



Universidade Federal da Paraíba

Centro de Tecnologia

Programa de Pós-Graduação em Engenharia Mecânica

- Mestrado - Doutorado

**IDENTIFICAÇÃO DO COMPORTAMENTO DE ATUADORES
ATIVOS COM MOLAS LMF UTILIZANDO REDES NEURAIAS
ARTIFICIAIS NÃO-LINEAR AUTORREGRESSIVAS COM
ENTRADA EXÓGENA (RNA NARX)**

Por

Caio Fernando Lira Correia Araújo

*Dissertação de Mestrado apresentada à Universidade Federal da
Paraíba para obtenção do grau de Mestre.*

João Pessoa - Paraíba

junho, 2019

Caio Fernando Lira Correia Araújo

**IDENTIFICAÇÃO DO COMPORTAMENTO DE ATUADORES
ATIVOS COM MOLAS LMF UTILIZANDO REDES NEURAIS
ARTIFICIAIS NÃO-LINEAR AUTORREGRESSIVAS COM
ENTRADA EXÓGENA (RNA NARX)**

Dissertação apresentada ao curso de
Pós-Graduação em Engenharia
Mecânica da Universidade Federal da
Paraíba, em cumprimento às
exigências para obtenção do Grau de
Mestre.

Orientador: Profº Dr. Marcelo Cavalcanti Rodrigues

João Pessoa - Paraíba

junho, 2019

Catálogo na publicação
Seção de Catalogação e Classificação

A663i Araujo, Caio Fernando Lira Correia.
IDENTIFICAÇÃO DO COMPORTAMENTO DE ATUADORES ATIVOS COM
MOLAS LMF UTILIZANDO REDES NEURAIAS ARTIFICIAIS
NÃO-LINEAR AUTOREGRESSIVA COM ENTRADA EXÓGENA (RNANARX)
/ Caio Fernando Lira Correia Araujo. - João Pessoa,
2019.

66 f. : il.

Orientação: Marcelo Cavalcanti Rodrigues.
Dissertação (Mestrado) - UFPB/CT.

1. ATUADOR LMF. 2. MOLAS. 3. RNA NARX. I. Rodrigues,
Marcelo Cavalcanti. II. Título.


UFPB/BC


**IDENTIFICAÇÃO DO COMPORTAMENTO DE
ATUADORES ATIVOS COM MOLAS LMF UTILIZANDO
REDES NEURAIS ARTIFICIAIS NÃO-LINEARES
AUTORREGRESSIVAS COM ENTRADA EXÓGENA (RNA
NARX)**


por

CAIO FERNANDO LIRA CORREIA ARAÚJO

Dissertação aprovada em 27 de junho de 2019


Prof. Dr. MARCELO CAVALCANTI RODRIGUES
Orientador – UFPB


Prof. Dr. CÍCERO DA ROCHA SOUTO
Examinador Interno - UFPB


Prof. Dr. KOJE DANIEL VASCONCELOS MISHINA
Examinador Externo – UFPB

DEDICATÓRIA

Dedico este trabalho a Deus, aos meus pais, Antônio Fernando e Luciana Lígia, aos meus irmãos, João Pedro e Fernanda de Lourdes, e a Érica Braga.

AGRADECIMENTOS

Agradeço ao Prof. Dr. Marcelo Cavalcanti Rodrigues pela disponibilidade, paciência e cooperação.

A todos os integrantes do Grupo de Pesquisa em Integridade e Inspeção (GPII) da UFPB. Ao Laboratório de Instrumentação e Controle (LINC) da UFPB.

A todos os amigos e colegas que estiveram presentes nesta jornada. Caio Brandão, David Domingos, Felipe Maraschin, Genilton de França, Gilsivan Cartaxo, Heitor Abdias, Lair Santos, Ronelly José, Rebeca Casimiro e em especial a Josué da Silva e Lucas Nicolau que deram um excelente suporte na etapa final.

Agradeço à CAPES pelo investimento na minha capacitação.

RESUMO

As Ligas Memória de Forma (LMF) são um dos Novos Materiais (NM) que vêm ganhando cada vez mais notoriedade nas últimas décadas, graças às suas novas características e flexibilidade de comportamento, que possibilitam a mudança de sua estrutura interna sob condições de temperatura e tensão. Pesquisas utilizam-se deste tipo de material para o desenvolvimento de atuadores, tanto ativos quanto passivos, porém, existindo limitações para aplicações dos atuadores ativos, uma vez que, suas propriedades não-lineares limitam a previsibilidade do comportamento. A utilização de sistemas inteligentes pode viabilizar as aplicações desses atuadores. Muitas pesquisas têm empregado materiais LMF a sistemas de controle ou monitoramento de elementos de fios. Assim, este trabalho propõe a utilização de redes neurais artificiais não-lineares autorregressivas com entrada exógena (RNA tipo NARX), para a previsão do comportamento histerético de molas LMF e atuadores, compostos por associações de molas LMF, utilizando dados experimentais para treinamento e validação da RNA. Foram utilizados dados de força e temperatura obtidos em ensaios sob condições de deformações de 150%, 200% e 300% para as molas, e 100% e 150% para os atuadores. Após a deformação, aplicou-se corrente elétrica para o aquecimento dos elementos, para assim, obter a variação da força gerada pelo material. Foram obtidos resultados satisfatórios, onde a RNA apresentou a capacidade de aprendizado do comportamento dos dados dos ensaios e obteve as médias percentuais absolutas dos erros em torno de 0,4 % no teste de validação.

Palavras Chaves: Atuador LMF; Molas; RNA NARX.

ABSTRACT

The Shape Memory Alloy (SMA) is one of the New Materials (NM) that have been increasing their notoriety in the last decades. Due to their new characteristics and behavioral flexibility, that make possible change its internal structure under stress and temperature conditions. Many researches have been using this material type to develop active or passive actuators, however, active actuators have limitations in the application for the predictability of the behavior because of the alloy non-linearity. With the use of smart systems, it is possible to make feasible many applications of these actuators. Many other researches have been using SMA materials with control systems or monitoring wire elements. So, this work proposes to use the neural network nonlinear autoregressive exogenous input (NN type NARX) to predict the hysteretic behavior of SMA springs and actuators, composed of SMA spring associations, based on experimental data to train and validate of the NN. It was used stress and temperature data obtained under conditions of deformation of 150%, 200% and 300% of springs and 100% and 150% of actuators. After the deformation, it was applied an electric current to heat the spring or actuator. It was obtained satisfactory results, where the NN presented the capability to learn the behavior of the test data and obtained an absolute average percentage error around 0.4% in the NN validation.

Keywords: LMF Actuator; Spring; NN NARX.

SUMÁRIO

Capítulo 1	13
1.1 INTRODUÇÃO	13
1.2 OBJETIVOS GERAIS	14
1.2.1 <i>Objetivos específicos</i>	14
Capítulo 2	16
2.1 REVISÃO BIBLIOGRÁFICA	16
2.1.1 <i>Aspectos gerais</i>	16
2.1.2 <i>Aplicações</i>	19
2.1.3 <i>Comportamento termomecânico</i>	21
2.1.4 <i>Ligas de Ni-Ti</i>	24
2.1.5 <i>Redes neurais</i>	26
Capítulo 3	36
3.1 MATERIAIS E MÉTODOS	36
3.1.1 <i>Aquisição dos Dados usados</i>	36
3.1.2 <i>Rede Neural Artificial</i>	39
Capítulo 4	44
4.1 RESULTADOS E DISCUSSÕES	44
4.1.1 <i>Molas com Deformação de 150%</i>	44
4.1.2 <i>Molas com Deformações de 200%</i>	47
4.1.3 <i>Molas com Deformações de 300%</i>	49
4.1.4 <i>Atuador com Deformação de 100%</i>	50
4.1.5 <i>Atuador com Deformação de 150%</i>	52
Capítulo 5	56
5.1 CONCLUSÕES	56
REFERÊNCIAS.....	57
APÊNDICE 1	61
<i>Script da RNA utilizada</i>	61

ÍNDICE DE ILUSTRAÇÕES

Figura 2.1 – Ciclo de transformações martensíticas e suas temperaturas características de transformação. O termo Propriedade refere-se ao parâmetro genérico que varia durante a transição, Calorimetria, Deformação, Resistência eléctrica, etc, (Simões, 2016).	18
Figura 2.2 -Dispositivos auto expansivos com memória de forma (Marston e Razavi, 2019).	19
Figura 2.3 - Arcos ortodônticos fabricados com ligas de LMF (Lagoudas, 2008).	20
Figura 2.4 Implantação de placas de LMF em motores de Boeing (Lagoudas, 2008).	21
Figura 2.5 -Demonstração do efeito da superelasticidade (Thompson, 2000).	21
Figura 2.6 - Representação da curva tensão-deformação característica da superelasticidade (Simões, 2016).	22
Figura 2.7 - Demonstração do efeito de memória de forma (Thompson, 2000).	23
Figura 2.8 - a) Martensita orientada com aplicação de tensão e b) remoção da carga e transformação em austenita em temperatura superior a A_f (Lagoudas, 2008).	24
Figura 2.9 – Ilustração comparativa da deformação mecânica da liga NiTi com o Aço inoxidável. Adaptado de (Thompson, 2000).	26
Figura 2.10 –Modelo de neurônio Não-Linear. Fonte do autor.	27
Figura 2.11 - (a) Função Limiar; (b) Função Linear por partes; (c) Função sigmoide para parâmetro de inclinação a variável, fonte: Haykin (2007).	28
Figura 2.12 - (a) Função de ativação Tangente Hiperbólica.	29
Figura 2.13 – (a) Redes Alimentadas Adiante com Camada Única; (b) Redes Alimentadas Diretamente com Múltiplas Camadas. Fonte: Haykin (2007).	30
Figura 2.14 – Rede recorrente com neurônios ocultos. Com laço de auto-realimentação (Haykin, 2007).	31
Figura 2.15 – Rede Neural tipo NARX (Bellouard, 2008).	31
Figura 2.16 - Diagrama de blocos para o treinamento utilizando o algoritmo de Levenberg-Marquardt. ADAPTADO de Irwin e Wikamowski (2011).	33
Figura 3.1 - Imagem da mola Emiliavaca (2016).	36
Figura 3.2 - Imagem da estrutura de De Souza, R. C. (2018).	37
Figura 3.3 - Atuador com molas em paralelo (Adaptado de Souza, J. D. S. (2018)).	38
Figura 4.1 - Evolução do Erro por época.	44

Figura 4.2 - Treinamento da rede neural artificial.....	45
Figura 4.3 - Validação da rede neural artificial.	46
Figura 4.4– Treinamento para identificação do comportamento histerético da rede neural artificial.	46
Figura 4.5 - Validação do comportamento histerético da rede neural artificial.....	47
Figura 4.6 - Evolução do erro para Mola com deformação de 200%.....	48
Figura 4.7 - Gráficos de treinamento e teste da Mola (200%).	49
Figura 4.8 - Evolução do erro para Mola com deformação de 300%.....	49
Figura 4.9 - Gráficos de treinamento e teste da Mola (300%).	50
Figura 4.10 – Evolução do erro para o atuador com deformação de 100%.	51
Figura 4.11 - Gráficos de treinamento e teste do Atuador (100%).	52
Figura 4.12– Evolução do erro para o atuador com deformação de 150%.	52
Figura 4.13 – Gráficos de treinamento e teste do atuador (150%).	53

ÍNDICE DE TABELAS

Tabela 3.1 - Dados máximos do ensaio das molas.	38
Tabela 3.2 – Dados máximos dos ensaios do atuador.	39
Tabela 4.1– Tabela dos erros médios.	54
Tabela 4.2 – Tabela dos erros percentuais médios.	54
Tabela 4.3– Relação percentual entre os erros máximos obtidos.	54

ÍNDICE DE EQUAÇÕES

Eq. (2.1).....	27
Eq. (2.2).....	29
Eq. (3.1).....	40
Eq. (3.2).....	41
Eq. (3.3).....	41
Eq. (3.4).....	42
Eq. (3.5).....	43
Eq. (3.6).....	43
Eq. (3.7).....	43
Eq. (3.8).....	43

LISTA DE SÍMBOLOS

NM - Novos Materiais

LMF - Ligas Memória de Forma

EMF - Efeito Memória de Forma

SE - Superelasticidade

RNA - Rede Neural Artificial

NARX - Não-linear Auto-regressivo com Entradas Exogenas

NiTi - Níquel-Titânio

Ms - Martensita Inicial

Mf - Martensita Final

As - Austenita Inicial

Af - Austenita Final

T - Temperatura

σ_{Ms} - Tensão crítica de início de transformação martensítica

σ_{Mf} - Tensão crítica de final transformação martensítica

σ_{As} - Tensão crítica de início de transformação austenítica

σ_{Af} - Tensão crítica de final de transformação austenítica

LVSI - Integração com escala muito ampla (Very large scale integration)

[z-1] - Atraso de unitário

μ - Coeficiente de combinação

PI - Controlador Proporcional Integral

VSC - Controle variável de estrutura

RNAS - Redes Neurais Artificiais Estáticas

RNAR - Redes Neurais Artificiais Recorrentes

RNARA - Redes Neurais Artificiais Recorrentes com Atraso

EQM - Erro Quadrático Médio

EMA - Erro Médio Absoluto

MAPE - Média Percentual Absoluta do Erro

CAPÍTULO 1

1.1 INTRODUÇÃO

Atualmente, diversos problemas enfrentados pela indústria e pela engenharia vêm sendo reanalisados. Com isso, novas soluções vêm surgindo como as aplicações de Novos Materiais (NM) que possuem características flexíveis. Dentre os NM encontramos materiais de efeito piezoelétricos, magnetostrictivos, memória de forma entre outros. Os materiais citados modificam as propriedades físicas de acordo com tensões aplicadas e/ou condições de temperatura (Rao *et al.*, 2015).

O grande aumento do número de artigos e patentes apresentados para estes tipos de materiais indica sua importância, presente e futura, no desenvolvimento e aplicação de atuadores em diversas áreas como construção civil, indústria aeroespacial, biomedicina e muitos outros campos (Da Silva, 2016). Materiais com ligas memória de forma (LMF) já são comumente utilizados em procedimentos biomédicos e ortodônticos. Molas e fios de LMF são largamente utilizados na ortodontia, tanto que, encontram-se facilmente molas e fios comerciais. Entretanto, para operar como atuadores mecânicos, as ligas precisam apresentar características definidas que possibilitem o controle e previsão do comportamento durante a vida útil. Um fator crítico para as LMF é a redução do seu efeito durante os ciclos de operação (Stoeckel e Yu, 1991; Bundhoo *et al.*, 2009; Macena *et al.*, 2015; Souza, J. D. S., 2018).

As LMF's modificam sua estrutura interna, mudando a fase, de acordo com a temperatura e/ou tensão mecânica aplicada. Geram assim, propriedades diferenciadas em relação às ligas metálicas comuns. Os efeitos dessas variações são conhecidos como Superelasticidade (SE) e Efeito Memória de Forma (EMF). Na SE, o material apresenta o comportamento histerético durante o carregamento e descarregamento da tensão mecânica aplicada (Lagoudas, 2008). Existem diversos atuadores passivos que, em geral, utilizam a SE. Atuadores com EMF necessitam de sistemas de controle ativo para aquecimento e/ou resfriamento (Moraes, 2017; Oliveira, 2017).

Após o surgimento das LMF, pesquisadores vêm propondo modelos numéricos capazes de descrever os comportamentos destas ligas. Os comportamentos se

caracterizam como problemas complexos e não-lineares. Uma alternativa para previsão do comportamento é a aplicação de Redes Neurais Artificiais que, baseadas em dados obtidos experimentalmente, podem identificar os padrões das curvas de histerese do material e deformações residuais (Nicolau, 2018).

1.2 JUSTIFICATIVA

Tendo em vista a disponibilidade de molas comerciais de LMF utilizadas para diversos fins, o passo inicial para aplicação em sistemas ativos é a identificação do comportamento deste tipo de elemento. Diversos estudos apresentam análises e aplicações para fios de LMF, porém, se faz necessário o desenvolvimento de pesquisas para aplicações de molas como atuadores ativos.

O trabalho propõe a utilização de Redes Neurais Artificiais não-linear autoregressivo com estrada exógena, RNA do tipo NARX, na previsão do comportamento histerético de molas ortodônticas de Liga Memória de Forma, e atuadores formado por associações das respectivas molas, além de, também validar a aplicação da RNA, anteriormente utilizada para detecção de deformações residuais em fios LMF, na previsão do comportamento de molas LMF.

1.3 OBJETIVOS GERAIS

Validação de uma Rede Neural Artificial para previsão do comportamento histerético de molas e atuadores formado por associação de molas compostas por material de liga memória de forma.

1.3.1 Objetivos específicos

- Definir a topologia da RNA para identificação de molas e de atuadores.
- Tratamento dos dados para utilização na RNA
- Treinamento e Validação da RNA, tipo NARX, para molas e atuadores utilizando variação de força e temperatura a partir de dados obtidos em ensaios;
- Análise dos resultados da RNA, tipo NARX, no aprendizado do comportamento das molas e atuadores de LMF;

3.4 ORGANIZAÇÃO DA DISSERTAÇÃO

A dissertação está dividida de cinco capítulos. No capítulo 1 é apresentada a introdução, justificativa e objetivos. No Capítulo 2, a revisão bibliográfica que consiste nos aspectos gerais das ligas LMF, bem como, o comportamento termomecânico das ligas e propriedades das ligas de Ni-Ti, além de uma revisão sobre redes neurais artificiais e artigos que tratam da utilização de RNAs para identificação e/ou controle de atuadores com ligas LMF. No capítulo 3 apresenta-se materiais e métodos de como foram obtidos os dados e o método para treinamento e validação da rede neural. No Capítulo 4 são apresentados e discutido os erros obtidos pela RNA. No Capítulo 5 apresentam-se as conclusões obtidas.

CAPÍTULO 2

2.1 REVISÃO BIBLIOGRÁFICA

Neste capítulo aborda-se, de forma geral, o conceito das ligas memória de forma, suas propriedades, suas aplicações, o comportamento termomecânico e as ligas Ni-Ti, com suas propriedades que variam de acordo com a composição. Também, se apresentam as redes neurais artificiais, suas aplicações para controle e previsão do comportamento das LMF.

2.1.1 Aspectos gerais das LMF

A procura por materiais que tenham a capacidade de reduzir custos, acelerar ou aperfeiçoar as operações tem sido cada vez maior. O avanço desses materiais é visto como uma redução no espaço que ele ocupa (miniaturização), rapidez nas respostas dos comandos e bom rendimento energético. Entre os materiais capazes de causar estes tipos de melhoria, estão as ligas com memória de forma, que podem funcionar como sensores e/ou atuadores (Oliveira, 2014).

Ligas com memória de forma são materiais denominados inteligentes ou materiais avançados, por ter sua obtenção de maneira não convencional, necessitando de conhecimentos prévios e técnicas específicas para a sua obtenção. Estes materiais apresentam uma série de aplicações fundamentadas em suas propriedades. Na área da Engenharia Mecânica, estas ligas despertam o interesse de diversas aplicações, como atuadores mecânicos, sendo estas: Componentes de automontagem, união de materiais (Luvas para tubulações, rebites para placas metálicas), sistemas de comando térmico, aplicações biomédicas (Sistemas ortopédicos e odontológicos), interruptores elétricos acionados termicamente (Termostato) e mancal para controle ativo de vibrações.

As ligas com memória de forma trabalham dentro de uma faixa de temperatura e possuem duas fases distintas, cada uma com uma estrutura cristalina diferente, portanto, diferentes propriedades. Uma das é a fase de alta temperatura, chamada austenita e a outra é a fase de baixa temperatura, chamada martensita. Austenita (geralmente cúbica) tem uma estrutura cristalina diferente da martensita (tetragonal, ortorrômbico ou monoclinico). A transformação de uma estrutura para a outra não

ocorre por difusão de átomos, mas sim por distorção da estrutura de corte. Tal transformação é conhecida como transformação martensítica. O nome martensita é devido ao cientista Alemão Adolf Martens e foi usado originalmente para descrever os microconstituintes duros, encontrado em aços endurecidos. Outros materiais (exceto os aços) são conhecidos por exibir o mesmo tipo de transformação de fase martensítica em estado sólido. Ocorre em ligas não ferrosas, metais puros, cerâmicos, minerais, compostos inorgânicos, gases solidificados e polímeros (Bellouard, 2008; Bundhoo *et al.*, 2008; Frenzel *et al.*, 2010; Petrini e Migliavacca, 2011).

Tem sido reconhecido que as transformações martensíticas não são difusoras, pois, a martensita pode crescer a temperaturas inferiores a 100 K em que a mobilidade dos átomos é desprezível. Isto não implica que todas as transformações martensíticas ocorrem em baixas temperaturas, muitas podem ocorrer em altas temperaturas e são também não difusivas. A martensita pode crescer com uma rapidez de velocidade de 1000 m/s, inconsistente com a difusão de átomos. Em muitos dos casos, a martensita que é obtida depende mais temperatura de partida da transformação, do que do tempo para essa temperatura, neste caso, a transformação é chamada de atérmica. Tal como referido por J. W. Christian em 1970, a cinética total de uma reação martensítica depende das etapas de nucleação e de crescimento, mas irá ser dominado, em grande parte, com a lentidão dos dois. Transformações martensíticas não obedecem à teoria clássica da nucleação (Ross e Crocker, 1970).

De acordo com Lagoudas (2008) e Otsuka e Wayman (1998), as quatro temperaturas distintas que caracterizam as SMAs na ausência de tensões são: Ms, Mf, As e Af. A temperatura Af corresponde à temperatura acima da qual há somente a presença de austenita estável. A temperatura Mf corresponde à temperatura abaixo da qual há somente a presença de martensita. A temperatura Ms e As correspondem às temperaturas em que se iniciam a indução térmica de formação de martensita e austenita, respectivamente.

Dessa forma a transformação martensítica é uma transição termodinâmica de primeira ordem, tendo em vista que o calor é liberado na sua formação, há uma histerese térmica associada, possui temperaturas características que definem os pontos inicial e final da formação de martensita e austenita e existe uma faixa de temperatura na qual a austenita e martensita coexistem. Logo a transformação

martensítica é classificada como termoelástica e não-termoelástica, e é diferenciada pela histerese de transformação térmica. A largura do ciclo de histerese é o produto da barreira de energia que deve ser superada para iniciar a transformação. A transformação termoelástica é caracterizada por ter uma pequena histerese e não-termoelástica por uma grande histerese (ver figura 2.1).




Figura 2.1 – Ciclo de transformações martensíticas e suas temperaturas características de transformação. O termo Propriedade refere-se ao parâmetro genérico que varia durante a transição, Calorimetria, Deformação, Resistência eléctrica, etc, (Simões, 2016).

No caso da transformação termoelástica, a força motriz é muito pequena e a interface entre austenita e martensita é muito móvel no resfriamento e aquecimento. Esta transformação é cristalogicamente reversível, visto que, a martensita é revertida para a fase mãe (austenita) na orientação original.

Para a transformação não-termoelástica, a força motriz é muito grande em comparação a termoelástica e a interface entre austenita e martensita é imutável, uma vez que, a martensita cresce para um tamanho crítico, de modo que, a transformação inversa ocorre pela re-nucleação da fase mãe (austenita), dessa forma, a transformação inversa não é reversível. O fenômeno da memória de forma e da superelástica são geralmente caracterizados por transformações termoelásticas, logo, a martensita e austenita são estruturas, estáveis em diferentes temperaturas, responsáveis por conferir às ligas as propriedades de efeito de memória de forma (EMF) e superelasticidade (SE) (Thompson, 2000).

2.1.2 Aplicações da LMFs

As propriedades das LMFs estão atraindo grande interesse tecnológico e motivando várias aplicações nos mais diversos campos da ciência e da engenharia. Aeroespacial, biomédica e robótica são algumas das áreas onde as LMFs têm sido utilizadas.

Os chamados dispositivos auto expansivos (Duerig *et al.*, 1999), também conhecidos como “stents”, em homenagem ao dentista C. T. Stent, são uma importante aplicação cardiovascular com ligas com memória de forma. Estes dispositivos são utilizados para sustentar o diâmetro interno de vasos tubulares como vasos sanguíneos, esôfago e duto biliar. Neste tipo de aplicação, uma trama cilíndrica com memória de forma, como apresenta a Figura 2.2, é inserida e posicionada por meio de um cateter em um vaso sanguíneo, por exemplo. Inicialmente, esta trama é pré-comprimida e encontra-se em seu estado martensítico. Conforme a trama é aquecida devido à temperatura interna do corpo, ela tende a recuperar a sua forma original, expandindo-se. Além de procedimentos como o de angioplastia, para evitar o ré entupimento de um vaso, estes dispositivos também podem ser utilizados no tratamento de aneurismas cerebrais, para a sustentação das paredes de um vaso enfraquecido (Marston e Razavi, 2019).



Figura 2.2 -Dispositivos auto expansivos com memória de forma (Marston e Razavi, 2019).

As propriedades das LMFs têm sido implementadas com sucesso numa grande variedade de aplicações dentárias. Arcos ortodônticos feitos com ligas NiTi têm sido utilizadas desde a década de 1970 e são mais eficazes do que outros materiais utilizados para este fim. Em um material elástico linear, como o aço inoxidável, é necessária uma grande quantidade de força para uma pequena variação, ou seja, O

processo resulta em uma grande quantidade de força sobre o dente para uma pequena movimentação da arcada dentária. A vantagem de arcos pseudoelásticos é que o material tem uma mudança irrelevante sobre tensão, e uma força moderada é requerida para movimentar os dentes durante um longo período de tempo, em comparação com aço inoxidável.

Além disso, a composição do material e o processamento podem ser concebidos para produzir diferentes níveis de força para diversas situações. A Figura 2.3 é um exemplo de aparelhos ortodônticos fabricados com LMF (Lagoudas, 2008).



Figura 2.3 - Arcos ortodônticos fabricados com ligas de LMF (Lagoudas, 2008).

Segundo Lagoudas (2008), os níveis de ruído do motor durante a decolagem e a aterrissagem tornaram-se mais regulamentados em todo o mundo. Para reduzir este ruído, alguns designers estão instalando chevrons nos motores para misturar o fluxo dos gases de escape do motor e reduzir o ruído. As vigas de LMF dobram as divisas durante os voos de baixa altitude ou de baixa velocidade, aumentando assim a mistura e reduzindo o ruído. Durante voos com grande altitude ou alta velocidade, estes componentes de LMF são resfriados, causando a transformação da austenita em martensita maclada, endireitando assim os chevrons e aumentando o desempenho do motor. O atual projeto Boeing para estas vigas de geometria variável pode ser visto na Figura 2.4.




Figura 2.4 Implantação de placas de LMF em motores de Boeing (Lagoudas, 2008).

2.1.3 Comportamento termomecânico

O comportamento termomecânico associado à transformação termoelástica das LMF envolve o efeito de superelasticidade (SE), bem como, o efeito de memória de forma (EMF), que associados a uma boa resistência mecânica, propiciam a utilização desses materiais nas mais diversas áreas de atuação.

Na SE, a LMF possui a capacidade de retornar para a sua forma original após submetida a aplicação de carga que gera grandes deformações (entre 3 e 6%), isto é, a LMF apresenta uma recuperação da deformação quando a carga é removida. Como ilustrado na Figura 2.5.




Figura 2.5 -Demonstração do efeito da superelasticidade (Thompson, 2000).

Quando o material, inicialmente, na fase austenítica ($T > A_f$), é submetido a um carregamento mecânico, pode ser iniciada sua transformação de fase quando se atinge a *tensão crítica de início de transformação martensítica* (σ_{Ms}) finalizando sua transformação quando a *tensão crítica de final de transformação martensítica* (σ_{Mf}) é atingida. Da mesma forma, durante o descarregamento, o material inicia sua transformação de fase reversa quando se atinge a *tensão crítica de início de transformação austenítica* (σ_{As}) completando a transformação quando se chega a

tensão crítica de final de transformação austenítica (σ_{Af}) (Strittmatter *et al.*, 2014; Qiu *et al.*, 2016; Simões, 2016; Witkowska *et al.*, 2017; Yang *et al.*, 2017). A figura 2.6 ilustra a transformação gerada devido a aplicação de tensão.




Figura 2.6 - Representação da curva tensão-deformação característica da superelasticidade (Simões, 2016).

No efeito de memória de forma, o material se mantém num estado deformado após a remoção da força externa e, em seguida, recupera a sua forma original após o aquecimento, ou seja, o aumento da temperatura proporciona distorções na rede, de forma que, o material retorne à sua forma original. Geralmente, estes materiais podem ser facilmente deformados pseudo-plasticamente (da ordem de até 6%) a uma temperatura relativamente baixa (abaixo de sua temperatura crítica, M_f) e ao serem expostos a uma temperatura mais elevada (acima de sua temperatura crítica, A_f) retomam sua forma inicial. (Montenegro *et al.*, 2016; Simões, 2016; Luiz F. Toledo, 2017; Zhang *et al.*, 2017). A figura 2.7 ilustra o comportamento mecânico do EMF.




Figura 2.7 - Demonstração do efeito de memória de forma (Thompson, 2000).

A temperatura em que se dá início a transformação da austenita em Martensita é A_s , que ocorre durante o resfriamento e é conhecida como Martensita Inicial (M_s), enquanto a temperatura onde essa transformação termina é conhecida como Martensita Final (M_f). A partir do resfriamento do ponto A_f para o ponto M_s , o material que antes apresentava uma estrutura austenítica passa a apresentar uma estrutura martensítica maclada não orientada. Ao submeter o material a um carregamento, a estrutura martensítica maclada presente no ponto M_s inicia seu processo de orientação a uma tensão crítica inicial, dando lugar a uma estrutura martensítica orientada, que finaliza seu processo de orientação a uma tensão crítica final (Figura 2.8a). A estrutura martensítica orientada permanece mesmo após o descarregamento, dando origem a uma deformação residual. Ao submeter o material a um aquecimento na ausência de carregamento mecânico, a transformação de fase reversa tem início quando a temperatura atinge A_s e finaliza na temperatura A_f , na qual a estrutura passa a ser completamente austenítica e a deformação residual é completamente recuperada, fazendo com que o material retorne a sua forma inicial (Figura 2.8b). Um subsequente resfriamento, resultará novamente na formação de uma estrutura martensítica maclada dando início a um novo ciclo do EMF (Lagoudas, 2008; Jun et al., 2017).




Figura 2.8 - a) Martensita orientada com aplicação de tensão e b) remoção da carga e transformação em austenita em temperatura superior a A_f (Lagoudas, 2008).

Portanto, é importante diferenciar as propriedades que as LMFs possuem em diferentes regimes de aplicações. As grandes vantagens nos materiais feitos de liga de memória de forma se dão graças à capacidade de dissipação de energia devido à presença do laço de histeretico que, normalmente, está associado às transformações micro estruturais martensíticas do material.

2.1.4 Ligas de Ni-Ti

De forma geral, as LMF são direcionadas para aplicações de desempenho que exigem baixas densidades de energia, grandes deformações recuperáveis, tensões elevadas e excelente biocompatibilidade. O comportamento único das LMF tem feito com que aplicações de caráter inovador tenham surgido nos setores aeroespacial, automotivo, automação e controle, odontologia e medicina, energia, aquecimento e ventilação, entre outros (Nespoli e Besseghini, 2011; Petrini e Migliavacca, 2011). Dentro da ampla variedade de LMF (Ag-Cd, Cu-Al-Ni, Cu-Al-Be, Fe-Mn-Si, etc), ligas à base de Ni-Ti associando EMF e SE, com boas trabalhabilidade e resistência mecânica, boa resistência à corrosão devido à camada de óxido de titânio que se forma naturalmente na superfície, considerável resistência à fadiga e boa estabilidade química são as mais usadas para a fabricação de dispositivos LMF. Estes materiais ganharam destaque em aplicações biomédicas devido à boa biocompatibilidade, excelente ressonância magnética e compatibilidade com tomografia computadorizada. Além disso, o comportamento mecânico de ligas Ni-Ti é mais semelhante à resposta do tecido biológico se comparada com a de outros materiais

metálicos comumente usados para dispositivos biomédicos, como aço inoxidável 316L e ligas de cromo-cobalto (Cr-Co) (Petrini e Migliavacca, 2011; El-Hadad *et al.*, 2014).

As ligas de Ni-Ti com memória de forma são um composto intermetálico. Este composto apresenta uma solubilidade moderada do Níquel e do Titânio, assim como de outros elementos metálicos, além de apresentar uma ductilidade comparável à de outras ligas. Esta solubilidade de um maior número de elementos permite uma modificação significativa tanto das suas propriedades mecânicas quanto das suas temperaturas de transformação (Krishnan, 2004).

As ligas binárias de Ni-Ti têm suas temperaturas de transformação tipicamente entre -40 e 100 ° C e mostram uma histerese de temperatura entre 20 e 40 ° C. É possível diminuir as temperaturas de transformação das ligas, quando se introduz um teor de níquel extremamente alto nas ligas de Ni-Ti. Além disso, é mais provável que estas ligas ricas em níquel apresentem superelasticidade, pois possuem maior força intrínseca e podem ser endurecidas com tratamentos térmicos. Entretanto, o tratamento com calor pode resultar em um aumento nas temperaturas de transformação e na resistência de ligas devido à formações de precipitados ricos em níquel (Saedi *et al.*, 2018).

Duerig (1991) descreveu as aplicações para ligas de memória de forma Ni-Ti agrupadas de acordo com a função primária do elemento de memória. Exemplos como as armações de óculos Ni-Ti, acoplamentos para união de tubulação hidráulica de aeronaves e conectores elétricos, atuadores tanto elétricos quanto térmicos. Outras utilizações das propriedades superelásticas de Ni-Ti foram descritas por Stoeckel e Yu (Stoeckel e Yu, 1991). Como a superelasticidade é um evento isotérmico, as aplicações com um ambiente de temperatura bem controlada são mais bem-sucedidas, por exemplo, no corpo humano. Outro exemplo é o fio Ni-Ti usado como fio ortodôntico e molas, em tele-linearizadores de agulha Mammalok® (para localizar e marcar tumores de mama), fios-guia para cateteres, agulhas de sutura, e hastes para óculos.

Estas ligas tem um melhor comportamento de memória de forma entre todas LMF já descobertas. Mesmo no estado policristalino, 8% de recuperação de forma é possível e 8% de deformação pseudoelástico é completamente reversível quando as amostras são submetidas a uma temperatura acima de A_f , e a tensão de ruptura é da ordem de 800 MPa. Quando em comparação com outras ligas como por exemplo o

aço inoxidável verifica-se que estas últimas apresentam menos de 1% de capacidade de recuperação como mostra a Figura 2.9 (Thompson, 2000).




Figura 2.9 – Ilustração comparativa da deformação mecânica da liga NiTi com o Aço inoxidável. Adaptado de (Thompson, 2000).

2.1.5 Redes neurais

Redes Neurais (RN) são estruturas inspiradas no funcionamento dos neurônios do cérebro humano. Elas são divididas em camadas de entrada, de saída e ocultas. As camadas interagem entre si através de pesos sinápticos e a função de ativação define a saída.

As redes neurais podem se adaptar à variações de cenários de forma simples, além de, também possuírem uma elevada capacidade de generalização, com isso podem trabalhar com sistemas não-lineares através do mapeamento de Entradas e Saídas.

Haykin (2007) lista oito vantagens para aplicação de redes neurais: Iniciando com a possibilidade de trabalhar com neurônios não-lineares, o que abre portas para trabalhos com entradas não-lineares. O mapeamento de Entrada-Saída, consiste no aprendizado supervisionado, que a própria rede adapta os pesos para aproximar-se da saída desejada: A adaptabilidade que permite a autocompensação quando ocorrem mudança no ambiente e aconselha-se utilizar um grande número de informações no tempo, tendo em vista a manutenção da robustez da rede. Quando submetido a padrões conflitantes, a rede possui a capacidade de descartar um padrão incoerente com a crença presente o que melhora a capacidade de classificação da rede neural. Qualquer neurônio da rede sofre influência dos demais neurônios da rede

e essa troca de informações gera a informação contextual; A tolerância a falhas das redes neurais está baseada na sua própria estrutura, caso ocorra falha em algum neurônio existem diversas conexões em paralelo o que minimizam a influência de danos à resposta da rede. Devido ao grande número de ligações paralelas as redes neurais podem utilizar da tecnologia LVSI (very-large-scale-integration) que permite a aquisição de comportamentos complexos de forma hierárquica.

A base para a operação de redes neurais é o neurônio. A Figura 2.10 expõe o modelo de neurônio não-linear, que apresenta três estruturas fundamentais que são um conjunto de sinapses que determinam um peso, o somador que executa a combinação linear e, por fim, a função de ativação que determina a saída. O Bias opera como uma válvula que permite aumentar ou diminuir a entradas para a funções de ativação, sendo ele positivo, eleva-se o número de entradas, o oposto ocorre quando negativo.





Figura 2.10 –Modelo de neurônio Não-Linear. Fonte do autor.


Descrevendo matematicamente (Eq. 2.1), temos o somatório do produto entre as entradas e os pesos, em seguida, adiciona-se o Bias. Caso cumpra com os requisitos para a função de ativação o valor é calculado e a saída apresentada.

$$y_k = \varphi \left(\sum_{j=1}^m w_{kj} * x_j + b_k \right) = \varphi(u) \quad \text{Eq. (2.1)}$$


A função de ativação permite a passagem do sinal de saída, caso ele obedeça a certas condições, e define a saída em relação ao campo local induzido “u” na Eq. (2.1). As principais funções de ativação estão representadas na Figura 2.11, e são elas as funções de ativação limiar (Figura 2.11 (a)), que é similar a uma função degrau, função linear por partes (Figura 2.11 (b)) e a função sigmoide (Figura 2.11 (c)) que se trata da função de ativação muito utilizada em redes neurais artificiais.



(a)



(b)



(c)

Figura 2.11 - (a) Função Limiar; (b) Função Linear por partes; (c) Função sigmoide para parâmetro de inclinação a variável, fonte: Haykin (2007).

A função de ativação Tangente Hiperbólica está descrita na eq. 2.2 e apresentadas graficamente na figura 2.12. O intervalo de resposta varia entre -1 e 1 apresentando uma simetria, que é um dos fatores para utilização da função de ativação.

$$F(n) = \frac{1 - e^{-2n}}{1 + e^{-2n}} \quad \text{Eq. (2.2)}$$




Figura 2.12 - (a) Função de ativação Tangente Hiperbólica.

As redes alimentadas adiante com camada única, figura 2.13 (a), existem apenas a camada de saída, ela pode ser considerada camada única pois a camada de entrada não altera os valores de entrada. Rede alimentadas diretamente com múltiplas camadas, figura 2.13 (b), apresentam as camadas de entrada e saída além de uma ou mais camadas intermediárias denominadas de camadas ocultas. Neste tipo de rede pode-se trabalhar com estatística de ordem elevadas e a confiabilidade dessas redes está diretamente atrelada ao tamanho do vetor de entrada (camada de entrada).




Figura 2.13 – (a) Redes Alimentadas Adiante com Camada Única; (b) Redes Alimentadas Diretamente com Múltiplas Camadas. Fonte: Haykin (2007).

Como analisado anteriormente, a liga memória de forma possui comportamento não-linear devido às propriedades termo-mecânicas do material. Considerando o elemento como um sistema mecânico que, sofrendo variação da estrutura interna, altera a função de transferência que descreve o comportamento do elemento, as redes neurais recorrentes possuem a capacidade de releitura do sistema, utilizando dados anteriormente fornecidos pela própria rede.

As redes neurais recorrentes, figura 2.14, possuem ao menos um laço de realimentação. A realimentação pode ser feita da saída do neurônio para a entrada de outro neurônio ou para a entrada do próprio neurônio. No segundo caso, a rede é chamada de auto-realimentada. A realimentação eleva o desempenho e a capacidade de aprendizagem da rede. Para detecção do comportamento não-linear utiliza-se elementos de atraso unitário [z^{-1}] que permitem o armazenamento de dados não-lineares.




Figura 2.14 – Rede recorrente com neurônios ocultos. Com laço de auto-realimentação fonte: Haykin (2007).

A Rede Neural Não-linear auto regressiva com entrada exógena, denominada NARX, figura 2.15, é um dos tipos de redes neurais recorrentes. Neste tipo de rede a camada de entrada recebe mais de um tipo de dados e sofrem influência dos atrasos, ou seja, os valores anteriores influenciam nos resultados subsequentes. Este tipo de rede possui a capacidade de prever mudanças no comportamento que variam em função do tempo (Wang e Song, 2014). Para a previsão são utilizados os dados externos e os dados obtidos pela própria rede.




Figura 2.15 – Rede Neural tipo NARX (Bellouard, 2008).

Na Tabela 2.1, apresenta-se as regras aplicadas por alguns algoritmos. O método do gradiente descendente consiste no gradiente definido na derivada do erro em relação ao peso. No modelo de Newton são utilizadas matrizes com derivadas segundas do erro em relação ao peso o que também pode ser chamado de Matriz Hessiana. No método de Gauss-Newton, devido à complexidade do cálculo da Matriz Hessiana, utilizou-se a matriz Jacobiana para, a partir dela, calcular uma aproximação da Matriz Hessiana de forma mais simplificada e o método de Levenberg-Marquardt.

Algoritmos	Regras de Implementação	Convergência	Complexidade Computacional
Gradiente descendente	$w_{k+1} = w_k - \alpha g_k$	Estável, lento	Gradiente
Newton	$w_{k+1} = w_k - H_k^{-1} g_k$	Instável, rápido	Gradiente e Hessiana
Gauss-Newton	$w_{k+1} = w_k - \left(J_k^T J_k \right)^{-1} J_k e_k$	Instável, rápido	Jacobiano
Levenberg-Marquardt	$w_{k+1} = w_k - \left(J_k^T J_k + \mu I \right)^{-1} J_k e_k$	Estável, rápido	Jacobiano

Tabela 2.1 – Adaptado do Livro de Irwin e Wikamowski (2011)

O método de Levenberg-Marquardt apresenta uma aproximação da matriz Hessiana, considerando um coeficiente de combinação não proposto no método de Gauss-Newton. Durante o treinamento, o modelo oscila entre o método de Gauss-Newton e o gradiente descendente sob as seguintes condições: Quando os valores de μ são próximos de zero o modelo se comporta como o de Gauss-Newton e quando os valores são grandes o modelo se comporta como o gradiente descendente, onde μ corresponde ao coeficiente de combinação. A descrição pode ser vista no diagrama apresentado na figura 2.16.




Figura 2.16 - Diagrama de blocos para o treinamento utilizando o algoritmo de Levenberg-Marquardt. Adaptado de Irwin e Wikamowski (2011).

2.1. 6 Aplicações de RNA em LMF

Asua *et al.* (2008) desenvolveu experimentos com fios LMF sob carregamento de tração e aquecimento por efeito joule. Usando o método de aproximação inversa da histerese para efetuar o controle, baseado na compensação não-linear da histerese, foi aplicado dois métodos experimentais, o primeiro, utilizando uma compensação linear para introduzir a mudança de fase da liga através de um controlador Proporcional Integral (PI), o segundo, baseou-se na aplicação de redes neurais artificiais que são capazes de reconhecer padrões não lineares. A rede neural escolhida possuía 3 camadas, a camada de entrada com 3 entradas, camada intermediária com 80 neurônios que possuem função de ativação sigmoide e camada de saída com 1 saída com função de ativação linear. A rede também considerou as saídas anteriores da própria rede, aprendendo a dinâmica do sistema, utilizando o algoritmo de Levenber-Marquardt. Os atuadores LMF usualmente são utilizados como sistemas “on-off”, porém, Asua *et al.* (2008) conclui que, utilizando técnicas de controle, os sistemas LMF podem ser utilizados com sucesso para aplicações de

micro-posicionamento com precisão micrométrica, apesar do comportamento não-linear.

Wang e Song (2014) propôs um modelo inovador para redes neurais recorrentes do tipo NARX com objetivo de analisar o comportamento de fios ultrafinos de LMF. O escopo central foi identificar e prever o comportamento não-linear e histerético do fio LMF. Foi utilizado um sistema que aplicava uma pré-carga ao fio e aferia a posição para determinar a variação do deslocamento após o aquecimento por efeito joule. As arquiteturas apresentadas foram: Jordan-P (Paralela) NARX e Jordan-plus-Elman. Na primeira, a realimentação ocorre da saída da rede para a entrada, no segundo caso, além da saída da rede influenciar na entrada, os resultados da camada oculta também são realimentados para a entrada. A rede foi treinada off-line partindo de dados experimentais coletados e utilizando o método Levenberg-Marquardt backpropagation para minimizar o erro entre o treinamento e os dados de referência. Para possibilitar a comparação entre as estruturas, foi adotada a mesma topologia que consistia em 20 (vinte) neurônios na camada oculta, 3 (três) entradas baseadas nos dados anteriores obtidos no experimento e 3 (três) entradas que se baseavam na resposta da rede. Ambas as estruturas aprenderam o comportamento, contudo, o erro apresentado pela arquitetura Jordan-plus-Elman foi inferior a Jordan-P, consolidando uma alternativa para identificação de materiais inteligentes.

Nikdel *et al.* (2014) propôs um controle preditivo usando redes neurais artificiais de um sistema com atuador de fio LMF, fixado em a um pivô acoplado em uma mola para detecção do deslocamento angular, similar ao comportamento de rotação de um braço humano. Além da identificação do sistema e controle por RNA utilizou-se o método de controle discreto não-linear por VSC (Variable Structure Control) para comparação dos resultados. São apresentados os modelos matemáticos utilizados para transferência de calor, modelo dinâmico, modelo de transformação de fase do fio LMF e modelo constitutivo do fio LMF. A topologia da RNA utilizada foi de 6000 épocas, 5 neurônios na camada oculta com função de ativação tangente hiperbólica com taxa de entradas de 5 ms. A previsão do comportamento mostrou-se aceitável para efetuar o controle. Comparando as respostas, o modelo preditivo com RNA mostrou-se superior ao VSC com relação ao tempo de subida, tempo de estabilização assim como um menor erro de estado permanente.

Um sistema de controle, em tempo real, utilizando Redes Neurais Artificiais com atraso foi implementado, por Mai *et al.* (2016), para o controle do deslocamento de um fio LMF utilizando tensão como entrada. O experimento foi feito utilizando uma máquina de tração, com sensor de laser acoplado, para medição do deslocamento entre a variação ocasionada pela mudança de fases do fio devido ao aquecimento por efeito joule. O objetivo foi a identificação da histerese do fio, em tempo real, e em seguida efetuar o controle, para isso, utilizou-se três tipos de redes neurais artificiais. Foram elas, redes neurais artificiais estáticas (RNAS), redes neurais recorrentes (RNAR) e redes neurais artificiais recontes com atraso (RNARA). A RNAS não se mostrou capaz de identificar o comportamento da histerese, em contrapartida, a RNAR e RNARA apresentaram um bom desempenho. Utilizando o Simulink, foram gerados sinais de tensão linear em diversas frequências para efetuar o deslocamento do fio. As comparações das redes neurais foram feitas através do Raiz do Erro Quadrático Médio (RMS). Entre a RNAR e a RNARA, a implementação do atraso reduziu o valor RMS, logo, a RNARA se mostrou mais apropriada para a identificação da histerese em tempo real. O artigo apresentou um excelente caminho para aplicações de identificação do comportamento histerético de fios com LMF utilizando a teoria de estabilidade de Lyapunov que garante a convergência da RNARA para o erro.

CAPÍTULO 3

3.1 MATERIAIS E MÉTODOS

Neste capítulo são apresentando os ensaios e elementos utilizados para a obtenção dos dados utilizados como referência para treinamento e validação da rede neural artificial do tipo NARX. Os procedimentos executados no pré-treinamento, treinamento, validação e pós-treinamento da rede neural, bem como a comparação e avaliação dos resultados da rede.

3.1.1 Aquisição dos Dados usados

3.1.1.1 Configuração Mola

Os dados utilizados para o treinamento foram coletados em experimentos no laboratório de Instrumentação e Controle – LINC da Universidade Federal da Paraíba e apresentados por Souza, J. D. S. (2018) e De Souza, R. C. D. (2018). Foram utilizadas molas ortodônticas da fabricante Morelli Ortodontia de diâmetro do fio de 0,2 mm, diâmetro externo da espira de 1,27 mm e distância entre olhais de 12 e 9 mm respectivamente. Na figura 3.1 apresenta-se a proporção da mola.



Figura 3.1 - Imagem da mola Emiliavaca (2016).

A estrutura de teste para coleta dos dados foi desenvolvida por De Souza, R. C. D. (2018) utilizando-se uma célula de carga tipo S, com capacidade de até 5 kgf, modelo SCSA/ZL-5 com alimentação de 10VccA. Na Figura 3.2 apresenta-se o desenho da estrutura com a célula de carga, suporte para as amostras e a maçaneta para aplicar os deslocamentos na mola executados.




Figura 3.2 - Imagem da estrutura de De Souza, R. C. D. (2018).

O módulo NI-9213 foi utilizado para coleta de dados de temperatura do termopar tipo K fixado na superfície de mola. Outro módulo, NI-9201, recebeu os sinais de tensão vindo da célula de carga e a leitura dos sinais foram feitas através uma rotina desenvolvida no LabView.

Foram selecionados três ensaios, apresentados na Tabela 3.1, que correspondem a valores atingidos durante os ensaios. Todos os dados coletados durante o ensaio foram utilizados para o treinamento e validação da rede neural artificial. As deformações para cada ensaio foram de 150%, 200% e 300% que correspondem a 22,5 mm, 27 mm e 36 mm. Para cada porcentagem de deformação foram feitos três ensaios com correntes elétricas distintas para observar a resposta do atuador em Newtons.

Deformação (150%)		
Corrente (mA)	Temperatura (°C)	Δ Força (N)
196	49,6	0,75
277	70,7	1,6
351	90,8	2,4
Deformação (200%)		
Corrente (mA)	Temperatura (°C)	Δ Força (N)
196	45,9	0,7
277	64,2	1,45
351	81,6	2,15
Deformação (300%)		
Corrente (mA)	Temperatura (°C)	Δ Força (N)
196	42,8	0,43
277	58,7	0,87
351	74,4	1,33

Tabela 3.1 - Dados máximos do ensaio das molas.

3.1.1.2 Configuração Atuador

No ensaio do atuador utilizou-se da mesma estrutura e instrumentação para caracterização, com exceção do tipo de pré-carregamento. Apresenta-se na Figura 3.3 o atuador que consiste em quatro micro-molas M12, fornecidas pela Dental Morelli, associadas em paralelo com distâncias entre olhais de 12 mm e comprimento útil de 7,5 mm com material de Liga Memória de Forma 50%Ni-50%Ti. A disposição das molas no atuador visou a otimização do espaço disponível no protótipo proposto por Souza, J. D. S. (2018). A geometria do atuador proporcionou uma maior força por milímetro deslocado em relação às molas individualmente.




Figura 3.3 - Atuador com molas em paralelo (Adaptado de Souza, J. D. S. (2018)).

Dos dados experimentais obtidos nos ensaios do atuador foram selecionados dois ensaios como mostrado na tabela 3.2, foram consideradas as deformações de 150% que apresentam melhor relação de força por deslocamento como apresentado por De Souza, R. C. D. (2018). As deformações foram de 100% e 150% que corresponde respectivamente deformações de 24 mm e 30 mm, considerando as distâncias entre os centros dos anéis de fixação que corresponde a 12 mm.

Deformação (100%)		
Corrente(mA)	Temperatura(°C)	Força(N)
220	57,4	3,977
255	77,7	4,877
332	92,5	6,871
Deformação (150%)		
Corrente(mA)	Temperatura(°C)	Força(N)
220	50,4	4,618
255	58,2	5,948
332	92,5	8,819

Tabela 3.2 – Dados máximos dos ensaios do atuador.

3.1.2 Rede Neural Artificial

Para simulação da rede neural é necessário a preparação dos dados de entrada. A RNA possui a capacidade de aprendizado do comportamento baseada nos dados. A preparação dos dados é essencial para garantir que o treinamento possua como alvo as condições reais ou desejadas. A RNA utilizada foi baseada na rede apresentada por Nicolau (Nicolau, 2018), que propõe a utilização de uma rede neural artificial não-linear com entrada exógena e com regularização bayesiana, para identificação das deformações residuais em fios de LMF no qual utilizou-se 12 neurônios na camada interna e 8 atrasos considerando os erros quadráticos médios admissíveis para treinamento e teste de 5×10^{-4} e 2×10^{-2} .

Algumas medidas são adotadas para redução do custo computacional da rede, a normalização é uma delas. A normalização consiste na transformação dos valores reais em números adimensionais que simplificam os cálculos da rede. Para início do funcionamento da rede são determinadas as condições iniciais para o peso e o bias.

A rede neural foi treinada utilizando o método de Levenberg-Marquardt, apresentado no capítulo 2, com regularização bayesiana que possui a vantagem de não necessitar da validação cruzada e entregar uma robustez ao modelo.

3.1.2.1 Pré-processamento

Preparação dos dados

Os dados foram alocados em arquivo de texto. A distribuição foi feita em 4 colunas que representavam em sequência crescente o tempo, ciclo, força e temperatura. Para cada deformação foram aplicados 3 ciclos, onde se variou a corrente elétrica, conseqüentemente, a taxa de aquecimento para obtenção dos valores de força. Os dois ciclos com menores correntes elétrica foram utilizados para o treinamento da rede neural artificial e o ciclo com a corrente elétrica mais elevada foi utilizado para a validação da rede.

Normalização

Os dados de força e temperatura foram normalizados utilizando a equação (3.1). Dada a função de ativação selecionada, Tangente Hiperbólica, o intervalo de variação para a normalização foi de $y_{min} = -1$ a $y_{max} = 1$. O objetivo da normalização foi simplificar os dados de forma que a rede conseguisse aprender com maior facilidade, ou seja, com um menor custo computacional. Foram utilizados o maior e menor valor dos dados para normalização da força e posteriormente para a normalização da temperatura.

$$Saída = y_{min} + \frac{(y_{max} - y_{min}) \cdot (Entrada - \min(Parâmetro))}{\max(Parâmetro) - \min(Parâmetro)} \quad \text{Eq. (3.1)}$$

Inicialização dos pesos

O trabalho da rede neural consiste na atribuição de pesos aleatórios, buscando um menor erro para o sistema. Para simplificar a inicialização da RNA e tendo em vista também a redução do custo computacional se utiliza os valores iniciais de [0 1] para o peso e bias.

Topologia da Rede

Visando a aplicação mais generalizada da rede neural, utilizou-se a mesma topologia tanto para as molas quanto para os atuadores. Foi determinado por tentativa e erro o número de 14 neurônios com 6 atrasos para 1 saída. Os parâmetros de treinamentos aplicados foram de 1000 épocas, erro admissível de treinamento de $2,5 \times 10^{-4}$ e erro admissível de teste de 1×10^{-4} .

O parâmetro interno de avaliação da rede utilizado, foi o erro quadrático médio do treinamento e o erro quadrático médio da validação, calculado pelas equações (3.2) e (3.3). Também foi utilizado erro quadrático médio, que corresponde a uma medida de previsão do erro, e o erro absoluto médio.

$$EQM_T = media((Força_{Treinamento_desn} - Resposta_{treinamento_desnor})^2) \quad \text{Eq. (3.2)}$$

$$EQM_V = media((Força_{Validação_desn} - Resposta_{Validação_desnor})^2) \quad \text{Eq. (3.3)}$$

Através da análise de erro pode-se identificar certas condições da rede como o sobretreinamento, que se caracteriza pela perda da capacidade de generalização. O sobretreinamento pode ser identificado quando o erro do treinamento tende a zero e ocorre um aumento no erro do teste. Para proteger a rede de situações como esta, determinou-se valores admissíveis para os erros de treinamento e teste, apresentados anteriormente na topologia.

3.1.2.2 Etapa de treinamento

O treinamento da rede consiste na variação dos pesos aplicados, esta variação é baseada no cálculo do erro e visa a redução da função custo permitindo a identificação do comportamento não-linear. Utilizou-se o modelo de Levenberg-Marquardt, apresentado na figura 2.16, que a partir dos valores dos erros determina-se as variações dos pesos. A regularização Bayesiana descarta a necessidade de validação cruzada e confere robustez ao modelo. A regularização consiste da atribuição de hiperparâmetros que influenciam na atribuição dos pesos forçando a rede neural a buscar o menor erro reduzindo o grau de oscilação dos pesos.

A fase de aprendizado do comportamento dos atuadores e molas LMF correspondeu ao treinamento da rede. No treinamento, as entradas foram os dados de força e temperatura em relação ao tempo. Para cada ciclo o material foi deformado em uma porcentagem definida e em seguida aplicou-se um sinal degrau de corrente elétrica, aquecendo o material. A resposta do atuador foi o aumento da força no elemento, o que corresponde a uma contração no atuador ou mola.

O erro foi calculado em cada etapa do treinamento e a partir dele a rede reajustava os pesos buscando a diminuição do erro. Utilizou-se o Erro Quadrático Médio (EQM). As condições iniciais foram atribuídas no pré-processamento.

Dependendo da variação entre o erro anterior e o erro calculado, seguindo as condições do método de Levenberg-Marquardt, calculava-se a matriz jacobiana para atribuir novos pesos. A redução do erro sinaliza que a aproximação quadrática está satisfatória e são incrementadas apenas variações no valor de μ , caso o erro tende a subir, o valor de μ sofre uma variação maior para encontrar uma curva quadrática mais adequada. Atingindo-se o erro admissível para o treinamento e validação, também definido no pré-processamento, a simulação é encerrada e os valores dos erros e pesos são salvos.

Validação

A validação do experimento se faz necessária para comprovar a capacidade de aprendizado da rede. O desempenho da rede neural artificial constata a capacidade da rede de aprender, de forma generalizada, o comportamento não-linear da liga memória de forma. Nessa etapa não ocorre variação dos pesos, como na etapa de treinamento. O erro da validação consiste na diferença entre os valores dos alvos e os valores obtidos pela rede neural.

3.1.2.3 Pós-Processamento

Desnormalização

Após todas as operações desenvolvidas pela rede neural artificial, são obtidos os resultados que devem retornar para a escala inicial, que foi apresentada antes da normalização dos dados. Para isso utiliza-se as Eq. 3.8, tanto para os parâmetros de força quanto para os parâmetros de temperatura. Trata-se de uma etapa do pós-processamento que permite a comparação com as situações reais do atuador ou mola.

$$Saída = \min(Parâmetro) + \frac{(\max(Parâmetro) - \min(Parâmetro)) \cdot (Entrada - y_{min})}{y_{man} - y_{min}} \quad \text{Eq. (3.4)}$$

Comparação e avaliação

A avaliação da rede neural foi feita baseada nos cálculos dos erros que correspondem a diferença entre os valores obtidos nos experimentos e os resultados da rede neural após a desnormalização.

Após a desnormalização os erros de treinamento e validação foram calculados para avaliação da qualidade da rede neural. Foram utilizados o Erro Quadrático Médio (EQM), eq. 3.2 e 3.3, o Erro Absoluto Médio (EAM), eq. 3.5 e 3.6, e a Média Percentual Absoluta do Erro (MAPE ou do inglês Mean Absolut Relative Error – MARE) representado na equação 3.7 e 3.8.

$$EMA_T = media(|Força_Treinamento_desn - Resposta_treinamento_desnor|) \quad \text{Eq. (3.5)}$$

$$EMA_V = media(|Força_Validação_desn - Resposta_Validação_desnor|) \quad \text{Eq. (3.6)}$$

$$MAPE_T = media\left(\frac{|Força_Treinamento_desn - Resposta_treinamento_desnor|}{|Força_Treinamento_desn|}\right) \quad \text{Eq. (3.7)}$$

$$MAPE_V = media\left(\frac{|Força_Validação_desn - Resposta_Validação_desnor|}{|Força_Validação_desn|}\right) \quad \text{Eq. (3.8)}$$

CAPÍTULO 4

4.1 RESULTADOS E DISCUSSÕES

Neste capítulo, apresentam-se os resultados do treinamento e validação da rede neural artificial para molas com deformações de 150%, 200% e 300% e atuador com deformações de 100% e 150%. Discute-se também os resultados da RNA baseados no erro quadrático médio, erro absoluto médio e média percentual absoluta do erro.

4.1.1 Molas com Deformação de 150%

A Figura 4.1 exibe o erro da RNA com relação aos valores de treinamento e valores de teste para cada época. Dada a topologia da rede (Pré-processamento, capítulo 3), fixam-se os valores para os erros mínimo admissíveis. Com a limitação do erro se impede o sobre treinamento que prejudicaria a capacidade de generalização da rede. A RNA busca a obtenção de ambos os erros dentro do número de épocas determinadas. O erro consiste na diferença entre os valores de referência e os obtidos pela rede. Para a situação em que o gráfico não alcançasse os erros admissíveis, poder-se-ia considerar que a rede encontrar-se-ia em um mínimo local.




Figura 4.1 - Evolução do Erro por época.

A intensidade da força aplicada pela mola varia de acordo com a corrente elétrica aplicada. Na Figura 4.2 apresentam-se dois ensaios, o primeiro, na abcissa, de zero até 200 segundos, a corrente elétrica aplicada possui um valor de 196 mA atingindo a temperatura de 42,11°C, e o segundo, de 200 a 400 segundos, onde o

valor de corrente foi de 276 mA e temperatura máxima de 57,24°C. O tempo de aquecimento da mola por corrente, para cada experimento, ficou em torno de 81 segundos e as forças atingiram, para o primeiro e segundo ensaio, o valor de 4,04 N e 4,90 N respectivamente. Como pode-se observar novamente na Figura 4.2, o treinamento da rede neural foi capaz de aprender o comportamento da força para as duas situações.




Figura 4.2 - Treinamento da rede neural artificial.

Na Figura 4.3 valida-se o treinamento da RNA. Pode-se observar que a rede foi capaz de prever o comportamento da mola quando sujeito a deformação de 150%. Observa-se que os dados de entrada utilizados foram de força e temperatura e com isso obtém-se a força gerada pelo efeito memória de forma. A corrente elétrica aplicada no experimento para obtenção dos dados utilizados no teste da rede foi de 351 mA resultando numa temperatura máxima de 73,19°C. Na etapa de validação são utilizados os pesos obtidos na etapa de treinamento da rede com o intuito de testar a capacidade previsão da RNA.




Figura 4.3 - Validação da rede neural artificial.

No gráfico da figura 4.4, tem-se 2 (dois) laços histeréticos que representam, assim como na figura 4.2, o comportamento dos dois ensaios com menores correntes. O laço menor corresponde ao primeiro ensaio, onde a corrente elétrica foi de 196 mA, alcançando 42,11°C, enquanto o laço histerético maior ao segundo com 276 mA atingindo 57,24°C. Além da identificação do comportamento dos ensaios constata-se na Figura 4.4 que o treinamento da RNA foi bem efetuado, visto que, conseguiu rastrear o comportamento dos dados.




Figura 4.4– Treinamento para identificação do comportamento histerético da rede neural artificial.

A variação da corrente elétrica implica diretamente na mudança da taxa de aquecimento, apesar das distintas correntes aplicadas, tanto para o treinamento

quanto para a validação, a rede neural apresenta a capacidade de prever o comportamento histerético, como identifica-se na figura 4.5.




Figura 4.5 - Validação do comportamento histerético da rede neural artificial.

A análise da qualidade da rede neural foi medida através da Média Percentual Absoluta do Erro (MAPE). A rede foi treinada 3 (três) vezes para cada mola sob determinada deformação. O resultado obtido para a mola com deformação de 150% foi o valor médio da MAPE foi de 0,26% para a etapa de treinamento e 0,39% para a etapa de validação.

4.1.2 Molas com Deformações de 200%

Dada a mesma topologia, a rede neural conseguiu atingir novamente os erros admissíveis desejados para a mola com deformação de 200%, como apresenta-se na Figura 4.6.






Figura 4.6 - Evolução do erro para Mola com deformação de 200%.


Os gráficos na Figura 4.7 (a) e (c) apresentam os resultados da etapa de treinamento da rede neural no qual atingiu-se a média do MAPE de 0,16%, demonstrando novamente a capacidade de aprendizagem da rede neural. Ainda na figura 4.7, os itens (b) e (d) correspondem à etapa de validação da rede que atingiu a média do MAPE de 0,36%. As temperaturas alcançadas nos ensaios foram de 40,43°C no primeiro ciclo, 53,7°C para o segundo ciclo e 66,16°C no terceiro e último ciclo.




(a)



(b)



(c)



(d)

Figura 4.7 - Gráficos de treinamento e teste da Mola (200%).

4.1.3 Molas com Deformações de 300%

Para finalizar a análise da RNA para mola isoladas, antes da apresentação dos testes feitos em atuadores com 4 molas em paralelo, aplicou-se a deformação de 300%. Como nos treinamentos anteriores, a RNA foi capaz de atingir os erros admissíveis solicitados antes do número máximo de épocas, como apresenta-se na figura 4.8.




Figura 4.8 - Evolução do erro para Mola com deformação de 300%.

Nos gráficos (a) e (c), da Figura 4.9, o treinamento mostra-se efetivo. Apesar do comportamento histerético da rede apresentar uma geometria diferente dos ensaios anteriores, a rede aprende com sucesso o perfil dos dados obtidos dos ensaios. Ressalta-se novamente que a RNA não se propõe a atingir todos os pontos

da validação, o que prejudicaria a capacidade de generalização da rede, o objetivo é identificar o padrão de comportamento dos dados dos ensaios. Na Figura 4.9, (b) e (d), apesar da distribuição dos dados serem menos homogêneos que nos ensaios anteriores, a RNA consegue identificar o padrão da curva alcançando MAPE de 0,10% para o treinamento e para a validação de 0,34%. As temperaturas alcançadas nos ensaios foram de 42,07°C no primeiro ciclo, 57,9°C para o segundo ciclo e 72,73°C no terceiro e último ciclo.




Figura 4.9 - Gráficos de treinamento e teste da Mola (300%).

4.1.4 Atuador com Deformação de 100%

O atuador, como apresenta-se na figura 3.3, é composto por 4 micro-molas associadas em paralelo. Os ensaios de caracterização do atuador seguiram os passos utilizados para a caracterização dos ensaios com molas individuais, diferenciando-se apenas na taxa de aquecimento (corrente elétrica) utilizada. Observa-se na figura 4.10 a evolução do erro para o atuador com deformação de 100% onde constata-se a

aquisição do erro admissível por parte da rede neural antes do número de épocas máximos.








Figura 4.10 – Evolução do erro para o atuador com deformação de 100%.

Nos resultados da etapa de treinamento do atuador, figura 4.11 (a) e (c), aplicou-se correntes elétricas de 219 mA e 255 mA alcançando temperaturas de 57,36°C e 67,75°C respectivamente. A rede seguiu os dados de entrada e obtendo o valor do MAPE de 0,33% no treinamento. Nos gráficos (b) e (d) da Figura 4.11, a corrente elétrica aplicada foi de 331 mA aquecendo o atuador a 92,5°C. Visualiza-se um maior erro entre a curva obtida através da RNA e os dados de referência apresentando a Média Percentual Absoluta do Erro (MAPE) de 0,47% para a validação. Apesar do erro mais elevado, comparado às validações anteriores, a rede consegue assimilar o comportamento do material durante o ensaio.





(c)



(d)

Figura 4.11 - Gráficos de treinamento e teste do Atuador (100%).

4.1.5 Atuador com Deformação de 150%

A última análise foi feita com o atuador sob uma deformação de 150%. A rede neural atingiu os valores admissíveis determinados como se apresenta na figura 4.12.




Figura 4.12– Evolução do erro para o atuador com deformação de 150%.

As Figuras 4.13 (a) e (c) que correspondem a etapa de treinamento obteve o MAPE de 0,25%. Nas Figuras 4.13 (b) e (d), referentes à validação da rede, obteve o valor MAPE de 0,44%. A RNA mostra-se efetiva ao aprender o comportamento da curva histerética. As temperaturas máximas obtidas para os três ciclos sob deformação de 150% em ordem crescente foi de 50,4°C, 58,17°C e 78,08°C em ordem crescente do número de ciclos.




Figura 4.13 – Gráficos de treinamento e teste do atuador (150%).

Na tabela 4.1 apresentam-se cada ensaio separado por elemento e por suas deformações, bem como, os valores dos erros obtidos para cada ensaio. Estão representados o Erro Quadrático Médio (EQM) e Erro Médio Absoluto (EMA). Os sufixos “_T” e “_V” correspondem respectivamente aos valores obtidos nos Treinamento e Validação. As escolhas das deformações de 150%, 200% e 300% das molas foram baseadas na bibliografia e a seleção das deformações dos atuadores de 100% e 150% se basearam no padrão de melhor relação de carregamento por força, identificado por De Sousa (2018).

Quando aplicadas ao atuador, a rede neural apresenta um erro superior aos elementos de mola simples, tanto para o treinamento quanto para validação. Os maiores erros podem ser atribuídos à associação das micro-molas que incorporam de forma não-linear o erro individual ao erro do atuador.

Elemento	Deformação (%)	EQM_T	EQM_V	EMA_T	EMA_V
Mola	150	0,0003	0,0015	0,0093	0,0198
Mola	200	0,0001	0,0010	0,0065	0,0166
Mola	300	0,0001	0,0007	0,0048	0,0173
Atuador	100	0,0019	0,0064	0,0250	0,0438
Atuador	150	0,0018	0,0074	0,0215	0,0496

Tabela 4.1– Tabela dos erros médios.

Na Tabela 4.2 são apresentados os valores da Média Percentual Absoluta do Erro (MAPE). O valor do MAPE permite uma comparação direta levando-se em consideração a porcentagem do erro para cada ensaio.

Elemento	Deformação (%)	MAPE_T	MAPE_V
Mola	150	0,26	0,44
Mola	200	0,16	0,36
Mola	300	0,10	0,34
Atuador	100	0,33	0,47
Atuador	150	0,25	0,44

Tabela 4.2 – Tabela dos erros percentuais médios.

A comparação separada de cada tipo de erro em relação a todos os ensaios está apresentada na tabela 4.3. Nela é apresentada a razão entre o erro do ensaio com o maior erro dentre todos os ensaios. A diferença entre o maior valor dos Erros quadráticos médios em relação ao menor chega a 94,74% para o treinamento e 90,54% para a validação. Comparando o maior erro médio absoluto com o menor, a diferença entre os erros chega a 80,8% para treinamento e 66,53% para validação. Na etapa de treinamento a diferença entre os valores extremos da Média Percentual Absoluta do Erro chegou a 69,7% e para a etapa de validação apenas 27,66%.

Elemento	Deformação (%)	EQM_T	EQM_V	EMA_T	EMA_V	MAPE_T	MAPE_V
Mola	150	15,79	20,27	37,20	39,92	78,79	93,62
Mola	200	5,26	13,51	26,00	33,47	48,48	76,60
Mola	300	5,26	9,46	19,20	34,88	30,30	72,34
Atuador	100	100,00	86,49	100,00	88,31	100,00	100,00
Atuador	150	94,74	100,00	86,00	100,00	75,76	93,62

Tabela 4.3– Relação percentual entre os erros máximos obtidos.

O tempo de convergência da rede foi rápido, tempos inferiores a 5 minutos, devido ao método de treinamento aplicado, Levenberg-Marquardt com regularização bayesiana. Apesar da variação da deformação inicial e das diferentes correntes elétricas aplicadas, que também pode ser entendido como diferentes temperaturas, e com um número baixo de dados utilizados para o treinamento, quando comparado a outros trabalhos referenciados (Nicolau, 2018).

Através da modificação da topologia da rede, o aumento do número de neurônios na camada oculta por exemplo, pode-se reduzir a MAPE da rede. Outra alternativa seria o aumento dos dados utilizados nos treinamentos, que podem ser, elevar a taxa de aquisição de dados ou utilizar um maior número de ensaios.

CAPÍTULO 5

5.1 CONCLUSÕES

O modelo de redes neurais artificiais autorregressivas com entradas exógenas (NARX) e regularização Bayesiana apresenta uma excelente capacidade de previsibilidade do comportamento não-linear de ligas memória de forma. Anteriormente aplicada para fios de LMF e agora validada para molas, pode-se constatar a excelente capacidade de generalização da rede.

A rede foi capaz de prever o comportamento do atuador apresentando um MAPE médio de 0,455% na etapa de validação, onde a rede efetivamente previa o comportamento baseando-se apenas nas entradas de temperatura e força. As temperaturas máximas aplicadas no atuador variaram de 50,4°C até 92,5°C. Para as molas individuais obteve-se o MAPE médio de 0,38% e temperaturas de máximas aplicas de 66,16°C até 72,73°C.

Os elementos com ligas memória de forma sofrem fadiga tanto mecânica quanto térmica, portanto, o conhecimento da variação de temperaturas de transformação é essencial para otimizar as aplicações. A capacidade preditiva da rede pode flexibilizar a utilização deste tipo de atuadores proporcionando uma maior eficiência e prolongamento da vida útil.

A rede se mostra robusta tendo a capacidade de aprender o comportamento dos elementos apesar da não-linearidade inerente a eles. Outro fator que demonstram a robustez é a capacidade de aprendizado que a rede apresentou sob diferentes condições impostas nos ensaios, assim como uma baixa média percentual absoluta do erro. A rede neural artificial do tipo NARX mostrou-se satisfatória, quando se compara os valores MAPE obtidos com os valores apresentados na bibliografia.

REFERÊNCIAS

ASUA, E.; ETXEBARRIA, V.; GARCÍA-ARRIBAS, A. Neural network-based micropositioning control of smart shape memory alloy actuators. **Engineering Applications of Artificial Intelligence**, v. 21, n. 5, p. 796-804, 2008. doi: <https://doi.org/10.1016/j.engappai.2007.07.003>

BELLOUARD, Y. Shape memory alloys for microsystems: A review from a material research perspective. **Materials Science and Engineering: A**, v. 481-482, p. 582-589, 2008. doi: 10.1016/j.msea.2007.02.166

BUNDHOO, V.; HASLAM, E.; BIRCH, B.; PARK, E. J. A shape memory alloy-based tendon-driven actuation system for biomimetic artificial fingers, part I: design and evaluation. **Robotica**, v. 27, n. 01, p. 131, 2008. doi: 10.1017/s026357470800458x

BUNDHOO, V.; HASLAM, E.; BIRCH, B.; PARK, E. J. A shape memory alloy-based tendon-driven actuation system for biomimetic artificial fingers, part I: design and evaluation. **Robotica**, v. 27, n. 1, p. 131-146, 2009. doi: 10.1017/S026357470800458X

DA SILVA, M. R. **LEVANTAMENTO E ANÁLISE DAS PERSPECTIVAS DE APLICAÇÕES DAS LIGAS COM MEMÓRIA DE FORMA**. 71º Congresso Anual abmWEEK, 2016. ISBN 1516392X.

DUERIG, T.; PELTON, A.; STÖCKEL, D. An overview of nitinol medical applications. **Materials Science and Engineering: A**, v. 273, p. 149-160, 1999. doi:

DUERIG, T. W. Applications of Shape Memory. **Materials Science Forum**, v. 56-58, p. 679-691, 1991. doi: 10.4028/www.scientific.net/MSF.56-58.679

EL-HADAD, S. H.; IBRAHIM, K. M.; WAGNER, L. Characteristics of Anodized Layer in Investment Cast Ni50Ti50 Shape Memory Alloy. **Journal of Metallurgy**, v. 2014, p. 6, 2014. doi: 10.1155/2014/346328

EMILIAVACA, A. **SMARt MORPHING WING: um protótipo de asa adaptativa acionada por micromolas de liga com memória de forma**. 2016. PPGEM, UFCG

FRENZEL, J.; GEORGE, E. P.; DLOUHY, A.; SOMSEN, C.; WAGNER, M. F. X.; EGGLER, G. Influence of Ni on martensitic phase transformations in NiTi shape memory alloys. **Acta Materialia**, v. 58, n. 9, p. 3444-3458, 2010. doi: 10.1016/j.actamat.2010.02.019

HAYKIN, S. **Redes neurais: princípios e prática**. Bookman Editora, 2007. ISBN 8577800865.

IRWIN, J. D.; WIKAMOWSKI, B. M. **The Industrial Electronics Handbook: Intelligent Systems**: Taylor & Francis 2011.

JUN, Y.; ZONGYUE, B.; LEI, T.; JINGLI, W.; HAIZHANG, L. Characteristics of Transformation and Low-temperature Deformation of Ti-51.1Ni Shape Memory Alloy. **Rare Metal Materials and Engineering**, v. 46, n. 7, p. 1782-1787, 2017. doi: 10.1016/s1875-5372(17)30166-2

KRISHNAN, V. B. Design, fabrication and testing of a shape memory alloy based cryogenic thermal conduction switch. 2004. doi:

LAGOUDAS, D. C. **Shape memory alloys: modeling and engineering applications**. Springer, 2008. ISBN 0387476857.

LUIZ F. TOLEDO, J. Z. G., JUAN M. OXOBY, YING CHEN, AND N´ESTOR O. P´EREZ-ARANCIBIA. System Identification of a NiTi-Based SMA Actuator Using a Modified. 2017. doi:

MACENA, M. C. B.; DE SÁ CATÃO, C. D.; RODRIGUES, R. D. Q. F.; VIEIRA, J. M. F. FIOS ORTODÔNTICOS, PROPRIEDADES MICROESTRUTURAIS E SUAS APLICAÇÕES CLÍNICAS: VISÃO GERAL. **Revista Saúde & Ciência Online**, v. 4, n. 2, p. 90-108, 2015. doi:

MAI, H.; SONG, G.; LIAO, X. Time-delayed dynamic neural network-based model for hysteresis behavior of shape-memory alloys. **Neural Computing and Applications**, v. 27, n. 6, p. 1519-1531, 2016. doi: 10.1007/s00521-015-1950-8

MARSTON, W.; RAZAVI, M. Improvement in Quality of Life After Iliac Vein Stenting in a Prospective Clinical Study of a Nitinol Venous Stent. **Journal of Vascular Surgery: Venous and Lymphatic Disorders**, v. 7, n. 2, p. 300, 2019. doi:

MONTENEGRO, E. D. O. S.; SIMÕES, J. D. B.; ARAÚJO, C. J.; JUNIOR, W. F. D. A.; SILVA, P. C. S. COMPORTAMENTO TÉRMICO E MECÂNICO DE TELAS DE LIGAS COM MEMÓRIA FORMA Ni-Ti OBTIDAS POR FUNDIÇÃO DE PRECISÃO. 2016. doi: 10.20906/cps/con-2016-0264

MORAES, Y. J. O. **Análise dinâmica aplicada ao controle passivo de vibrações em estrutura do tipo pórtico incorporando minimolas superelásticas de nitinol**. 2017. PPGEM, UFCG

NESPOLI, A.; BESSEGHINI, S. A complete thermo-mechanical study of a NiTiCu shape memory alloy wire. **Journal of Thermal Analysis and Calorimetry**, v. 103, n. 3, p. 821-826, 2011. doi: 10.1007/s10973-010-1042-z

NICOLAU, L. F. **Identificação e previsão neural de atuadores com memória de forma na presença de deformação residual significativa**. 2018. PPGEM, UFPB

NIKDEL, N.; NIKDEL, P.; BADAMCHIZADEH, M. A.; HASSANZADEH, I. Using Neural Network Model Predictive Control for Controlling Shape Memory Alloy-Based Manipulator. **IEEE Transactions on Industrial Electronics**, v. 61, n. 3, p. 1394-1401, 2014. doi: 10.1109/TIE.2013.2258292

OLIVEIRA, A. G. **Concepção e análise dinâmica de sistema com controle de mancal adaptativo incorporando molas LMF**. 2017. PPGEM, UFCG

OLIVEIRA, H. **Análise de um Absorvedor Dinâmico Pseudoelástico**. 2014. Dissertação (Mestrado em Engenharia Mecânica). Brasília: Universidade de ...

OTSUKA, K.; WAYMAN, C. **Mechanism of shape memory effect and superelasticity**. 1998.27-49.

PETRINI, L.; MIGLIAVACCA, F. Biomedical Applications of Shape Memory Alloys. **Journal of Metallurgy**, v. 2011, p. 1-15, 2011. doi: 10.1155/2011/501483

QIU, Y.; YOUNG, M. L.; NIE, X. High Strain Rate Compression of Martensitic NiTi Shape Memory Alloy at Different Temperatures. **Metallurgical and Materials Transactions A**, v. 48, n. 2, p. 601-608, 2016. doi: 10.1007/s11661-016-3857-0

RAO, A.; SRINIVASA, A. R.; REDDY, J. N. **Design of shape memory alloy (SMA) actuators**. Springer, 2015. ISBN 9783319031873.

ROSS, N.; CROCKER, A. A generalized theory of martensite crystallography and its application to transformations in steels. **Acta metallurgica**, v. 18, n. 4, p. 405-418, 1970. doi:

SAEDI, S.; SAGHAIAN, S. E.; JAHADAKBAR, A.; SHAYESTEH MOGHADDAM, N.; TAHERI ANDANI, M.; SAGHAIAN, S. M.; LU, Y. C.; ELAHINIA, M.; KARACA, H. E. Shape memory response of porous NiTi shape memory alloys fabricated by selective laser melting. **Journal of Materials Science: Materials in Medicine**, v. 29, n. 4, p. 40, 2018. doi: 10.1007/s10856-018-6044-6

SIMÕES, J. D. B. **FABRICAÇÃO DE COMPONENTES MINIATURIZADOS DE LIGAS COM MEMÓRIA DE FORMA NI-TI USANDO FUNDIÇÃO DE PRECISÃO**. 2016. 239. (Doutor). Universidade Federal de Campina Grande

SOUZA, J. D. S. **Desenvolvimento de uma Garra Robótica Utilizando Molas de Liga com Memória de Forma como Atuador**. 2018. PPGEM, UFPB

SOUZA, R. C. D. **Caracterização termomecânica de atuadores com memória de forma**. 2018. PPGEM, UFPB

STOECKEL, D.; YU, W. Superelastic Ni--Ti Wire. **Wire journal international**, v. 24, n. 3, p. 45-50, 1991. doi:

STRITTMATTER, J.; CLIPA, V.; GHEORGHITA, V.; GÜMPEL, P. Characterization of NiTi Shape Memory Damping Elements designed for Automotive Safety Systems. **Journal of Materials Engineering and Performance**, v. 23, n. 7, p. 2696-2703, 2014. doi: 10.1007/s11665-014-1045-1

THOMPSON, S. A. An overview of nickel–titanium alloys used in dentistry. **International Endodontic Journal**, v. 33, n. 4, p. 297-310, 2000. doi: doi:10.1046/j.1365-2591.2000.00339.x

WANG, H.; SONG, G. Innovative NARX recurrent neural network model for ultra-thin shape memory alloy wire. **Neurocomputing**, v. 134, p. 289-295, 2014. doi: <https://doi.org/10.1016/j.neucom.2013.09.050>

WITKOWSKA, J.; KAMIŃSKI, J.; PŁOCIŃSKI, T.; TARNOWSKI, M.; WIERZCHOŃ, T. Corrosion resistance of NiTi shape memory alloy after hybrid surface treatment using low-temperature plasma. **Vacuum**, v. 137, p. 92-96, 2017. doi: 10.1016/j.vacuum.2016.12.034

YANG, S.; ZHANG, F.; WU, J.; LU, Y.; SHI, Z.; WANG, C.; LIU, X. Superelasticity and shape memory effect in Cu–Al–Mn–V shape memory alloys. **Materials & Design**, v. 115, p. 17-25, 2017. doi: 10.1016/j.matdes.2016.11.035

ZHANG, L.; HE, Z. Y.; TAN, J.; ZHANG, Y. Q.; STOICA, M.; PRASHANTH, K. G.; CORDILL, M. J.; JIANG, Y. H.; ZHOU, R.; ECKERT, J. Rapid fabrication of function-structure-integrated NiTi alloys: Towards a combination of excellent superelasticity and favorable bioactivity. **Intermetallics**, v. 82, p. 1-13, 2017. doi: 10.1016/j.intermet.2016.11.004

APÊNDICE 1

Script da RNA utilizada

```
clear;close all;clc;
%Entradas dos dados
load Training100D.txt;
load Training100DC2.txt;
load Training100DC3.txt;

%Separação dos dados em vetores
time = Training100D(:,1); %tempo
temperature = Training100D(:,4); %temperatura
force = Training100D(:,3); %força
%Dados até o 2° Ciclo
time1 = Training100DC2(:,1); %tempo
temperature1 = Training100DC2(:,4); %temperatura
force1 = Training100DC2(:,3); %força
%Dados até o 3° Ciclo
time2 = Training100DC3(:,1); %tempo
temperature2 = Training100DC3(:,4); %temperatura
force2 = Training100DC3(:,3); %força

%Normalização dos dados
temperature_train_norm = temperatureNorm(temperature1,temperature);
force_train_norm = targetNorm(force1,force);

%Topologia da Rede Neural
NumDelay = 6; %Número de Atrasos
NumNeurons = 14; %Número de Neurônios
NumInputs = NumDelay*2; %Número de Entradas
NumOutputs = 1; %Número de Saídas

%Preparação dos dados de força e temperatura como entradas e alvos
[time_prep,temperature_prep] = timePreparation(time1,temperature1,NumDelay,NumOutputs);
[inputs,target] = dataPreparation(temperature_train_norm,force_train_norm,NumDelay,NumOutputs);
%Divisão dos dados entre treinamento e teste
[train,validation,test] = dividerand([time_prep,temperature_prep,inputs,target],0.8,0,0.2);
%Preparação das variáveis de tempo e temperatura do experimento
time_train = train(1:NumOutputs,:);
temperature_train = train(NumOutputs+1:NumOutputs*2,:);
%Entradas e Alvos
inputs_train = train((NumOutputs*2+1):(NumOutputs*2+NumDelay*2),:);
targets_train = train((NumOutputs*2+NumDelay*2)+1:end,:);
inputs_test = test((NumOutputs*2+1):(NumOutputs*2+NumDelay*2),:);
targets_test = test((NumOutputs*2+NumDelay*2)+1:end,:);
N_train = length(inputs_train);
N_test = length(inputs_test);

%Inicialização dos Pesos
W = rand(NumInputs,NumNeurons); %Pesos da Camada de Interna
Bw = rand(1,NumNeurons); %Pesos dos Bias de Interna
V = rand(NumNeurons,NumOutputs); %Pesos da Camada de Saída
Bv = rand(1,NumOutputs); %Pesos dos Bias de Saída
%Parâmetros do Treinamento
NumEpoch = 1000; %Número Máximo de Épocas
Error_ADM_train = 2.5e-4; %Erro admissível para o treinamento
Error_ADM_test = 1e-4; %Erro admissível para o teste
```

```
%Iniciando o coeficiente de combinação e os hiperparâmetros (Regulação Bayesiana)
mu = 10; alpha = 0.01; beta = 1;
```

```
% Preparação dos Vetores de Erro do Treinamento e do Teste
```

```
Error_Train = zeros(NumEpoch,1);
```

```
Error_Test = zeros(NumEpoch,1);
```

```
%Preparação da figura da evolução dos erros
```

```
figure(1);
```

```
loglog(Error_Train);grid on;hold on;
```

```
% Treinamento da rede
```

```
for m = 1:NumEpoch
```

```
    %Evitando instabilidade devido ao valor de mu muito pequeno ou grande
```

```
    if (mu > 1e20 || mu < 1e-10)
```

```
        disp('Erro devido ao valor do mu');
        break
```

```
    end
```

```
    %Início do Loop de Treinamento: Minimização da Função de Custo
```

```
    weight = [W(:);Bw(:);V(:);Bv(:)]; %Vetor de pesos
```

```
    %Propagação dos dados na rede neural
```

```
    [y_train,J_train] = Propagation(inputs_train,weight,NumInputs,NumNeurons,NumOutputs);
```

```
    [y_test,J_test] = Propagation(inputs_test,weight,NumInputs,NumNeurons,NumOutputs);
```

```
    Error_Train(m) = mean(mean((targets_train - y_train).^2)); %Erro do treinamento
```

```
    Error_Test(m) = mean(mean((targets_test - y_test).^2)); %Erro do teste
```

```
    %Construindo Gráfico da evolução dos erros encontrados
```

```
    plot(m>Error_Train(m),'b*',m>Error_Test(m),'r*');
```

```
    %Testando se o erro foi minimizado ao valor admissível
```

```
    if (Error_Train(m) < Error_ADM_train) && (Error_Test(m) < Error_ADM_test)
```

```
        disp('Erro Admissível foi obtido');
```

```
        break
```

```
    else
```

```
        %Calculando a matriz Hessiana e realizando a correção dos pesos
```

```
        Hessian = 2*beta*(J_train'*J_train) + 2*alpha*mu*eye(length(weight));
```

```
        error = (targets_train - y_train)';
```

```
        dw = Hessian\((2*beta*J_train'*error(:) + 2*alpha*weight);
```

```
        weight_pos = weight - dw;
```

```
        [y_pos,-] = Propagation(inputs_train,weight_pos,NumInputs,NumNeurons,NumOutputs);
```

```
        Error_Pos = mean(mean((targets_train - y_pos).^2));
```

```
        %Se o erro for reduzido devido as mudanças nos pesos estas mudanças são
```

```
        %salvas, senão as correções são descartadas.
```

```
        if Error_Pos <= Error_Train(m)
```

```
            mu = mu/5;
```

```
            weight = weight_pos;
```

```
            gama = length(weight) - 2*alpha*(trace(inv(Hessian)));
```

```
            alpha = gama/(2*(weight'*weight));
```

```
            beta = (N_train - gama)/(2*sum(sum((targets_train - y_pos).^2)));
```

```
            %Reorganizando os vetores de pesos para o armazenamento da configuração
```

```
            %da rede neural e para o processo de propagação
```

```
            W = reshape(weight(1:NumInputs*NumNeurons),[NumInputs,NumNeurons]);
```

```
            Bw =
```

```
reshape(weight(NumInputs*NumNeurons+1:(NumInputs*NumNeurons)+NumNeurons),[1,NumNeurons]);
```

```
            V =
```

```
reshape(weight((NumInputs*NumNeurons)+NumNeurons+1:(NumInputs*NumNeurons)+NumNeurons+(NumNeurons*NumOutputs)),[NumNeurons,NumOutputs]);
```

```
            Bv =
```

```
reshape(weight((NumInputs*NumNeurons)+NumNeurons+(NumNeurons*NumOutputs)+1:end),[1,NumOutputs]);
```

```
        else
```

```

        mu = mu*5;
    end
end
Error_Test(m)
Error_Train(m)
%Construindo Gráfico da evolução dos erros encontrados
loglog(m,Error_Train(m),'b*',m,Error_Test(m),'r*');
pause(0.1)

end

%Informando que o treinamento foi encerrado
disp('Treinamento Encerrado');
% Construindo os arquivos para o armazenamento dos erros
file_ID00 = fopen('Errors_100D.txt','wt');
data_saved = [Error_Train;Error_Test];
fprintf(file_ID00,'%8.20f %8.20fn',data_saved');
%Saving Weights
weights_save = [W(:);Bw(:);V(:);Bv(:)];
file_ID000 = fopen('Weights_100D.txt','wt');
fprintf(file_ID000,'%8.20fn',weights_save');

%Pós-treinamento

%Desnormalização da resposta da rede neural e dos dados do treinamento
response_train_denorm = targetDenorm(y_train,force);
force_train_denorm = targetDenorm(targets_train,force);

%Normalização dos dados
temperature_val_norm = temperatureNorm(temperature2,temperature);
force_val_norm = targetNorm(force2,force);
%Preparação das entradas e da saída
[time_val,temperature_val] = timePreparation(time2,temperature2,NumDelay,NumOutputs);
[inputs_val,targets_val] =
dataPreparation(temperature_val_norm,force_val_norm,NumDelay,NumOutputs);
%Propagação dos dados para a validação
[y_val,~] = Propagation(inputs_val,weight,NumInputs,NumNeurons,NumOutputs);
%Desnormalização da resposta da validação
response_val_denorm = targetDenorm(y_val,force);
force_val_denorm = targetDenorm(targets_val,force);

%Avaliação do treinamento com a validação

disp('Erro Quadrático médio');
EMQ_Treinamento = mean((force_train_denorm - response_train_denorm).^2)
EMQ_Val = mean((force_val_denorm - response_val_denorm).^2)

disp('Erro médio Absoluto');
EMA_train = mean(abs(force_train_denorm - response_train_denorm))
EMA_val = mean(abs(force_val_denorm - response_val_denorm))

disp('Erro médio percentual');
EMP_train = mean((force_train_denorm - response_train_denorm)./force_train_denorm)
EMP_val = mean((force_val_denorm - response_val_denorm)./force_val_denorm)

disp('Erro absoluto médio percentual - MAPE');

```

```
MAPE_train = mean(abs(force_train_denorm - response_train_denorm)./abs(force_train_denorm))
MAPE_val = mean(abs(force_val_denorm - response_val_denorm)./abs(force_val_denorm))
```

%Arquivos do Treinamento

```
data_training = [time_train temperature_train force_train_denorm response_train_denorm];
file_ID01 = fopen('Training_100D.txt','wt');
data_training_format = strcat(repmat('%8.12f ',1,min(size(data_training))),'\n');
fprintf(file_ID01,data_training_format,data_training);
fclose(file_ID01);
```

%Arquivos da Validação

```
data_validation = [time_val temperature_val force_val_denorm response_val_denorm];
file_ID02 = fopen('Validation_100D.txt','wt');
data_validation_format = strcat(repmat('%8.12f ',1,min(size(data_validation))),'\n');
fprintf(file_ID02,data_validation_format,data_validation);
fclose(file_ID02);
```

%Gráficos da Resposta dos Erros

```
figure(2)
loglog(1:m,Error_Train(1:m),'b',1:m,Error_Test(1:m),'r','linewidth',1.5);grid on;
title('Evolução do Erro – Atuador (150%)')
xlabel('Época ')
ylabel('Erro')
legend('Treinamento','Test')
axis([0 250 1e-4 max(Error_Train)])
```

```
%savefig('Evolução do Erro - Atuador (100%)','jpeg','-r600')
```

%Gráficos da Resposta do Treinamento

```
figure(3)
plot(time_train(:,1),force_train_denorm(:,1),'k.',time_train(:,1),response_train_denorm(:,1),'r');grid on;
title('Evolução da Força – Atuador (150%)')
xlabel('Tempo (s)')
ylabel('Força (N)')
legend('Exp','RNA','Location','southeast')
```

```
figure(4)
plot(temperature_train(:,1),force_train_denorm(:,1),'k.',temperature_train(:,1),response_train_denorm(:,1),'r');grid on;
title('Evolução da Histerese – Atuador (150%)')
xlabel('Temperatura (°C)')
ylabel('Força (N)')
legend('Exp','RNA')
```

%Gráficos da Resposta da Validação

```
figure(5)
plot(time_val(:,1),force_val_denorm(:,1),'k.',time_val(:,1),response_val_denorm(:,1),'r');grid on;
title('Evolução da Força – Atuador (150%)')
xlabel('Tempo (s)')
ylabel('Força (N)')
legend('Exp','RNA')
```

```
figure(6)
plot(temperature_val(:,1),force_val_denorm(:,1),'k.',temperature_val(:,1),response_val_denorm(:,1),'r');
grid on;
title('Evolução da Histerese – Atuador (150%)')
xlabel('Temperatura (°C)')
ylabel('Força (N)')
legend('Exp','RNA')
```