

Modelagem de Histerese de Atuador SMA Baseada em Rede Neural Artificial e Controle de Posição

Thiago Veiga Santos* Márcia Lissandra Machado Prado**
Thiago Alberto Barbosa*** Jes de Jesus Fiais Cerqueira****

* Departamento de Tecnologia, Universidade Estadual de Feira de Santana, BA, (e-mail: thiagoveiga@gmail.com).

** Departamento de Tecnologia, Universidade Estadual de Feira de Santana, BA, (e-mail: marcia.lissandra@gmail.com).

*** Departamento de Tecnologia, Universidade Estadual de Feira de Santana, BA, (e-mail: thiago.barbosa@ieee.org).

**** Departamento de Engenharia Elétrica e de Computação, Universidade Federal da Bahia, BA, (e-mail: jes@ufba.br).

Abstract: This work presents a model's hysteretic behavior development of a shape memory alloy actuator, or SMA, based on artificial neural network. The model's SMA position control is determined by a PID controller, which has the wire temperature as feedback, obviating the use of position sensors. To achieve the objectives proposed in the research, experiments and tests were carried out in order to analyze the relationship between temperature and material deformation. Concerned with the actuator's non-linearity, a neural network was developed with this relation in mind. Also, this neural network aims to indicate, predicatively, the SMA position based on the temperature. Results are presented at the end of the article, showing the efficiency of the control system without the use of a physical sensor.

Resumo: Este trabalho apresenta o desenvolvimento de uma modelagem do comportamento histerético de um atuador de liga de memória de forma, ou SMA, baseada em rede neural artificial. Esse modelo é utilizado com um controlador PID para o controle de posição da SMA, que possui como realimentação a temperatura do fio, possibilitando o controle sem a utilização de sensores de posição. Para atender aos objetivos propostos na pesquisa, experimentos e testes foram realizados com o intuito de analisar a relação entre temperatura e deformação do material. Referente à não linearidade do atuador, foi desenvolvida uma rede neural capaz de modelar essa relação e indicar, de maneira aproximada, a posição da SMA a partir da temperatura. Resultados são apresentados ao final do artigo, evidenciando a aplicabilidade do sistema de controle sem a utilização de um sensor físico.

Keywords: Shape memory alloy, Control systems, Neural Network, Instrumentation, Signals

Palavras-chaves: Ligas de memória de forma, Sistemas de controle, Rede Neural, Instrumentação, Sinais

1. INTRODUÇÃO

Nos últimos anos, tem-se notado um grande interesse no estudo das ligas de memória de forma ou SMA (Shape Memory Alloy), como atuadores (Ma et al., 2004). Isso ocorre devido às características ímpares desse material, como a capacidade de produzir deformações com aplicação de baixa tensão (Jayender et al., 2008), a capacidade de retornar ao formato inicial (Nguyen and Ahn, 2009), a alta relação peso/potência (Jayender et al., 2008) e a biocompatibilidade (Barbosa et al., 2018).

A força natural do atuador SMA permite que ele seja capaz de acionar dispositivos sem a necessidade da utilização de engrenagens, evitando, assim, folgas e desgastes a longo

prazo (Tai and Ahn, 2010). Essas qualidades apresentadas explicam o frequente uso desse material em diferentes áreas científicas como: na área médica, fazendo o papel de catéteres ativos, na robótica, exercendo a função de fibras musculares artificiais e na indústria, mostrando-se uma alternativa promissora para o controle de vibrações (Jayender et al., 2008).

Por propriedades moleculares, o SMA apresenta duas fases distintas: a martensita e a austenita. Em temperaturas mais elevadas, ocorre a fase chamada de austenita, na qual o material tem sua estrutura mais elástica. Assim que o processo de diminuição de temperatura se inicia, começa a fase martensita, onde o material tem sua estrutura mais plástica (Romano and Tannuri, 2008). A união dessas fases provoca uma histerese acentuada na resposta do atuador (Tai and Ahn, 2010).

* Este trabalho foi parcialmente apoiado pela FAPESB (nº do processo: 5037/2018)

A histerese ocorre a partir da relação entre a deformação e temperatura do material (Romano and Tannuri, 2008). Contudo, a existência de múltiplos valores de temperatura relacionados a um único valor de deslocamento, faz com que essa vinculação não deva ser feita de maneira associativa (Zhao and Tan, 2008). Com o potencial de surgir novas aplicações da SMA como atuador (Barbosa et al., 2018), tornou-se necessária a modelagem do seu comportamento histerético.

Este artigo propõe a utilização de uma rede neural que seja capaz de determinar a relação entre temperatura e deformação, tornando possível, de maneira aproximada, encontrar valores de deformação da liga de memória de forma a partir da temperatura do fio. Dessa forma, pode ser descartada a necessidade de equipamentos, como *Encoders*, potenciômetros e sensores de distância por laser, para determinar a deformação do material em certas aplicações.

Na Seção 2 serão apresentados os passos para a realização do trabalho, desde a construção da plataforma de testes até a elaboração da rede neural e criação do sistema de controle para sua validação. Na Seção 3 serão apresentados os resultados alcançados e, por fim, na Seção 4 serão descritas as conclusões obtidas com o projeto.

2. METODOLOGIA

A metodologia adotada neste trabalho consistiu na construção de uma plataforma que viabilizou os testes físicos necessários e a obtenção de variáveis importantes. Posteriormente foi elaborada uma rede neural capaz de modelar o comportamento histerético da SMA, possuindo como entrada a temperatura do material.

Após esta etapa, foi aplicado um controlador de posição PID para validar a eficácia da rede neural na substituição de equipamentos capazes de determinar a deformação do fio do atuador. A seguir, essas etapas serão abordadas e detalhadas:

2.1 Construção da plataforma de testes

Na fase de desenvolvimento da plataforma de testes, foi construída uma estrutura de alumínio em forma de retângulo capaz de apoiar o atuador SMA. O *encoder* foi inserido na estrutura de forma que possuísse dupla função, tanto de indicar a deformação do fio, quanto de exercer a função de roldana para o peso que seria suspenso pelo atuador SMA. O diagrama esquemático da plataforma pode ser visualizado na Figura 1.

A plataforma de testes experimental é composta dos seguintes componentes:

- Termopar (sensor de temperatura)
 - O termopar foi fixado ao fio de SMA com cola Super Bonder da LOCTITE, cola resistente a temperatura e de rápida secagem.
- SMA Modelo MIGA One
 - O Cartão SMA é uma forma prática do fio de SMA que facilitou o levantamento do peso (250 gramas) da plataforma. Este cartão pesa cerca de 13 gramas e apresenta um tempo de atuação de aproximadamente 1 segundo, sendo alimentado por 5 volts.

- Encoder
 - O encoder, que indica a deformação do fio de SMA, funcionou como espécie de roldana para o peso ser levantado.

Aquisição de temperatura O desenvolvimento do circuito de condicionamento para o termopar foi baseado na amplificação do sinal que vem do termopar. Segundo Thomas Seebeck, quando dois metais distintos unidos são aquecidos em sua junção, surge uma diferença de potencial elétrico entre as suas extremidades (Nunes et al., 2017). Entretanto, a tensão dessa diferença de potencial é muito baixa, necessitando, assim, ser amplificada para facilitar sua aquisição e análise.

Com o auxílio do amplificador de instrumentação AD595 que, além de amplificador, funciona como a junta fria (referência) do termopar, tornou-se possível receber e determinar a temperatura baseada na tensão.

Além da montagem do circuito, a aquisição do sinal resultante foi realizada com o auxílio de um microcontrolador MEGA da plataforma ARDUINO fazendo o papel de aquirentor de dados e do software MATLAB. Utilizando o pacote que o MATLAB oferece com o interfaceamento para o microcontrolador, *MATLAB Support Package for Arduino*, foi possível realizar a comunicação iterativa.

Aquisição da medida de deformação Similar à aquisição da temperatura, a deformação também é adquirida com o auxílio de um microcontrolador da plataforma ARDUINO em conjunto com o software MATLAB. A diferença é que não há necessidade de um circuito de condicionamento, já que o encoder já é preparado para entregar tais informações.

Alimentação do atuador SMA O sinal de alimentação da SMA é gerado na plataforma ARDUINO utilizando a função PWM (técnica que consiste em emular um sinal analógico através de pulsos digitais) das portas digitais do arduíno, foi possível modificar a tensão de maneira escolhida para o projeto. Para analisar o comportamento da SMA, o microcontrolador envia uma onda senoidal amortecida, com período de 50 segundos, de 0 volt até 1,6 volts, que decai ao longo do tempo para ponderar o comportamento da temperatura e da deformação do fio de SMA, que pode ser visualizada na Figura 2, na qual cada amostra corresponde a 1,6 segundos.

Esse sinal, que inicialmente tem valor de 0 volt até 1,6 volts, decai a cada período chegando ao valor de 0 volt até 1 volt. Posteriormente, reinicia-se o processo.

Como a região de valor negativo da onda não apresentaria utilidade na aplicação proposta, foi aplicado um *offset* com o valor da metade da amplitude total de cada onda.

2.2 Rede neural para modelagem da histerese

O desenvolvimento de uma rede neural capaz de modelar o comportamento histerético da SMA foi dividido em duas etapas: a aquisição de dados pertinentes a partir da plataforma, presente na Figura 1, e a divisão da duas fases da histerese.

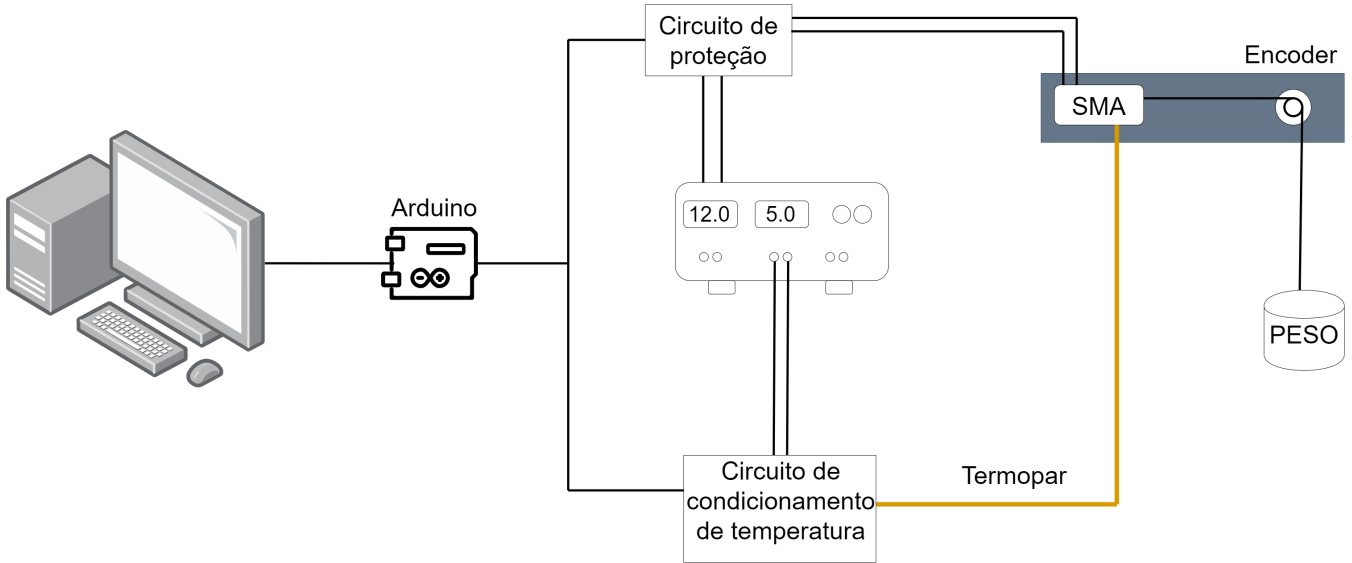


Fig. 1. Plataforma de testes.

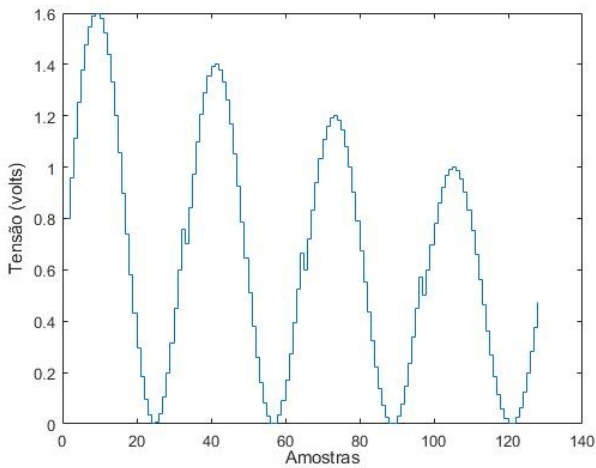


Fig. 2. Sinal de tensão utilizado no experimento

No que tange a primeira etapa, foram obtidos 1792 valores de pares de temperatura e deformação com o auxílio da plataforma de testes durante, aproximadamente, 25 horas de repetição do sinal de entrada, com períodos de pausa no processo de 3 minutos e descarte do primeiro ciclo pós-pausa.

Esses valores foram armazenados em vetores para facilitar a implementação da rede neural.

Na segunda etapa, foi implementado um sinal de distinção das fases da histerese com a intenção de verificar a tendência do valor da temperatura. Deste modo, se o valor da temperatura atual (V_{Atual}) for maior que o último valor ($V_{Anterior}$), o sinal de distinção ($TagSignal$) será "1", porém, se for menor que o último valor, o sinal de distinção será "0", como pode ser visto na Equação (1). No caso da temperatura ser igual a temperatura anterior, o sinal de distinção será o mesmo da última iteração.

$$TagSignal \begin{cases} V_{Atual} > V_{Anterior} \rightarrow 1 \\ V_{Atual} < V_{Anterior} \rightarrow 0 \\ V_{Atual} = V_{Anterior} \rightarrow TagSignal \end{cases} \quad (1)$$

Como são apenas duas fases, a associação com os valores 1 e 0 é suficiente para a rede neural aprender a diferenciação entre elas. A Figura 4 demonstra o esquema de entradas e saída da rede neural.

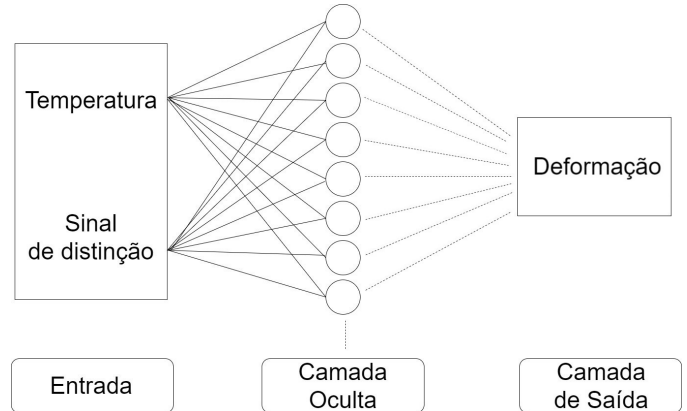


Fig. 3. Esquema simplificado de entradas da rede neural

Outro aspecto importante, considerado na modelagem da rede neural é que em situações de deformação parcial da SMA ocorre um fenômeno na histerese chamado *minor loops*, que são ciclos de histerese menores contidas em uma histerese completa. Modelar essa situação aumenta a precisão da relação entre as diferentes variáveis da histerese e aumenta a consistência de dados para o treinamento da rede neural.

Na hipótese de utilizar apenas o *major loop* (o loop de maior amplitude) como referência para o comportamento do material, encontram-se resultados satisfatórios para situações de condições fixas de alimentação da SMA e temperatura. Como a proposta do trabalho é substituir




Fig. 4. Rede Neural *feedforward* desenvolvida no MATLAB

o sensor de posição em situações diversas, a estratégia de consideração dos *minor loops* mostra-se melhor empregada.

O sinal mostrado na Figura 2 é responsável por gerar as histereses do material. Por sua vez, os *minor loops* gerados podem ser visualizados na Figura 3. Cada loop subsequente tende a ser menor que o atual, sendo o primeiro loop o *major loop* e o segundo, terceiro e quarto loops (*minor loops*), em ordem decrescente.

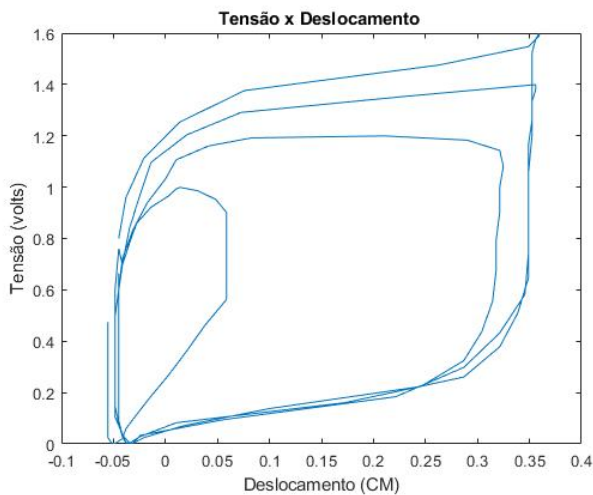


Fig. 5. *Minor Loops* de tensão e distância

Como os valores de tensão e temperatura são diretamente proporcionais, os *minor loops* são relevantes na relação entre temperatura e deformação.

Por fim, com a obtenção de dados de temperatura e a abstração de um sinal indicativo de tendência da histerese (Tag Signal), foi possível elaborar a rede neural.

Com o auxílio do software MATLAB, foi desenvolvida uma rede neural *feedforward* de duas entradas (temperatura e sinal de distinção) e uma saída (deformação).

A rede neural tem três camadas ocultas com, 16, 8 e 4 neurônios, respectivamente, somando 164 sinapses. Esse valor final de sinapses representa 9,15% do valor total de exemplos disponíveis, não apresentando problemas de *overfitting* (no qual a rede neural memoriza os dados de entrada) e *underfitting* (quando a rede neural não consegue aprender por falta de iterações) (Haykin, 1999).

Outros números de neurônios e de camadas ocultas foram testados, como: 16 neurônios em uma única camada oculta,

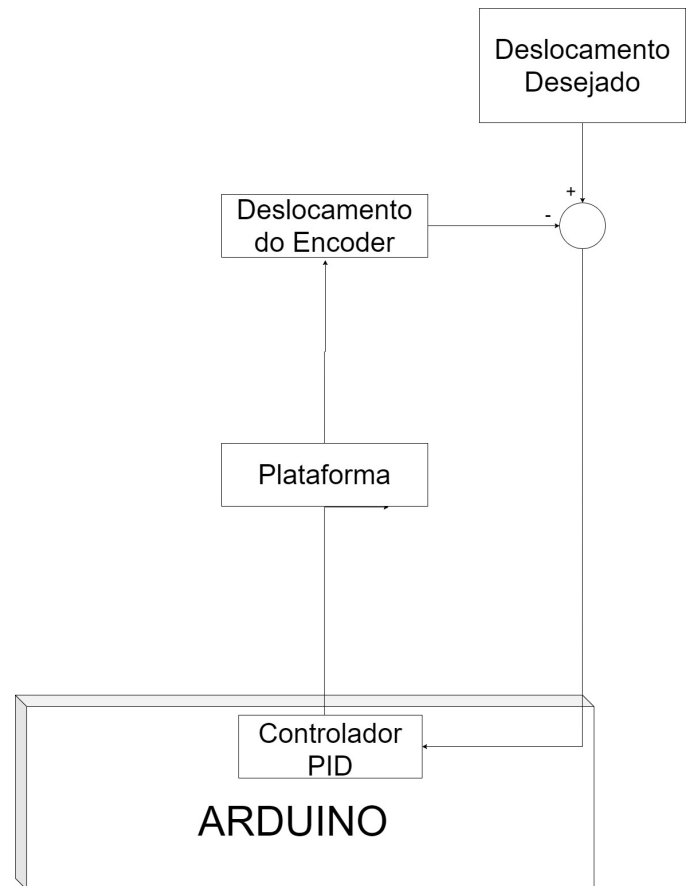


Fig. 6. Esquema de controle sem o uso da Rede Neural

32 neurônios também em uma única camada oculta e 32 neurônios divididos igualmente em duas camadas ocultas. Contudo, os resultados não foram tão satisfatórios como os encontrados na abordagem final.

Maiores números de camadas ocultas e neurônios não alteraram de forma significativa o resultado final da saída da rede neural, como também, não tiveram um bom desempenho em relação ao tempo de treinamento.

Ambas as camadas têm como função de ativação a função sigmóide e utilizam o treinamento baseado no algoritmo *backpropagation*, que resume-se no aprendizado por correção de erro (em que o erro é retro-propagado da camada de saída para as camadas intermediárias da RNA) (Haykin, 1999).

Na Figura 5 é apresentada a arquitetura completa da rede utilizando o comando *view* da interface nativa para

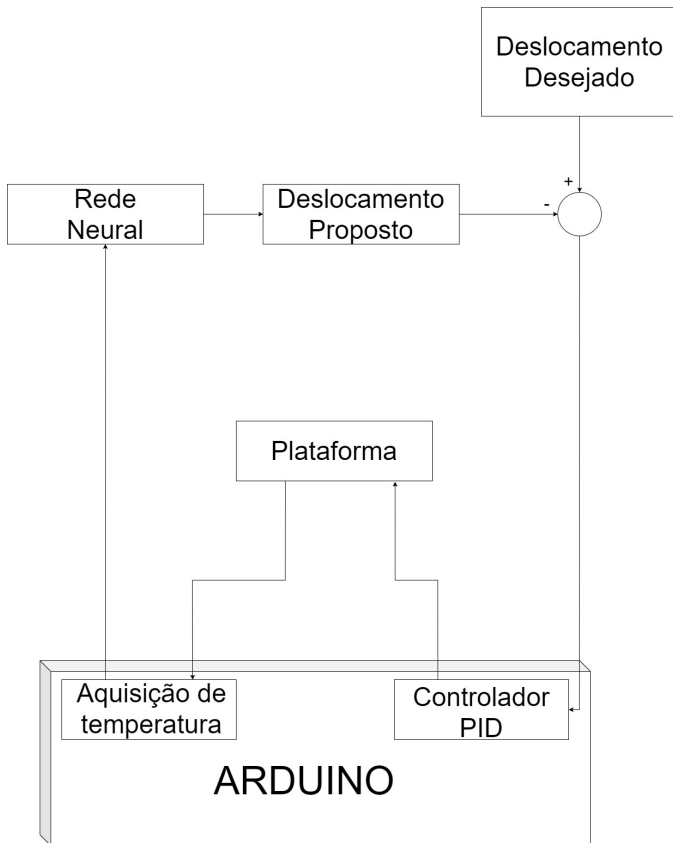


Fig. 7. Esquema de controle com o uso da Rede Neural monitoramento de redes neurais do MATLAB. A camada de saída tem como função de ativação uma função linear para não interferir no resultado da saída de cada camada.

2.3 Controle de posição da SMA

O modelo da rede neural foi utilizado em um controle de posição PID capaz de manter a SMA deformada na metade de seu alcance máximo.

Inicialmente, o controlador PID foi aplicado utilizando um encoder, conforme Figura 6.

A nomenclatura *PID* vem das ações que esse controlador exerce: ação de controle proporcional (*P*), ação de controle integral (*I*) e ação de controle derivativa (*D*) (Nise, 2012).

Ação de controle proporcional: A proporcionalidade desse controlador existe quando aplicado um ganho fixo (K_p), este valor será multiplicado pela magnitude do termo de erro. Esse artifício tem como função gerar uma ação corretiva na saída do controlador, baseada na sua realimentação. Entretanto, se o (K_p) for alto demais, o sistema apresentará uma sobrelevação (Nise, 2012).

Ação de controle derivativa: A ação derivativa tem como característica a aplicação de um sinal proporcional à derivada do sinal de erro diretamente relacionada a taxa de mudança de erro, o valor do ganho (K_d) indica a intensidade da ação derivativa. Esse fator resolve o problema de sobrelevação, porém pode causar uma nova adversidade, o erro de regime permanente (Nise, 2012), caso o valor do ganho (K_d) seja muito alto.

A equação de um controle derivativo junto ao controle proporcional é apresentada na Equação (2).

$$G_c(s) = K_p + K_d s \quad (2)$$

Ação de controle integral: A ação integral consiste na aplicação de um sinal proporcional à integral do sinal de erro. Dessa forma, a componente integral (K_i) é somada ao longo do tempo e acumula sempre que existir erro, por menor que ele seja. Essa ação de controle é capaz de resolver o problema de erro de regime. Porém, conforme demonstrado na Equação (3), a estabilidade do sistema pode ser reduzida com o acréscimo de um novo polo (Nise, 2012).

$$G_c(s) = K_p + \frac{K_i}{s} \quad (3)$$

Controlador PID completo: A junção das ações é capaz de resolver os dois problemas: sobrelevação e erro de regime. Entretanto, é necessária a correta sintonia do controlador para evitar tanto a diminuição da estabilidade, já citada, quanto a possível lentidão da resposta transitória. A Equação (4) reflete como ficaria um controle PID completo (Nise, 2012).

$$G_c(s) = K_p + K_d s + \frac{K_i}{s} \quad (4)$$

A sintonia do controle foi arbitrada de maneira aproximativa já que a planta do atuador era desconhecida, impossibilitando a utilização de algumas metodologias de projeto e sintonia de controladores PID, tais como alocação de polos (Ogata, 2010), e as duas abordagens de sintonia de ganhos Ziegler-Nichols (Ogata, 2010). No caso dos métodos de sintonia, foram realizadas diversas tentativas para obter o período crítico e/ou a resposta ao degrau unitário para a utilização da tabela dos métodos, porém em nenhum caso foi possível a aproximação. Portanto, o controlador aplicado, ou seja, os valores dos ganhos (K_p) = 10, (K_d) = 1 e (K_i) = 0,5 foram obtidos de forma empírica.

Em seguida, foram adicionados ao esquema de controle, a aquisição de temperatura e a rede neural, com o intuito de comparar com o desempenho de um sistema que utilize um encoder (Figura 7).

3. RESULTADOS

Nesta seção serão apresentados os resultados obtidos a partir do treinamento da rede neural. Também será demonstrada a comparação entre o sistema de controle utilizando o sensor de deslocamento e o sistema de controle utilizando a rede neural que determina de maneira aproximada a deformação baseando-se na temperatura.

A primeira etapa de análise de resultados foi em relação a rede neural. Encontrar um comportamento histerético o mais próximo do comportamento real era de suma importância para o decorrer do projeto.

A Figura 8 apresenta o resultado da rede neural utilizada no projeto, com 28 neurônios totais divididos em três camadas ocultas de 16, 8 e 4 neurônios, respectivamente. A




Fig. 8. Comparação: Em azul, histerese gerada pela rede neural de 28 neurônios divididos em três camadas, 16, 8 e 4 neurônios, respectivamente. Em laranja, histerese real gerada através de experimentos na plataforma de testes

rede foi capaz de respeitar o valor mínimo de deformação e ter valores mais próximos da histerese real que as outras abordagens, além de discernir as fases de aquecimento e resfriamento

Todas as histereses geradas pelas redes neurais implementadas extrapolaram um pouco os valores máximos da histerese real utilizada como comparação (em azul os resultados de histereses geradas pelas diferentes redes neurais e em laranja a histerese real, utilizada como referência).

Outro fator considerável sobre a medição é a propriedade de memória de formato do material que, ao ser exposto a longos testes e baterias de coletas de dados, responde de maneira mais rápida ao mesmo estímulo. Para evitar muita inconsistência nesses dados de entrada da rede neural, as últimas sequências de dados coletados de cada dia foram removidas.




Fig. 9. Resposta do controle utilizando sensor de deslocamento. Em azul, a resposta do controle e, em vermelho, a amplitude referência

Após encontrar um resultado satisfatório no desempenho da rede neural, houve a comparação do desempenho do sistema de controle utilizando um encoder, Figura 6, em




Fig. 10. Resposta do controle utilizando a rede neural. Em azul, a resposta do controle e, em vermelho, a amplitude referência

relação à aplicabilidade da rede neural como medidora de deformação, Figura 7.

O controle da rede neural, demonstrado na Figura 10, apresenta um tempo de estabilização mais rápido, 27 segundos, próximo da metade do tempo de estabilização do controle que utiliza o sensor físico, 58 segundos, conforme Figura 9. A aproximação da deformação baseada na temperatura faz com que esse controle se estabilize em um tempo menor já que a rede neural, por reconhecer o comportamento não linear pelo qual foi treinada, tem uma resposta mais rápida que a do encoder, porém existe uma sobrelevação de 0,05 milímetro neste projeto. Esse quesito não interferiu no desempenho do controle, já que o sistema se estabiliza em seguida.

A abordagem de controle que utiliza a rede neural apresenta um erro de regime menor que 10%. Tal valor é satisfatório, principalmente em aplicações que impossibilitem a utilização de um dispositivo físico. Em outros termos, a compensação de ter esse erro de regime é ter uma

estabilização mais rápida e uma aplicabilidade maior em múltiplos sistemas.

Adotar o uso do controlador em superfícies nas quais não é viável a aplicação de sensores de deslocamento, como nas juntas de um robô, e possibilitar conhecer melhor o comportamento da temperatura da SMA (aspecto pouco explorado em outros trabalhos da literatura) são as principais vantagens dessa abordagem.

4. CONCLUSÕES

Após a análise dos resultados obtidos com os sistemas de controle, foi possível perceber que a utilização de uma rede neural para modelagem de comportamentos não lineares atende a aplicação de controle de posição de ligas de memória de forma sem sensores físicos de deslocamento. Constatando, ainda, que essa abordagem deve ser útil em projetos que impossibilitem a utilização de sensores de medição ou que utilizem um número muito grande desses sensores, como na robótica.

A utilização de redes neurais em oposição a modelos matemáticos fixos manifestou-se como uma solução interessante para representar a relação entre temperatura e deformação do material.

A implementação do sistema de controle teve um caráter secundário nesse projeto, sendo útil para comparar o modelo de rede neural com o sensor de posição, não sendo o foco principal da pesquisa. Dessa maneira, um complemento ao trabalho seria a utilização de uma segunda rede neural para sintonização dos ganhos do controlador PID.

Outro trabalho futuro significativo seria o aperfeiçoamento dos sensores da plataforma de teste, tendo em vista que a exatidão dos dados aferidos tem relação direta ao desempenho do aprendizado da rede neural.

AGRADECIMENTOS

Os autores agradecem à FAPESB bem como à UEFS e UFBA pelo apoio ao desenvolvimento deste trabalho.

REFERÊNCIAS

- Barbosa, T.A., Cerqueira, J.J.F., and Lima, A.M.N. (2018). Shape memory alloy modeling and simulation. In *XXI Congresso Brasileiro de Automática*, 204–209.
- Haykin, S. (1999). *Redes Neurais: Princípios e Prática*. Prentice Hall, São Paulo, 2 edition.
- Jayender, J., Patel, R.V., Nikumb, S., and Ostojic, M. (2008). Modeling and control of shape memory alloy actuators. *IEEE TRANSACTIONS ON CONTROL SYSTEMS TECHNOLOGY*, 16(2), 279–287.
- Ma, N., Song, G., and Lee, H.J. (2004). Position control of shape memory alloy actuators with internal electrical resistance feedback using neural networks. *IOP Publishing Ltd Smart Materials and Structures*, 13(4), 777–783.
- Nguyen, B.K. and Ahn, K.K. (2009). Feedforward control of shape memory alloy actuators using fuzzy-based inverse preisach model. *IEEE TRANSACTIONS ON CONTROL SYSTEMS TECHNOLOGY*, 17(2), 434–441.
- Nise, N.S. (2012). *ENGENHARIA DE SISTEMAS DE CONTROLE*. LTC, Rio de Janeiro, 6 edition.
- Nunes, L., H.J., Barbosa, R., A.T., Jesus-Lopes, Carlos, J., Santos, R.D., and Miguel, L. (2017). Cogeração de energia através do efeito seebeck: Um estudo bibliométrico. In *VIII Congresso Brasileiro de Gestão Ambiental*, 1–7.
- Ogata, K. (2010). *Engenharia de Controle Moderno*. Prentice Hall, São Paulo, 5 edition.
- Romano, R. and Tannuri, E.A. (2008). Modelagem e validação experimental de um atuador baseado em liga de memória de forma. *Sba Controle Automação*, 19(1), 30–42.
- Tai, N.T. and Ahn, K.K. (2010). A rbf neural network sliding mode controller for sma actuator. *International Journal of Control, Automation, and Systems*, 8(6), 1296–1305.
- Zhao, X. and Tan, Y. (2008). Modeling hysteresis and its inverse model using neural networks based on expanded input space method. *IEEE TRANSACTIONS ON CONTROL SYSTEMS TECHNOLOGY*, 16(3), 484–490.