

APLICAÇÃO DE REDES NEURAIS A SISTEMAS NÃO LINEARES

Helder da Silva Camargos (1), Evaldo Khater (2)

(1) Aluno do Curso de Engenharia Industrial Mecânica, Departamento de Engenharia Mecânica, Universidade Federal de São João del Rei, Praça Frei Orlando 170, Centro, São João del Rei MG, CEP: 36307-954.

(2) Departamento de Engenharia Mecânica, Universidade Federal de São João del Rei, Praça Frei Orlando 170, Centro, São João del Rei MG, CEP: 36307-954

RESUMO

As redes neurais artificiais consistem em um método de solucionar problemas de inteligência artificial, construindo um sistema que tenha circuitos que simulem o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. São mais quett isso, são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. O uso de redes neurais artificiais na identificação de sistemas dinâmicos apresenta as seguintes vantagens: (i) habilidade de tratar sistemas não lineares: relevante nas aplicações em identificação de sistemas dinâmicos e classificação de padrões; (ii) tolerância a falhas: o conhecimento é distribuído pela rede neural, mais que em uma simples localização de memória. Uma parte das conexões pode estar inoperante, sem mudanças significativas no desempenho de toda a rede neural; (iii) adaptabilidade: capacidade da rede neural em auto-ajustar-se. Os aspectos de aprendizado, auto-organização, generalização e treinamento estão intrinsecamente ligados a esta característica; (iv) aprendizado: uma rede neural pode modificar seu comportamento em resposta ao ambiente (Kovacs, 1996).

Nesse trabalho foram feitas as identificações de sistemas dinâmicos não lineares, usando o algoritmo de retropropagação do erro. Surgiu, então, a necessidade do estudo de métodos numéricos de otimização que pudessem fornecer maior acurácia aos resultados. Dessa forma foram estudados quatro métodos: Gradiente, Gradiente com Momento, Gradiente Conjugado e Levenberg-Marquardt. Abaixo, estão representados 2 modelos não lineares propostos (Narenda, 1990):

$$y(k+1) = 0,3y(k) + 0,6y(k-1) + f[u(k)] \quad (1)$$

onde

$$f(u) = 0.6\sin(\pi u) + 0.3\sin(3\pi u) + 0.1\sin(5\pi u)$$

$$u = \sin\left(\frac{2\pi k}{25}\right) \quad \text{onde} \quad u = \sin\left(\frac{2\pi k}{250}\right) + \sin\left(\frac{2\pi k}{25}\right)$$

$$y(k+1) = (5y(k)y(k-1)/1 + y^2(k) + y^2(k-1) + y^2(k-2) + u + 0.8u(k-1)) \quad (2)$$

Para uma melhor comparação da complexidade dos sistemas treinados, foi utilizada uma única arquitetura para as 2 redes. Adotou-se a seguinte configuração:

- 1 vetor de entrada ($k = 1 \times 100$) com valores distribuídos no intervalo 1 a 100.
- 10 neurônios na camada de entrada
- 20 neurônios na camada oculta.
- 1 neurônio na camada de saída.

Como critério de parada usou-se um erro de 10^{-3} ou 5000 iterações para ambas funções. Dada a entrada da rede neural, juntamente com o modelo de referência, o próximo passo foi a realização da realimentação da rede neural a partir da resposta da mesma ao término de cada iteração definindo assim um sistema múltiplo de alimentação da rede neural dinâmica (Haykin, 1999).

As tabelas abaixo resumem os principais resultados obtidos com a identificação das funções não lineares:

	MÉTODO	ITERAÇÕES	TEMPO PROC.	ERRO
FUNÇÃO (1)	Gradiente	5000	32'15''	0,00108
	Gradiente Mom.	939	9'42''	0,00099
	Gradiente Conj.	54	1'03''	0,00098
	Levenberg-Mar.	4	0'10''	0,00058
FUNÇÃO (6)	Levenberg-Mar.	5000	9:43'34''	0,01051

Tabela 1. Resultado numérico do treinamento das funções

O resultado a seguir refere-se a rede neural dinâmica desenvolvida utilizando a Eq. (6):

	MÉTODO	ITERAÇÕES	TEMPO PROC.	ERRO
FUNÇÃO (6)	Levenberg-Mar.	5000	9h 25'59''	0,00901

Tabela 2. Resultado do treinamento da Eq. (2) através da realimentação da entrada

Na identificação da Eq. (1) com o método do gradiente foram realizadas 5000 iterações num tempo de 32 min e 15 seg e o erro estipulado não foi alcançado, como pode ser visto na tabela (1). Com isso, houve a necessidade de se usar um método mais eficaz. O resultado dado pelo método do gradiente com momento é parecido com o resultado alcançado pelo método do gradiente na identificação da mesma equação. No entanto, o método do gradiente com momento apresenta uma ligeira vantagem no que diz respeito ao tempo, como pode ser visto na Tab. (1).

É na identificação dessa Eq. (1) que se percebe a vantagem do método gradiente conjugado em relação ao dois métodos já mencionados. Esse fato é confirmado pela Tab. (1) que mostra que o erro atingiu também 10^{-3} como era previsto num menor número de iterações e menor tempo.

O método de Levenberg-Marquardt na identificação da equação (1) mostrou-se o mais eficiente. Os resultados observados na Tab. (1) mostram que este método ofereceu o melhor desempenho na identificação da Eq. (1), reduzindo o tempo e o nº de iterações em relação aos outros métodos.

A seguir, realizou-se novamente, o treinamento da Eq. (2), porém dinamicamente. O resultado obtido mostrou que a rede convergiu para o erro estipulado e num menor intervalo de tempo, ao contrário do que ocorreu com a mesma função treinada estaticamente como pode ser visto pela Tab. (2).

Nesse trabalho pode-se perceber a flexibilidade que essas redes possuem, podendo ser adaptadas de acordo com a complexidade da função. Para se fazer essa adaptação é necessário encontrar um equilíbrio entre a suposição e a lógica.

Verificou-se também que o método do gradiente apresenta bons resultados na identificação de funções simples. No entanto, quando se deseja implementar uma função mais complexa, deve-se buscar métodos mais robustos, que possam melhorar a convergência da rede neural treinada. Posteriormente as funções foram treinadas com o método de Levenberg-Marquardt e este mostrou-se o mais adequado para a implementação da função não linear, reduzindo o tempo e o nº de iterações.

A rede neural dinâmica desenvolvida nesse trabalho, mostrou um menor custo operacional para funções mais complexas, como foi feito utilizando a Eq. (2).

Os resultados obtidos nesse trabalho proporcionaram incentivos para a continuidade da análise do Método Levenberg-Marquardt em outros modelos de identificação. O vasto campo das redes neurais artificiais proporcionam estudos avançados na busca do aperfeiçoamento na identificação e controle de sistemas dinâmicos.

REFERÊNCIAS BIBLIOGRÁFICAS

Haykin, S. Neural Networks: A Comprehensive Foundation. Prentice-Hall, 1999, 696p.

Kovács, L. Z. Redes Neurais Artificiais: Fundamentos e Aplicações. 2º edição; Collegium Cognito, 1996.

Narendra, S. K., Parthasaraty, K. Identification and Control of Dynamical Systems Using Neural Networks. IEEE Trans. on Neural Networks, v.1, n.1, march 1990.