

Estudo da Robustez e da Capacidade de Generalização dos Algoritmos RPROP e Backpropagation na Modelagem do Comportamento à Fadiga de Compósitos

Raimundo Carlos Silverio Freire Júnior

*UFRN – CCET – Programa de Doutorado em Engenharia e Ciência dos Materiais
Lagoa Nova – Natal – RN – CEP: 59072-970*

E-mail: freirej@ufrnet.br

Adrião Duarte Dória Neto

*UFRN – CT – Programa de Pós Graduação de Engenharia Elétrica
Lagoa Nova – Natal – RN – CEP: 59072-970*

E-mail: adriao@leca.ufrn.br

Eve Maria Freire de Aquino

*UFRN – CT – DEM – Programa de Pós Graduação de Engenharia Mecânica
Lagoa Nova – Natal – RN – CEP: 59072-970*

E-mail: eve@dem.ufrn.br

Resumo

O objetivo deste trabalho é comparar dois algoritmos de treinamento na obtenção de uma rede neural para o modelamento do comportamento à fadiga de um material compósito, de modo que, se possa obter esse comportamento utilizando-se de uma quantidade reduzida de curvas S-N. Utilizando-se no treinamento os algoritmos Back-propagation e o RPROP testados a partir da técnica da validação cruzada. Durante o treinamento, a capacidade de generalização e robustez são fatores preponderantes diante da quantidade reduzida de curvas S-N. A partir dos resultados obtidos percebeu-se que os dois algoritmos de treinamento conseguiram generalizar o comportamento à fadiga do material porém somente o algoritmo de retropropagação pela regra do momento produziu resultados mais robustos do que a rede treinada com o algoritmo RPROP.

Palavras-chave: RPROP, Back-propagation, Fadiga, Materiais Compósitos.

1. Introdução

Durante o projeto de estruturas e equipamentos submetidos à cargas cíclicas na qual se utiliza materiais compostos como matéria prima, é freqüente a necessidade de grande quantidade de ensaios de fadiga para a obtenção de um certo nível de confiança no material, faz-se isso, principalmente, devido ao pouco conhecimento da resposta à carregamento dinâmico destes materiais, fazendo com que os mesmos se tornem pouco previsíveis, se comparado aos materiais convencionais [1].

A partir dos ensaios, obtêm-se as curvas S-N (amplitude de tensão versus número de ciclos) que são utilizadas para a construção de Diagramas de Fadiga de Vida Constante, que são de grande importância na aplicação e projeto. Porém, estes diagramas, quando construídos com pequena quantidade de curvas S-N subestimam ou sobreestimam o comportamento real do

compósito, verificando a necessidade sempre crescente de se fazer mais ensaios para a obtenção de maior precisão nos resultados [2].

Pesando desse modo, desenvolveu-se uma rede perceptron de múltiplas camadas com o intuito de modelar matematicamente o comportamento à fadiga de materiais compósitos, porém para se fazer este tipo de modelamento, se faz necessário a utilização de um algoritmo de treinamento que possua uma grande capacidade de generalização.

A capacidade de generalização de uma RNA está intrinsecamente relacionada com fatores como a boa escolha de uma arquitetura de rede e o tipo de algoritmo de treinamento utilizado. Quando se escolhe de maneira satisfatória a arquitetura de rede e o algoritmo de treinamento consegue-se otimizar a resposta obtida pela RNA [3].

Assim, verifica-se neste trabalho a possibilidade de utilização de dois algoritmos de treinamento o Back-propagation e o RPROP para a verificação das suas respectivas capacidades de generalização.

2. Dados experimentais usados

O material utilizado para análise foi um plástico reforçado com fibra de vidro obtido na literatura [4] com sigla **DD16** com 36 % de volume de fibra, fabricado pelo processo de moldagem com transferência de resina na qual a matriz é orto-polyester e possui como configuração (90/0/±45/0)_s, nas camadas à 0° e 90° possui tecido de fibra de vidro do tipo D155 (527 g/m²) e à ±45 possui tecido do tipo DB120 (393 g/m²).

Os ensaios foram realizados em um equipamento de teste da marca Instron 8501 com frequência de 10 Hz ou inferior. Para garantir que o material não sofresse aquecimento por histerese utilizou-se resfriamento a ar nas amostras. Foram feitos 454 ensaios, nos quais 59 foram ensaios estáticos (34 ensaios de tração e 25 de compressão), e os outros 395 foram utilizados para se fazer ensaios de fadiga para várias razões de fadiga (tensão mínima dividida pela tensão máxima) de 1.1, 1.43, 2, 10, -2, -1, -0.5, 0.1, 0.5, 0.7, 0.8 e 0.9. O diagrama de fadiga de vida constante e o número de corpos de prova para cada razão de fadiga (**R**) são demonstrados na tabela 1.

Para maiores detalhes sobre os ensaios, matéria prima ou processo de fabricação deste material pode-se consultar as literaturas [5-7].

Tabela 1. Dados obtidos para as constantes das curvas S-N e número de corpos de prova (CPs)

R	A	B	p	CPs
1,1	1,26	0,00408	1,00	6
1,43	1,78	0,0128	1,00	6
2	2,01	0,0118	1,50	20
10	2,27	0,0461	1,03	50
-2	2,50	0,00964	2,00	32
-1	2,60	0,0226	1,75	27
-0,5	2,69	0,109	1,05	21
0,1	2,47	0,0900	1,00	93
0,5	2,21	0,0471	1,25	66
0,7	1,99	0,0232	1,66	23
0,8	1,80	0,0167	1,69	28
0,9	1,46	0,00658	1,88	23
σ_{ultt}	632 MPa		σ_{ultc}	-400 MPa

3. Arquitetura e Treinamento da RNA

Para a criação do modelo matemático, utilizou-se a rede perceptron de múltiplas camadas com a arquitetura

consistindo de dois neurônios de entrada (tensão média e número de ciclos) e um neurônio de saída (amplitude de tensão), de modo que, se pudesse ter ao fim uma função que satisfizesse a condição mostrada na equação 1.

$$\sigma_a = f(\sigma_{med}, N) \quad (1)$$

Na qual σ_a é a amplitude de tensão aplicada (tensão máxima menos a tensão mínima dividido por dois), σ_{med} é a tensão média (tensão máxima mais a tensão mínima dividido por dois) e **N** é o número de ciclos na qual ocorreu a quebra do material.

Trabalhou-se com uma camada oculta com 2 a 30 neurônios, todos com bias e com função de ativação sigmóide nos neurônios ocultos e função linear no neurônio de saída. Os algoritmos utilizados para o treinamento foram o RPROP e o de Retropropagação com base na regra momento [8-9].

Fez-se o treinamento da rede a partir dos dados obtidos pela curva S-N, utilizando-se para tanto, a equação 2. Pode-se verificar a utilização desta equação em trabalhos da literatura [2-10]. Os valores das constantes **A**, **B** e **p** para cada razão de fadiga dados pela equação 2 são mostrados na tabela 1, na qual σ_{ultt} é o valor de tensão última à tração e σ_{ultc} é o valor de tensão última à compressão. Vale salientar aqui que o calculo feito para a obtenção destas constantes foi para 50 % de probabilidade de falha e utilizou-se o método dos mínimos quadrados para a obtenção destes valores.

$$\log(\sigma_a) = A - B \cdot [\log(N)]^p \quad (2)$$

Um diagrama esquemático demonstrando o modo de treinamento da RNA e o modelo de RNA obtido é mostrado na figura 2. Nesta figura, **T** representa o número de funções (curvas S-N obtidas da equação 2) utilizadas para o treinamento da RNA, **A** o número total de funções utilizadas, e o erro obtido entre resposta desejada e a resposta atual (utiliza-se neste trabalho os valores normalizados, variando entre 0 e 1, para a obtenção do erro) da RNA e **w** a matriz de pesos sinapticos da RNA.

Para o treinamento da RNA utilizou-se dois conjuntos de treinamento uma com três razões de fadiga **3R** (**R** = 10, -2 e 0.1) e a outra com 6 razões de fadiga **6R** (**R** = 2, 10, -2, -1, 0.1 e 0.5). A escolha destes conjuntos de treinamento foi feita objetivando, analisar a capacidade de generalização dos algoritmos de treinamento com uma pequena base de dados. Além disso, as razões de fadiga escolhidas foram feitas considerando uma melhor distribuição dos dados dentro das regiões de carregamento, utilizando-se também como critério o número de corpos de prova ensaiados. Durante o treinamento verificou-se o comportamento da **EMQ**

(equação 3) do conjunto total de dados, objetivando verificar a generalização da **RNA**.

$$EMQ = \frac{1}{2 \cdot Q} \cdot \sum_{i=1}^Q \sum_{j=1}^m (d_i - z_j)^2 \quad (3)$$

Na equação acima o **EMQ** é o erro médio quadrático, **Q** representa o tamanho do conjunto de dados, **m** o número de neurônios de saída (para este estudo $m = 1$), d_i e z_j são as respostas desejadas e a resposta atual do nó de saída, respectivamente.

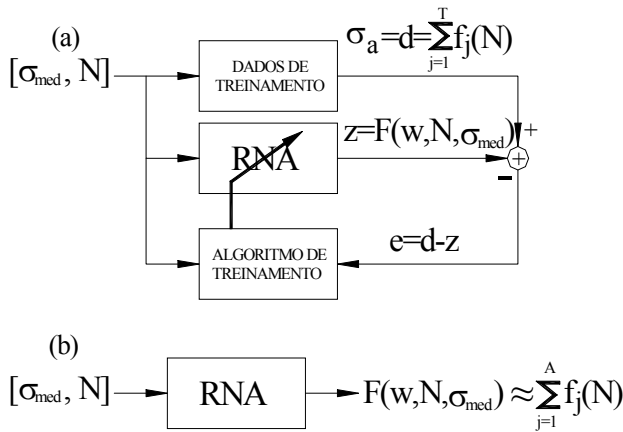


Figura 2. (a) Método de treinamento da **RNA**. (b) Modelo obtido pelo treinamento da **RNA**.

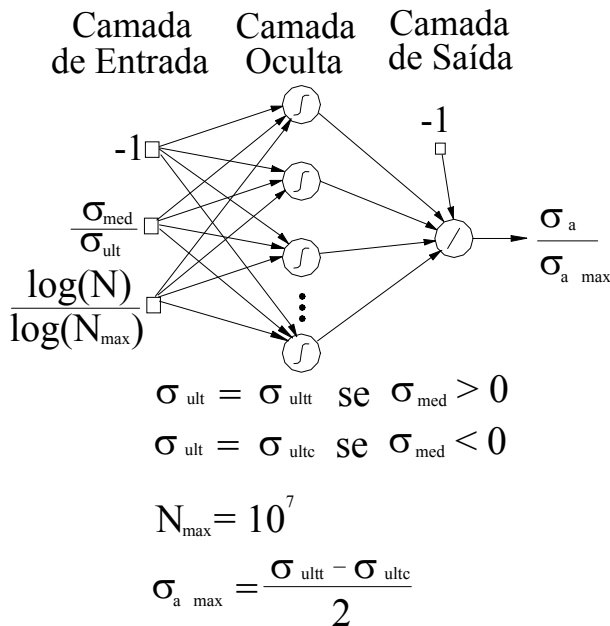


Figura 3. Arquitetura da **RNA**.

Tanto nos neurônios de entrada quanto no neurônio de saída fez-se a normalização dos dados, para o caso da tensão média fez-se esta normalização considerando o

sinal da mesma conforme mostra a figura 3. Esta modificação da normalização foi feita com o intuito de tornar os dados melhor distribuídos, facilitando desse modo o aprendizado da **RNA** [8].

Além dos dados obtidos pelas curvas **S-N**, utilizou-se os valores dos ensaios estáticos no treinamento objetivando facilitar a generalização da **RNA**.

4. Análise da Robustez e da capacidade de generalização dos algoritmos **RPROP** e **Back-propagation**

Demonstra-se na tabela 2 os melhores resultados obtidos para cada conjunto de treinamento e algoritmo de treinamento utilizado. Por estes resultados percebe-se que o algoritmo de treinamento **RPROP** obteve melhores resultados do que o algoritmo **Back-propagation**, pois obteve menores valores de **EMQ** para os dois conjuntos de treinamento utilizados.

Tabela 2. Melhores resultados obtidos para cada conjunto de treinamento e algoritmo de treinamento utilizado

Algoritmo de Treinam.	Conj. de Treinam.	EMQ		Neurônios Ocultos	Épocas de Treinam.
		Conj. de Treinam.	Conj. Total		
RPROP	3R	3,4E-7	3,9E-4	15	4000
RPROP	6R	1,7E-5	7,6E-5	26	899
Back	3R	6,2E-4	5,0E-4	8	349
Back	6R	1,5E-4	1,8E-4	23	3988

Apesar dos melhores resultados, o algoritmo de treinamento **RPROP** não possui uma robustez durante o treinamento. Por exemplo, quando se faz a validação cruzada (**EMQ** do conjunto total de dados e de treinamento em função do número de épocas de treinamento) percebe-se que o valor de mínimo obtido para o conjunto total de dados (**EMQ** mínimo) ocorre para épocas de treinamento bastante variadas, conforme se pode verificar nas figuras 4 e 5.

Os valores mínimos de **EMQ** do conjunto total de dados também foram muito dispersos para os dois conjuntos de treinamento analisados, conforme se pode verificar no exemplo da figura 6 para o conjunto de treinamento **3R**, considerando a camada oculta possuindo entre 2 e 30 neurônios. Desse modo, pode-se concluir que apesar dos resultados para alguns casos se apresentarem satisfatórios, não significa necessariamente que este algoritmo seja robusto, pois conforme se apresenta nos resultados não se sabe exatamente o que se pode obter após um treinamento com o algoritmo **RPROP**.

Vale salientar aqui que, o objetivo deste trabalho é a obtenção de um algoritmo que seja capaz não só de modelar o material analisado, mas que também possa ser

aplicado a outros casos, para tanto o mesmo precisa necessariamente ter bastante estabilidade (evitando mínimos locais) e robustez, o que não se verificou para o algoritmo RPROP, conforme foi dito anteriormente.




Figura 4. Curvas de **EMQ** obtidas para o treinamento utilizando o algoritmo RPROP de uma **RNA** com 9 neurônios ocultos e com o conjunto de treinamento **3R**.




Figura 5. Curvas de **EMQ** obtidas para o treinamento utilizando o algoritmo RPROP de uma **RNA** com 17 neurônios ocultos e com o conjunto de treinamento **3R**.

No caso do algoritmo Back-propagation, obteve-se uma maior estabilidade nos resultados, para exemplificar esta estabilidade pode-se verificar na figura 7 que existe uma relação entre o resultado apresentado pelo EMQ mínimo e o EMQ obtido pelo conjunto de treinamento demonstrando uma pequena dispersão dos resultados principalmente se comparando ao algoritmo RPROP. Isto demonstra a robustez do algoritmo Back-propagation no treinamento de redes neurais utilizadas como aproximadores de funções não lineares.

Ainda para o treinamento utilizando o conjunto de treinamento **3R** com algoritmo Back-propagation

verificou-se que o número de épocas de treinamento necessárias para a obtenção do **EMQ** mínimo foi de aproximadamente 300, este tipo de análise não foi possível para o algoritmo RPROP conforme se comentou anteriormente.

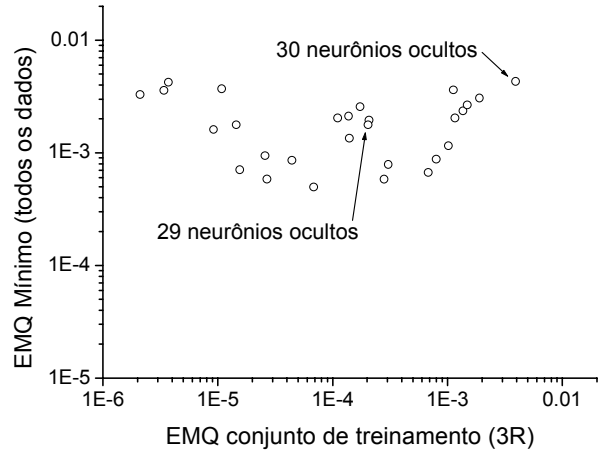


Figura 6. Dispersão do **EMQ** mínimo obtido para o conjunto total de dados durante o treinamento com o algoritmo RPROP com o conjunto de treinamento **3R**.

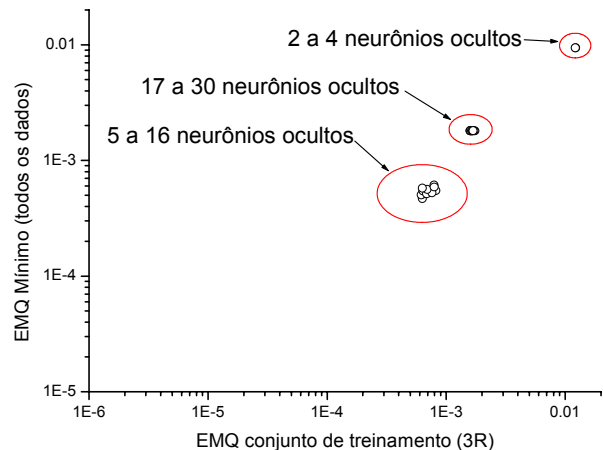


Figura 7. Dispersão do **EMQ** mínimo obtido para o conjunto total de dados durante o treinamento com o algoritmo Back-propagation com o conjunto de treinamento **3R**.

Já para o caso do conjunto **6R** treinado com o algoritmo Back-propagation, não ocorreu uma separação das curvas de EMQ do conjunto de treinamento e do conjunto total de dados, conforme se pode observar no exemplo da figura 8. Este tipo de comportamento é bastante desejável quando se deseja utilizar redes neurais como aproximadores de funções e convém salientar que com esta quantidade de curvas S-N distribuídas uniformemente pode-se obter resultados bem precisos.

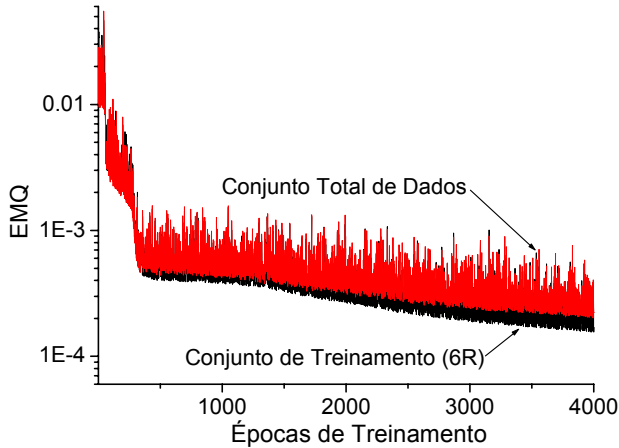


Figura 8. Curvas de **EMQ** obtidas para o treinamento usando o algoritmo Back-propagation com 25 neurônios ocultos e com o conjunto de treinamento **6R** (**R** = 2, 10, -2, -1, 0.1 e 0.5).

5. Análise das RNAs treinadas com o algoritmo Back-propagation

Apresenta-se na figura 9 um Diagrama de vida constante feito com uma RNA com 8 neurônios ocultos treinada com o algoritmo Back-propagation e se utilizou como conjunto de **3R** no treinamento. Por esta figura, percebe-se que apesar das curvas de vida constante representarem satisfatoriamente os valores obtidos pela equação 2. Para algumas curvas **S-N**, existem variações significativas, como por exemplo para **R** = -1 e 0,8.

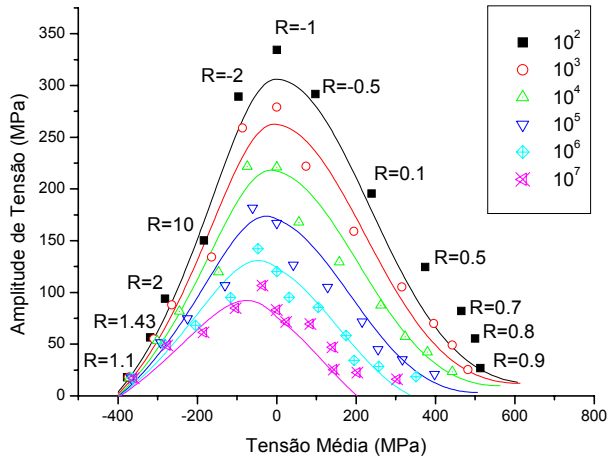


Figura 9. Diagrama de vida constante obtido de uma RNA com 8 neurônios ocultos treinada com o conjunto de dados **3R**. Com 349 épocas de treinamento.

Porém se analisarmos estes casos em separado estas curvas **S-N**, conforme mostra-se na figura 10, pode-se verificar que apesar da diferença de resultados entre os

dados obtidos da RNA e os dados obtidos da equação 2, os valores obtidos pela RNA não se distanciam excessivamente dos resultados experimentais podendo ser considerados satisfatórios. É interessante notar que se obteve uma generalização da RNA utilizando-se apenas três curvas **S-N**, isto demonstra o grande potencial que as RNAs possuem na previsão de vida à fadiga em materiais compostos.

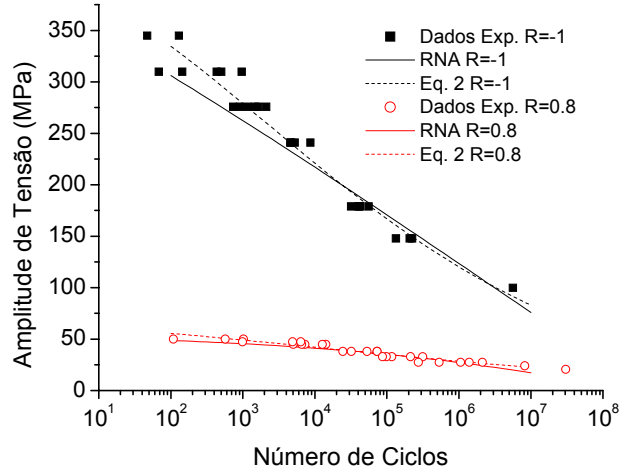


Figura 10. Dados Experimentais e Curvas **S-N** obtidas para **R** = -1 e **R** = 0.8. As curvas **S-N** foram obtidas da Equação 3 e de uma RNA com 8 neurônios ocultos treinada com o conjunto de dados **3R** (**R** = 10, -2 e 0.1).




Figura 11. Diagrama de vida constante obtido de uma RNA com 23 neurônios ocultos treinada com o conjunto de dados **6R**. Com 3988 épocas de treinamento.

Porém se se desejar uma melhor generalização na RNA deve-se utilizar uma maior quantidade de dados para treinamento, neste caso, com um conjunto de dados com 6 curvas **S-N** (**6R**), obteve-se para uma RNA com 23 neurônios ocultos um diagrama de vida constante como o demonstrado na figura 11.

A partir deste diagrama percebe-se como a RNA consegue generalizar bem todos os resultados obtidos, e que somente para $R = 2$ com $N = 10^7$, tem-se um distanciamento significativo entre resultados obtidos pela RNA e pela Eq. 2 deste R . Porém, novamente se se comparar estas curvas S-N obtidas pela RNA com os resultados experimentais para este e para outros casos como por exemplo para $R = -0.5$ e 0.9 , se verificará que as variações dos valores são pouco significativas, conforme é demonstrado na figura 12.

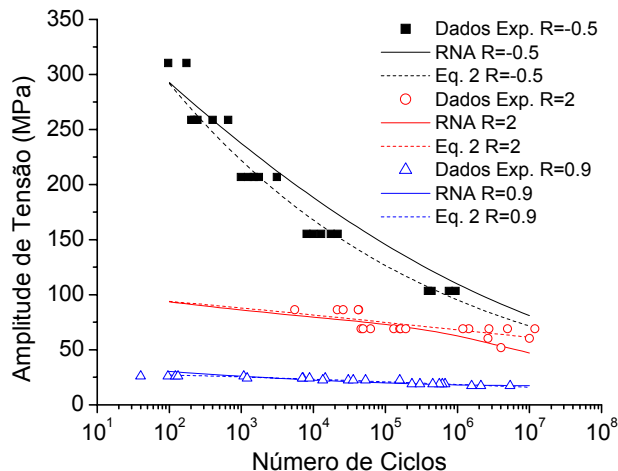


Figura 11. Dados Experimentais e Curvas S-N obtidas para $R = -0.5, 2$ e 0.9 . As curvas S-N foram obtidas da Equação 3 e de uma RNA com 23 neurônios ocultos treinada com o conjunto de dados 6R ($R = 2, 10, -2, -1, 0.1$ e 0.5).

5. Conclusões

A partir dos resultados obtidos pode-se concluir que apesar do algoritmo de treinamento RPROP apresentar resultados bastante satisfatórios no treinamento para obtenção do comportamento à fadiga de materiais compósitos, estes resultados se apresentam bastantes instáveis e, deste modo, este algoritmo é desaconselhável para este tipo de análise.

Já no caso do algoritmo Back-propagation pode-se dizer que existe uma estabilidade e robustez no treinamento apresentando resultados confiáveis, existindo a capacidade de aplicação deste algoritmo para análises futuras do comportamento à fadiga de outros materiais compósitos.

Outra conclusão importante diz respeito ao conjunto de treinamento 6R treinada com o algoritmo Back-propagation, na qual se obteve a generalização da rede mesmo para épocas de treinamento elevadas. Isto demonstra que, para este número de curvas S-N ou para valores maiores, pode-se obter resultados de grande confiança da rede durante o projeto.

6. Agradecimentos

Os autores agradecem à CAPES pelo financiamento da Bolsa de Doutorado, e à Universidade do Estado de Montana pela disponibilização da sua base de dados na Internet. E ao Prof. Paulo Henrique pelo auxílio no início dos trabalhos.

7. Referencias bibliográficas

1. Lee, J. A., Almond, D. P., Harris, B., "The Use of Neural Network for the Prediction of Fatigue Lives of Composite Materials", *Composites Part A: Applied Science and Manufacturing*, 30 (10), 1999, pp. 1159-1169.
2. Philippidis, T. P., Vassilopoulos, A. P., "Complex Stress State Effect on Fatigue Life of GRP Laminates. Part I, experimental", *International Journal of Fatigue*, Vol. 24, 2002, pp. 813-823.
3. Freire Júnior, R. C. S., Dória Neto, A. D., Aquino, E. M. F., "Building of Constant Life Diagrams of Fatigue Using Artificial Neural Networks", *International Journal of Fatigue*, Vol. 27, 2005, pp. 746-751.
4. DOE/MSU Composite Material Fatigue Database, Montana State University - Bozeman, 2003.
5. Wahl, N., Samborsky, D., Mandell, J., Cairns, D., "Spectrum Fatigue Lifetime and Residual Strength for Fiberglass Laminates in Tension", *Wind Energy 2001*, 2001, pp. 49-59.
6. Wahl, N., Samborsky, D., Mandell, J., Cairns, D., "Effects of Modeling Assumptions on the Accuracy of Spectrum Fatigue Lifetime Predictions for a Fiberglass Laminate", *Wind Energy 2002*, 2002, pp. 19-26.
7. Mandell, J., Reed, R., Samborsky, D., "DOE/MSU Composite Material Fatigue Database: Test, Methods, Material and Analysis", SAND97-3002, Sandia National Laboratories, 1997.
8. Haykin, H., "Redes Neurais Princípios e Prática", 2ª Ed., 2001.
9. Riedmiller, M., Braun, H., "A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm", *International Conference on Neural Networks*, Vol. 1, 1993, pp. 586-591.
10. Read, P., Sheno, R., "A Review of Fatigue Damage Modelling in the Context of Marine FRP Laminates", *Marine Structures*, Vol. 8, 1995, pp. 257-278.