

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA REPRESENTAR O COMPORTAMENTO VISCOELÁSTICO

Marcelo Massarani

Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia Mecânica, Av. Prof. Mello Moraes 2231, Cidade Universitária, 05508-900, São Paulo. Brasil.

E-mail: massarani@pobox.com

Resumo

O comportamento viscoelástico não linear de materiais ainda é representado de forma rudimentar por modelos constitutivos analíticos. É proposto o uso de redes neurais artificiais para representar o comportamento viscoelástico de materiais sob carregamentos uniaxiais.

Alguns exemplos são desenvolvidos usando redes neurais artificiais que geram sua própria arquitetura e também redes neurais recorrentes para representar o comportamento viscoelástico de materiais. Os resultados obtidos podem ser considerados animadores.

As vantagens observadas no uso de redes neurais artificiais para representar o comportamento de materiais são as seguintes: nenhuma hipótese a respeito do comportamento do material é necessária; o comportamento do material é apreendido diretamente dos dados de ensaios; e não é necessário nenhuma aproximação numérica para usar uma rede neural artificial já treinada.

Palavras-chave: equações constitutivas, redes neurais artificiais, viscoelasticidade.

1. INTRODUÇÃO

Os modelos constitutivos representam adequadamente o comportamento viscoelástico somente na região de comportamento linear. Para tensões maiores, que caracterizam o comportamento não linear, faltam modelos constitutivos capazes de descrevê-lo. Mesmo para o caso de tensão uniaxial, os comportamentos de fluência são representados de forma rudimentar pelos modelos constitutivos existentes.

As redes neurais artificiais (RNA's) constituem um conceito computacional inspirado no que atualmente se acredita ser a forma de funcionamento do cérebro humano. São constituídas por várias unidades de processamento, denominados *neurônios*, conectados entre si. Cada neurônio recebe valores de outros neurônios com os quais está conectado, calcula um valor e o transmite adiante para outros neurônios da RNA. As RNA's mais comuns são formadas por camadas de neurônios (de entrada, oculta e de saída) e o fluxo de informações percorre o sentido da camada de entrada para a camada de saída.

As conexões entre neurônios são caracterizadas por *pesos* que multiplicam os valores transferidos de um neurônio para outro. Os pesos das ligações entre neurônios são ajustados para se obter valores de saída compatíveis com os de entrada. Os algoritmos que realizam esta função são chamados de *algoritmos de treinamento*. Nas aplicações mais comuns, as RNA's são treinadas apresentando-se os valores de entrada e de saída esperada para a RNA.

O uso de RNA's para representar o comportamento de um material é uma forma alternativa de aquisição de conhecimento. A RNA funciona como "caixa-preta". O conhecimento a respeito do comportamento do material é absorvido dos dados provenientes de ensaios, ficando armazenado nos pesos das ligações entre os neurônios. As informações

para explicar o comportamento do material não estão disponíveis nas RNA's, mas pode-se simular o seu comportamento.

A contribuição deste trabalho consiste em verificar a viabilidade de uma forma alternativa de se representar o comportamento viscoelástico de materiais no caso uniaxial de tensão usando RNA's.

Vários paradigmas de RNA's podem ser testados para modelar o comportamento viscoelástico de materiais. Alguns exemplos são desenvolvidos a seguir para verificar a viabilidade desta abordagem.

2. EXEMPLO 1 - CURVAS ISÓCRONAS TENSÃO-DEFORMAÇÃO A PARTIR DE DADOS COM RUÍDOS.

É interessante verificar o que acontece quando são usados dados provenientes diretamente dos ensaios de fluência no treinamento de RNA's. Para isso são utilizados dados publicados por Findley & Khosla (1956), de ensaios de fluência de corpos de prova de polietileno. A quantidade de dados é reduzida e apresentam ruídos.

Findley & Khosla ensaiaram corpos de prova de polietileno a uma temperatura constante de 25 °C, submetidos cargas uniaxiais constantes de 75 psi, 150 psi, 225 psi e 300 psi. Os dados disponíveis são valores de deformação em um dado instante para a tensão correspondente. No total 83 valores estão disponíveis (Figura 1).

Uma RNA foi desenvolvida para representar a função que relaciona deformação com tempo e tensão. A RNA tem a tensão e o tempo como entradas e a deformação como saída. Dos 83 valores disponíveis, 10 foram separados para constituir o conjunto de dados teste e os 73 restantes formam o conjunto de treinamento.

A medida de erro usada é obtida normalizando a soma dos quadrados das diferenças pelo desvio padrão (Equação 1). O erro fica invariante com relação translações (*offsets*) e transformações (*scaling*) dos vetores de saída.

$$erro = \frac{\sqrt{\frac{\sum_p \sum_o dif_{p,o}^2}{p \cdot o}}}{\sqrt{\frac{p \cdot o \cdot \sum_p \sum_o alvo_{p,o}^2 - \left(\sum_p \sum_o alvo_{p,o} \right)^2}{p \cdot o \cdot (p \cdot o - 1)}}} \quad (1)$$

com:

p número de pares;

o número de unidades de saída da RNA;

$dif_p = alvo_p - saída_p$;

$saída_p$ é o valor de saída da rede para o par de treinamento p .;

$alvo_p$ é o valor esperado como saída da rede.

Uma RNA do tipo Cascor (Fahlmann & Lebiere, 1990) foi obtida com o programa FAST v.2.2 (Arras & Mohraz, 1996) para um erro máximo de 10% para o conjunto de treinamento.

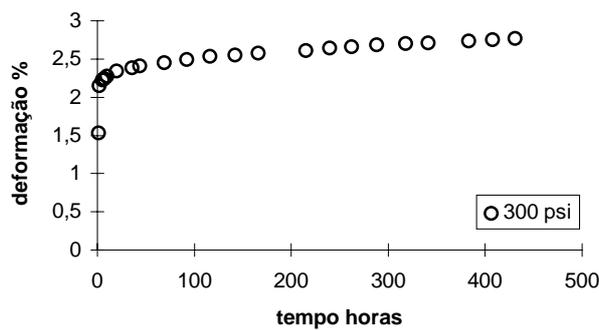
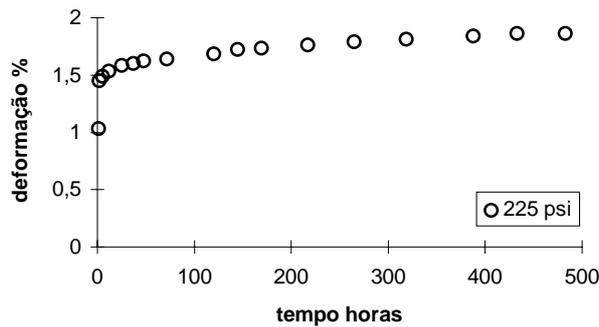
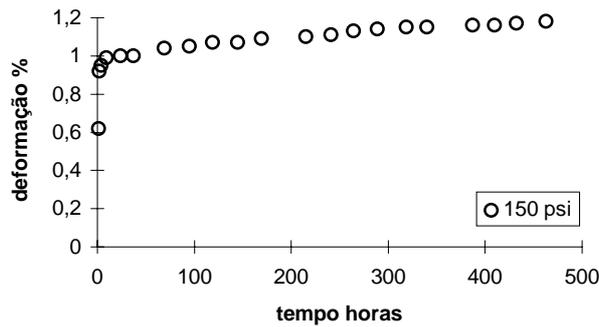
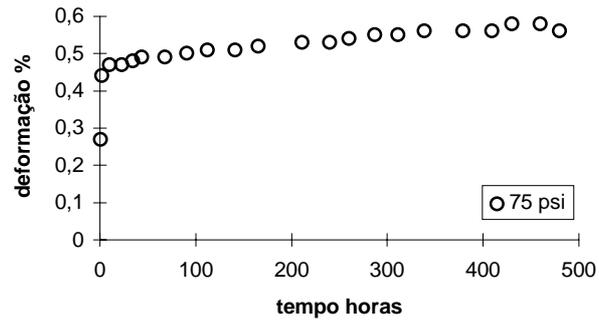


Figura 1 - Dados de ensaio de fluência do polietileno.

A seguir estão indicadas curvas de fluência (cortes por planos perpendiculares ao eixo das tensões nas curvas isócronas tensão-deformação) fornecidas pela RNA (Figura 2).

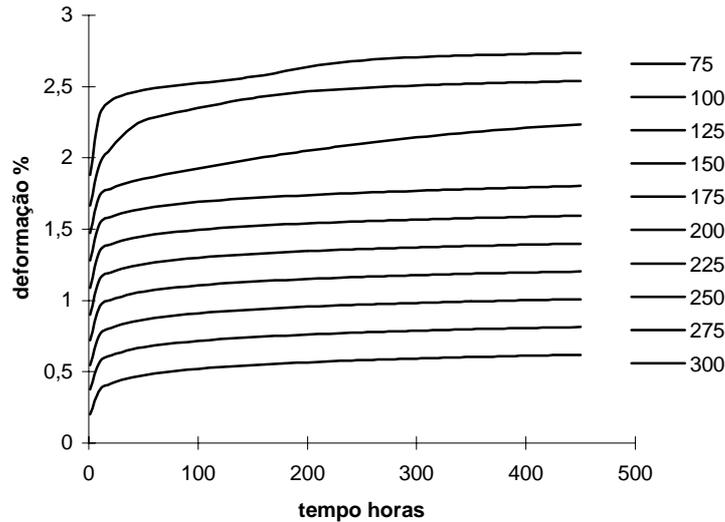


Figura 2 - Curvas de fluência fornecida por RNA obtida para um erro máximo de 10 %.

3. EXEMPLO 2 - FLUÊNCIA E RECUPERAÇÃO

Os modelos constitutivos conhecidos ainda têm grande dificuldade para representar alguns comportamentos viscoelásticos. Por exemplo as deformações causadas por carga e posterior descarga de um material (fluência e recuperação). Nesse caso específico não foi encontrado nenhum modelo analítico que represente para um dado material a fluência e a recuperação de uma forma geral.

Para representar o comportamento de fluência e recuperação foi selecionado um paradigma de RNA recorrente. Esse paradigma de RNA possui um comportamento dinâmico e o estado da RNA é alterado de acordo com os valores previamente apresentados.

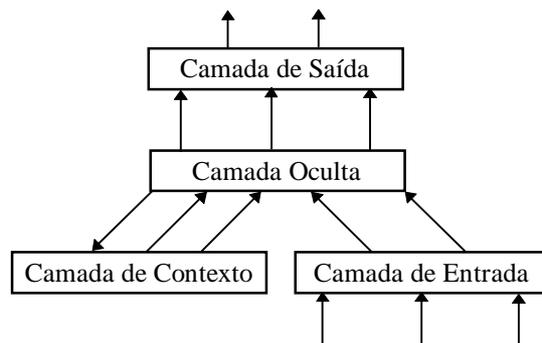


Figura 3 - RNA recorrente simples.

A falta de dados de ensaios de fluência de materiais viscoelásticos nas condições de carga e descarga e também a falta de um modelo constitutivo capaz de representar o comportamento do material, foram os motivos da adoção de um “pseudo-material” como fonte de dados para treinamento. Como hipóteses básicas temos as seguintes: material obedece o modelo constitutivo proposto por Glockner & Szyszkowski (1987,1990) e para condições de carregamentos complexos (carga/descarga, variações de tensão) vale o Princípio da

Superposição de Boltzmann. Estas hipóteses podem aproximar o comportamento a fluência de um material (Ward, 1983).

Glockner & Szyszkowski propuseram um modelo constitutivo que considera que a taxa de deformação total de um material é a soma de três parcelas: uma taxa de deformação elástica, uma taxa de deformação recuperável (reversível) e uma taxa de deformação permanente (irreversível) (Equação 2).

$$\dot{\epsilon} = \frac{\dot{\sigma}}{E} + \frac{1}{v_1} \frac{d}{dt} \int_0^t \sigma^n(\tau) j(t-\tau) d\tau + \frac{1}{v_2} \sigma^n(t) \quad (2)$$

onde E , n , v_1 e v_2 são parâmetros do material.

O material escolhido foi o asbesto, cujos parâmetros foram determinados por Glockner & Szyszkowski (1987): $E = 8,1 \text{ GPa}$; $n = 1,4$; $v_1 = 8,67 \cdot 10^6 \text{ MPa}^n \cdot \text{h}$; $v_2 = 354 \cdot 10^8 \text{ MPa}^n \cdot \text{h}$; $t_1 = 100 \text{ h}$.

Foram considerados 30 casos de carregamentos. Uma parte composta por tensão constante de 0 a 10000 horas. Outra parte composta por tensão constante seguida de descarregamento antes de 10000 horas.

Uma RNA recorrente simples (Elman, 1991 e 1993) com dois neurônios na camada de entrada (tempo e tensão) e um neurônio na camada de saída (deformação), foi treinada com os dados gerados a partir das condições de carregamento. A configuração da RNA que apresentou o melhor resultado contém 35 neurônios na camada oculta.

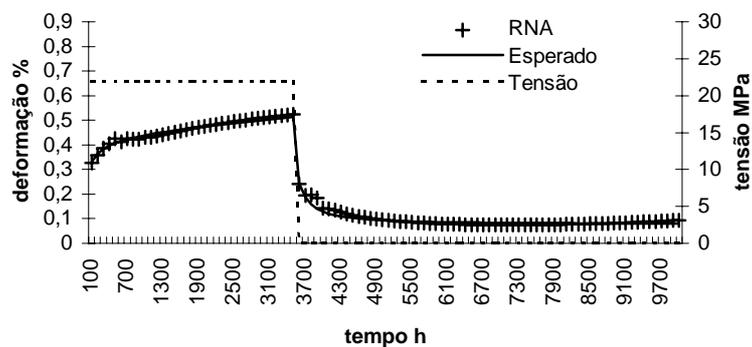


Figura 3 - Caso de teste 9: tensão de 22 MPa descarregado a 3600 horas.

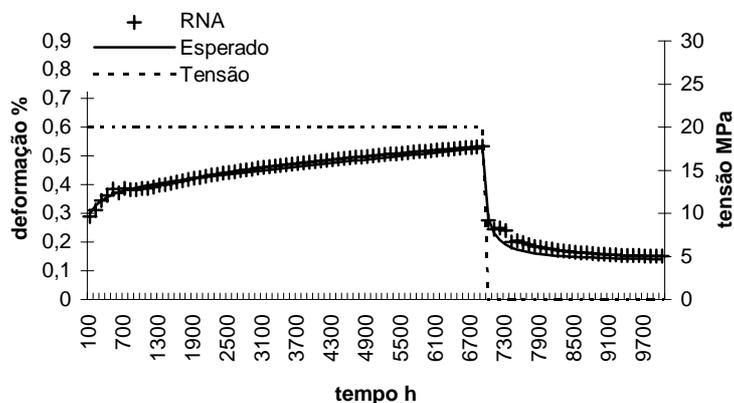


Figura 4 - Caso de teste 10: tensão de 20 MPa descarregado a 7000 horas.

O erro mínimo alcançado para os casos de treinamento foi de 7,9% (Equação 1) e de 7,8% para os casos de teste após 12000 épocas de treinamento (uma época de treinamento é a denominação dada para o ciclo de apresentação de todos os pares à RNA durante a fase de treinamento). Os valores obtidos para dois casos de teste estão mostrados nas figuras 3 e 4. Foi usado o programa FAST v.2.2 (Arras & Mohraz, 1996) para treinar a RNA.

É interessante notar que para se obter os resultados apresentados nas figuras, nenhuma hipótese a respeito do comportamento do material foi necessária. A RNA foi treinada a partir de exemplos do comportamento viscoelástico não linear obtidos do modelo analítico.

4. EXEMPLO 3 - HISTÓRIA DE CARREGAMENTOS COMPLEXA

Uma RNA recorrente com dois neurônios na camada de entrada (tempo e tensão) e um neurônio na camada de saída (deformação), foi treinada para determinar a deformação de um material viscoelástico submetido a uma história de carregamentos uniaxiais. As tensões podem ser tanto constantes com variações discretas. O paradigma usado foi o mesmo empregado no exemplo anterior: RNA recorrente simples proposto por (Elman, 1991 e 1993).

O material utilizado é o mesmo do exemplo anterior com o modelo constitutivo descrito no item anterior. Um total de 60 histórias de carregamentos foram geradas aleatoriamente por um programa de computador. Destas 50 fazem parte do conjunto de dados de treinamento e 10 do conjunto de dados de teste. Cada história pode ter de nenhuma até 4 variações no valor da tensão e possuem 100 pontos no intervalo de 0 a 10000 horas.

A configuração da RNA que apresentou o melhor resultado contém 35 neurônios na camada oculta, sendo que todos os neurônios da camada de saída e da camada oculta possuem função de transferência do tipo *sigmoid*.

O erro mínimo alcançado para os casos de treinamento foi de 21% (Equação 1) e de 16,5% para os casos de teste após 4700 épocas de treinamento. Os valores obtidos para dois casos de teste estão mostrados nas figuras a seguir (Figura 5 e Figura 6). Foi usado o programa FAST v.2.2 para treinar a RNA.

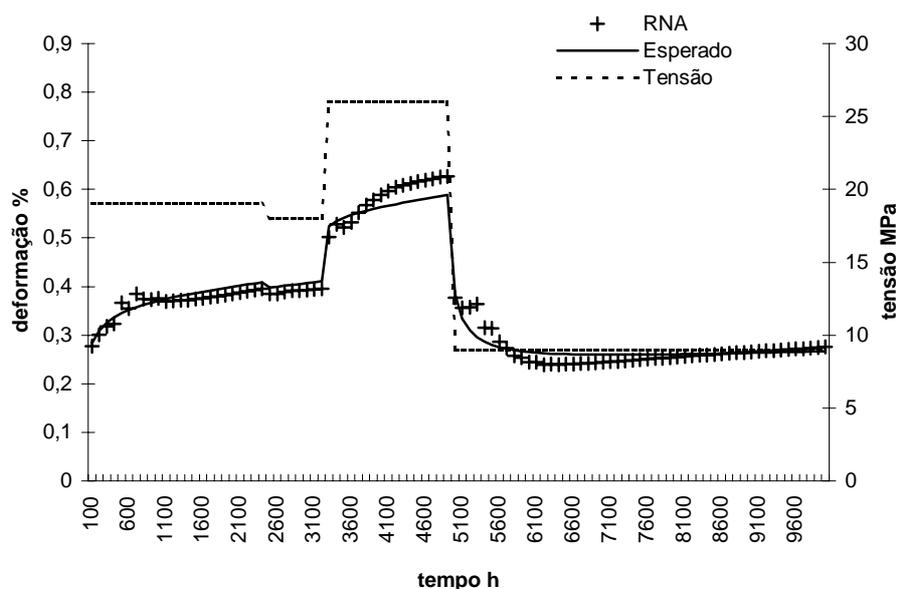


Figura 5 - Caso de teste 7: 19 MPa - 18 MPa - 26 MPa - 9 MPa.

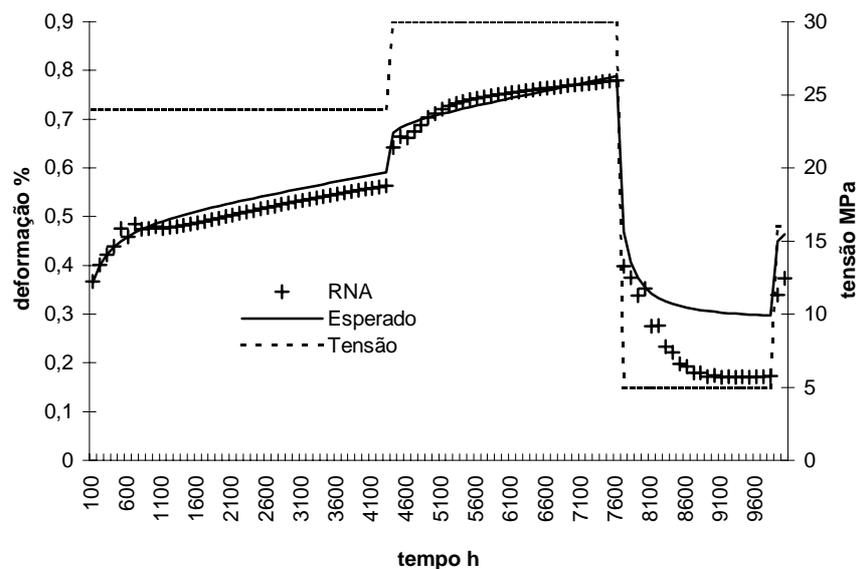


Figura 6 - Caso de teste 10: 24 MPa - 30 MPa - 5 MPa - 16 MPa.

Observa-se dos resultados indicados nas figuras que a forma geral das curvas é representada pela RNA.

5. CONCLUSÕES

Os resultados dos exemplos foram obtidos sem o estabelecimento de hipóteses a respeito do material e sem a definição de expressões matemáticas, o que é a grande vantagem do uso de RNA's para representar o comportamento viscoelástico de materiais. Os mesmos resultados apresentados pelas RNA's seriam extremamente trabalhosos de se obter com modelos constitutivos analíticos.

A maior desvantagem do uso de RNA's é o número de ensaios necessários para se obter os exemplos para o treinamento. Os modelos constitutivos analíticos são baseados em regras e expressões que definem parâmetros do material obtidos de poucos ensaios. Ao contrário das RNA's, os modelos analíticos permitem economizar nos ensaios.

Nenhuma aproximação numérica é necessária com o uso de RNA's para representar o comportamento viscoelástico. A não linearidade fica impregnada nos pesos das ligações distribuídos na RNA.

6. BIBLIOGRAFIA

- Arras, M.K.; Mohraz, K., 1996, "FORWISS artificial neural network simulation toolbox - FAST v2.2.", Bavarian Research Center for Knowledge-Based Systems (FORWISS), Erlangen.
- Elman, J.L., 1991, "Incremental learning, or The importance of starting small", CRL Technical Report 9101, Center for Research in Language, University of California, San Diego.

- Elman, J.L., 1993, "Learning and development in neural networks: The importance of starting small", *Cognition*, n.48, pp.71-99.
- Fahlmann, S.E.; Lebiere, C., 1990, "The cascade-correlation learning architecture", In Touretzky, D.S. (ed.) *Advances in Neural Information Processing 2*, Morgan Kaufmann, San Mateo CA, USA, pp.524-532.
- Fahlmann, S.E.; Lebiere, C., 1990, "The cascade-correlation learning architecture. Pittsburgh", Technical Report CMU-CS-90-100, Carnegie Mellon University.
- Findley, W.N; Khosla, G., 1956, "An equation for tension creep of three unfilled thermoplastics", *SPE Journal*, December, pp.20-24.
- Glockner, P.G.; Szyszkowski, W., 1987, "On a multiaxial non-linear hereditary constitutive law for non-ageing materials with fading memory" *International Journal of Solids Structures*, v.23, n.2, p.305-324.
- Glockner, P.G.; Szyszkowski, W., 1990, "An engineering multiaxial constitutive model for nonlinear time-dependent materials" *International Journal of Solids Structures*, v.26, n.1, pp.73-82.
- Ward, I.M., 1983, "Mechanical properties of solid polymers", 2^a ed., , John Wiley & Sons, Chichester, 475p.