



VI CONGRESSO NACIONAL DE ENGENHARIA MECÂNICA
VI NATIONAL CONGRESS OF MECHANICAL ENGINEERING
18 a 21 de agosto de 2010 – Campina Grande – Paraíba - Brasil
August 18 – 21, 2010 – Campina Grande – Paraíba – Brazil

INFLUÊNCIA DO CONJUNTO DE TREINAMENTO NA GENERALIZAÇÃO DE RNAs UTILIZADAS NA ANÁLISE DA FADIGA DE MATERIAIS COMPÓSITOS

Bremmer Bernardo Vasconcelos de Sena

UFRN – CT – Engenharia Mecânica
Campus Universitário – Lagoa Nova – Natal – RN – CEP: 59072 - 970
E-mail: bremmer02@yahoo.com.br

Raimundo Carlos Silverio Freire Júnior

UFRN – CT - Programa de Pós-Graduação de Engenharia Mecânica
Campus Universitário – Lagoa Nova – Natal – RN – CEP: 59072 – 970
E-mail: freirej@ufrnet.br

Resumo. *Em projetos de estruturas e equipamentos submetidos a cargas cíclicas onde se utilizam compósitos como matéria prima, é frequente a necessidade de grande quantidade de ensaios de fadiga para a obtenção de certo grau de confiança do material. Tais ensaios tornam-se inconvenientes por serem bastante demorados. A solução ideal seria a obtenção da resposta à fadiga desses materiais com o mínimo de ensaios e o máximo de confiança possível. Encontram-se na literatura, vários modelos matemáticos que são utilizados com o intuito de prever a vida desses materiais através de Diagramas de Falha, recentemente se iniciou a utilização com Redes Neurais Artificiais (RNAs). Sabe-se que para que a rede possa dar uma boa resposta é necessário um conjunto de dados que represente bem a característica do comportamento à fadiga do material. Esse trabalho tem como objetivo analisar a influência da escolha do conjunto de dados no treinamento de redes neurais, fazendo um comparativo entre o conjunto de dados que considera as curvas S-N mais avaliadas, que são para $R = 10, -1$ e $0,1$; com outros dois conjuntos de dados onde se troca a curva para $R = -1$ ou por um R dentro da região de carga variável com predominância da tração ou com predominância da compressão, verificando, desse modo, a região de dados que melhor representa o comportamento geral do material compósito. Para tanto se fez o treinamento de nove materiais extraídos da literatura (definidos pelas siglas: C10, C12, DD16, HTA-913, IM7-977, MAT(0)₂, T800-5245, QQ1 e QQ1t), e em seguida analisou-se o comportamento do coeficiente de correlação e do erro médio quadrático para os referidos materiais.*

Palavras chave: *Redes Neurais Artificiais, Conjunto de Treinamento, Fadiga, Materiais Compósitos.*

1. INTRODUÇÃO

Os materiais compósitos são constituídos por dois ou mais materiais, no qual se leva em consideração a compatibilidade entre suas fases constituintes, ou seja, matriz e reforço. O estudo desses materiais é de extrema importância para diversos campos de aplicação que se estendem desde equipamentos de uso recreativo até aplicações militares, essa possibilidade de aplicação tão vasta deve-se principalmente às várias características que podem ser obtidas destes materiais, onde podemos destacar o seu baixo peso aliado a uma boa resistência mecânica, resistência à corrosão entre outros (Freire Jr, 2005; Levy, 2006).

Os materiais metálicos apresentam propriedades bem definidas, repetidas e previsíveis a partir dos processos clássicos de fabricação já consolidados tecnologicamente ao longo de muitas décadas. Por outro lado, as propriedades dos compósitos são significativamente influenciadas por uma grande quantidade de parâmetros. Se por um lado este fato torna o modelamento matemático do comportamento mecânico dos compósitos difícil e trabalhoso, por outro pode possibilitar a liberdade de ajustar a manufatura do material compósito dotando-o de propriedades adequadas à necessidade, atendendo a um requisito específico do projeto. Dessa forma, o compósito pode ser efetivamente projetado simultaneamente ao componente estrutural de que se necessita para uma dada aplicação, dotando-o de propriedades únicas, de forma a atender aos requisitos específicos exigidos do projeto (Levy, 2006).

Durante o projeto de estruturas e equipamentos submetidos a cargas cíclicas na qual se utilizam compósitos como matéria prima, é frequente a necessidade de grande quantidade de ensaios de fadiga para a obtenção de certo grau de confiança do material. Porém tais ensaios tornam-se inconvenientes por serem bastante demorados, ensaios de fadiga de alto ciclo possuem número de ciclos superior a 10^3 , aliado a este fator temos um outro, o pouco conhecimento da resposta à carregamento dinâmico desses materiais, fazendo com que os mesmos se tornem pouco previsíveis, se comparado aos materiais convencionais (Freire Jr, 2005; Sutherland, 1999).

A solução ideal seria a obtenção, com razoável confiança da resposta à fadiga do material com uma mínima quantidade de ensaios. Isso habilitaria o projetista a fazer previsões preliminares da provável vida à fadiga do material antes de se despendar tempo e dinheiro em uma análise mais profunda com grande número de ensaios (Freire Jr, 2005).

Deste modo, encontram-se na literatura especializada, vários modelos matemáticos que são usados com o intuito de prever a vida dos materiais compósitos através de Diagramas de Falha, analisando de modo global o comportamento à fadiga do material. Dentre esses modelos, existem os modelos empíricos e semi-empíricos e, mais recentemente se iniciou a utilização de Redes Neurais Artificiais (RNAs) também com esse mesmo objetivo. Contudo, para o caso de RNAs o estudo verificado pela literatura ainda se encontra em fase embrionária e há muito que ser feito (Freire Jr, 2005, Mandell et al., 1997; Bond, 1999; Beheshty et al., 1999).

Este trabalho possui o objetivo de fazer uma análise mais ampla dos modelos de RNA considerando o conjunto de treinamento utilizado para treinar a rede bem como sua utilização em compósitos à base de fibra de carbono, verificando a capacidade das RNAs de modelar esses tipos de compósitos.

2. MATERIAIS OBTIDOS DA LITERATURA

Para este trabalho se utilizou três materiais compósitos publicados em trabalhos anteriores (Freire Jr, 2005; Freire Jr, 2009) e os outros seis extraídos da literatura, sendo três desses materiais confeccionados utilizando fibra de carbono e o restante com fibra de vidro.

Utilizou-se dois laminados confeccionados industrialmente pelo processo de laminação manual (hand-lay-up), com resina de poliéster insaturada ortoftálica e reforço de fibra de vidro-E nas formas de manta (5cm,450g/m²) e tecido têxtil bidirecional (450g/m²). Tais laminados diferenciam-se pela configuração de suas laminas, sendo o laminado C10 apresentando simetria no sentido de suas fibras, enquanto que o laminado C12 não possui simetria (Freire Jr, 2005).

Outro material analisado foi um plástico reforçado com fibra de vidro obtido da literatura (DOE/MSU, 2003) 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 (527g/m²) e à ±45 e tecido do tipo DB (393g/m²).

Outro material utilizado é denominado de MAT(0)₂ (DOE/MSU,2003) trata-se de um plástico com fibra de vidro com duas camadas ensaiado no sentido principal da fibra e fabricado na forma de tecido D155 com gramatura de 527g/m² e a matriz é a base de poliéster na qual utilizou-se a Coresina 63-AX-051 pelo processo “hand lay-up”, possuindo 48% de volume de fibra de vidro.

Os três laminados fabricados em fibra de carbono são: HTA/913, com fibra ENKA de alta resistência matriz com fibra BSL 913 de epoxy com baixa cura; T800/5245, com fibra Toray de alta resistência a falha, matriz Narmco epoxy e o IM7/977, com fibra Hercules de elevada resistência a falha e matriz 977 modificada. Todos os laminados possuem a seguinte configuração [(±45,0)₂]s com 65% de volume de fibra e fabricados pelo processo hand-lay-up (B. Harris, J. A. Lee e T. Adam, 1997)

Para melhor conhecimento das configurações, processo de fabricação, entre outros, pode-se consultar a literatura (Freire Jr, 2009; DOE/MSU,2003; B. Harris, J. A. Lee e T. Adam, 1997; N. Gathercole, H. Reiter, T. Adam e B. Harris, 1994)

3. PRÉ-PROCESSAMENTO DOS DADOS

Para a obtenção das curvas S-N dos materiais aqui estudados, foi aplicada a generalização da lei da potencia “power law”, apresentada na equação 1.

$$\log(\sigma_a) = A - B \cdot [\log(N)]^P \quad (1)$$

Na equação acima, **A**, **B** e **P** são constantes que devem ser determinadas, **N** é o número de ciclos para a ruptura do material e σ_a é a amplitude de tensão a qual o material está sujeito. Os valores das constantes **A**, **B** e **P** para cada razão de fadiga dados pela equação 1 são mostrados nas Tabelas 1, 2 e 3, onde σ_{ultT} é o valor de tensão última à tração (limite de resistência à tração) e σ_{ultC} é o valor de tensão última à compressão (limite de resistência à compressão). Os valores das constantes mostrados nas Tabelas de 1 a 3 referentes aos materiais HTA-913, IM7-977, T800-5245, QQ1 e QQ1t, os valores das contantes para os demais materiais podem ser encontradas em trabalhos anteriores (Freire Jr. e Sena, 2009; Freire Jr. 2005).

Percebe-se pelos valores obtidos para o coeficiente de correlação que a equação utilizada se adequou bem aos dados experimentais, isso só não ocorre para **R** = -0,3 do **IM7-977**, porém isso acontece devido à dispersão desses dados ser muito alta.

Tabela 1: Dados obtidos para as curvas S-N e razões de fadiga dos materiais HTA-913 e IM7-977

R	HTA/913			r	IM7/977			r
	A	B	P		A	B	P	
10	2,62	0,026	1,20	0,97	2,57	0,0045	1,88	0,93
-1,5	2,87	0,0013	3	0,92	2,81	0,00067	3	0,90
-1	2,99	0,013	1,81	0,99	2,95	0,02	1,36	0,94
-0,3	2,91	0,00084	3	0,99	2,99	0,00089	3	0,79
0,1	2,74	0,00046	3	0,95	2,78	0,00037	3	0,90
σ_{ultC}		σ_{ultT}			σ_{ultC}		σ_{ultT}	
-970 (MPa)		1270 (MPa)			-900 (MPa)		1430 (MPa)	

Tabela 2: Dados obtidos para as curvas S-N e razões de fadiga do T800/5245

Razão de Fadiga (R)	A	B	P	Coeficiente de Correlação (r)
10	2,6	0,010	1,62	0,88
-1,5	2,86	0,006	2	0,95
-1	2,9	0,0010	3	0,95
-0,6	3,12	0,058	1,02	0,97
-0,3	3,03	0,017	1,5	0,96
0,1	2,86	0,017	1,31	0,95
0,5	2,62	0,014	0,97	0,85
σ_{ultC}	-880 (MPa)		σ_{ultT}	1670 (MPa)

Tabela 3: Dados obtidos para as curvas S-N e razões de fadiga dos materiais QQ1 e QQ1t

R	Laminado QQ1			r	Laminado QQ1t			r
	A	B	P		A	B	P	
10	2,47	0,026	1,28	0,98	2,08	0,082	0,72	0,98
-2	2,72	0,064	0,97	0,98	2,32	0,106	0,99	0,99
-1	2,83	0,06	1,37	0,99	2,15	0,060	1,30	0,99
-0,5	2,86	0,091	1,18	0,99	2,04	0,071	1,19	0,98
0,1	2,67	0,097	1,2	0,98	1,8	0,071	1,06	0,99
0,5	2,34	0,045	1,44	0,98	1,55	0,044	1,21	0,99
0,7	—	—	—	—	1,31	0,033	1,81	0,98
σ_{ultC}		σ_{ultT}			σ_{ultC}		σ_{ultT}	
-691,89 (MPa)		868,69 (MPa)			-274 (MPa)		148,24 (MPa)	

4. MODELAMENTO MATEMÁTICO

Para a criação do modelo matemático, utilizou-se a rede perceptron de múltiplas camadas treinado pelo Algoritmo Back Propagation, com 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 um função que satisfizesse a condição mostrada na equação 2.

$$\sigma_a = f(\sigma_{med}, N) \tag{2}$$

Onde 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 em que ocorreu a ruptura do material (Freire Jr, 2005).

Trabalhou-se com uma camada oculta com 2 a 30 neurônios, todos com bias e função de ativação sigmoide nos neurônios ocultos e função linear no neurônio de saída. O algoritmo utilizado para o treinamento foi o de Retro propagação com base na regra do momento (Freire Jr, 2005; Haykin, 2001). Fez-se o treinamento da rede a partir dos dados obtidos pela curva S-N, utilizando-se para tanto, a equação 1 (Freire Jr, 2005).

O diagrama abaixo demonstra o modo de treinamento da RNA (a) e o modelo obtido (b), onde TRE representa o número de curvas (curvas S-N obtidas da equação 1) utilizadas para o treinamento da RNA, TOD é o número total de funções utilizadas, e e é o erro entre a resposta desejada e a resposta atual da RNA e w é a matriz de pesos sinápticos da RNA (Freire Jr, 2005).

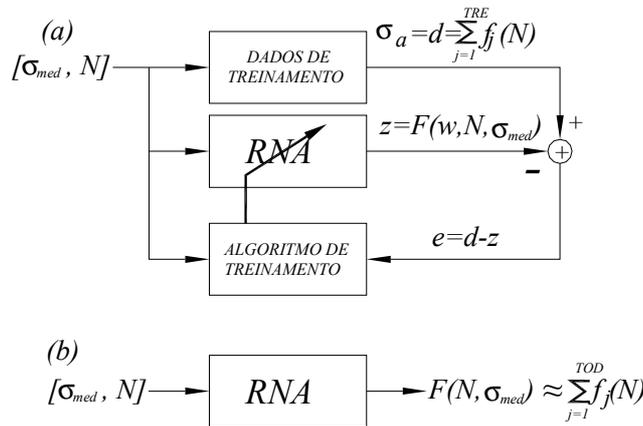


Figura 1. (a) Método de treinamento da . (b) Modelo obtido pelo treinamento da RNA.

Os valores escolhidos para a constante de momento e a taxa de aprendizado foram de 0.7 e de 0.1. Na escolha dos dados para treinamento foram consideradas as razões de fadiga apresentadas da Tabela 4. A escolha destes conjunto de treinamento foi feita objetivando uma melhor distribuição dos dados dentro das regiões de carregamento.

Neste trabalho, buscou-se analisar a influência da escolha do conjunto de dados no treinamento de redes neurais, fazendo um comparativo entre o conjunto de dados que considera as curvas S-N mais avaliadas, que são para $R = 10, -1$ e $0,1$; com outros dois conjuntos de dados onde se troca a curva para $R = -1$ ou por um R dentro da região de carga variável com predominância da tração (T-C) ou com predominância da compressão (C-T), verificando, desse modo, a região de dados que melhor representa o comportamento geral do material compósito.

A variação do valor de R está relacionada com os tipos de tensões que podem ser aplicados ao material de modo que: entre $1 < R < \infty$, as tensões vão de variáveis compressivas até as pulsivas de compressão (C-C), entre $-\infty < R < -1$ o tipo de tensão é variável de tração/compressão com compressão dominante (C-T), entre $-1 \leq R < 0$, as tensões que vão de alternadas até variáveis de tração/compressão com tração dominante (T-C); e entre $0 \leq R < 1$, as tensões são totalmente trativas (T-T). Para melhor compreensão da variação do valor de R , o esquema dessas regiões delimitadas pela razão de fadiga (R), como também está demonstrada no gráfico amplitude de tensão (σ_a) versus a tensão média (σ_{med}) exposto na Figura 2 (Freire Jr, 2005).

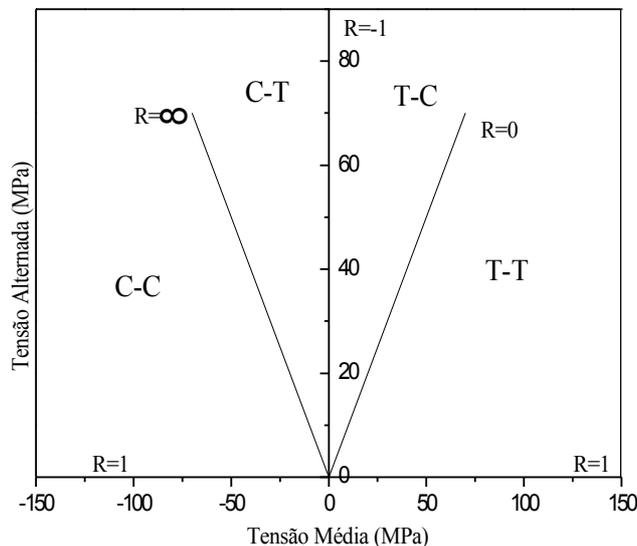


Figura 2. Gráfico da amplitude de tensão (σ_a) versus a tensão média (σ_{med}), demonstrando a variação da razão de fadiga

Conforme se verifica nesta Figura a ideia da escolha do conjunto de treinamento se justifica, pois dependendo de quais valores de R são utilizados no treinamento ter-se-á um conjunto de dados que melhor representa as características do comportamento à fadiga do material, ou então um conjunto de dados no qual estas características podem estar sendo desconsideradas.

Tabela 4: Curvas S-N utilizadas no treinamento da RNA

MATERIAL	CONJUNTO DE DADOS			
	T-C	C-T	Clássico	Todos
C10	—	0; -1,57; 0,1	10; -1; 0,1	1,43; 10; -1,57; -1; 0,1; 0,7
C12	—	10; -1,57; 0,1	10; -1; 0,1	1,43; 10; -1,57; -1; 0,1; 0,7
DD16	10; -0,5; 0,1	10; -2; 0,1	10; -1; 0,1	1,1; 1,43; 2; 10; -2; -1; -0,5; 0,1; 0,5; 0,7; 0,8; 0,9
HTA-913	10; -0,3; 0,1	10; -0,3; 0,1	10; -1; 0,1	10; -1,5; -1; -0,3; 0,1
IM7-977	10; -0,3; 0,1	10; -0,3; 0,1	10; -1; 0,1	10; -1,5; -1; -0,3; 0,1
MAT(0) ₂	10; -0,5; 0,1	—	10; -1; 0,1	2; 10; -1; -0,5; 0,1; 0,5
QQ1	10; -0,5; 0,1	10; -2; 0,1	10; -1; 0,1	10; -2; -1; -0,5; 0,1; 0,5
QQ1t	10; -0,5; 0,1	10; -2; 0,1	10; -1; 0,1	10; -2; -1; -0,5; 0,1; 0,5; 0,7

Tanto nos neurônios de entrada quanto nos neurônios 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 (Haykin, 2001).

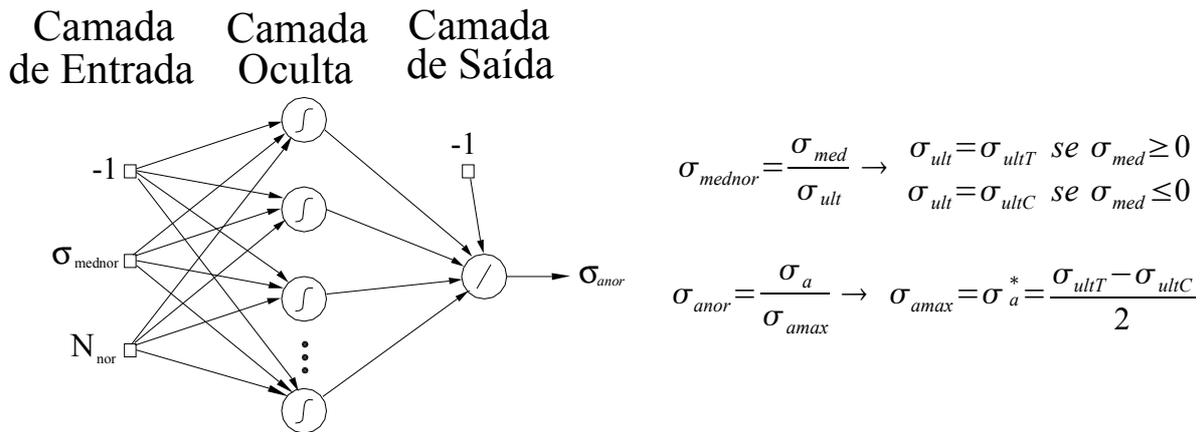


Figura 3. Diagrama demonstrando o modelo de simulação da RNA (Freire Jr, 2005).

Conforme dito anteriormente no estudo aqui desenvolvido verificou-se a influência da escolha do conjunto de dados no treinamento de uma RNA, em materiais compósitos submetido à fadiga. Vale salientar ainda que todos os neurônios aqui utilizados possuem bias e função de ativação sigmoide nos neurônios ocultos e função linear no neurônio de saída. O range de análise do número de ciclos neste estudo ficou entre 10^2 e 10^7 ciclos, ao passo que os dados experimentais analisados estão nesta região. O software utilizado para implementação de todos os algoritmos utilizados nesta pesquisa foi o MATLAB.

5. RESULTADOS

Para a análise dos resultados utilizou-se a técnica de validação cruzada, esta técnica analisa o EMQ (erro médio quadrático) do conjunto de treinamento (EMQ_{TRE}) e do conjunto total de dados (EMQ_{TOD}), fazendo com que, ao final do treinamento se escolha os pesos sinápticos da rede no menor valor de EMQ_{TOD} .

Apresenta-se na Figura 3 um exemplo do comportamento do EMQ_{TOD} e do EMQ_{TRE} em função do número de épocas de treinamento analisadas, para o MAT(0)₂, HTA, IM7, T88, QQ1 e QQ1t.

Analisando os resultados obtidos durante o treinamento por validação cruzada, se verificou que para o conjunto de treinamento as curvas de EMQ_{TOD} e EMQ_{TRE} possuíam o comportamento seguinte: 1) acompanhamento das duas curvas de EMQ_{TOD} e EMQ_{TRE} com valores aproximados ou na mesma ordem de grandeza (Figura 4 (a)) ou 2) o acompanhamento de EMQ_{TOD} e EMQ_{TRE} na mesma ordem de grandeza com separação das duas curvas antes de 1500

épocas de treinamento onde a tendência do EMQ_{TOD} é estabilizar-se em um valor superior ao do EMQ_{TRE} como pode ser observado na Figura 4 (b). Vale salientar que esse comportamento foi verificado para os dois conjuntos de treinamento utilizados nos materiais IM7-977 e T800-5245.

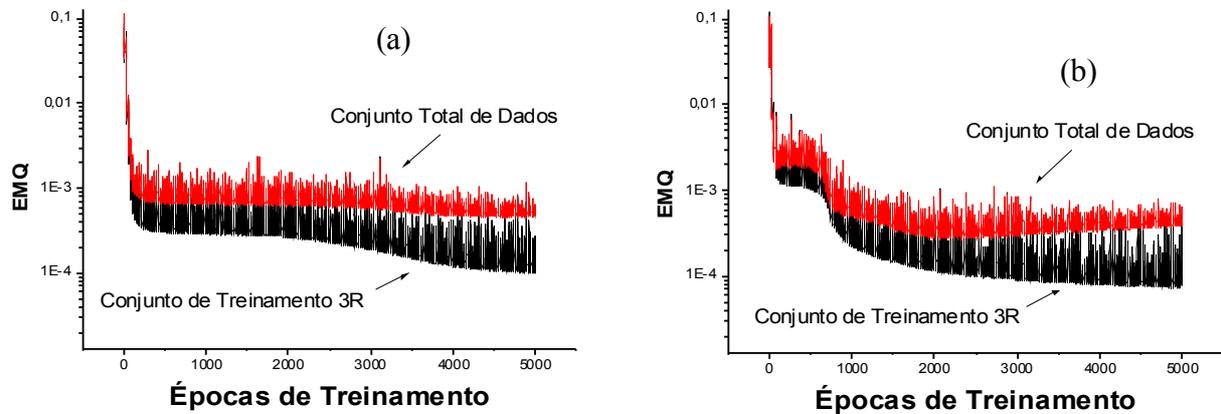


Figura 4. Curvas de EMQ obtidas durante o treinamento de uma RNA com 26 neurônios ocultos para o IM7-977 (a) e 23 neurônios ocultos (b) para o T800-5245, com conjunto de treinamento 3R ($R= 10; -0,3; 0,1$).

É interessante comentar que o comportamento demonstrado na Figura 4 (a) foi verificado para os materiais IM7-977, HTA-913 e QQ1t, na Figura (b) tem-se o comportamento para o QQ1. Em trabalhos anteriores pode-se observar o comportamento do erro para os materiais C10, C12 e DD16 (Freire Jr, 2005; Freire Jr, 2008) e para o $MAT(0)_2$ (Freire Jr. e Sena, 2009).

A capacidade de aprendizado depende da representatividade dos exemplos disponíveis e da complexidade da arquitetura da rede. Sabe-se que um treinamento excessivo pode levar a um resultado insatisfatório, pois é comum a falta de um conjunto de dados suficientemente grande para a validação da rede, um treinamento muito longo pode levar a rede a mascarar os resultados podendo-se dizer até mesmo que a rede “memoriza” os resultados. De outras pesquisas (Freire Jr, 2005; Freire Jr, 2007) viu-se que a solução ideal seria a utilização do bom senso limitando o número de épocas de treinamento e o valor do EMQ_{TRE} , outro fator que deve ser mencionado é a escolha do conjunto de dados, para que a rede possa dar uma boa saída, faz-se necessário um conjunto de dados que represente de modo satisfatório o comportamento à fadiga do material.

Na Tabela 5 tem-se os valores de EMQ para os melhores resultados obtidos para cada conjunto de treinamento dos materiais analisados, os resultados dos materiais DD16, C10 e C12 foram extraídos de pesquisas anteriores (Freire Jr, 2005; DOE/MSU, 2003; Freire Jr, 2007).

Tabela 5: Melhores resultados obtidos para cada conjunto de treinamento (as RNAs utilizaram entre 2 e 30 neurônios ocultos e foram treinadas até 5000 épocas de treinamento).

Material Compósito	T-C		C-T		CLÁSSICO	
	EMQ_{TRE}	EMQ_{TOD}	EMQ_{TRE}	EMQ_{TOD}	EMQ_{TRE}	EMQ_{TOD}
C10	—	—	0,000089	0,00048	0,00016	0,00050
C12	—	—	0,00030	0,00040	0,00010	0,00023
DD16	0,00028	0,00050	0,00043	0,00030	0,00022	0,00035
HTA-913	0,00018	0,00015	0,000076	0,000097	0,000032	0,00011
IM7-977	0,00032	0,0030	0,00013	0,00044	0,000054	0,0012
$MAT(0)_2$	0,000056	0,00027	—	—	0,000062	0,00025
T800-5245	0,00049	0,0014	0,00014	0,00026	0,00026	0,0014
QQ1	0,00016	0,00033	0,00011	0,00018	0,00010	0,00025
QQ1t	0,000066	0,00033	0,00020	0,00016	0,000063	0,00021

Percebe-se na Tabela 5 que para todos os materiais os resultados do treinamento (EMQ_{TOD}) com uma das curvas S-N na região de compressão-tração (C-T) apresentam melhores resultados em relação aos conjuntos de dados clássico ($R= 10; -1$ e $0,1$) e com utilização de uma das curvas S-N na região de tração-compressão (T-C). Tal fato ocorre devido os dados de compressão possuírem um maior número de informações sobre o comportamento à fadiga do compósito,

devido ao processo de fratura depender tanto do comportamento da fibra quanto do comportamento da resina, enquanto que à tração basicamente só é influenciado pela resistência da fibra. Ainda da Tabela 5, é possível observar que com exceção dos materiais IM7-977 e T800-5245, os resultados do treinamento (EMQ_{TOD}) com predominância de tração-compressão apresenta resultados melhores que o conjunto de treinamento com as curvas S-N clássica.

Pelos resultados apresentados para o conjunto de dados C-T de treinamento percebe-se que se pode utilizar como critério de parada da EMQ o valor de 0,0004 para materiais onde se possui os valores de $R=0,1; 10$ e um R dentro da região de carga variável (compressão-tração) sob o domínio da compressão. Para uma melhor compreensão dos resultados da Tabela 5, tem-se na Figura 5 o comportamento do EMQ_{TOD} para cada material nas regiões analisadas.

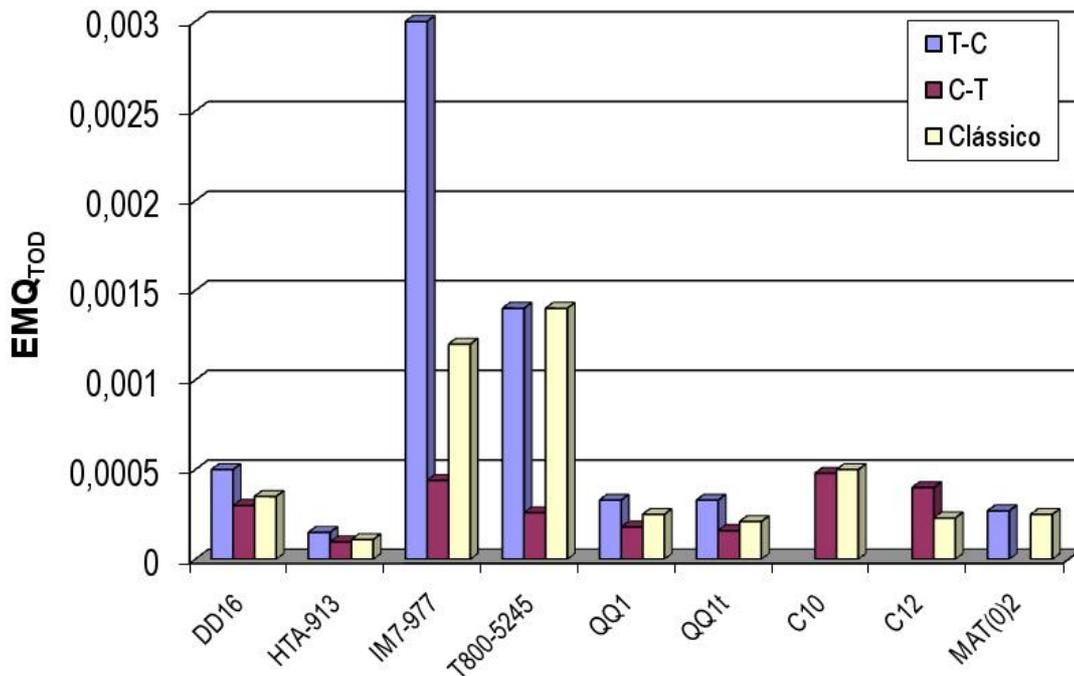


Figura 5. Comportamento do EMQ_{TOD} dos conjuntos de treinamento nas regiões de T-C, C-T e Clássico para os materiais: DD16, HTA-913, IM7-977, T800-5245, QQ1 e QQ1t.

Nas Figuras 6, 7 e 8 tem-se os diagramas de Goodman para os materiais fabricados em fibra de carbono, treinados com um conjunto de treinamento de 3R com predominância de compressão, considerando os melhores resultados obtidos. Os diagramas de Goodman para os demais materiais em fibra de vidro podem ser vistos em trabalhos anteriores (Freire Jr. e Sena, 2009).

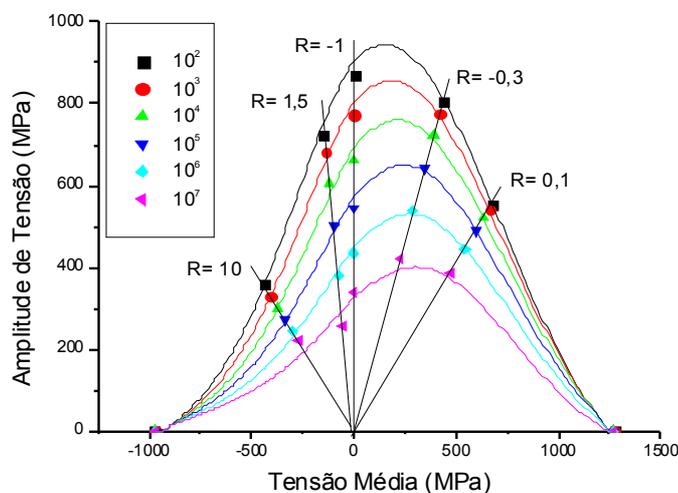


Figura 6. Diagrama de Goodman obtido através da Rede Neural com 12 neurônios ocultos treinado com um conjunto de treinamento HTA-912 - 3R ($R= 10, -0,3$ e $0,1$). Com 4033 épocas de treinamento.

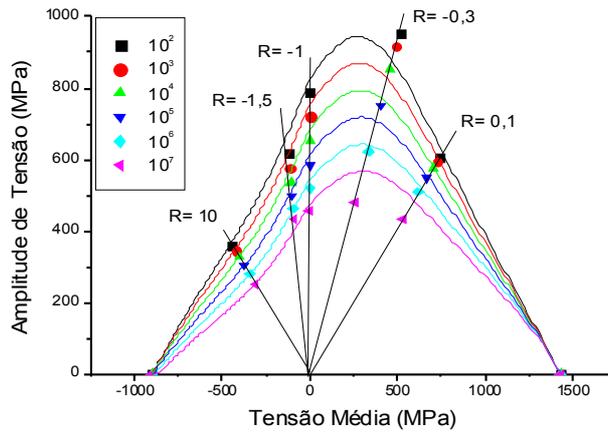


Figura 7. Diagrama de Goodman obtido através da Rede Neural com 26 neurônios ocultos treinado com um conjunto de treinamento, IM7-977 – 3R (R= 10; -0,3 e 0,1). Com 4879 épocas de treinamento.

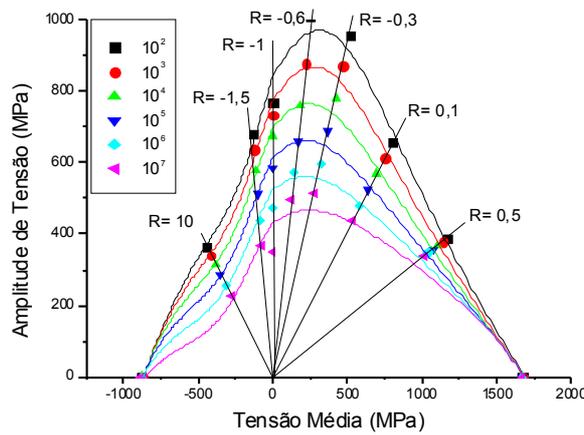


Figura 8. Diagrama de Goodman obtido através da Rede Neural com 26 neurônios ocultos treinado com um conjunto de treinamento, T800-5245 – 3R (R= 10; -1,5 e 0,1). Com 2001 épocas de treinamento.

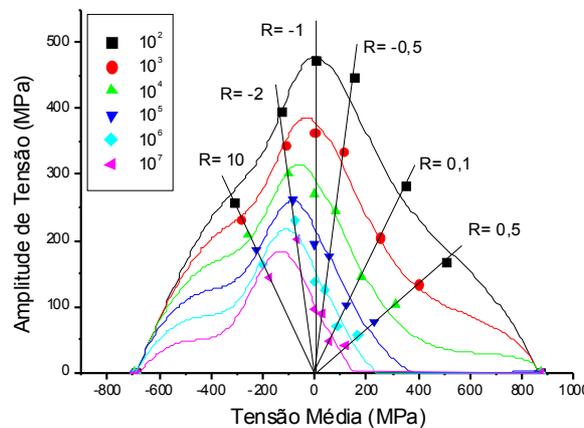


Figura 9. Diagrama de Goodman obtido através da Rede Neural com 29 neurônios ocultos treinado com um conjunto de treinamento QQ1- 3R (R= 10; -2 e 0,1). Com 2829 épocas de treinamento.

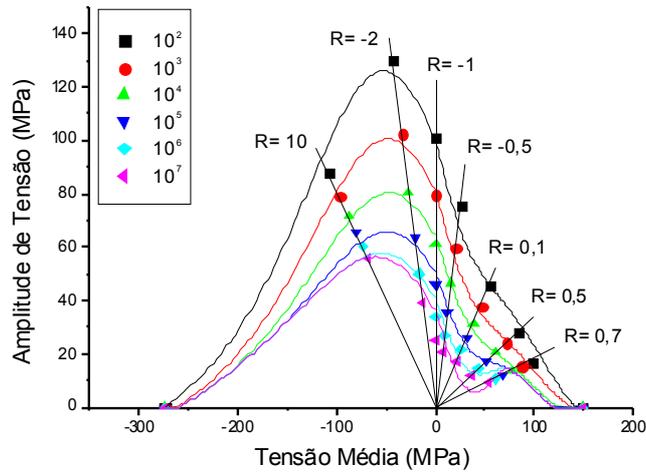


Figura 10. Diagrama de Goodman obtido através da Rede Neural com 11 neurônios ocultos treinado com um conjunto de treinamento QQ1t- 3R (R= 10; -2 e 0,1). Com 4806 épocas de treinamento.

Das Figuras 7 e 8 observamos que para os materiais IM7-977 e T800-5245, percebe-se que as maiores variações nos resultados ocorrem para $R = 0,3$; desse modo com o intuito de se fazer uma avaliação qualitativa desses resultados se construiu a Figura 11. Essa Figura demonstra as curvas **S-N** obtidas pela **RNA** e pela equação (1) bem como os dados experimentais. Por esses resultados percebe-se que as curvas obtidas pela **RNA** estão numa região de segurança com relação aos dados experimentais.

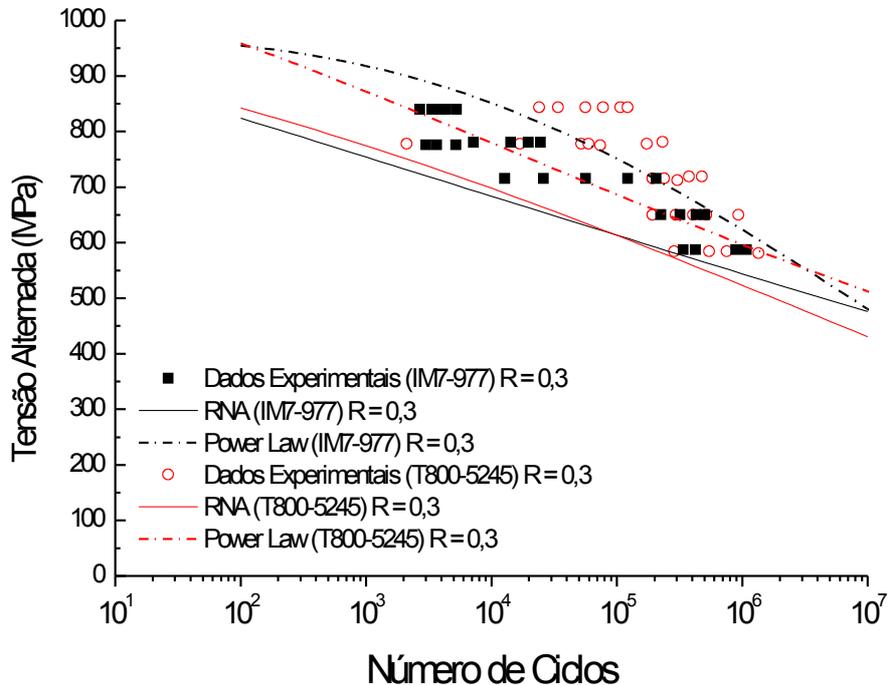


Figura 11. Curvas **S-N** do IM7-977 e T800-5245 para $R = 0,3$; comparando os dados experimentais obtidos da literatura, os dados obtidos pela **RNA** e dados obtidos pela lei da potência, treinado com **3R**.

Analisando as Figuras 6 a 10 percebe-se que a rede conseguiu modelar de modo bastante satisfatório o comportamento dos materiais, a partir disto nota-se o benefício da utilização de Redes Neurais no comportamento à fadiga de materiais compósitos escolhendo um conjunto de dados que esteja na região com predominância de

compressão (C-T), pois utilizando somente 3 curvas S-N consegue-se bons resultados relacionados ao treinamento por Redes Neurais Artificiais.

7. CONCLUSÕES

Conforme se verificou uma RNA clássica de perceptron de múltiplas camadas foi suficiente para modelar o comportamento à fadiga dos materiais C10, C12, DD16, HTA-913, IM7-977, MAT(0)₂, T800-5245, QQ1 e QQ1t utilizando apenas 3 curvas S-N.

Com base nesses resultados e em resultados de trabalhos anteriores (Freire Jr, 2005) se verificou que o conjunto de dados para os materiais IM7-977 e T800-5245 com predominância tração-compressão (T-C) não apresenta bons resultados em relação ao modelo clássico utilizado na literatura, fato este que não ocorre para os demais materiais, onde o conjunto de dados nas regiões com predominância de tração-compressão (T-C) e compressão-tração (C-T) apresentam melhores resultados que o conjunto de dados clássico.

Com base nesta análise se verificou que a os dados de compressão possuem mais informações sobre o comportamento à fadiga do compósito devido ao processo de fratura depender tanto do comportamento da fibra quanto do comportamento da resina, enquanto que à tração basicamente só é influenciado pela resistência da fibra.

8. AGRADECIMENTOS

A Pró-reitoria de Pesquisa da Universidade Federal do Rio Grande do Norte (PROPESQ), pelo apoio recebido. Ao Conselho Nacional de Desenvolvimento de Pesquisa Científico e Tecnológico (CNPQ) pela bolsa de pesquisa. Ao Departamento de Engenharia Mecânica da UFRN, pelas instalações cedidas no laboratório de Pós Graduação em Engenharia Mecânica (PPGEM).

9. REFERÊNCIAS BIBLIOGRÁFICAS

- Beheshty, M. H., Harris, B. and Adam, T., 1999, "An Empirical Fatigue-Life Model for High-Performance Fibre Composites with and without Impact Damage", *Composites – Part A: Applied Science and Manufacturing*, Vol. 30, pp. 971-987.
- Bond, I. P.; "Fatigue Life Prediction for GRP Subject to Variable Amplitude Loading", *Composites: Part A*, Vol. 30, pp. 961-970, 1999.
- Composite Materials", *Composites Part A: Applied Science and Manufacturing*, Vol. 30, No. 10, pp. 1159-1169.
- DOE/MSU 2003. *Composite Material Fatigue Database*, Montana State University-Bozeman, p.272.
- Freire Jr, R. C. S., 2005, Tese de Doutorado, "Fadiga de Alto Ciclos em Compósitos de PRFV. Propriedade Mecânica e Prevenção de Falha", Universidade Federal do Rio Grande do Norte, p. 171.
- Freire Jr, R. C. S., Aquino, E. M. F., Dória Neto, A. D., 2005, "Building life diagrams of fatigue using artificial neural networks", *International Journal of Fatigue*, Vol. 27, p. 746-751.
- Freire Jr, R. C. S., Aquino, E. M. F., Dória Neto, A. D., 2007, "Applying ANN Modeling in Fatigue Failure of GFRP", 19th International Congress of Mechanical Engineering, Vol. 11, p. 1-10.
- Freire Jr, R. C. S., Aquino, E. M. F., Dória Neto, A. D., 2009, "Comparative study between ANN models and convencional equations in the analysis of fatigue of GRP", *International Journal of Fatigue*, Vol. 31, pp. 831-839.
- Freire Jr, R. C. S., Sena, Bremmer B. V. de, 2009, "ESTABLISHING A STOP CRITERION IN ARTIFICIAL NEURAL NETWORK TRAINING FOR COMPOSITE MATERIALS", COBEM 2009.
- Haykin, S., 2001, "Redes Neurais Princípios e Prática", 2^o Ed., 893 p.
- Levy, F. N. e Pardini, L. C. 2006, "Compósitos Estruturais – Ciência e Tecnologia 1 ed."
- Mandell, J. F. and Samborsky, D. D., 1997, "DOE/MSU Composite Material Fatigue Database: test Methods, Materials and Analysis", SAND97-3002, Sandia National Laboratories, Albuquerque, 140 p.
- Philippidis, T. P. and Vassilopoulos, A. P., 1999, "Fatigue of Composite Laminates under off-axis Loading", *International Journal of Fatigue*, Vol. 21, pp. 253-262.
- Philippidis, T. P. and Vassilopoulos, A. P., 2001, "Complex stress state effect on fatigue life of GRP laminates", *International Journal of Fatigue*, Part I, experimental, Vol. 24, pp. 813-823.
- Sutherland, H. J., 1999, "On the Fatigue Analysis of Wind Turbines", SAND99-0089, Sandia National Laboratories, Albuquerque, 133 p.



VI CONGRESSO NACIONAL DE ENGENHARIA MECÂNICA
VI NATIONAL CONGRESS OF MECHANICAL ENGINEERING
18 a 21 de agosto de 2010 – Campina Grande – Paraíba - Brasil
August 18 – 21, 2010 – Campina Grande – Paraíba – Brazil

INFLUENCE OF TRAINING SET IN GENERALIZATION OF ANN_s USED IN ANALYSIS OF FATIGUE OF COMPOSITE MATERIALS

Bremmer Bernardo Vasconcelos de Sena

UFRN – CT – Engenharia Mecânica
Campus Universitário – Lagoa Nova – Natal – RN – CEP: 59072 - 970
E-mail: bremmer02@yahoo.com.br

Raimundo Carlos Silverio Freire Júnior

UFRN – CT - Programa de Pós-Graduação de Engenharia Mecânica
Campus Universitário – Lagoa Nova – Natal – RN – CEP: 59072 – 970
E-mail: freirej@ufnet.br

Abstract. *In the design of equipment and structures subjected to cyclic loading where composites are used as raw material, it is often necessary large amount of fatigue tests to obtain a degree of confidence of the material. These tests become inconvenient for being slow. The ideal solution would be to obtain the answer to the fatigue of these materials with minimal testing and maximum confidence possible. They are in the literature, several mathematical models that are used in order to predict the life of these materials through diagrams failed, recently initiated the use of Artificial Neural Networks (ANNs). It is known that the network can give a good answer requires a data set that best represent the characteristic of the fatigue of the material. This work aims to analyze the influence of the choice of data set to train neural networks, making a comparison between the data set that considers the most valued SN curves, which are for $R = 10$, -1 , and 0.1 ; with two sets of data exchange where the curve for $R = -1$ or an R in the region of variable load with a predominance of traction or compression with predominant, verifying thus the data region which best represents the behavior overall composite material. For that we made the training of nine materials extracted from the literature (defined by the letters: C10, C12, DD16, HTA-913, IM7-977, MAT (0)₂, T800-5245, QQ 1 and QQ1t), and then analyzed The behavior of the correlation coefficient and mean square error for these materials.*

Keywords: *Artificial Neural Network, Training Set, Fatigue, Composite Materials.*