgicas caracterizadas por erupções cutâneas cujos elementos básicos são eritema (coloração avermelhada da pele) e descamação [1]. Redes Neurais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes. Elas apresentam a capacidade de armazenar e utilizar conhecimento, bem como o reconhecimento de padrões. Este trabalho apresenta uma RNA do tipo MLP treinada pelo algoritmo *backpropagation* utilizando o método do gradiente conjugado escalonado como solução para o auxílio no diagnóstico de ESD [2].

Objetivos

1. Implementar uma RNA do tipo MLP para reconhecimento de padrões.
2. Treinar a rede com um banco de dados de histórico clínico para diagnosticar doenças eritemato-escamosas.

1 Arquitetura da Rede

A RNA utilizada é uma MLP com 34 termos na camada de entrada, uma camada escondida com 50 neurônios e uma camada de saída com 6 neurônios, como na figura 1.

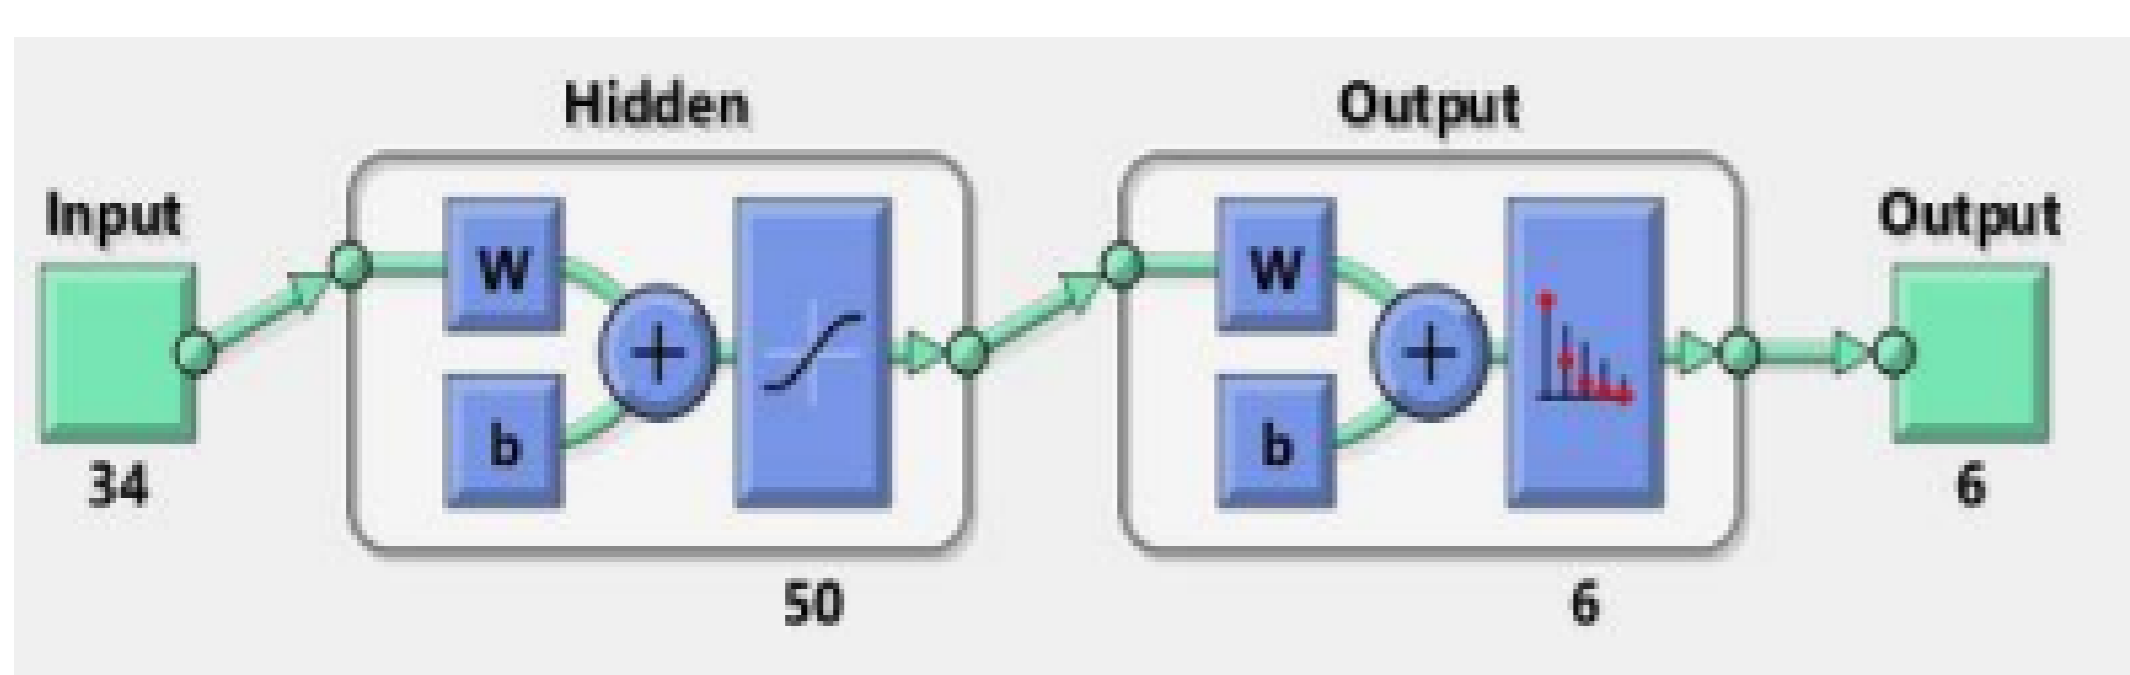


Figura 1: Arquitetura da RNA

Função de Ativação

A camada escondida é treinada com a função de ativação sigmoide, mostrada na Equação 1:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

A camada de saída utiliza uma função de ativação do tipo *softmax* (equação 2), uma generalização da função logística.

$$\sigma(z) = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad (2)$$

Backpropagation e o método do gradiente conjugado

O método de treinamento aplicado é chamado de Gradiente Conjugado Escalonado (GCE). O GCE mostra uma convergência superlinear na maioria dos problemas encontrados na literatura [3].

Banco de Dados

O banco de dados utilizado nesse estudo contém o histórico médico de 366 pacientes que foram avaliados para a

identificação de 12 sintomas clínicos e 22 características histopatológicas. Assim, contém 34 parâmetros que caracterizam a dermatose (entrada da RNA) e 6 classes que representam as seis diferentes patologias (saída para treinamento da RNA). Na ordem: psoríase, dermatite seborreica, líquen plano, pitiríase rosa, dermatite crônica e pitiríase rubra pilaris

Resultados

A rede foi treinada com 75 % dos dados, os restantes 30% foram divididos igualmente para teste e validação. A Figura 2 mostra a saída atingida pela rede neural e a compara com a saída esperada fornecida pela base de dados. A Figura 3 mostra a matriz de confusão, usada para representar as contradições entre a verdade de campo e o resultado do processo de classificação.

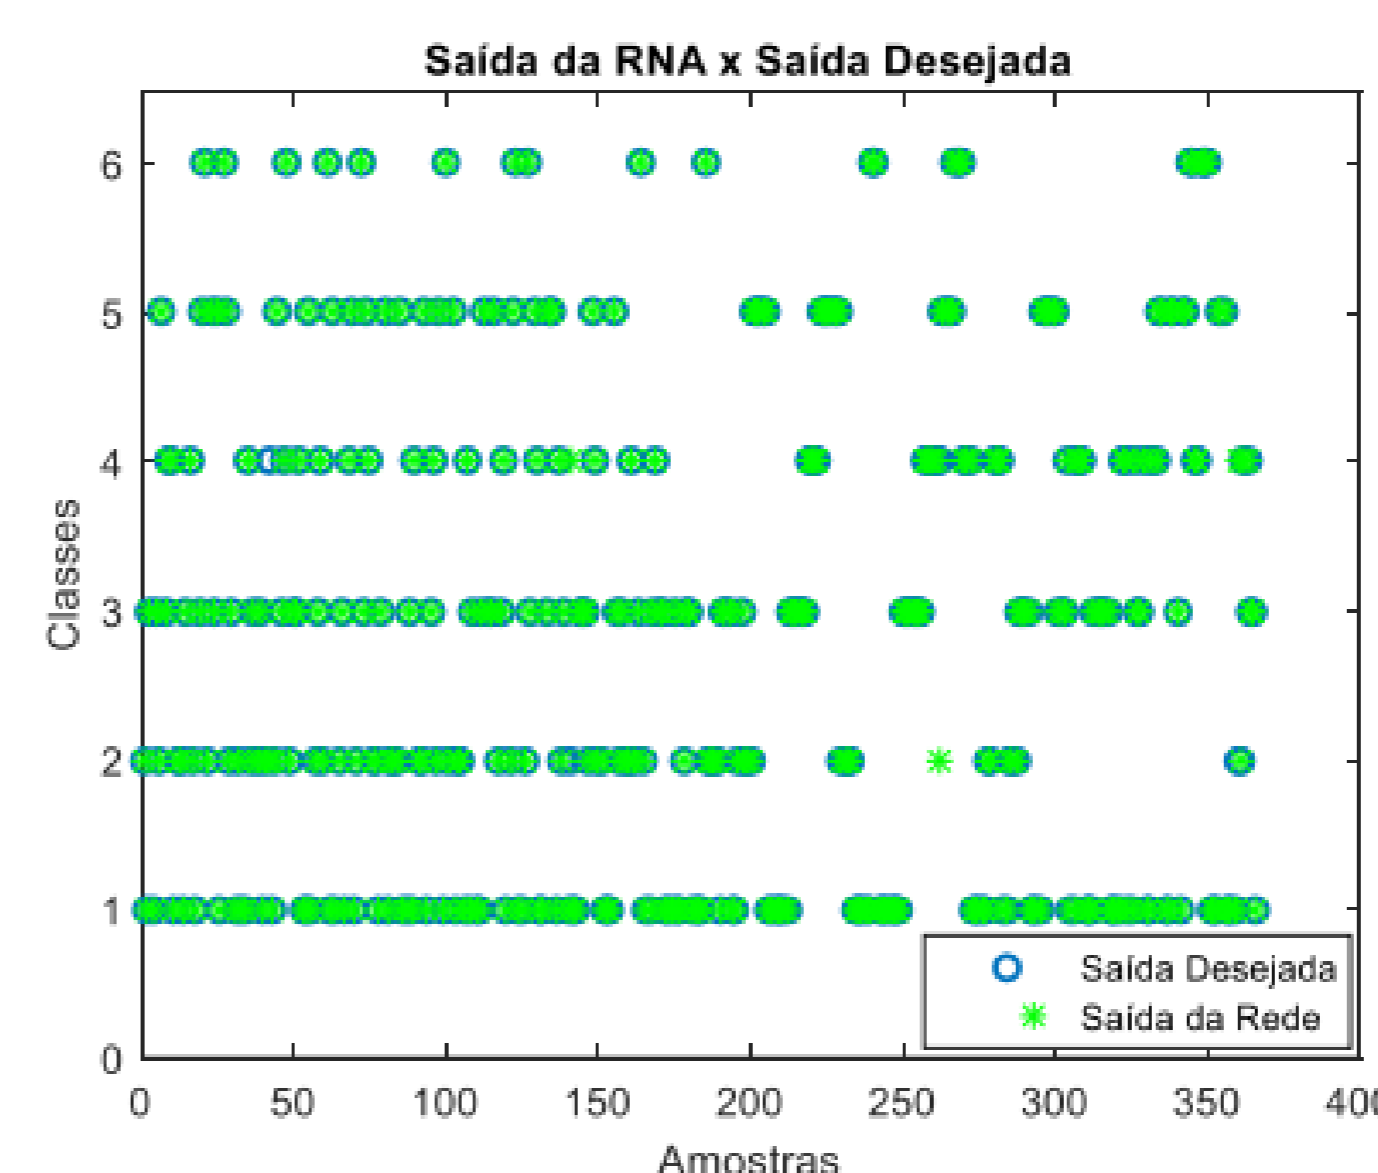


Figura 2: Comparação entre o resultado esperado e o resultado obtido pela RNA

		Confusion Matrix						
		1	2	3	4	5	6	
Output Class	1	112 30.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	61 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	71 19.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	1 0.3%	49 13.4%	0 0.0%	0 0.0%	98.0% 2.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	52 14.2%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 5.5%	100% 0.3%
		100% 0.0%	100% 0.0%	98.6% 1.4%	100% 0.0%	100% 0.0%	100% 0.0%	99.7% 0.3%
		1	2	3	4	5	6	

Figura 3: Matriz de Confusão

Conclusão

A alta capacidade de generalização das RNAs com uma arquitetura adequada combinada com o método de treinamento do gradiente é eficaz para o problema de diagnósticos de ESD. A rede apresentou taxa elevada de 99,7% de acertos.

Referências

- [1] Rachel C Garcia, Maria CW Rey, and Luiz AG Bernd. Dermatoses não-alérgicas: desafios diagnósticos. *Rev. bras. alerg. imunopatol.*, pages 222–229, 2005.
- [2] Simon Haykin. *Redes neurais: princípios e prática*. Bookman Editora, 2001.
- [3] Martin Fodslette Møller. A scaled conjugate gradient algorithm for fast supervised learning. *Neural networks*, 6(4):525–533, 1993.

Agradecimentos

À PROEX/UFPA e ao 34º CBM pelo apoio financeiro.