

**NATHAN LUAN DUTRA SARMENTO**

**ESTUDO DO COMPORTAMENTO E CONTROLE DE ATUADORES DE LIGA DE  
MEMÓRIA DE FORMA UTILIZANDO REDES NEURAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica - PPGEE, da Universidade Federal da Paraíba - UFPB, como requisito para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Cícero da Rocha Souto

**JOÃO PESSOA**

**2019**

**NATHAN LUAN DUTRA SARMENTO**

**ESTUDO DO COMPORTAMENTO E CONTROLE DE ATUADORES DE LIGA DE  
MEMÓRIA DE FORMA UTILIZANDO REDES NEURAI**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica - PPGEE, da Universidade Federal da Paraíba - UFPB, como requisito para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Cícero da Rocha Souto

**JOÃO PESSOA**

**2019**

**Catálogo na publicação**  
**Seção de Catalogação e Classificação**

S246e Sarmento, Nathan Luan Dutra.

ESTUDO DO COMPORTAMENTO E CONTROLE DE ATUADORES DE LIGA  
DE MEMÓRIA DE FORMA UTILIZANDO REDES NEURAIS / Nathan  
Luan Dutra Sarmento. - João Pessoa, 2019.  
79 f. : il.

Orientação: Cícero da Rocha Souto Souto.  
Dissertação (Mestrado) - UFPB/CEAR.

1. Ligas de Memória de Forma. 2. Filtro de Kalman. 3.  
Realimentação de Resistência Elétrica. 4. Redes Neurais  
Artificiais. 5. Controle Preditivo. I. Souto, Cícero da  
Rocha Souto. II. Título.

UFPB/BC

**UNIVERSIDADE FEDERAL DA PARAÍBA – UFPB**  
**CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS – CEAR**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGE**

A Comissão Examinadora, abaixo assinada, aprova a Dissertação

**ESTUDO DO COMPORTAMENTO E CONTROLE DE ATUADORES DE LIGA DE**  
**MEMÓRIA DE FORMA UTILIZANDO REDES NEURAS**

Elaborado por

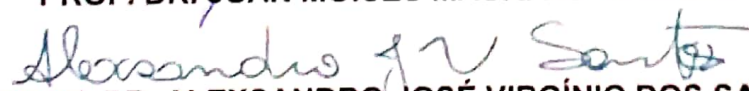
**NATHAN LUAN DUTRA SARMENTO**

como requisito parcial para obtenção do grau de  
**Mestre em Engenharia Elétrica.**

**COMISSÃO EXAMINADORA**

  
**PROF. DR. CÍCERO DA ROCHA SOUTO (Presidente)**

  
**PROF. DR. JUAN MOISÉS MAURICIO VILLANUEVA**

  
**PROF. DR. ALEXSANDRO JOSÉ VIRGÍNIO DOS SANTOS**

João Pessoa/PB, 25 de fevereiro de 2019

*Este trabalho é dedicado à minha família*

# Agradecimentos

Os agradecimentos deste trabalho são direcionados:

- Ao Pai Celestial, pela força e perseverança, pela capacidade e sabedoria;
- À minha esposa Helijane Sarmiento, pelo apoio incondicional ao longo dos anos;
- Ao professor Cícero Souto, pela orientação, confiança, por estar sempre à disposição para qualquer problema que tiver e, além de tudo, pelos conselhos sobre a vida pessoal e profissional que eu levarei para sempre;
- À minha família, pelo apoio, estímulo e por nunca desistirem de mim, não apenas durante esses anos de formação, mas durante toda a minha vida;
- Aos colegas de laboratório, em particular a Zé, Maxsuel e Lucas por toda ajuda e apoio;
- A todos os professores e a todas as pessoas anônimas que, de forma direta ou indireta, contribuíram para a realização deste trabalho.

*“Saruman acredita que apenas um grande poder pode manter o mal sob controle. Mas não foi isso que descobri. Eu descobri que são as coisas pequenas, os feitos diários das pessoas comuns, os simples atos de bondade e amor, que mantém o mal afastado.”*  
*(Gandalf, o Cinzento)*

# Resumo

Ligas de memória de forma são materiais inteligentes e que podem ser utilizados como atuadores em diversas situações. O controle de atuadores de liga de memória de forma, porém, pode ser desafiador devido à não-linearidade e comportamento histerético deste tipo de material. Nesse sentido, o uso de Redes Neurais Artificiais torna-se um artifício interessante em termos de sensoriamento e controle dos atuadores de liga de memória de forma. Foi realizado um estudo com molas feitas de Ligas de Memória de Forma, visando maior compreensão dos fenômenos físicos de transformação de fases para controle desse tipo de atuador. O uso da resistência elétrica como elemento sensor para realimentação foi proposto, e uma Rede Neural Artificial foi projetada para aprendizagem da relação entre a resistência elétrica e força exercida pela mola de Liga de Memória de Forma. Além disso, um circuito de acionamento foi desenvolvido e foi projetado um Filtro de Kalman para estimação das variáveis a serem utilizadas no controle do atuador. Por fim, um método de controle baseado em Redes Neurais foi proposto e seus resultados foram mostrados. O uso de Redes Neurais foi eficiente tanto em termos de sensoriamento quanto em termos de controle. Além disso, a força aplicada pelas molas de Liga de Memória de Forma convergiu de forma satisfatória para os valores de referência no sistema em malha fechada.

**Palavras-chaves:** Ligas de Memória de Forma, Filtro de Kalman, Realimentação de Resistência Elétrica, Redes Neurais Artificiais, Controle Preditivo.



# Abstract

Shape Memory Alloys are intelligent materials and can be used as actuators in many situations. The control of Shape Memory Alloys actuators may be challenging due to the non-linear and hysteretic behavior of this type of material. This way, the use of Artificial Neural Networks is a interesting tool to work as sensor and to implement the control of Shape Memory Alloys actuators. Studies with Shape Memory Alloys springs have been conducted to understand the phase transformation phenomenon in order to implement a control strategy. Electric resistance feedback has been used as sensor element, and an Artificial Neural Network has been developed to learn the relationship between the electric resistance and the force applied by the spring. Besides, an actuation circuit has been developed and an Extended Kalman Filter has been designed to estimate the state variables of the system. Finally, a neural network based predictive control strategy has been proposed and its results have been shown. The use of Artificial Neural Networks were efficient both as sensor and as model into the predictive controller. In addition, the force applied by the Shape Memory Alloy springs has satisfactorily converged to the reference values of force in the closed loop controlled system.

**Keywords:** Shape Memory Alloys, Kalman filter, Electric Resistance Feedback, Artificial Neural Networks, Predictive Control.

# Lista de ilustrações

Figura 1 – Ilustração esquemática das mudanças de fase em LMFs . . . . .	18
Figura 2 – Ilustração esquemática do Efeito de Memória de Forma . . . . .	19
Figura 3 – Exemplo de LMF submetida ao processo de treinamento sob carga mecânica constante . . . . .	20
Figura 4 – Diagrama esquemático do algoritmo do Filtro de Kalman . . . . .	25
Figura 5 – Diagrama esquemático do algoritmo do EKF . . . . .	27
Figura 6 – Neurônio biológico . . . . .	29
Figura 7 – Neurônio artificial - paralelos com o neurônio biológico . . . . .	29
Figura 8 – Funções de Ativação . . . . .	30
Figura 9 – Camadas de uma RNA . . . . .	32
Figura 10 – Diagrama esquemático do processo de treinamento de uma RNA . . . .	32
Figura 11 – Diagrama de blocos de um MCP . . . . .	34
Figura 12 – Diagrama de blocos de um controlador preditivo utilizando RNA . . .	35
Figura 13 – Limitador de corrente usando LM317 . . . . .	37
Figura 14 – Circuito divisor de tensão . . . . .	38
Figura 15 – Sensor de corrente de efeito Hall ACS712 . . . . .	38
Figura 16 – Caracterização e Modelagem da curva característica para sensor ACS712	39
Figura 17 – Diagrama esquemático do circuito de potência projetado . . . . .	40
Figura 18 – Placa de aquisição de dados NI USB-6212 . . . . .	40
Figura 19 – Estrutura com mola de LMF e célula de carga . . . . .	41
Figura 20 – Módulo HX711 para leitura e processamento do sinal da célula de carga	41
Figura 21 – Diagrama de blocos do EKF . . . . .	42
Figura 22 – Diagrama de blocos das saídas e estados do sistema . . . . .	44
Figura 23 – RNAs do tipo <i>feedforward</i> utilizando uma e duas camadas ocultas . . .	48
Figura 24 – RNAs recorrentes utilizando uma e duas camadas ocultas . . . . .	49
Figura 25 – RNAs do tipo <i>feedforward</i> utilizando uma e duas camadas ocultas . . .	51
Figura 26 – Diagrama de blocos do controlador preditivo simplificado . . . . .	52
Figura 27 – Relação <i>Força</i> $\times$ <i>Resistência Elétrica</i> para a mola de LMF em diferentes frequências . . . . .	55
Figura 28 – Relação <i>Força</i> $\times$ <i>Resistência Elétrica</i> para a mola de LMF em diferentes frequências (valores normalizados) . . . . .	56
Figura 29 – Curva <i>Força</i> $\times$ <i>Resistência Elétrica</i> com assíntotas . . . . .	57
Figura 30 – Comparação das curvas de diferentes frequência - Experimento 1 . . . .	58
Figura 31 – Comparação das curvas de diferentes frequência - Experimento 2 . . . .	58
Figura 32 – Comparação das curvas de diferentes frequência - Experimento 3 . . . .	59
Figura 33 – Treinamento de uma RNA do tipo <i>feedforward</i> com uma camada oculta	61

Figura 34 – Treinamento de uma RNA do tipo <i>feedforward</i> com duas camadas ocultas	62
Figura 35 – Treinamento de uma RNA recorrente com uma camada escondida . . .	63
Figura 36 – Treinamento de uma RNA recorrente com duas camadas escondidas . .	64
Figura 37 – Treinamento da RNA do tipo <i>feedforward</i> com uma camada escondida para modelo do controlador preditivo . . . . .	65
Figura 38 – Diagrama de blocos do sistema em malha fechada . . . . .	66
Figura 39 – Controle de força usando controle preditivo baseado em RNA . . . . .	67
Figura 40 – Controle de força usando controle preditivo baseado em RNA . . . . .	68
Figura 41 – Comparação do erro entre a força exercida e o valor de referência da força . . . . .	69

# Lista de tabelas

Tabela 1	–	Classificação dos diferentes tipos de RNAs . . . . .	31
Tabela 2	–	Valores do fator de correção $\alpha$ de acordo com o erro percentual entre força medida e referência . . . . .	53
Tabela 3	–	Valores do MSE para os diferentes tipos de RNAs . . . . .	66

# Lista de abreviaturas e siglas

LMF	<i>Liga de Memória de Forma</i>
PWM	<i>Pulse Width Modulation</i>
RNA	<i>Redes Neurais Artificiais</i>
SME	<i>Shape Memory Effect</i>
MEMS	<i>MicroElectricalMechanical Systems</i>
TWSME	<i>Two Way Shape Memory Effect</i>
EKF	<i>Extended Kalman Filter</i>
DAQ	<i>Data Aquisition System</i>
MPC	<i>Modelo de Controle Preditivo</i>
MSE	<i>Mean Square Error</i>
DAQ	<i>Data Aquisition System</i>
DAQ	<i>Data Aquisition System</i>

# Lista de símbolos

$A_s$	Temperatura inicial da austenita
$A_f$	Temperatura final da austenita
$M_s$	Temperatura inicial da martensita
$M_f$	Temperatura final da martensita
$\sigma_s$	Tensão inicial da desgeminação
$\sigma_f$	Tensão final da desgeminação
$\varepsilon$	Deformação
$x$	Vetor de estados
$z$ ou $y$	Vetor de saídas
$A$	Matriz de estados
$B$	Matriz de entradas
$C$ ou $H$	Matriz de saídas
$D$	Matriz de alimentação
$w$	Ruído do processo
$v$	Ruído de medição
$Q$	Covariância do ruído do processo
$R$	Covariância do ruído de medição
$P$	Matriz de covariância
$K$	Ganho de Kalman
$u$	Entrada do sistema
$\hat{x}$	Vetor de estados estimado
$\hat{x}^-$	Vetor de estados estimado a priori
$\hat{P}$	Matriz de covariância estimada

$\hat{P}^-$	Matriz de covariância estimada a priori
$e$	Erro de estimação
$e^-$	Erro de estimação a priori
$J$	Matriz jacobiana
$\Gamma$	Jacobiano da função de estados em relação ao ruído de processo
$\Lambda$	Jacobiano da função de saída em relação ao ruído de medição
$V_{SMA}$	Tensão sobre o atuador de SMA
$I_{SMA}$	Corrente que circula sobre o atuador de SMA
$R_{SMA}$	Resistência do atuador de SMA
$f_{ant}$	Função $f(x[n], u[n], w[n])$ baseada no próprio estado anterior
$f_{est}$	Função $f(x[n], u[n], w[n])$ baseada nna combinação dos outros estados
$f_{ent}$	Função $f(x[n], u[n], w[n])$ baseada na entrada do sistema
$p$	Matriz de pesos para cálculo de $f(x[n], u[n], w[n])$
$\alpha$	Fator de correção
$I'$	Corrente prevista pelo controlador
$F'$	Força prevista pela rede neural
$F$	Força lida pelo sensor
$\Delta I$	Variação de corrente a ser adicionada à corrente de entrada

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
<b>1.1</b>	<b>Objetivos</b>	<b>16</b>
<b>1.2</b>	<b>Organização do texto</b>	<b>16</b>
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>17</b>
<b>2.1</b>	<b>Ligas de Memória de Forma (LMF)</b>	<b>17</b>
2.1.1	Transformação de Fases em LMFs	18
<b>2.2</b>	<b>Feedback por Resistência Elétrica</b>	<b>20</b>
<b>2.3</b>	<b>Filtro de Kalman</b>	<b>21</b>
2.3.1	Filtro de Kalman Discreto	22
2.3.2	O Filtro de Kalman Discreto - Algoritmo	23
2.3.3	O Filtro Estendido de Kalman	25
<b>2.4</b>	<b>Redes Neurais Artificiais (<i>Artificial Neural Networks</i> - RNA)</b>	<b>28</b>
2.4.1	Redes Neurais Biológicas	28
2.4.2	Redes Neurais Artificiais - RNA	28
2.4.3	Processo de aprendizagem em RNAs	31
<b>2.5</b>	<b>Modelo de Controle Preditivo</b>	<b>33</b>
<b>3</b>	<b>MATERIAIS E MÉTODOS</b>	<b>36</b>
<b>3.1</b>	<b>Circuito de Acionamento</b>	<b>36</b>
<b>3.2</b>	<b>Protótipo do Estudo de Frequências com Mola</b>	<b>41</b>
<b>3.3</b>	<b>Implementação do Filtro Estendido de Kalman</b>	<b>42</b>
<b>3.4</b>	<b>Redes Neurais</b>	<b>47</b>
3.4.1	Rede Neural como Sensor de Resistência Elétrica	47
3.4.2	Rede Neural como Modelo	50
<b>3.5</b>	<b>Implementação do Controle Preditivo</b>	<b>51</b>
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>54</b>
<b>4.1</b>	<b>Interpretação das curvas de Resistência Elétrica × Força</b>	<b>54</b>
<b>4.2</b>	<b>Escolha da frequência do sinal PWM</b>	<b>58</b>
<b>4.3</b>	<b>Treinamento da Rede Neural</b>	<b>59</b>
4.3.1	Rede Neural como Sensor	60
4.3.2	Rede Neural como Modelo para o Controlador Preditivo	60
<b>4.4</b>	<b>Controlador Preditivo</b>	<b>66</b>
<b>5</b>	<b>CONCLUSÕES</b>	<b>71</b>



**REFERÊNCIAS . . . . . 73**

# 1 Introdução

Ligas de memória de forma - LMF- são ligas metálicas que demonstram a capacidade de recuperar sua forma original após uma deformação “pseudoplástica”, ou desenvolver forças consideráveis de restituição ao restringir sua recuperação, após a imposição de um campo de temperatura e/ou tensões, por meio de transformações de fase induzidas no material [SILVA, 2015]. Recentemente, o uso de LMF como atuadores tem atraído bastante interesse, devido a características como confiabilidade, alta densidade energética, simplicidade de projeto e operação silenciosa.

Apesar do potencial de uso de LMF como atuadores nos mais diversos campos de aplicação, são encontradas dificuldades no controle desse tipo de atuador, tais como a baixa eficiência energética, não-linearidade e comportamento histerético desse tipo de material e resposta lenta em comparação com atuadores convencionais [PAN et al., 2017]. Estas características devem ser consideradas, uma vez que podem levar desde uma performance indesejada até uma dinâmica instável no sistema.

Além disso, o fenômeno de memória de forma é um fenômeno termomecânico, consequência de uma mudança na estrutura cristalina entre uma fase de baixa temperatura, conhecida como martensita, e uma fase de alta temperatura, conhecida como austenita [LI; TIAN, 2018]. Porém, o aquecimento por efeito Joule é bastante utilizado para lidar com LMFs, de forma que a relação entre deformação do material e corrente elétrica aplicada torna-se indireta, uma vez que o aquecimento é regido por diversas equações da termodinâmica. Ainda, deve ser levado em consideração que a atuação por PWM é prática e eficiente em termos de controle e automação e, por isso, bastante utilizada em diversos trabalhos com LMFs [ZHANG; XU; YANG, 2017; LIAO, 2016; PAI; RIEPOLD; TRACHTLER, 2016], porém pode causar efeitos indesejados em termos termoeletrônicos.

Um último desafio a ser considerado ao se trabalhar com LMFs é a instrumentação eletrônica do sistema, uma vez que a temperatura ao longo de um fio ou mola de LMF pode não ser uniforme devido a diversos motivos. Dessa forma, muitas vezes um único sensor de temperatura, por exemplo, pode não ser suficiente para entender o comportamento do atuador. Além disso, um maior número de sensores para realização do controle desse tipo de sistema pode tornar o projeto oneroso e inviável.

Neste contexto, este trabalho traz uma maior compreensão sobre o uso de ligas de memória de forma bem como o estudo de soluções para as dificuldades acima expostas.

Uma primeira abordagem a ser considerada é como o uso de atuação por PWM pode influenciar o aquecimento por efeito Joule, e através deste estudo buscar as melhores características possíveis para o sinal de controle. Em segundo lugar, é proposto

a utilização da resistência elétrica dos atuadores de LMF como elemento sensor para o sistema. A medição de resistência elétrica é relativamente mais simples e menos ruidosa que a leitura de temperatura. Além disso, o uso da resistência elétrica pode evitar o problema da distribuição desuniforme de temperatura ao longo do atuador de LMF, simplificando a instrumentação eletrônica do sistema. Por fim, para lidar com os problemas de não-linearidade dos materiais, são utilizadas Redes Neurais Artificiais - RNAs. As RNAs são capazes de aprender comportamentos não-lineares através de seu algoritmo de aprendizado e, portanto, podem lidar de forma mais natural com as características das Ligas de Memória de Forma. Serão utilizadas Redes Neurais para fins de sensoramento e realimentação do sistema, bem como para fins de controle de atuadores de LMF.

## 1.1 Objetivos

Esta dissertação tem como objetivo geral desenvolver uma estratégia de controle para atuadores de Liga de Memória de Forma, baseando-se no *feedback* de resistência elétrica e em Redes Neurais Artificiais. Para alcançar o objetivo principal, alguns objetivos específicos são propostos:

1. Revisão bibliográfica de Ligas de Memória de Forma para melhor entendimento do princípio de funcionamento dos atuadores;
2. Estudo da influência da modulação por largura de pulso para aquecimento por efeito Joule;
3. Desenvolvimento da instrumentação eletrônica do sistema;
4. Estudo do comportamento resistivo de atuadores de LMF e projeto de uma rede neural artificial para atuar como sensor para *feedback* de resistência elétrica;
5. Estudo de técnicas de controle de atuadores de LMF utilizando *feedback* de resistência elétrica, e projeto de um controlador para uma mola de LMF.

## 1.2 Organização do texto

No Capítulo 2, é feita uma breve revisão bibliográfica sobre os principais pontos a serem abordados no texto. No Capítulo 3 são mostrados os materiais utilizados e montagens feitas, assim como as estratégias utilizadas para obtenção de curvas e treinamento da rede neural. No Capítulo 4 são mostrados os gráficos levantados dos experimentos e uma breve discussão sobre os mesmos. No Capítulo 5 é mostrada uma breve síntese do trabalho e são manifestadas ideias para possíveis trabalhos futuros.

## 2 Revisão Bibliográfica

Nesse capítulo será apresentada uma revisão bibliográfica sobre os materiais e teorias utilizadas para desenvolvimento do projeto.

### 2.1 Ligas de Memória de Forma (LMF)

Ligas de memória de forma - LMF - são ligas metálicas que demonstram a capacidade de recuperar sua forma original após uma deformação “pseudoplástica”, ou desenvolver forças consideráveis de restituição ao restringir sua recuperação, após a imposição de um campo de temperatura e/ou tensões, por meio de transformações de fase induzidas no material [SILVA, 2015]. Este fenômeno de transformação é conhecido como efeito de memória de forma (*Shape Memory Effect* - SME) [JANI et al., 2014]. Estas ligas foram inicialmente descobertas por Arne Ölander, em 1932 [ÖLANDER, 1932], e o termo “memória de forma” foi inicialmente usado por Vernon em 1941 para seu material polimérico dental.

Uma nova perspectiva sobre materiais com memória de forma veio com a descoberta da liga de níquel e titânio NiTi por Buehler e sua equipe, enquanto investigavam materiais úteis para proteção contra aquecimento. Percebeu-se que esta liga, além de outras propriedades mecânicas, possuía a capacidade de recuperar sua forma. Este material ficou, então, conhecido como nitinol, devido à composição química da liga (NiTi) e seu local de descobrimento, o Laboratório de Artilharia Naval (*Naval Ordnance Laboratory* - NOL) [BUEHLER; GILFRICH; WILEY, 1963].

Desde a descoberta inicial do nitinol, em 1963, diversas outras ligas foram desenvolvidas, cada uma com suas próprias características. Por exemplo, a adição de cobalto ou ferro à liga de NiTi causou uma drástica redução nas temperaturas de transformação, inspirando a criação da primeira LMF comercializável no mundo, a Cryofit. Em 1978, Melton e Mercier mostraram que a adição de cobre à liga de NiTi não muda as temperaturas de transformação de fase consideravelmente, mas estreita a curva de histerese. Outras ligas tais como NiTiNb, FeMnSi, CuAlNi e CuZnAl podem ser encontradas no comércio, embora as ligas de NiTi ainda sejam preferidas para a maioria das aplicações.


A demanda para o uso de LMFs tem crescido em diversas áreas da engenharia e ciência, tais como em aplicações industriais [WU; SHETCKY, 2000; ZIDER; KRUMME, 1988; HAUTCOEUR; EBERTHARDT, 1997], estruturas e compostos [FURUYA, 1996], indústria automotiva [BUTERA; CODA; VERGANI, 2007; SHAPE... , 1990], indústria aeroespacial [BIL; MASSEY; ABDULLAH, 2013; HARTL; LAGOUDAS, 2007; HUMBE-

ECK, 1999; SCHETKY, 1991], sistemas microeletromecânicos (*MicroElectroMechanical Systems* - MEMS) [HUMBEECK, 1999; SUN et al., 2012; KOHL, 2010; KAHN; HUFF; HEUER, 1998; FUJITA; TOSHIYOSHI, 1998], robótica [KHEIRIKHAH; RABIEE; EDALAT, 2011; FURUYA; SHIMADA, 1991; SREEKUMAR et al., 2007], engenharia biomédica [HUMBEECK, 1999; SUN et al., 2012; MORGAN, 2004; DUEIRIG; PELTON; STÖCKEL, 1999], entre outros.

### 2.1.1 Transformação de Fases em LMFs

Dentro de uma faixa de temperatura, um material que apresenta memória de forma possui duas fases, com diferentes estruturas cristalinas e propriedades. Estas fases são denominadas como *austenita* e *martensita*. A austenita é presente em altas temperaturas e apresenta estrutura cristalina cúbica. A martensita, por sua vez, é presente em baixas temperaturas e possui estrutura cristalina tetragonal, ortorômbica ou monoclinica. Cada cristal da martensita formada pode ter uma diferente orientação, chamada variante. Normalmente, quando o material está na fase martensita, possui variantes randômicas, estando em um estado chamado *martensita geminada*. Porém, ao se aplicar uma carga mecânica à liga, algumas das variantes são orientadas e há, assim, uma variante dominante. A este estado denomina-se *martensita desgeminada*. Na martensita desgeminada, portanto, há uma deformação macroscópica na própria estrutura da liga. A ideia das transformações de fase é mostrada, esquematicamente, na Figura 1. A transformação de fases de austenita para martensita e vice-versa é a base para o comportamento único das LMFs.


Figura 1 – Ilustração esquemática das mudanças de fase em LMFs



Resumidamente, no processo de “desgeminção”, a deformação que o material sofre permanece mesmo após a retirada da carga mecânica. O aquecimento do material, entretanto, resulta na transformação de fase de martensita desgeminada para austenita e

leva a uma completa recuperação da forma original. Resfriar o material leva a uma completa transformação da fase austenita para a fase martensita geminada, sem aparente mudança de forma. Este processo é conhecido como Efeito de Memória de Forma (*Shape Memory Effect* - SME). Neste processo, a temperatura de início da austenita ( $A_s$ ) é a temperatura na qual começa o processo de transformação de martensita para austenita, e temperatura final da austenita ( $A_f$ ) é a temperatura na qual essa transformação se encerra. Durante o processo de resfriamento, por sua vez, a transformação começa a se reverter na temperatura inicial de martensita ( $M_s$ ) e se encerra na temperatura final de martensita ( $M_f$ ) [JANI et al., 2014]. Ainda, denominam-se as tensões de início da desgeminção e de final da desgeminção por  $\sigma_s$  e  $\sigma_f$ , respectivamente. Por fim, uma importante variável no estudo do comportamento de LMFs é a deformação, que indica o quanto as dimensões da LMF mudam ao longo do processo, e é representada por  $\varepsilon$ . Na Figura 2 é mostrado um esquema do SME.

Figura 2 – Ilustração esquemática do Efeito de Memória de Forma

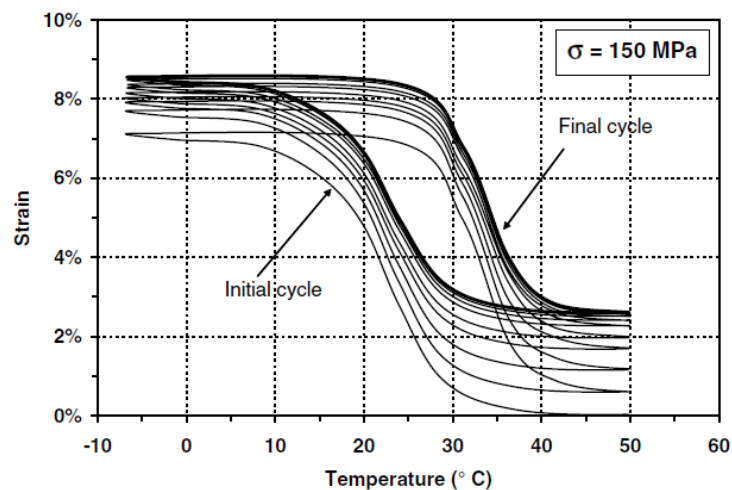


Na Figura 2, o processo de A para B corresponde ao resfriamento com transformação de fase de austenita para martensita. No processo de B para C, há a desgeminção da LMF em martensita, formando assim a martensita desgeminada. No processo de C para D, há a retirada da tensão mecânica inicialmente aplicada para o processo de desgeminção. A retirada da carga mecânica, porém, não implica no retorno à forma original, fato que pode ser observado pela deformação residual que se mantém. No processo de D para E, há um aquecimento, até que a liga chegue à temperatura  $A_s$ . No processo de E para A, quando o aquecimento atinge  $A_f$ , há a transformação de fase de martensita para austenita, conjuntamente com a recuperação da forma original, conforme pode ser visto no eixo da deformação. Normalmente, o comportamento de LMFs é descrito pelas curvas de Deformação  $\times$  Temperatura ou Tensão  $\times$  Temperatura.

A histerese é um fenômeno importante a ser considerado neste tipo de material. Histerese é uma medida da diferença nas temperaturas de transição entre aquecimento e resfriamento, e geralmente é definida pela diferença entre as temperaturas nas quais o material está 50% na fase austenita (durante o aquecimento) e 50% na fase martensita (durante o resfriamento) [BUEHLER; WANG, 1968]. Esta propriedade é importante e requer consideração na hora de escolher uma LMF para determinada aplicação.

Algumas vezes, uma LMF pode exibir transformações de forma repetitivas quando submetida a um ciclo térmico. Este comportamento é conhecido como *Two Way Shape Memory Effect* - TWSME. O TWSME pode ser observado em uma LMF que sofreu, de forma repetitiva, ciclagem térmica ao longo de um caminho específico. A este processo denomina-se *treinamento*. Quando uma LMF está treinada, seu ciclo histerético estabiliza, permitindo o uso de ferramentas computacionais para estudo de seu comportamento. Um exemplo de material que foi submetido ao processo de treinamento é mostrado na Figura 3.

Figura 3 – Exemplo de LMF submetida ao processo de treinamento sob carga mecânica constante



## 2.2 Feedback por Resistência Elétrica

A resistência elétrica é a capacidade de um corpo qualquer se opor à passagem de corrente elétrica mesmo quando existe uma diferença de potencial aplicada. A resistência elétrica de um objeto, por sua vez, depende, primariamente, do material do qual é feito este objeto e de sua forma. Em LMFs, embora a composição química do material permaneça a mesma ao longo dos ciclos de ativação, as mudanças de fases fazem com que a resistividade do material seja alterada, mudando, assim, sua resistência elétrica.

Um desafio que tem sido encontrado ao utilizar-se atuadores de LMF é realizar o controle de deformação através do *feedback* de alguma variável do sistema. O *feedback* através de posição é o mais utilizado, mas possui a desvantagem de seu alto custo. O

*feedback* de temperatura também tem sido estudado, mas tem se mostrado pouco prático, devido à dificuldade de medir, com precisão, o valor de temperatura ao longo de um atuador que se encontra em ambiente aberto. Nesse sentido, a relação entre variação de resistência elétrica e deformação em um atuador de LMF durante as transformações de fase é determinística e repetitiva em alguns âmbitos [MA GANGBING SONG, 2003], especialmente devido ao fato de que sua resistividade depende diretamente da fração de martensita no material. Dessa forma, o *feedback* de resistência elétrica pode substituir, por exemplo, o sensor de posição.

Diversos estudos foram realizados para compreender o comportamento da variação de resistência elétrica em LMFs. Em [ZHANG; YIN; ZHU, 2013] é feito um estudo e proposto um modelo de atuação para músculos artificiais utilizando LMFs baseados em *feedback* de resistência elétrica. Em [CUI; SONG; LI, 2010; NOVÁK et al., 2008] modelos matemáticos são propostos para descrever a relação entre resistência elétrica e deformação em fios de LMF. Em geral, essas relações são não-lineares e dependem de diversos fatores, tornando os modelos pouco práticos em termos de controle e processamento e exigindo estratégias mais complexas para utilização destes materiais. Por exemplo, em [SCHIEDECK; MOJRZISCH, 2011] é desenvolvida uma estratégia de controle que baseia-se no gradiente da variação de resistência elétrica para controle do aquecimento de atuadores de LMF.

Neste sentido, o uso de Redes Neurais Artificiais mostra-se como uma abordagem interessante para a implementação de controle por *feedback* de resistência elétrica. As redes neurais conseguem aprender comportamentos não-lineares, bem como entender a histerese típica dos materiais de LMF. Por exemplo, em [MA GANGBING SONG, 2003] é realizado o controle de posição de um atuador de LMF por *feedback* de resistência elétrica utilizando redes neurais para aprendizado do comportamento de variação de resistência elétrica. Neste trabalho, será utilizada uma Rede Neural Artificial para aprendizado do padrão de variação de resistência elétrica e posterior controle dos atuadores de LMF através do *feedback* de resistência elétrica.

## 2.3 Filtro de Kalman

O filtro de Kalman foi inicialmente apresentado por Rudolf E. Kalman em seu artigo *A New Approach to Linear Filtering and Prediction Problems*, em 1960 [KALMAN, 1960]. Trata-se de uma ferramenta que pode estimar as variáveis de uma vasta gama de processos. Basicamente, trata-se de um filtro recursivo que estima os estados de um sistema dinâmico linear a partir de uma série de medições ruidosas.



### 2.3.1 Filtro de Kalman Discreto

Na engenharia de controle, uma representação em espaço de estados é um modelo matemático de um sistema físico composto de um conjunto de variáveis de entrada, de saída e de estado relacionadas entre si por meio de equações diferenciais de primeira ordem. Para abstrair-se do número de entradas, saídas e estados, as variáveis são expressas em vetores e as equações diferenciais e algébricas são escritas na forma matricial (esta forma é possível somente quando o sistema dinâmico é linear e invariante no tempo). A representação em espaço de estados (também conhecida como “abordagem no domínio do tempo”) fornece uma maneira prática e compacta para modelar e analisar sistemas com múltiplas entradas e saídas [HENDERSON, 2010].

A representação mais geral de sistemas invariantes no tempo, com  $p$  entradas,  $q$  saídas e  $n$  variáveis de estado, em espaço de estados, é dada pela da seguinte forma:

$$\begin{aligned}\dot{x} &= Ax(t) + Bx(t) \\ y(t) &= Cx(t) + Du(t)\end{aligned}\tag{2.1}$$

Onde:

$x(\cdot)$  é chamado vetor de estados,  $x(t) \in \mathbb{R}^n$

$y(\cdot)$  é chamado vetor de saídas,  $y(t) \in \mathbb{R}^q$

$u(\cdot)$  é chamado vetor de entradas,  $u(t) \in \mathbb{R}^p$

$A$  é a matriz de estados,  $\dim[A] = n \times n$

$B$  é a matriz de entradas,  $\dim[B] = n \times p$

$C$  é a matriz de saídas,  $\dim[C] = q \times n$

$D$  é a matriz de alimentação,  $\dim[D] = q \times p$

$\dot{x} = \frac{dx(t)}{dt}$

A Equação 2.1 é a representação em espaço de estados em tempo contínuo. Para o domínio discreto, tem-se a seguinte representação, onde a derivada do vetor de estados torna-se a predição dos estados na próxima iteração:

$$\begin{aligned}x(k+1) &= Ax(k) + Bx(k) \\ y(k) &= Cx(k) + Du(k)\end{aligned}\tag{2.2}$$

Na maioria das aplicações, a matriz de alimentação  $D$  pode ser considerada nula.

Um problema básico nos sistemas de controle, conhecido como problema do projeto do observador (*Observer Design Problem*), é determinar os estados de um sistema tendo acesso apenas às suas saídas. A resolução deste problema baseia-se no modelo de espaço de estados. Neste novo modelo, representa-se a saída do sistema como  $z$  ao invés de  $y$ , indicando que a saída é, na verdade, a leitura de um sensor usado para tal fim, e a matriz

de saídas  $C$  é representada por  $H$ . Além disso, os índices subscritos indicam a iteração da variável no processo. Assim, tem-se novas equações que representam o espaço de estados deste sistema:

$$x_k = Ax_{k-1} + Bx_k + w_{k-1} \quad (2.3)$$

$$z_k = Hx_k + v_k \quad (2.4)$$

Os termos  $w_k$  e  $v_k$  são variáveis aleatórias que representam os ruídos de processo e medição, respectivamente. Obviamente, no mundo real, estes ruídos estão presentes na maioria dos sistemas. Por exemplo, cada sensor tem uma determinada faixa de operação, e à medida que as leituras se aproximam dos limites do sensor, o sinal começa a se degradar. Além disso, uma porção de ruído é adicionado ao sinal através do sensor e dos circuitos elétricos.

Um outro problema a ser considerado é que os estados do sistema são desconhecidos, uma vez que se tem acesso apenas às leituras ruidosas dos sensores. Assim, os modelos apenas podem dar uma estimativa do estado real. Obviamente, essa dificuldade se agrava quando se considera que nem sempre esses modelos são previsíveis.

Neste contexto, o Filtro de Kalman entra como uma importante ferramenta para lidar com o problema do Observador de Estados. Essencialmente, o Filtro de Kalman é um conjunto de equações matemáticas que implementam um estimador de estados baseado em predição e correção, que é ótimo no sentido que minimiza a covariância do erro estimado.

### 2.3.2 O Filtro de Kalman Discreto - Algoritmo

Tomando como base as equações 2.3 e 2.4, nas quais  $w_k$  e  $v_k$  representam os ruídos de processo e medição. É assumido que estes ruídos são independentes entre si, brancos e possuem distribuição normal, ou seja:

$$\begin{aligned} p(w) &\sim N(0, Q) \\ p(v) &\sim N(0, R) \end{aligned} \quad (2.5)$$

Onde  $Q$  é a *covariância do ruído de processo* e  $R$  é a *covariância do ruído de medição*. Define-se  $P$  como a covariância do erro e  $K$  como o um ganho, denominado *Ganho de Kalman*, que será utilizado no algoritmo de Kalman. Ainda, define-se variáveis *a priori* como variáveis estimadas na iteração  $k$  a partir do processo anterior, e define-se variáveis *a posteriori* como variáveis estimadas na iteração  $k$  a partir da medição dos sensores,

$z_k$ . Assim, definem-se  $x^-$ ,  $\hat{x}$ ,  $P^-$  e  $\hat{P}$  como os estados *a priori*, os estados *a posteriori*, a covariância do erro *a priori* e a covariância do erro *a posteriori*, respectivamente.

Os erros podem ser encontrados da seguinte forma:

$$\begin{aligned} e_k^- &\equiv x_k - \hat{x}_k^- \\ e_k &\equiv x_k - \hat{x}_k \end{aligned} \quad (2.6)$$

A covariância dos erros *a priori* e *a posteriori* é definida da seguinte forma:

$$P_k^- = E[e_k^- e_k^{-T}] \quad (2.7)$$

$$P_k = E[e_k e_k^T] \quad (2.8)$$

O filtro de Kalman estima um processo em duas frentes: o processo de *Predição* e o processo de *Correção*. As equações utilizadas no processo de predição são mostradas nas equações 2.9 e 2.10.

$$\hat{x}_k^- = A\hat{x}_{k-1} + Bu_k \quad (2.9)$$

$$\hat{P}_k^- = AP_{k-1}A^T + Q \quad (2.10)$$

Já as equações utilizadas no processo de correção são mostradas nas equações 2.11, 2.12 e 2.13:

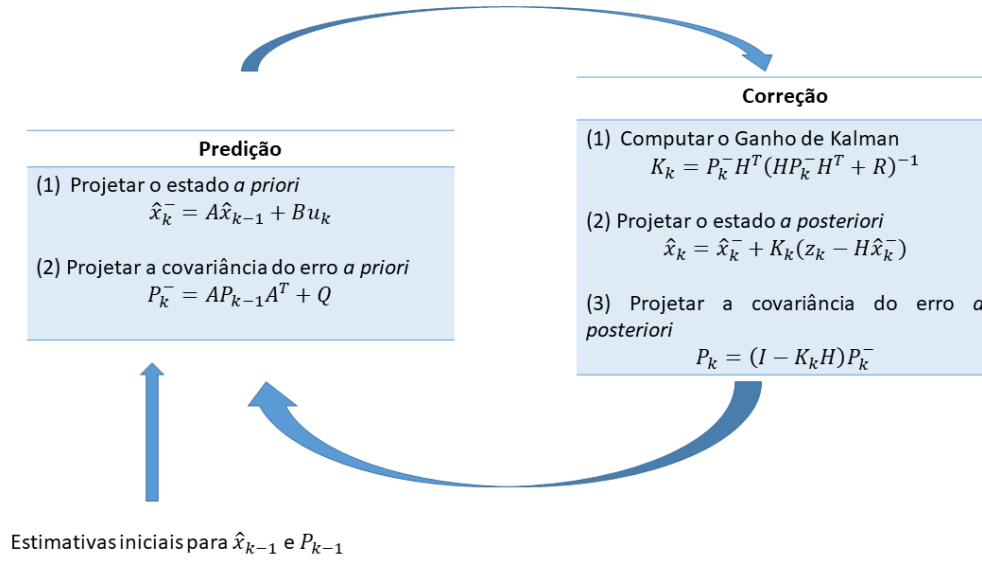
$$K_k = P_k^- H^T (H P_k^- H^T + R)^{-1} \quad (2.11)$$

$$\hat{x}_k = \hat{x}_k^- + K(z_k - H\hat{x}_k^-) \quad (2.12)$$

$$P_k = (I - K_k H) P_k^- \quad (2.13)$$

Deve-se fornecer ao algoritmo valores iniciais para os estados ( $\hat{x}_{k-1}$ ) e para a covariância dos erros ( $P_{k-1}$ ). Assim, o processo iterativo do Filtro de Kalman pode ser resumido na Figura 4

Figura 4 – Diagrama esquemático do algoritmo do Filtro de Kalman



As matrizes  $Q$  e  $R$ , em geral, são constantes, e são projetadas a partir dos ruídos estimados no sistema e nos sensores. A diferença  $(z_k - H\hat{x}_k^-)$  na Equação 2.12 é chamada de inovação de medição, ou residual, e reflete a discrepância entre a predição da medição  $H\hat{x}_k^-$  e a medição atual  $z_k$ . Além disso, à medida que a covariância do erro de medição  $R$  se aproxima de zero, a medição atual  $z_k$  adquire maior peso em relação a predição da medição  $H\hat{x}_k^-$ , enquanto que à medida que a covariância do erro estimado se aproxima de zero,  $z_k$  adquire menor peso em relação à  $H\hat{x}_k^-$ .

A natureza recursiva do Filtro de Kalman é uma das vantagens de seu uso, tornando aplicações práticas do mesmo mais factíveis que, por exemplo, o filtro de Wiener.

### 2.3.3 O Filtro Estendido de Kalman

As aplicações mais comuns do Filtro de Kalman para sistemas não-lineares são na forma do Filtro de Kalman Estendido (*Extended Kalman Filter* - EKF) [JAZWINSKI, 2007]. A estimação de sistemas não-lineares é extremamente importante, visto que a maioria dos sistemas na engenharia são desse tipo. O EKF simplesmente lineariza todas as transformações não-lineares e substitui as transformações lineares do Filtro de Kalman por matrizes jacobianas.

Assim, as equações 2.3 e 2.4, utilizadas para o Filtro de Kalman, são agora substituídas pelas equações 2.14 e 2.15, onde  $f$  e  $h$  são funções não-lineares que descrevem a

relação entre o estado atual e a saída do sistema com os estados anteriores, entradas e ruídos de processo e medição.

$$x_k = f(x_{k-1}, u_k, w_{k-1}) \quad (2.14)$$

$$z_k = h(x_k, v_k) \quad (2.15)$$

A matriz jacobiana, ou simplesmente *jacobiano*, é a matriz formada pelas derivadas parciais de primeira ordem de uma função vetorial. Suponha uma função  $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$  que leva um vetor de entrada  $x \in \mathbb{R}^n$  a um vetor de saída  $f(x) \in \mathbb{R}^m$ . A matriz jacobiana  $J$  da função  $f$  é definida da seguinte forma:

$$J = \begin{bmatrix} \frac{\partial f}{\partial x_1} & \cdots & \frac{\partial f}{\partial x_n} \end{bmatrix} = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \cdots & \frac{\partial f_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial f_m}{\partial x_1} & \cdots & \frac{\partial f_m}{\partial x_n} \end{bmatrix} \quad (2.16)$$

O jacobiano é importante porque se a função  $f$  é diferenciável em um ponto  $x$ , então o jacobiano define um mapa linear  $\mathbb{R}^n \rightarrow \mathbb{R}^m$ , que é a melhor aproximação linear da função  $f$  em torno do ponto  $x$ . Dessa forma, através do jacobiano, pode-se linearizar um sistema não-linear, iteração por iteração, para aplicação do Filtro de Kalman, desde que as funções de  $f$  e  $h$ , descritas nas equações 2.14 e 2.15 possuam derivadas parciais naquele ponto de operação.

Assim, a partir da Equação 2.16, pode-se linearizar as equações 2.14 e 2.15 para aplicá-las ao Filtro de Kalman. Inicialmente, denominam-se as matrizes  $F$ ,  $H$ ,  $\Gamma$  e  $\Lambda$  como os seguintes jacobianos:

$$F = \frac{\partial f(\hat{x}_{k-1}, u_k, w_k)}{\partial x} \quad (2.17)$$

$$H = \frac{\partial h(\tilde{x}_k, v_k)}{\partial x} \quad (2.18)$$

$$\Gamma = \frac{\partial f(\hat{x}_{k-1}, u_k, w_k)}{\partial w} \quad (2.19)$$

$$\Lambda = \frac{\partial h(\tilde{x}_k, v_k)}{\partial v} \quad (2.20)$$

Onde  $\tilde{x}$  é o estado estimado sem considerar os ruídos de processo e medição. A partir das equações 2.17, 2.18, 2.19 e 2.20, pode-se reescrever o algoritmo do Filtro de Kalman.

As equações do processo de medição para o EKF são descritas nas equações 2.21 e 2.22.

$$\hat{x}_k^- = f(\hat{x}_{k-1}, u_k, 0) \quad (2.21)$$

$$P_k^- = F_k P_{k-1} F_k^T + \Gamma_k Q_{k-1} \Gamma_k^T \quad (2.22)$$

As equações do processo de correção para o EKF são descritas nas equações 2.23, 2.24 e 2.25.

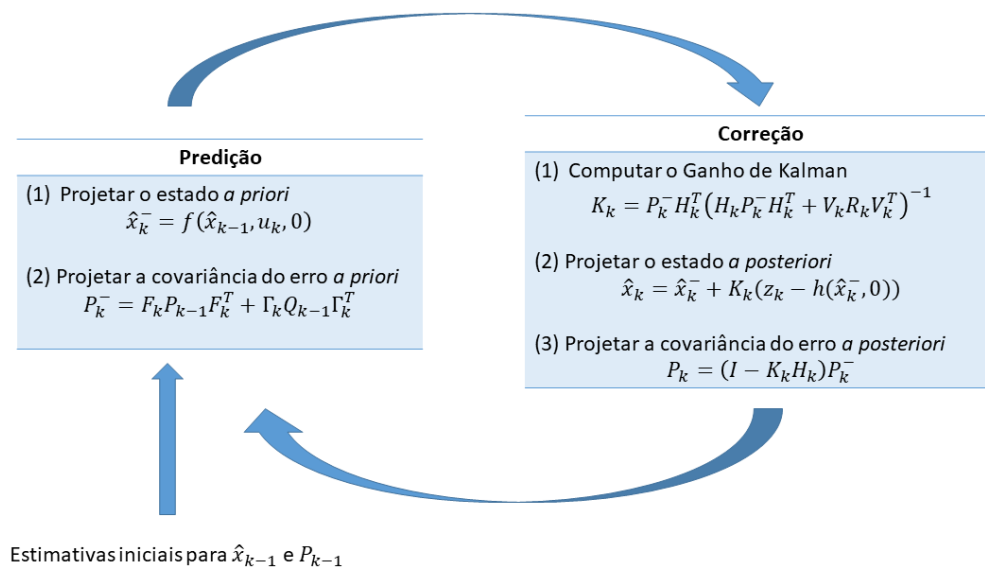
$$K_k = P_k^- H_k^T (H_k P_k^- H_k^T + V_k R_k V_k^T)^{-1} \quad (2.23)$$

$$\hat{x}_k = \hat{x}_k^- + K_k (z_k - h(\hat{x}_k^-, 0)) \quad (2.24)$$

$$P_k = (I - K_k H_k) P_k^- \quad (2.25)$$

Deve-se fornecer ao algoritmo valores iniciais para os estados ( $\hat{x}_{k-1}$ ) e para a covariância dos erros ( $P_{k-1}$ ). Assim, o processo iterativo do EKF pode ser resumido na Figura 5.

Figura 5 – Diagrama esquemático do algoritmo do EKF



## 2.4 Redes Neurais Artificiais (*Artificial Neural Networks* - RNA)

Redes Neurais Artificiais, ou simplesmente RNA (*Artificial Neural Networks*), são sistemas computacionais inspirados nas redes neurais biológicas que compõem o cérebro humano. Estes sistemas “aprendem” tarefas baseados em observação de comportamentos e exemplos. O processo de aprendizagem, para uma RNA, significa melhorar sua performance progressivamente. O objetivo inicial do uso de RNAs era resolver problemas da mesma forma que o cérebro humano faria. Ao longo do tempo, porém, a atenção foi voltada para alcançar determinadas habilidades mentais específicas. Desde então, RNAs tem sido utilizadas em diversas áreas, tais como visão computacional, reconhecimento de fala, aprendizado de padrões, redes sociais, video games, medicina, entre outras.

### 2.4.1 Redes Neurais Biológicas

Os neurônios são células nervosas, que desempenham o papel de conduzir os impulsos nervosos. Estas células especializadas são, portanto, as unidades básicas do sistema que processa as informações e estímulos no corpo humano. O neurônio pode ser considerado a unidade básica da estrutura do cérebro e do sistema nervoso. Há cerca de 86 bilhões de neurônios no sistema nervoso humano [HAYKIN, 2001].

Na Figura 6 é mostrado um neurônio e seus componentes. Dentre os diversos componentes de um neurônio, destacam-se, a nível de entendimento do funcionamento das redes neurais, o **dendrito**, o **corpo celular** e o **axônio**. Os dendritos recebem sinais elétricos de diversas fontes, que são então transmitidos ao corpo celular. O corpo celular, então, acumula os diversos sinais que chegam através dos dendritos. Quando o sinal acumulado ultrapassa um certo limiar, o *threshold*, um pulso elétrico é transmitido a outros neurônios através do axônio. Além disso, o axônio pode transferir informação a outros tipos de células com o intuito de controlá-las [KRIESEL, 2005].

Um processo importante na transmissão de informação pelos neurônios é o entendimento da sinapse. A sinapse é o ponto de interconexão de um neurônio com outros neurônios. A transmissão do sinal via sinapse pode ser feita eletricamente ou quimicamente, e a quantidade de sinal transmitido depende da força das conexões (pesos sinápticos).

### 2.4.2 Redes Neurais Artificiais - RNA

Da mesma forma que o neurônio é a célula-base das redes neurais biológicas, ao estudar redes neurais artificiais, projeta-se um modelo de neurônio a ser implementado de forma computacional. O modelo computacional do neurônio é mostrado na Figura 7.

Figura 6 – Neurônio biológico


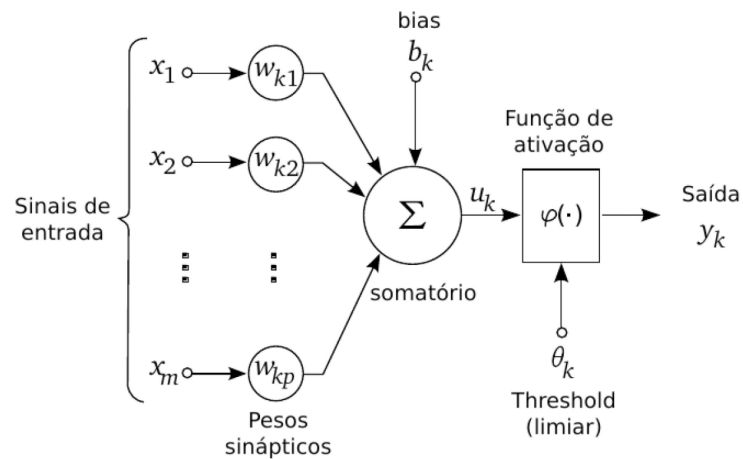


Figura 7 – Neurônio artificial - paralelos com o neurônio biológico



São traçados, então, paralelos entre o modelo computacional do neurônio e os neurônios reais:


- **Entradas** - Representam os sinais captados pelos dendritos de um neurônio. Um neurônio pode ter diversas diferentes entradas.
- **Pesos** - Representam os pesos sinápticos que existem na transmissão de informação de um neurônio para outro.
- **Somatório** - Realiza a soma ponderada das entradas, de acordo com os pesos. Representa o acúmulo de sinal realizado pelo corpo celular.



- **Função de ativação** - Baseado no valor de *threshold*, determina o sinal de saída do neurônio baseado na soma ponderadas das entradas.
- **Saída** - Representa o sinal a ser transmitido para outros neurônios através do axônio

O valor de *Bias* é um valor utilizado para que a saída do neurônio não seja nula caso todas as entradas sejam nulas. A função de ativação, normalmente, é projetada para que o valor de saída seja normalizado, independente do valor das entradas do neurônio. Dentre as diversas funções de ativação normalmente utilizadas, destacam-se a função de Heaviside, a função de Fermi ou a Tangente hiperbólica. Na Figura 8 são mostradas estas funções de ativação.

Figura 8 – Funções de Ativação



Redes Neurais típicas são composta por diferentes camadas:

- **Camada de Entrada (*Input Layer*)** - Contém os neurônios que recebem a informação que será usada para treinamento
- **Camada de Saída (*Output Layer Layer*)** - Contém os neurônios que geram as saídas da rede
- **Camadas Escondidas (*Hidden Layer*)** - Encontram-se entre a camada de entrada e a camada de saída. O papel da *Hidden Layer* é transformar as entradas de forma que a camada de saída gere as respostas esperadas.

A disposição das camadas de uma rede neural é mostrada na Figura 9. Diferentes tipos de arquitetura são usadas para o projeto de RNAs. Cada arquitetura possui características próprias, que dependem da forma como os neurônios e camadas se conectam. A Tabela 1 mostra as diferentes classificações de RNAs dependendo do parâmetro adotado.

Tabela 1 – Classificação dos diferentes tipos de RNAs

Parâmetro	Tipo de Rede	Descrição
Conexões entre neurônios e camadas	<i>FeedForward</i> ou Recorrente	<ul style="list-style-type: none"> <li>• <i>FeedForward</i> - Não possui realimentação</li> <li>• Recorrente - Possui realimentação</li> </ul>
Número de camadas escondidas	<i>Single Layer</i> ou <i>Multi Layer</i>	<ul style="list-style-type: none"> <li>• <i>Single Layer</i> - Possui uma camada escondida</li> <li>• <i>Multi Layer</i> - Possui mais de uma camada escondida</li> </ul>
Natureza dos pesos	Fixa ou Adaptativa	<ul style="list-style-type: none"> <li>• Fixa - Os pesos são fixados <i>a priori</i> e não são mudados</li> <li>• adaptativa - Os pesos são modificados ao longo do treinamento</li> </ul>
Memória	Estática ou Dinâmica	<ul style="list-style-type: none"> <li>• Estática - Não possuem memória, ou seja, a saída atual depende apenas das entradas atuais</li> <li>• Dinâmica - Possuem memória, ou seja, a saída atual depende das entradas atuais, bem como das entradas e estados passados</li> </ul>

### 2.4.3 Processo de aprendizagem em RNAs

As redes neurais “aprendem” ajustando os valores dos pesos e do *bias* (*threshold*) de forma iterativa, de forma a alcançar o valor desejado de saída. Para que o processo de aprendizado ocorra, porém, é necessário que a RNA seja treinada primeiro. Um conjunto de dados é utilizado para realização do treinamento da RNA, conhecidos como *Training Set*. O processo de aprendizado pode ser resumido na Figura 10.

Figura 9 – Camadas de uma RNA


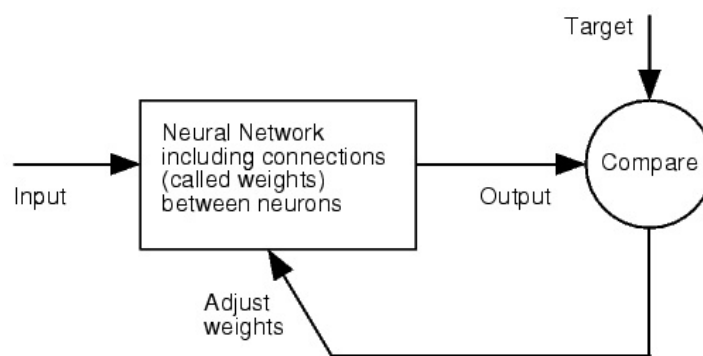


Figura 10 – Diagrama esquemático do processo de treinamento de uma RNA



O treinamento das RNAs é feito seguindo um conjunto de regras, conhecidas como **algoritmo de aprendizagem**. Existem diferentes algoritmos de aprendizagem, dentre os quais destacam-se:

- *Gradient Descent*
- *Back propagation*
- *Hebbian Rule*
- *Levenberg Marquadt*
- *Hopfield Law*
- entre outros

Cada algoritmo de aprendizagem possui características próprias e aplicações para os quais são mais adequados. Outra característica importante quanto ao treinamento de RNAs trata-se do tipo de treinamento, que pode ser dividido da seguinte forma:

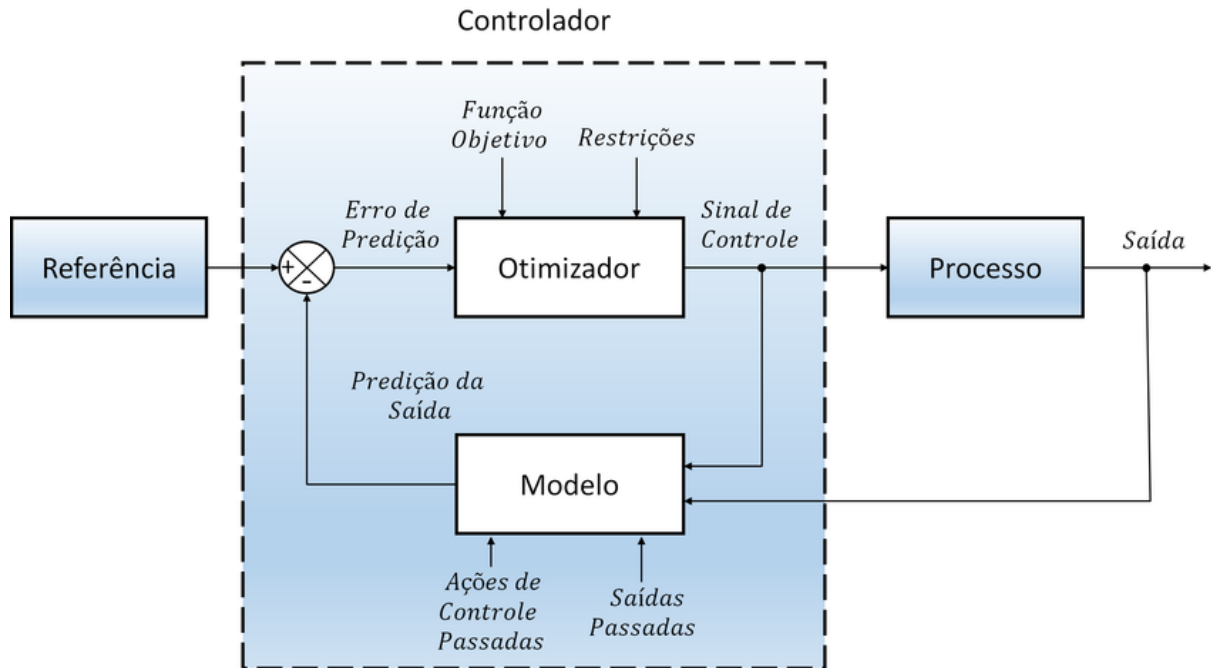
- **Treinamento Supervisionado** - No treinamento supervisionado, o conjunto de dados usado para o treinamento consiste nas entradas de um sistema bem como as saídas desse sistema, conhecidas como *target* (alvo). Dessa forma, cada conjunto de treinamento pode ser comparado aos dados do *target*, de forma que a rede pode receber um vetor de erros preciso, e fazer as devidas correções nos pesos [KRIESEL, 2005].
- **Treinamento Não-Supervisionado** - No treinamento não-supervisionado, o conjunto de dados usado para o treinamento consiste apenas nas entradas do sistema, ou seja, as saídas desejadas para esse sistema são desconhecidas. Dessa forma, a rede tenta, por ela mesma, detectar similaridades e gerar padrões. É o método de aprendizado que mais se aproxima da aprendizagem biológica.
- **Treinamento de Reforço** - No treinamento de reforço, os valores de saída são desconhecidos, assim como no treinamento não-supervisionado, porém, a cada iteração do algoritmo, um valor lógico ou real é recebido, indicando se o resultado está certo ou não, e, possivelmente, o quão certo ou errado esses valores são.
- **Treinamento *Offline*** - O ajuste nos valores do peso e do *threshold* é feito apenas quando todos os dados de treinamento são apresentados à rede.
- **Treinamento *Online*** - O ajuste nos valores do peso e do *threshold* é feito cada vez que uma amostra de treinamento é apresentada à rede.

O processo de aprendizado pode ser encerrado de acordo com a precisão dos resultados obtidos ou com o número de iterações realizadas. Cabe ao projetista determinar quando parar o treinamento, dependendo da necessidade de uso e precisão das RNAs.

## 2.5 Modelo de Controle Preditivo

O Modelo de Controle Preditivo (MCP) é um método de controle de processos bastante utilizado na indústria e na academia. A base do controle preditivo é o cálculo de uma sequência futura dos sinais de entrada de um processo de forma que uma função de custo definida sobre um horizonte de previsões seja minimizada [GEORGIEVA; AZEVEDO, 2011]. A realização do controle preditivo, por sua vez, exige um modelo dinâmico razoavelmente satisfatório do processo a ser controlado, uma vez que as previsões do sinal de entrada serão baseadas neste modelo. Na Figura 11 é ilustrado o Modelo de Controle Preditivo de um processo aleatório.

Figura 11 – Diagrama de blocos de um MCP

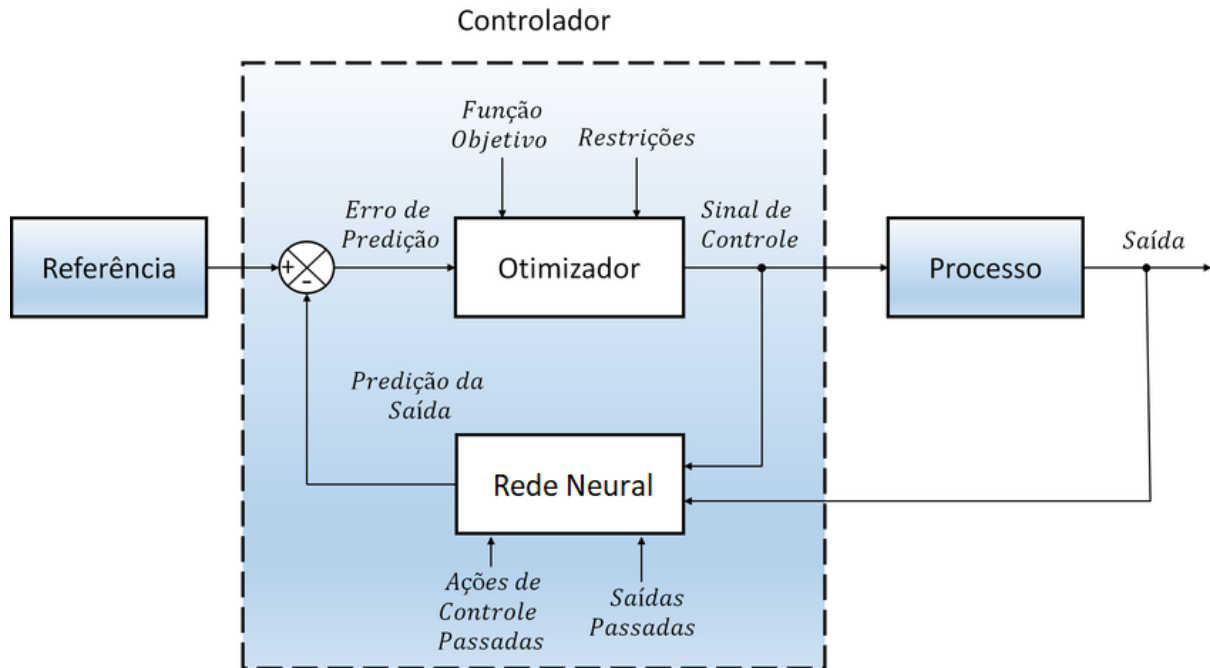


Em resumo, conforme ilustrado na Figura 11, a leitura do sensor e o modelo são usados para prever os valores futuros de saída. Então, as mudanças apropriadas nas variáveis de saída podem ser calculadas através tanto das previsões do modelo quanto da leitura dos sensores. Em essência, as mudanças em cada variável manipulada são coordenadas considerando a relação entrada-saída representada pelo modelo do processo [SEBORG; EDGAR; MELLICHAMP, 2010].

Ao se trabalhar com Ligas de Memória de Forma, a não-linearidade e histerese do material devem ser levadas em consideração. Dessa forma, um modelo matemático satisfatório pode ser de difícil obtenção ou exigir simplificações que limitem o uso prático de atuadores de LMF. Nesse sentido, o uso de redes neurais artificiais torna-se interessante no desenvolvimento de um modelo dinâmico satisfatório para estratégia de controle. Dessa forma, é possível substituir o modelo do processo no diagrama de blocos da Figura 11 por uma RNA treinada para este propósito, conforme mostrado na Figura 12.

O controle preditivo baseado redes neurais usa uma RNA para prever a performance futura da planta. A fim de otimizar esta performance através de um certo horizonte de tempo, o controlador calcula o sinal de entrada da planta [NIKDEL et al., 2014]. Entradas e saídas passadas da planta podem ser usadas para esse fim. Dessa forma, pode-se coletar dados sobre a operação e fazer o treinamento da RNA de forma *offline*.

Figura 12 – Diagrama de blocos de um controlador preditivo utilizando RNA



Vários trabalhos utilizando controle preditivo baseado em redes neurais tem sido desenvolvidos. Em [HUANG; LEWIS, 2003], é proposto um controle preditivo baseado em redes neurais para sistemas dinâmicos não-lineares com atraso temporal. Em [YOO; PARK; CHOI, 2005] é proposto um modelo de controle preditivo para sistemas caóticos utilizando uma RNA recorrente. Esta mesma ideia é utilizada em [YOO; CHOI; PARK, 2006] para o controle de movimento em robôs móveis. Em [CHENG et al., 2015], este tipo de controlador é usado em atuadores piezoelétricos. Em [WANG; GAO; QIU, 2016], uma combinação de controle preditivo baseado em RNA e em modelo é desenvolvido visando o controle de processos industriais.

Tendo em vista a não-linearidade e comportamento histerético de materiais com memória de forma, o controle preditivo baseado em RNAs se mostra como uma estratégia interessante no uso de atuadores de LMF. Alguns trabalhos tem sido desenvolvidos nesse sentido. Em [NIKDEL et al., 2014], é utilizado controle preditivo baseado em redes neurais para controle de um manipulador construído com fios de LMF. Em [NIKDEL et al., 2014] uma rede neural histerética é utilizada como modelo para implementação do controle preditivo. Em [SRIVASTAVA; WARD; PATEL, 2017], o controle preditivo de fios de LMF utiliza uma RNA adaptativa. Neste trabalho, um controlador preditivo simplificado será utilizado para controle de força de uma mola de LMF.

## 3 Materiais e Métodos

Este capítulo tem como objetivo mostrar os materiais utilizados e os métodos de atuação e análise adotados para o estudo feito.

### 3.1 Circuito de Acionamento

O ciclo térmico em uma Liga de Memória de Forma é essencial para as diversas aplicações práticas deste material. O aquecimento de LMFs, por sua vez, pode ser feito de diversas formas. Uma das técnicas de aquecimento mais utilizadas e práticas é o aquecimento por efeito Joule. O efeito Joule, também conhecido como aquecimento resistivo, é o processo no qual a passagem de corrente elétrica através de um condutor produz calor. Dentre as vantagens do uso do aquecimento resistivo, destaca-se a capacidade de controle de temperatura através de circuitos elétricos relativamente simples.

A **Modulação por Largura de Pulso** (*Pulse Width Modulation* - PWM) é uma técnica de modulação usada para codificar uma mensagem em um sinal pulsado, e seu principal uso é permitir o controle de potência para dispositivos elétricos. Dentre as diversas técnicas de modulação existentes, PWM tem a vantagem de ser robusta em relação a ruídos, efetiva em economia de energia e facilmente implementada através de microcontroladores [MA; SONG, 2003].

Por último, a análise da resistência elétrica, conforme visto na seção 2.2, é interessante em termos de automação para sistemas que utilizam Ligas de Memória de Forma. De fato, a medição de resistência elétrica tende a ser mais simples e confiável que as medições de temperatura, por exemplo, que tendem a ser desuniformes ao longo de fios ou molas de LMF. Visando o estudo mais detalhado do comportamento da resistência elétrica, é desejável que o circuito de acionamento consiga realizar o controle da corrente elétrica que flui pelo atuador de LMF através do sinal PWM de entrada, independentemente da resistência elétrica do próprio atuador. De fato, a resistência elétrica dos atuadores de LMF variam de acordo com a fase do material, temperatura, tensão aplicada, número de ciclagens, entre outros fatores, sendo desejável a manutenção do valor da corrente elétrica independente dos fatores citados.

Portanto, é interessante, visando o aquecimento por efeito Joule de LMFs, projetar um circuito de acionamento baseado na modulação PWM. O uso do PWM torna viável o uso de diferentes microcontroladores para atingir o controle de um sistema. Além disso, o circuito projetado deve ser instrumentado de forma a permitir a leitura periódica da resistência elétrica do atuador de LMF. Dessa forma, destacam-se os requisitos e materiais


de projeto:

1. Circuito de potência ativado por PWM
2. Sensores de tensão e corrente para estimação da resistência elétrica
3. Reguladores de tensão para controle da corrente elétrica
4. Sensores de Força para treinamento da Rede Neural

O circuito de potência proposto utiliza um transistor bipolar de junção BC547 e um transistor de efeito de campo IRF 9510 para chaveamento da alimentação do circuito controlada pela entrada PWM. Além disso, utiliza os reguladores de tensão LM317 para manutenção da corrente elétrica no LMF. Estes reguladores de tensão são responsáveis por manter a corrente elétrica constante, independentemente da carga ligada aos mesmos, desde que a potência requerida pelo circuito não ultrapasse o limite de fornecimento do dispositivo. O circuito limitador de corrente usando o LM317 é mostrado na Figura 13 e o valor desta corrente é mostrado na Equação 3.1.

$$I_{limit} = \frac{1,2}{R_1} \quad (3.1)$$


Figura 13 – Limitador de corrente usando LM317



Para a leitura da tensão sobre o LMF, utiliza-se um divisor de tensão resistivo. O objetivo do divisor de tensão é limitar o valor máximo da tensão de saída para leitura do DAQ, uma vez que os valores de pico de tensão podem ultrapassar os valores limites de leitura do dispositivo. Para o projeto do divisor de tensão, foram utilizados um resistor de precisão de  $330\Omega$  e um resistor de precisão de  $470\Omega$ . O circuito divisor de tensão é mostrado na Figura 14.



Figura 14 – Circuito divisor de tensão



A tensão de saída de um circuito divisor de tensão pode ser encontrada através da Equação 3.2

$$V_{out} = \frac{R_2}{R_1 + R_2} V_{in} \quad (3.2)$$

Onde  $V_{in}$  é a tensão de entrada do circuito e  $V_{out}$  é a tensão de saída do circuito.

Aplicando a Equação 3.2 para  $R_1 = 470\Omega$  e  $R_2 = 330\Omega$ , obtém-se a seguinte equação (considerando  $V_{in} = V_{LMF}$ , onde  $V_{LMF}$  é a tensão sobre o atuador LMF):

$$V_{out} = 0,4125V_{LMF} \Rightarrow V_{LMF} = 2,42V_{out} \quad (3.3)$$

Para a leitura de corrente elétrica é utilizado um sensor de corrente de efeito Hall, o ACS712, que é mostrado na Figura 15. A calibração deste sensor foi feita com auxílio do LabView e MATLAB, e sua curva característica e o modelo matemático proposto são mostrados na Figura 16. A escolha do sensor de corrente por efeito Hall visa trazer o mínimo de interferência no circuito, uma vez que a maioria dos sensores de corrente elétrica necessita da utilização de um resistor em série com a carga para aferição dessa grandeza. O modelo matemático para o sensor é descrito pela Equação 3.4

Figura 15 – Sensor de corrente de efeito Hall ACS712



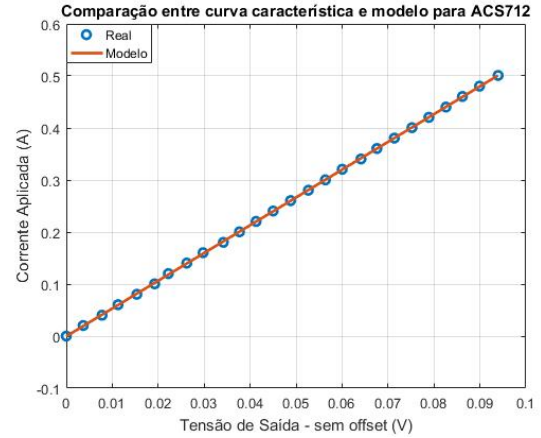


Figura 16 – Caracterização e Modelagem da curva característica para sensor ACS712



(a) Caracterização ACS712



(b) Comparação entre curva característica e modelo

$$I = 5,3361V_{out} \quad (3.4)$$

Onde  $I$  é a corrente elétrica que circula pelo sensor e  $V_{out}$  é a tensão de saída do ACS712, que é lida pelo sistema de aquisição.

As equações 3.3 e 3.4 serão usadas, posteriormente, para o projeto do Filtro de Kalman. Por fim, a partir dos valores de resistência elétrica e corrente adquiridos, estima-se o valor da resistência elétrica do LMF através da 1ª Lei de Ohm:

$$R = \frac{V_{LMF}}{I} \quad (3.5)$$

Onde  $R$  é a resistência elétrica,  $V_{LMF}$  é a tensão sobre o atuador LMF e  $I$  a corrente lida pelo sensor de efeito Hall.

O diagrama esquemático do circuito de potência é mostrado na Figura 17.

Cabe destacar que todos os dispositivos utilizados para sensoramento possuem incertezas intrínsecas a seu funcionamento. Por exemplo, o divisor resistivo utilizado para leitura de tensão possui variações inerentes aos valores de resistência elétrica utilizados, tipicamente de 1% para os resistores escolhidos. O sensor Hall, por sua vez, possui ruído característico de aproximadamente  $21mV$ , fornecido pelo fabricante. Em todos esses casos, o uso do Filtro de Kalman visa lidar de forma satisfatória com essas incertezas.

Para realizar a aquisição dos dados de tensão e corrente e escrita do sinal PWM, utiliza-se o placa de aquisição USB-6212, da *National Instruments*. O NI USB-6212 é um dispositivo que possui até 32 canais de entrada analógica (AI), até 2 canais de saída analógica (AO), dois contadores, e até oito linhas de entrada digital (DI) e oito linhas de

saída digital (DO), ou 32 linhas bidirecionais de entrada e saída digital (DIO) [DAQ..., 2009]. O USB-6212 é mostrado na Figura 18.

Figura 17 – Diagrama esquemático do circuito de potência projetado

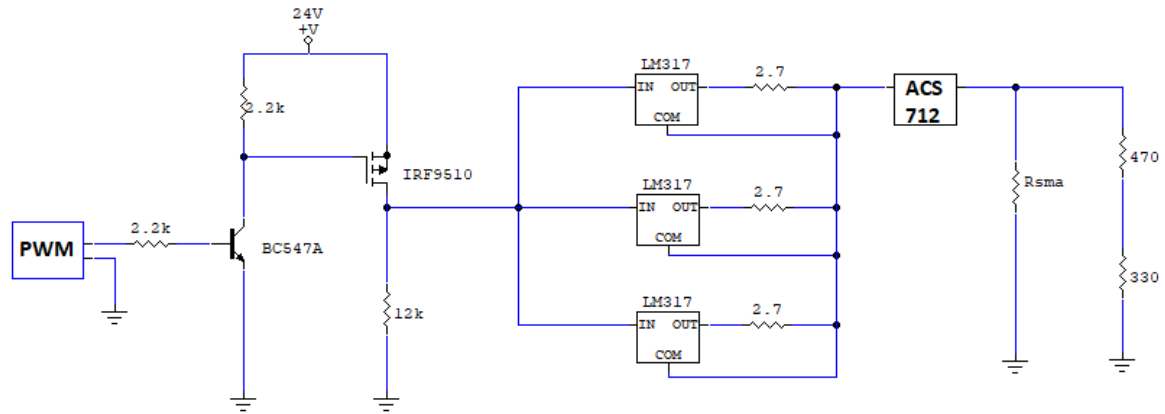


Figura 18 – Placa de aquisição de dados NI USB-6212

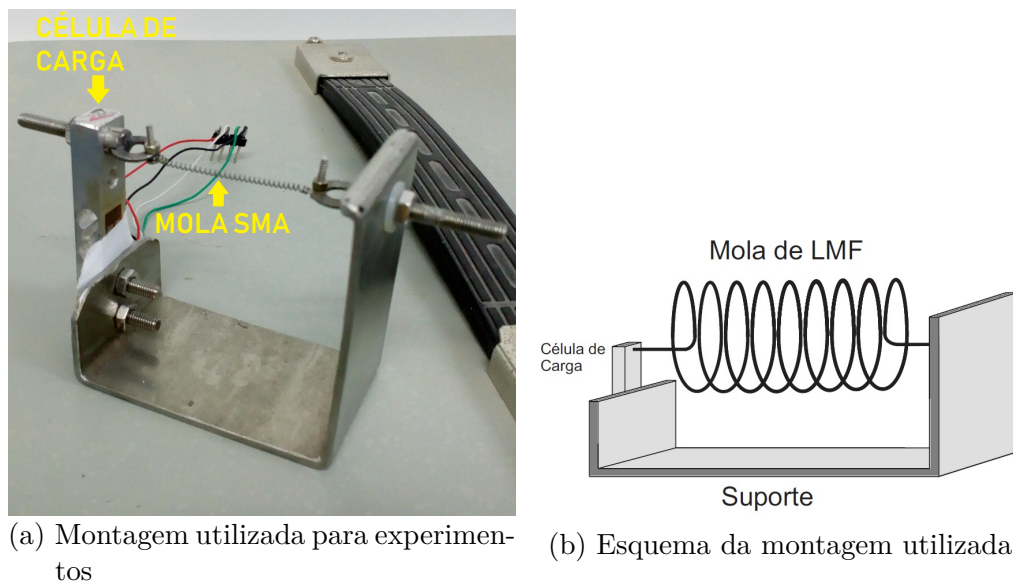


A frequência de amostragem do sinal utilizado para os experimentos foi de 100kHz, o que garantiu boa confiabilidade às formas de onda da corrente e tensão lidas. O valor de 100kHz foi escolhido empiricamente ao analisar-se o custo de processamento que o aumento de frequência de amostragem causou ao sistema.

## 3.2 Protótipo do Estudo de Frequências com Mola


Na seção 3.1 foi abordada a estratégia de acionamento de atuadores LMF por PWM, e suas vantagens. Porém, embora o acionamento por PWM seja frequentemente empregado em trabalhos que envolvem LMFs, um estudo sobre como a frequência deste sinal interfere na atuação não é recorrente nas literaturas. Dessa forma, para promover esse estudo, foi concebido uma plataforma de teste usando uma mola de LMF. Além do circuito de acionamento já exposto na seção 3.1, foi utilizada uma célula de carga para medição da força exercida pela mola ao longo do processo de ciclagem. Dessa forma, as curvas de *Resistência elétrica*  $\times$  *Força* para diferentes valores de frequência foram levantadas. A montagem da estrutura da mola e célula de carga é mostrada na Figura 19

Figura 19 – Estrutura com mola de LMF e célula de carga



O módulo HX711 foi utilizado para processamento do sinal da célula de carga, fornecendo o valor da força exercida pela mola em gramas-força (gf). Este componente é mostrado na Figura 20. Um microprocessador Arduino é utilizado para a comunicação entre o HX711 e o computador, uma vez que este componente utiliza comunicação I2C, inexistente na placa de aquisição NI USB-6212, da *National Instruments*.

Figura 20 – Módulo HX711 para leitura e processamento do sinal da célula de carga



Para o levantamento das curvas de *Resistência elétrica*  $\times$  *Força*, variou-se o valor do *Duty Cycle* de forma crescente até atingir o valor limite de corrente elétrica, estipulado durante o treinamento da mola. Ao atingir o valor máximo de corrente, o *Duty Cycle* foi, então, decrescido gradualmente até o nível inicial de corrente do experimento, concluindo, assim, uma ciclagem completa. Foram feitas três ciclagens completas para cada frequência escolhida.


Os valores escolhidos de frequência para condução dos experimentos foram  $100Hz$ ,  $200Hz$ ,  $400Hz$ ,  $500Hz$ ,  $800Hz$ ,  $1000Hz$  e  $2000Hz$ . Estes valores foram escolhidos com base na frequência de amostragem utilizada para o experimento. Dessa forma, sempre houve um número inteiro de ciclos completos, o que facilitou uma estimativa mais precisa do valor RMS de corrente e tensão e, consequentemente, da resistência elétrica da mola.

### 3.3 Implementação do Filtro Estendido de Kalman

Na subseção 2.3.2 foi descrito o Filtro de Kalman, bem como suas equações, aplicações e vantagens. Foi projetado um Filtro de Kalman para o sistema de acionamento do LMF a fim de tornar as estimativas de resistência elétrica menos susceptíveis a ruídos e perturbações, especialmente do sensor de corrente Hall, que tende a apresentar uma resposta ruidosa.

O diagrama de blocos do Filtro de Kalman Estendido é mostrado na Figura 21. Dessa forma, para implementação do EKF computacionalmente, é necessário definir quais são os estados  $x$  do sistema, as saídas  $z$ , as entradas  $u$ , e as funções  $f(x, u, w)$  e  $g(x, v)$ . A partir destes valores, pode-se então definir  $F$ ,  $H$ ,  $\Gamma$  e  $\Lambda$  através das equações 2.17, 2.18, 2.19 e 2.20, respectivamente.

Figura 21 – Diagrama de blocos do EKF



Inicialmente, definem-se os estados do sistema como sendo a **corrente** que circula pelo atuador de LMF, a **tensão** sobre o atuador de LMF, a **resistência elétrica** do atuador de LMF e a **força** exercida pela mola sobre a plataforma experimental. Dessa forma, o vetor de estados é descrito na Equação 3.6. A entrada do sistema, por sua vez, é o

*Duty Cycle* aplicado ao circuito de potência. Para termos de simplificação, a entrada será normalizada para valores entre 0 e 1. A entrada do sistema, então, é representada pela Equação 3.7. Por fim, o vetor de saída do sistema é composto pela **corrente**, a **tensão** sobre o atuador de LMF e a **força** exercida pela mola sobre a plataforma experimental. De fato, as saídas são também estados do sistema. O vetor de saída é mostrado na Equação 3.8.

$$x[n] = \begin{bmatrix} I_{LMF}[n] \\ V_{LMF}[n] \\ R_{LMF}[n] \\ F_{LMF}[n] \end{bmatrix} \quad (3.6)$$

$$u[n] = DC[n] \quad (3.7)$$

$$z[n] = \begin{bmatrix} I_{LMF}[n] \\ V_{LMF}[n] \\ F_{LMF}[n] \end{bmatrix} \quad (3.8)$$

Além disso, as funções  $f(x, u, w)$  e  $g(x, v)$  devem ser definidas. A função  $g(x, v)$  pode ser definida com auxílio das equações 3.3 e 3.4, e considerando que os valores fornecidos pelo módulo HX711 são iguais a força aplicada pela mola à célula de carga:


$$z[n] = g(x[n], v[n]) = \begin{bmatrix} g_1(x[n], v[n]) \\ g_2(x[n], v[n]) \\ g_3(x[n], v[n]) \end{bmatrix} = \begin{bmatrix} 0,1874x_1[n] \\ 0,4125x_2[n] \\ x_4[n] \end{bmatrix} \quad (3.9)$$

Já a função  $f(x, u, w)$  estima os estados na próxima iteração a partir dos estados e entradas atuais do sistema. Além disso, como os estados do sistema tratam-se da corrente, tensão e resistência elétrica do atuador LMF, conforme a Equação 3.6, pode-se encontrar cada uma destas variáveis em função das demais. Para tornar mais clara essa ideia, toma-se base no seguinte diagrama de blocos apresentado na Figura 22.

Percebe-se que os estados  $x_1[n+1]$ ,  $x_2[n+1]$  e  $x_3[n+1]$  podem ser estimados a partir da entrada  $u[n]$ , bem como dos estados passados,  $x_1[n]$ ,  $x_2[n]$  e  $x_3[n]$ . Além disso, é usual tomar como parâmetro importante da estimação de estados usando o EKF o próximo estado sendo igual ao estado anterior, isto é,  $x[n+1] = x[n]$ , especialmente quando o sistema encontra-se em regime permanente. Por fim, o estado  $x_4[n+1]$  é estimado exclusivamente igualando-o ao estado anterior  $x_4[n]$ .

Dessa forma, é possível admitir 3 diferentes funções  $f(x, u, w)$  para os estados  $x_1[n+1]$ ,  $x_2[n+1]$  e  $x_3[n+1]$ , cada qual dependendo de que parâmetros serão utilizados para a estimação dos próximos estados.

Figura 22 – Diagrama de blocos das saídas e estados do sistema



### 1. Estimação de estados através do valor anterior do estado

A estimação dos estados a partir do valor anterior do próprio estado é simples e pode ser realizada segundo a Equação 3.10, especialmente quando o sistema encontra-se em regime permanente.

$$\begin{aligned}
 x[n+1] = \begin{bmatrix} x_1[n+1] \\ x_2[n+1] \\ x_3[n+1] \\ x_4[n+1] \end{bmatrix} &= f_{ant}(x[n], u[n], w[n]) = \begin{bmatrix} f_{ant_1}(x[n], u[n], w[n]) \\ f_{ant_2}(x[n], u[n], w[n]) \\ f_{ant_3}(x[n], u[n], w[n]) \\ f_{ant_4}(x[n], u[n], w[n]) \end{bmatrix} = \\
 &= \begin{bmatrix} x_1[n] + w[n] \\ x_2[n] + w[n] \\ x_3[n] + w[n] \\ x_4[n] + w[n] \end{bmatrix} \quad (3.10)
 \end{aligned}$$

### 2. Estimação através da combinação dos outros estados

A estimação dos estados pode ser feita através da combinação dos outros estados, segundo a Equação 3.11. A Equação 3.11, por sua vez, pode ser obtida a partir do

diagrama mostrado na Figura 22.

$$x[n+1] = \begin{bmatrix} x_1[n+1] \\ x_2[n+1] \\ x_3[n+1] \end{bmatrix} = f_{est}(x[n], u[n], w[n]) = \begin{bmatrix} f_{est_1}(x[n], u[n], w[n]) \\ f_{est_2}(x[n], u[n], w[n]) \\ f_{est_3}(x[n], u[n], w[n]) \end{bmatrix} = \begin{bmatrix} \frac{x_2[n]}{x_3[n]} + w[n] \\ x_1[n] \cdot x_3[n] + w[n] \\ \frac{x_2[n]}{x_1[n]} + w[n] \end{bmatrix} \quad (3.11)$$

A estimação de estados através da combinação dos outros estados não se aplica à estimativa de força  $x_4[n+1]$ .

### 3. Estimação através da entrada $u[n]$

A estimação através da entrada  $u[n]$  do sistema é dada pela Equação 3.12, que também pode ser obtida a partir da Figura 22.

$$x[n+1] = \begin{bmatrix} x_1[n+1] \\ x_2[n+1] \\ x_3[n+1] \end{bmatrix} = f_{ent}(x[n], u[n], w[n]) = \begin{bmatrix} f_{ent_1}(x[n], u[n], w[n]) \\ f_{ent_2}(x[n], u[n], w[n]) \\ f_{ent_3}(x[n], u[n], w[n]) \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^3 \left( \frac{1,2}{R_{adj_i}} \right) \cdot u[n] + w[n] \\ \sum_{i=1}^3 \left( \frac{1,2}{R_{adj_i}} \right) \cdot u[n] \cdot x_3[n] + w[n] \\ \sum_{i=1}^3 \left( \frac{1,2}{R_{adj_i}} \right) \cdot u[n] \cdot \sum_{i=1}^3 \left( \frac{1,2}{R_{adj_i}} \right) \cdot u[n] \cdot x_3[n] + w[n] \end{bmatrix} \quad (3.12)$$

A estimação de estados através da entrada  $u[n]$  não se aplica à estimativa de força  $x_4[n+1]$ .

Tendo em vista as diferentes formas de calcular a função  $f(x[n], u[n], w[n])$ , propõe-se uma estratégia de ponderação no cálculo desta função através de uma matriz de pesos. Esta matriz, basicamente, estabelece qual a porcentagem de cada forma de cálculo de  $f(x[n], u[n], w[n])$  vai compor o valor final de  $x[n+1]$ . A matriz de porcentagem  $P$  é proposta na Equação 3.13:

$$P = \begin{bmatrix} p_{ant_1} & p_{ant_2} & p_{ant_3} \\ p_{est_1} & p_{est_2} & p_{est_3} \\ p_{ent_1} & p_{ent_2} & p_{ent_3} \end{bmatrix} \quad (3.13)$$

Onde os termos  $p_{ant}$  são os pesos referentes às funções que utilizam a estimação através dos valores anteriores do próprio estado, os termos  $p_{est}$  são os pesos referentes



às funções que utilizam a estimação através de uma combinação dos outros estados e os termos  $p_{ent}$  são os pesos referentes às funções que utilizam a estimação através do valor de entrada do sistema. Dessa forma,  $x[n+1]$  pode ser estimado pela soma ponderada das funções  $f_{ant}$ ,  $f_{est}$  e  $f_{ent}$  conforme a Equação 3.14. Como o estado  $x_4[n+1]$  é estimado apenas pelos seu valor anterior  $x_4[n]$ , a matriz de pesos não se aplica a este estado.

$$\begin{aligned}
 x[n+1] &= \begin{bmatrix} x_1[n+1] \\ x_2[n+1] \\ x_3[n+1] \end{bmatrix} = f(x[n], u[n], w[n]) = \begin{bmatrix} f_1(x[n], u[n], w[n]) \\ f_2(x[n], u[n], w[n]) \\ f_3(x[n], u[n], w[n]) \end{bmatrix} = \\
 &= \begin{bmatrix} p_{ant1} \cdot f_{ant1} + p_{est1} \cdot f_{est1} + p_{ent1} \cdot f_{ent1} + w[n] \\ p_{ant2} \cdot f_{ant2} + p_{est2} \cdot f_{est2} + p_{ent2} \cdot f_{ent2} + w[n] \\ p_{ant3} \cdot f_{ant3} + p_{est3} \cdot f_{est3} + p_{ent3} \cdot f_{ent3} + w[n] \end{bmatrix} = \\
 &= \begin{bmatrix} p_{ant1} \cdot x_1[n] + p_{est1} \cdot \frac{x_2[n]}{x_3[n]} + p_{ent1} \cdot \sum_{i=1}^3 \left( \frac{1,2}{R_{adj_i}} \right) \cdot u[n] + w[n] \\ p_{ant2} \cdot x_2[n] + p_{est2} \cdot x_1[n] \cdot x_3[n] + p_{ent2} \cdot \sum_{i=1}^3 \left( \frac{1,2}{R_{adj_i}} \right) \cdot u[n] \cdot x_3[n] + w[n] \\ p_{ant3} \cdot x_3[n] + p_{est3} \cdot \frac{x_2[n]}{x_1[n]} + p_{ent3} \cdot \sum_{i=1}^3 \left( \frac{1,2}{R_{adj_i}} \right) \cdot u[n] \cdot \sum_{i=1}^3 \left( \frac{1,2}{R_{adj_i}} \right) \cdot u[n] \cdot x_3[n] + w[n] \end{bmatrix} \quad (3.14)
 \end{aligned}$$

Para que a estimação ponderada seja precisa, é necessário que  $p_{ant1} + p_{est1} + p_{ent1} = 1$ ,  $p_{ant2} + p_{est2} + p_{ent2} = 1$  e  $p_{ant3} + p_{est3} + p_{ent3} = 1$ . A ideia de utilizar a soma ponderada é dar mais ou menos importância à forma de calcular a função  $f(x[n], u[n], w[n])$ . Por exemplo, quando o sistema está em regime permanente, é interessante que o peso da estimação através do próprio estado anterior seja maior, devido à maior confiabilidade dos próprios estados já filtrados. Já em um momento de transistório, é interessante atribuir maior peso à entrada, por exemplo, uma vez que a convergência através da entrada tende a ser mais rápida, apesar da menor precisão.

Uma vez que a Equação 3.14 está definida, é possível definir  $F$ ,  $H$ ,  $\Gamma$  e  $\Lambda$  através das equações 2.17, 2.18, 2.19 e 2.20, respectivamente. Dessa forma, para o EKF projetado, tem-se o seguinte:

$$F = \begin{bmatrix} p_{ant1} & \frac{p_{est1}}{x_3[n]} & -\frac{p_{est2} \cdot x_2[n]}{x_3^2[n]} \\ p_{est2} \cdot x_3[n] & p_{ant2} & p_{est2} \cdot x_1[n] + p_{ent2} \left( \sum_{i=1}^3 \frac{1,2}{R_{adj_i}} \cdot u[n] \right) \\ -\frac{p_{est3} \cdot x_2[n]}{x_1^2[n]} & \frac{p_{est3}}{x_1[n]} & p_{ant3} \end{bmatrix} \quad (3.15)$$

$$H = \begin{bmatrix} 0,1874 & 0 & 0 \\ 0 & 0,4247 & 0 \end{bmatrix} \quad (3.16)$$

$$\Gamma = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3.17)$$

$$\Lambda = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \quad (3.18)$$

Tomando como base as equações 3.6, 3.7, 3.14, 3.9 3.15, 3.16, 3.17, 3.18, 2.21, 2.22, 2.23, 2.24 e 2.25, e conforme visto na subseção 2.3.3, projetou-se o Filtro de Kalman Estendido para o levantamento das curvas tanto da mola de LMF quanto dos fios de LMF usados na confecção da mão. O EKF foi implementado com auxílio do software LabView. O Filtro de Kalman é inicializado com os valores iniciais das variáveis estimadas durante os experimentos de coleta de dados, de forma que a convergência dos valores estimados seja mais rápida possível.

## 3.4 Redes Neurais

Duas redes neurais são treinadas para implementação do projeto de controle do atuador de LMF: uma rede que atuará como sensor para *feedback* da resistência elétrica, e outra rede que atuará como modelo para o projeto do controlador preditivo simplificado. As RNAs foram treinadas com auxílio do software MATLAB, a partir dos dados coletados, e foram implementadas com auxílio do software LabView. No LabView, são criados blocos para os neurônios e camadas das RNAs treinadas, nas quais é feito todo o processo de propagação das entradas através dos pesos e funções de ativação. Os valores de entradas das redes são atualizados a cada iteração a partir da estimação de estados do Filtro de Kalman, de forma que as primeiras previsões das redes neurais tendem a falhar, mas convergem em poucas iterações para os valores reais de força.


### 3.4.1 Rede Neural como Sensor de Resistência Elétrica

Conforme visto na subseção 2.4.2, redes neurais do tipo *feedforward* são RNAs que não possuem realimentação entre suas camadas. Redes neurais *recorrentes* são RNAs que possuem realimentação entre suas camadas. Neste trabalho, é utilizada uma RNA do tipo *feedforward* e uma RNA do tipo recorrente para aprendizagem do comportamento de resistência elétrica em uma mola de LMF. utilizam-se RNAs destas diferentes topologias a fim de verificar a importância de realimentações na previsão do comportamento histerético do atuador de memória de forma.


Na figura 23 são mostradas as topologias das redes do tipo *feedforward* utilizando uma e duas camadas ocultas. Já na figura 24 são mostradas as topologias das redes recorrentes utilizando uma e duas camadas ocultas. Sabe-se, da literatura, que uma RNA não precisa que mais de duas camadas ocultas para solucionar a maioria dos problemas. De fato, um elevado número de neurônios ou de camadas pode levar a um erro de *overfitting*,

ou seja, a rede “memoriza” o comportamento dos dados apresentados para treinamento, mas não é capaz de generalizar este comportamento em situações até mesmo ligeiramente diferentes das condições de treinamento. Dessa forma, como regra prática no projeto de RNAs, visa-se o menor número possível de camadas e de neurônios por camada que atendam a uma certa performance desejada. Para fins de comparação, será usado o Erro Médio Quadrático (*Mean Square Error* - MSE) como variável analisada. Em ambas as topologias, camadas ocultas com 5 neurônios são utilizadas.

Figura 23 – RNAs do tipo *feedforward* utilizando uma e duas camadas ocultas



(a) RNA do tipo *feedforward* com uma camada oculta

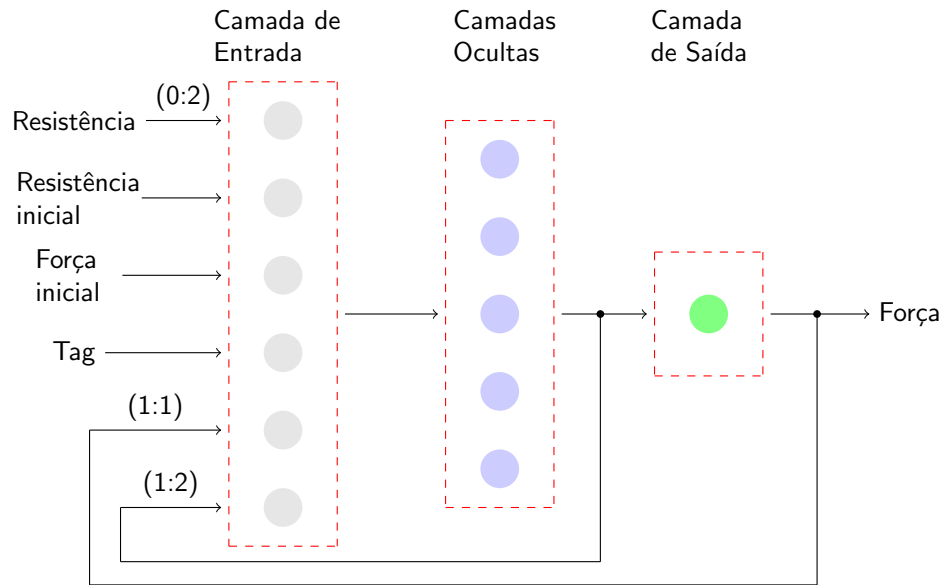


(b) RNA do tipo *feedforward* com duas camadas ocultas


Os dados utilizados como entradas da RNA do tipo *feedforward* são os valores de variação de resistência elétrica, os valores iniciais de resistência elétrica e força e um sinal de *tag*. Este sinal de *tag* serve para identificar o ciclo de transformação de fase do material, ou seja, se o atuador está sendo transformado da fase martensita para austenita

(aquecimento) ou da fase austenita para martensita (resfriamento). Os dados utilizados como *target* são os valores de variação de força, em grama força (gf).

Figura 24 – RNAs recorrentes utilizando uma e duas camadas ocultas



(a) RNA recorrente com uma camada oculta



(b) RNA recorrente com duas camadas ocultas

Nas RNAs recorrentes, além dos dados de entrada anteriormente citados, a realimentação da saída e a realimentação das camadas ocultas também são utilizadas como entradas. A entrada de resistência elétrica é um vetor de três elementos, representado graficamente na Figura 24 por “(0:2)”, indicando um vetor composto pela resistência elétrica atual e os últimos dois valores de resistência elétrica. Os termos “(1:1)” e “(1:2)”, também representados graficamente na Figura 24, indicam vetores do último e dos dois últimos

elementos de cada variável, respectivamente (estes vetores não contém os valores atuais destas variáveis). Os termos “(1:1)” e “(1:2)” estão ligados às realimentações da saída ou das camadas ocultas.

A utilização dos dados iniciais de resistência elétrica e força, em ambas as redes, são importantes devido ao fato de a resistência elétrica e a força exercida pela mola de LMF serem influenciadas por outros fatores, tais como temperatura, desgaste da mola, desgaste do suporte, entre outros. Por este motivo, os dados para treinamento utilizados são as variações de resistência elétrica e, dessa forma, ao adicionar estas entradas à Rede Neural, busca-se torná-la mais abrangente em diversas situações. Para a realização do treinamento, duas molas de LMF, de comprimento 12 mm, são utilizadas. Experimentos adicionais foram conduzidos com as molas para verificação da eficácia da RNA treinada, e uma terceira mola, de mesmo comprimento, foi utilizada para os testes da RNA que atua como sensor e da RNA que atua como modelo para o controle preditivo.

Em todos os treinamentos, foram utilizados o algoritmo de Levenberg-Marquadt com validação cruzada. O erro mínimo admissível escolhido foi 0, de forma que o treinamento encerra apenas quando o número máximo de épocas ou o número de *checks* de validação são atingidos. Estes parâmetros de treinamento são os mesmos para todas as RNAs, de forma que os resultados dependem principalmente do tipo de rede e do número de neurônios e camadas adotados. No total, foram utilizados para treinamento um total de 7619 amostras coletadas através da instrumentação eletrônica do sistema. Deste total de amostras, 75% foram utilizados para treinamento, 15% foram utilizados para validação e 10% foram utilizados para testes.


### 3.4.2 Rede Neural como Modelo

De forma similar à RNA implementada como sensor, foram testadas redes neurais, porém apenas redes *feedforward*. Os dados utilizados como entradas da RNA do tipo *feedforward* são os valores de corrente elétrica e um sinal de *tag*. De forma similar, este sinal de *tag* serve para identificar o ciclo de transformação de fase do material, ou seja, se o atuador está sendo transformado da fase martensita para austenita (aquecimento) ou da fase austenita para martensita (resfriamento). Os dados utilizados como *target* são os valores de variação de força, em grama força (gf). Na Figura 25 é mostrada a topologia de RNA utilizada para o modelo do controlador preditivo.

Diferentemente da RNA treinada como sensor, esta rede usa como entrada o valor de corrente elétrica que atua na mola de LMF devido ao fato que esta é a variável manipulada da planta. De fato, os valores de resistência elétrica não podem ser efetivamente alterados, mas são consequência direta da mudança de corrente elétrica no atuador. Dessa forma, o controlador preditivo fornece à planta um novo valor de corrente elétrica que será

aplicado ao sistema. O valor de corrente é alterado a partir da alteração do Duty Cycle do sinal PWM. Apenas a topologia com uma camada oculta foi treinada.

Figura 25 – RNAs do tipo *feedforward* utilizando uma e duas camadas ocultas



Igualmente à RNA implementada como sensor, foram utilizados para treinamento um total de 7619 amostras coletadas através da instrumentação eletrônica do sistema. Deste total de amostras, 75% foram utilizados para treinamento, 15% foram utilizados para validação e 10% foram utilizados para testes.

### 3.5 Implementação do Controle Preditivo

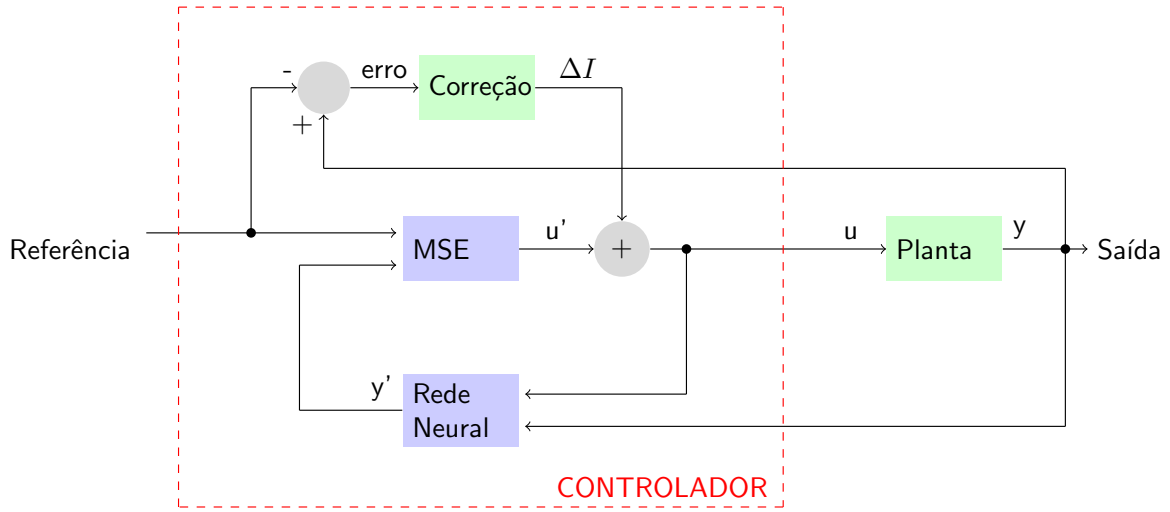
Conforme visto na seção 2.5, para implementação do controle preditivo baseado em redes neurais, necessita-se de um modelo do processo a ser controlado e um bloco de otimização, que fornecerá o valor de entrada ao sistema através da minimização de uma certa função de custo. O modelo utilizado para o controlador será a RNA treinada conforme visto na subseção 3.4.2.

Portanto, uma função de custo deve ser implementada de forma que o bloco de otimização funcione corretamente. Existem diversas funções de custo que podem ser utilizadas para esse fim. Em comum, as funções de custo se baseiam nas entradas e saídas passadas do sistema para realizar a previsão.

Dependendo do tamanho do horizonte de previsão, a resolução da função de custo pode se tornar difícil ou exigir certo custo computacional, especialmente quando se trabalha com sistemas embarcados cujo processador deve atender a diversas exigências do sistema. Dessa forma, é desejável que a função de custo do controlador preditivo seja a mais simples possível, sem que haja uma perda considerável de performance.

Nesse sentido, é proposto um modelo de controlador preditivo simplificado, baseado em redes neurais, no qual a função de custo é o erro médio quadrático (*Mean Square Error - MSE*) e o horizonte de previsão é unitário, ou seja, a função de custo é calculada a partir do último valor de entrada e a previsão é apenas para a próxima iteração. Obviamente, uma função de custo tão simplificada pode prejudicar a performance do sistema. Dessa forma, também é proposto uma função de correção, baseada no erro entre saída e referência, a fim de compensar a simplicidade da função de custo. A ideia dessa função de correção é aumentar ou diminuir a corrente aplicada ao processo, caso os valores de corrente previstos pela função de custo não façam o valor de força exercida pelo atuador de LMF convergir para o valor desejado. O diagrama de blocos do controlador simplificado é mostrado na Figura 26.

Figura 26 – Diagrama de blocos do controlador preditivo simplificado



A função de Erro Médio Quadrático pode ser calculada de acordo com a Equação 3.19, onde  $y'$  é o valor de força previsto pelo modelo da rede neural e  $R$  é o valor da referência. A partir do erro médio quadrático calculado, um novo valor de entrada para o sistema é estimado. O valor de corrente elétrica que deve ser somado à entrada é calculado a partir do erro entre o valor medido de força e da referência, segundo a Equação 3.20. O termo  $\alpha$  trata-se de um fator de correção, que varia de acordo com o valor percentual do erro em relação à referência, de forma que quanto maior o valor do erro, maior deve ser a correção a ser aplicada ao sistema. O valor do fator de correção  $\alpha$  pode ser determinado a partir Tabela 2. Os valores de  $\alpha$  foram determinados experimentalmente.

$$MSE = (y'(t) - R(t))^2 \quad (3.19)$$

$$\Delta I = \alpha \cdot erro \quad (3.20)$$

Tabela 2 – Valores do fator de correção  $\alpha$  de acordo com o erro percentual entre força medida e referência

<b>Erro Percentual</b>	<b>Fator de Correção <math>\alpha</math></b>
$erro > 20\%$	0,02
$10\% < erro < 20\%$	0,015
$5\% < erro < 10\%$	0,01
$1\% < erro < 5\%$	0,005
$erro < 1\%$	0,002



## 4 Resultados e Discussões

Neste capítulo, são discutidos os resultados obtidos através das simulações e testes experimentais das implementações apresentadas no Capítulo 3.

### 4.1 Interpretação das curvas de Resistência Elétrica $\times$ Força

Foram conduzidos experimentos de ciclagem completa nas diferentes frequências especificadas na seção 3.2 e as curvas da relação **Força  $\times$  Resistência Elétrica** são levantadas e mostradas na Figura 27.


Um fato interessante a se perceber na análise da Figura 27 é que, embora as curvas pareçam seguir um mesmo padrão, elas encontram-se, graficamente, em diferentes posições. Esse deslocamento entre as curvas em diferentes experimentos é explicado pelo fato de que o Efeito de Memória de Forma em si varia de acordo com o uso do material. De fato, a fadiga em LMFs é um das grandes dificuldades em encontrar repetibilidade em atuadores feitos desses materiais.

Nesse sentido, é interessante, ao invés de estudar os valores absolutos de força e resistência elétrica, estudar seus valores normalizados, de forma que fatores externos tais como a fadiga do material e a temperatura possuam menor influência nas curvas levantadas. Na Figura 28 são mostradas as curvas normalizadas de Força  $\times$  Resistência Elétrica.

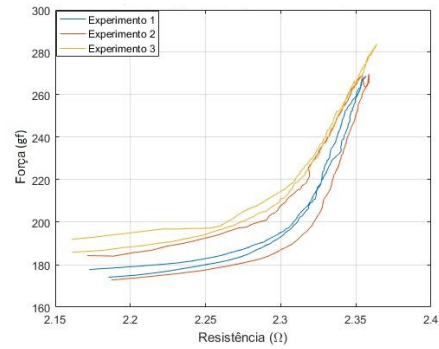
Analizando a Figura 28, percebe-se que as curvas, em geral, se sobrepõem. Isso significa que a forma das curvas se mantém ao longo das ciclagens, embora sua posição gráfica possa mudar devido a outros fatores. Dessa forma, uma Rede Neural deve ser capaz de compreender e prever com certa precisão outras grandezas, tal como a força, a partir da resistência elétrica. Além disso, é importante fornecer à RNA os valores iniciais de resistência elétrica e força para que a estimação de valores seja mais fiel à realidade.

Um segundo ponto interessante a ser analisado nas curvas mostradas é a mudança na inclinação das curvas, que pode ser mostrada através de assíntotas. Para exemplificar a ideia, foi tomada uma das curvas realizadas no experimento (frequência de 400 Hz, experimento 1) e traçadas duas assíntotas, conforme mostrado na Figura 29.


Figura 27 – Relação *Força*  $\times$  *Resistência Elétrica* para a mola de LMF em diferentes frequências




(a) Relação entre força e resistência elétrica - 100 Hz




(b) Relação entre força e resistência elétrica - 200 Hz




(c) Relação entre força e resistência elétrica - 400 Hz




(d) Relação entre força e resistência elétrica - 500 Hz



(e) Relação entre força e resistência elétrica - 800 Hz




(f) Relação entre força e resistência elétrica - 1000 Hz




(g) Relação entre força e resistência elétrica - 2000 Hz


Figura 28 – Relação *Força*  $\times$  *Resistência Elétrica* para a mola de LMF em diferentes frequências (valores normalizados)




(a) Relação entre força e resistência elétrica - 100 Hz




(b) Relação entre força e resistência elétrica - 200 Hz




(c) Relação entre força e resistência elétrica - 400 Hz




(d) Relação entre força e resistência elétrica - 500 Hz



(e) Relação entre força e resistência elétrica - 800 Hz




(f) Relação entre força e resistência elétrica - 1000 Hz



(g) Relação entre força e resistência elétrica - 2000 Hz

Figura 29 – Curva Força x Resistência Elétrica com assíntotas



Nesta figura, através das assíntotas, pode-se perceber duas diferentes inclinações, indicadas pela assíntota 1 e pela assíntota 2, respectivamente. A região coincidente com a assíntota 1 corresponde à faixa onde o material encontra-se totalmente em seu estado de martensita, enquanto a região coincidente com a assíntota 2 corresponde à faixa onde o material encontra-se totalmente em seu estado de austenita. A região intermediária, onde há mudança seguida de inclinação, corresponde a uma faixa de transição, onde o material se transforma da fase martensita para fase austenita gradualmente. Esta interpretação baseia-se no fato de que a inclinação da curva **Força × Resistência Elétrica** depende da porcentagem de martensita ou austenita no material, e que quando o material encontra-se completamente na fase martensita ou austenita, esta inclinação tende a ser constante.

Para encontrar os pontos exatos de início e final da austenita e martensita ( $A_s$ ,  $A_f$ ,  $M_s$  e  $M_f$ , respectivamente), carecem experimentos que integrem as curvas levantadas com as curvas de temperatura, nas quais as temperaturas de transformação estão bem definidas.

Por fim, cabe destacar que as curvas apresentadas possuem histerese, em maior ou menor grau, justificando, assim, o uso de redes neurais para desenvolvimento da estratégia de controle dos atuadores de LMF.

## 4.2 Escolha da frequência do sinal PWM

A análise da Figura 28 permitiu concluir a forma das curvas tendem a ser iguais, variando apenas em seus valores iniciais de força e resistência elétrica que, por sua vez, dependem de fatores externos, tais como temperatura, fadiga do material e desgaste da plataforma de teste. Para tornar a análise mais completa, realiza-se uma comparação das curvas normalizadas a diferentes frequências, para verificação de algum padrão não-usual neste comportamento. Nas figuras 30, 31 e 32 são mostrados gráficos de comparação das curvas de diferentes frequências.

Figura 30 – Comparação das curvas de diferentes frequência - Experimento 1




Figura 31 – Comparação das curvas de diferentes frequência - Experimento 2





Figura 32 – Comparação das curvas de diferentes frequência - Experimento 3



Ao analisar as figuras 30, 31 e 32, nota-se que as curvas de frequência 1000 Hz e 2000 Hz tendem a se afastar das curvas de frequência mais baixa. Uma hipótese para tal fato é que, pelo fato de os sistemas térmicos serem dezenas de vezes mais lentos que os sistemas elétricos, frequências muito altas tendem a não conseguir prover o mesmo nível de potência ao atuador de LMF. Porém, faltam dados suficientes para uma melhor explicação do fenômeno, bem como a estimulação da mola a frequências mais altas.

Em termos de controle, contudo, prioriza-se a escolha das frequências mais baixas ( $f \leq 500\text{Hz}$ ), uma vez que tendem a ser mais próximas de um padrão único. Além disso, a escolha de frequências mais baixas diminui a taxa de amostragem mínima, não sobrecarregando, assim, o sistema de aquisição.

Para implementação do controle do atuador de LMF, será utilizada a frequência de 100 Hz.

### 4.3 Treinamento da Rede Neural

Conforme exposto na seção 3.4, diversas ciclagens foram feitas utilizando duas molas de LMF na plataforma experimental mostrada na Figura 19, e os dados coletados nessas ciclagens foram utilizados para o treinamento das redes neurais propostas. Uma terceira mola, de mesmo tamanho das utilizadas no treinamento, foi utilizada para realização dos testes da utilização das RNAs treinadas como sensor e como modelo para o controlador preditivo.

### 4.3.1 Rede Neural como Sensor

Iniciamente, nas figuras Figura 33 e Figura 34 são mostrados os testes feitos com RNAs do tipo *feedforward* com uma e duas camadas escondidas, respectivamente. Estas redes são mostradas na Figura 23.

Um segundo teste foi feito com os mesmos dados e é mostrado nas figuras Figura 35 e Figura 36. Neste teste, são utilizadas RNAs recorrentes, com realimentação a partir da saída e das camadas ocultas, conforme visto na Figura 24. Novamente, são testadas redes com uma e duas camadas escondidas.


A fim de comparação entre os resultados obtidos, foram calculados os erros médios quadráticos (MSE) entre os valores fornecidos pelas RNAs que atuam como sensores e o módulo HX711, leitor de força na célula de carga. Os valores de MSE calculados são mostrados na tabela 3. Os valores de MSE apresentados se referem às médias entre os três experimentos realizados para cada topologia de rede.

A análise da Tabela 3 permite verificar que um aumento no número de camadas ocultas, tanto para as redes recorrentes quanto para as redes do tipo *feedforward* não fornecem uma melhoria significativa no desempenho da estimação de força. Além disso, o uso de RNAs recorrentes não se mostrou mais eficiente que as RNAs *feedforward*. De fato, os valores de MSE são bem próximos para ambas as topologias. Portanto, tomando como base estes dados, a RNA do tipo *feedforward* com uma camada oculta é escolhida para implementação do sensor para *feedback* de resistência elétrica, visando a simplicidade de implementação e menor custo de processamento computacional. Além disso, por possuir um menor número de neurônios e pesos, esta topologia tende a ter melhor capacidade de generalização.


### 4.3.2 Rede Neural como Modelo para o Controlador Preditivo

A partir dos resultados obtidos pela a RNA do tipo *feedforward* como sensor, é projetada uma RNA *feedforward* com uma camada oculta, conforme mostrado na Figura 25. Na figura Figura 37 são mostrados os testes feitos com a rede treinada. Vale ressaltar, conforme visto na subseção 3.4.2, que esta RNA utiliza como entrada os valores de corrente elétrica aplicada à mola de LMF e o sinal de *Tag*, visto que são as variáveis que efetivamente podem ser alteradas.


A média dos valores de MSE dos testes feitos foi de 1,21. Não foram realizados testes com RNAs com mais de uma camada oculta.

Figura 33 – Treinamento de uma RNA do tipo *feedforward* com uma camada oculta

(a) Experimento 1




(b) Experimento 2




(c) Experimento 3




Figura 34 – Treinamento de uma RNA do tipo *feedforward* com duas camadas ocultas

(a) Experimento 1




(b) Experimento 2




(c) Experimento 3


Figura 35 – Treinamento de uma RNA recorrente com uma camada escondida



(a) Experimento 1




(b) Experimento 2




(c) Experimento 3


Figura 36 – Treinamento de uma RNA recorrente com duas camadas escondidas



(a) Experimento 1




(b) Experimento 2




(c) Experimento 3


Figura 37 – Treinamento da RNA do tipo *feedforward* com uma camada escondida para modelo do controlador preditivo



(a) Experimento 1



(b) Experimento 2



(c) Experimento 3

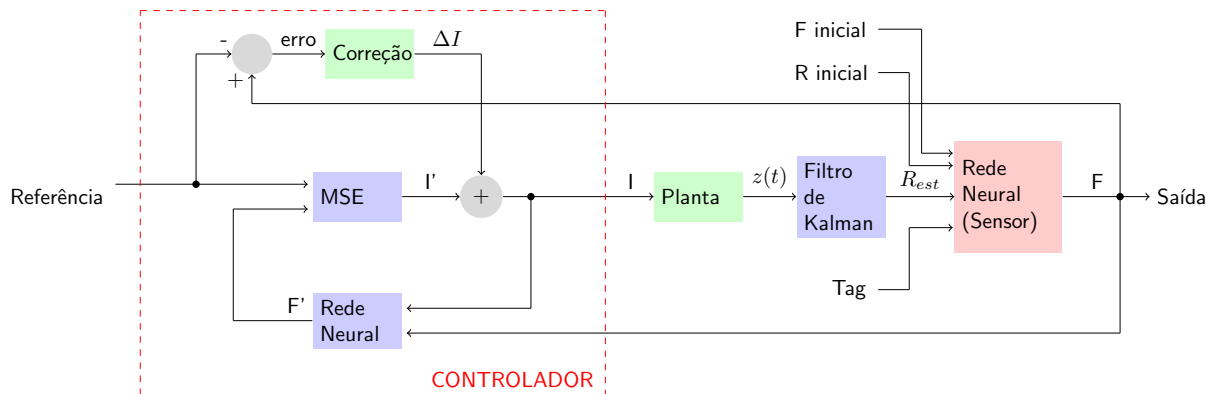
Tabela 3 – Valores do MSE para os diferentes tipos de RNAs

Tipo de Rede	MSE
RNA <i>feedforward</i> com uma camada oculta	6,25
RNA <i>feedforward</i> com duas camadas ocultas	2,79
RNA recorrente com uma camada oculta	7,98
RNA recorrente com três camadas ocultas	3,02

## 4.4 Controlador Preditivo


Um controlador preditivo simplificado foi projetado conforme visto na seção 3.5. O sistema como um todo, portanto, utiliza duas RNAs: uma como sensor e outra como modelo para o controlador. O sistema em malha fechada controlado por *feedback* de resistência elétrica é mostrado na Figura 38, onde  $I'$  é a corrente prevista pelo controlador a ser aplicada ao sistema,  $\Delta I$  é a quantidade de corrente a ser adicionada à corrente prevista pelo controlador devido ao fator de correção,  $I$  é a corrente elétrica efetivamente aplicada à mola de LMF,  $R$  é o valor de resistência elétrica estimada pelo Filtro de Kalman através do sensor,  $F$  é a força prevista pela RNA que atua como sensor e  $F'$  é a força prevista pela RNA que atua como modelo do controlador.

Figura 38 – Diagrama de blocos do sistema em malha fechada




Dois diferentes experimentos foram conduzidos para testar o controle e são mostrados na Figura 39 e na Figura 40, respectivamente. Nestes gráficos, são mostrados as comparações entre os dados de força medidos pelo módulo HX711, pela rede neural e a referência, além do sinal de entrada de corrente calculdo pelo controlador.

Figura 39 – Controle de força usando controle preditivo baseado em RNA




(a) Comparação dos valores de força com a referência desejada




(b) Valores da corrente de entrada

Figura 40 – Controle de força usando controle preditivo baseado em RNA



(a) Comparação dos valores de força com a referência desejada




(b) Valores da corrente de entrada


A partir da análise dos gráficos das figuras 39 e 40, percebe-se que o valor de força estimado pela RNA sensora acompanha com boa precisão o valor de referência, fato comprovado através dos gráficos mostrados na Figura 41. Porém, o valor de força lida

pelo módulo HX711 não segue tão bem a referência quando o valor estimado pela RNA, embora esteja sempre próximo a esse valor. Isto é explicado pelo fato que o controlador utiliza como feedback de força a leitura da rede neural, ou seja, há uma convergência de controle em relação à estimativa de força fornecida pela RNA sensora. Se o valor estimado da RNA sensora difere do valor fornecido pelo sensor de força, o controle será satisfatório em relação à leitura da rede, mas insatisfatório em relação ao sensor real de força. Este fato exemplifica bem a razão de possuir boas aproximações nas redes neurais treinadas.

Figura 41 – Comparação do erro entre a força exercida e o valor de referência da força



(a) Erro entre os valores de força com a referência desejada para o experimento 1



(b) Erro entre os valores de força com a referência desejada para o experimento 2



O controle preditivo baseado em redes neurais, portanto, mostrou-se eficiente no controle do atuador de LMF, desde que as redes neurais utilizadas estejam próximas dos valores reais estimados.

## 5 Conclusões

Neste trabalho, foi desenvolvido um estudo sobre o funcionamento e técnicas de sensoriamento e controle de atuadores de liga de memória de forma através de redes neurais artificiais. Dentre os trabalhos desenvolvidos, destacam-se o projeto do Filtro de Kalman para a dada aplicação, o projeto da RNA sensora e o projeto do controlador preditivo simplificado baseado em uma RNA treinada como modelo do sistema. Também, experimentos com uma mola de LMF foram conduzidos para levantamento das curvas de Força  $\times$  Resistência Elétrica. A partir dos dados levantados, foi descrito o comportamento da relação entre força e resistência elétrica com base nas transformações de fase do material e foi escolhida uma frequência de acionamento para os fios de SMA a serem utilizados na mola de LMF.

A partir dos resultados experimentais obtidos e explanados no Capítulo 4, destacam-se nos seguintes pontos:

- O comportamento da relação entre força e resistência elétrica é não-linear e histerético, sendo necessário, portanto, estratégias de análise e controle mais refinadas;
- A utilização do Filtro de Kalman Estendido trouxe mais exatidão e confiabilidade às leituras realizadas, as quais tendem a ser ruidosas, especialmente devido ao sensor de corrente por efeito Hall;
- As transformações de fase em LMFs modificam a inclinação da relação entre força e resistência elétrica. Isso era esperado devido à mudança na estrutura cristalina do material e é esperado que a inclinação das curvas que envolvem resistência elétrica possuam comportamento semelhante em relação a outras grandezas físicas, tais como temperatura e deformação do material;
- O formato das curvas de Força  $\times$  Resistência Elétrica tende a seguir um padrão específico conforme visto nas curvas normalizadas obtidas pela mola de LMF, embora estejam graficamente deslocadas devido ao desgaste natural do material. De fato, o comportamento analisado tende a ser repetitivo ao se analisar as variações de força e resistência elétrica, o que tornou possível o treinamento e uso de RNAs no projeto do sensor para realimentação e no projeto do controlador;
- O uso de redes neurais *feedforward* foi eficiente em reproduzir as curvas dos experimentos-teste realizados, tanto como sensor para *feedback* de resistência elétrica quanto para atuar como um modelo para o controlador preditivo. Por outro lado, o uso de redes neurais recorrentes não trouxe uma melhora significativa nas previsões, justificando

assim o uso de uma topologia mais simples e que exige menor esforço computacional. Além disso, o número de camadas utilizadas apresentou pouca influência em relação à eficiência;

- O modelo de controlador proposto foi eficiente em se tratando de seguir a referência a partir dos dados de leitura da RNA sensora. Houve pequenos erros em relação à leitura proveniente do módulo HX711 devido aos desvios da leitura da RNA sensora em relação à leitura do módulo, naturalmente ruidosa. Embora os erros não tenham sido consideráveis, uma melhora no modelo da rede neural sensora, assim como uma melhor filtragem da leitura do módulo HX711, acarretará maior precisão no controle.

Em resumo, o uso de redes neurais artificiais no projeto de controle do atuador de LMF mostrou-se interessante, tendo em vista que o comportamento não-linear e histerético foi bem descrito e um controle baseado utilizando *feedback* de resistência elétrica foi bem sucedido. Naturalmente, o fenômeno de memória de forma envolve uma gama maior de variáveis, o que teoricamente poderia dificultar o controle da força de um atuador quando tem-se apenas a informação de resistência elétrica do mesmo. Porém, o uso de RNAs, tanto no sensoreamento quanto no controle da mola conseguiu superar as dificuldades naturais da modelagem e atuação sobre o dispositivo. Obviamente, uma melhor instrumentação eletrônica do sistema, bem como melhores modelos das redes neurais, podem tornar o projeto mais eficiente.

São propostos, para a continuação da pesquisa, os seguintes itens:

- Melhoramento do circuito de acionamento e medição utilizado, visando maior precisão na obtenção de resultados;
- Levantamento de curvas de resistência elétrica para diferentes molas de diferentes dimensões, visando maior generalidade no projeto de controle de atuadores de LMF;
- Estudo de topologias diferentes de redes neurais visando maior aproximação entre modelos e dados experimentais;
- Estudo de metodologias diferentes de controle que envolvam os modelos de redes neurais levantados

# Referências

- BIL, C.; MASSEY, K.; ABDULLAH, E. J. Wing morphing control with shape memory alloy actuators. *Journal of Intelligent Material Systems and Structures*, v. 24, n. 7, p. 879–898, 2013. Citado 2 vezes nas páginas 17 e 18.
- BUEHLER, W. J.; GILFRICH, J. W.; WILEY, R. C. Effects of low-temperature phase changes on the mechanical properties of alloys near composition tni. *Journal of Applied Physics*, v. 34, p. 475, 1963. Citado na página 17.
- BUEHLER, W. J.; WANG, F. E. A summary of recent research on the nitinol alloys and their potential application in ocean engineering. *Ocean Engineering*, v. 1, n. 1, p. 105 – 120, 1968. ISSN 0029-8018. Citado na página 20.
- BUTERA, F.; CODA, A.; VERGANI, G. Shape memory actuators for automotive applications. *Nanotec IT newsletter*, p. 12–16, 2007. Citado na página 17.
- CHENG, L. et al. Neural-network-based nonlinear model predictive control for piezoelectric actuators. *IEEE Transactions on Industrial Electronics*, v. 62, n. 12, p. 7717–7727, Dec 2015. ISSN 0278-0046. Citado na página 35.
- CUI, D.; SONG, G.; LI, H. Modeling of the electrical resistance of shape memory alloy wires. *Smart Materials and Structures*, v. 19, n. 5, p. 055019, 2010. Citado na página 21.
- DAQ M Series NI USB-621x User Manual. [S.l.], 2009. Citado na página 40.
- DUERIG, T.; PELTON, A.; STÖCKEL, D. An overview of nitinol medical applications. *Materials Science and Engineering: A*, v. 273-275, p. 149 – 160, 1999. ISSN 0921-5093. Citado na página 18.
- FUJITA, H.; TOSHIYOSHI, H. Micro actuators and their applications. *Microelectronics Journal*, v. 29, n. 9, p. 637 – 640, 1998. ISSN 0026-2692. Low Dimensional Structures and Devices: Micromachined Devices. Citado na página 18.
- FURUYA, Y. Design and material evaluation of shape memory composites. *Intell Mater Syst Struct*, p. 321–330, 1996. Citado na página 17.
- FURUYA, Y.; SHIMADA, H. Shape memory actuators for robotic applications. *Materials & Design*, v. 12, n. 1, p. 21 – 28, 1991. ISSN 0261-3069. Citado na página 18.
- GEORGIEVA, P.; AZEVEDO, S. F. Neural networks for model predictive control. In: . [S.l.: s.n.], 2011. p. 111–118. ISBN 978-1-4244-9635-8. Citado na página 33.
- HARTL, D. J.; LAGOUDAS, D. C. Aerospace applications of shape memory alloys. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, v. 221, n. 4, p. 535–552, 2007. Citado 2 vezes nas páginas 17 e 18.
- A. Hautcoeur e A. Eberthardt. *Eyeglass frame with very high recoverable deformability*. 1997. US 5640217. Citado na página 17.

- HAYKIN, S. *Redes Neurais: princípios e práticas*. [S.l.]: Bookman, 2001. Citado na página 28.
- HENDERSON, G. Fundamentals of kalman filtering: a practical approach – third edition. progress in aeronautics and astronautics. *The Aeronautical Journal* (1968), Cambridge University Press, v. 114, n. 1152, p. 121–122, 2010. Citado na página 22.
- HUANG, J.-Q.; LEWIS, F. L. Neural-network predictive control for nonlinear dynamic systems with time-delay. *IEEE Transactions on Neural Networks*, v. 14, n. 2, p. 377–389, March 2003. ISSN 1045-9227. Citado na página 35.
- HUMBEECK, J. V. Non-medical applications of shape memory alloys. *Materials Science and Engineering: A*, v. 273-275, p. 134 – 148, 1999. ISSN 0921-5093. Citado 2 vezes nas páginas 17 e 18.
- JANI, J. M. et al. A review of shape memory alloy research, applications and opportunities. *Materials & Design* (1980-2015), v. 56, p. 1078 – 1113, 2014. ISSN 0261-3069. Citado 2 vezes nas páginas 17 e 19.
- JAZWINSKI, A. H. *Stochastic processes and filtering theory*. [S.l.]: Dover Publications, inc., 2007. Citado na página 25.
- KAHN, H.; HUFF, M. A.; HEUER, A. H. The tini shape-memory alloy and its applications for mems. *Journal of Micromechanics and Microengineering*, v. 8, n. 3, p. 213, 1998. Citado na página 18.
- KALMAN, R. E. A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, v. 82, n. 35, 1960. Citado na página 21.
- KHEIRIKHAH, M. M.; RABIEE, S.; EDALAT, M. E. A review of shape memory alloy actuators in robotics. In: SOLAR, J. Ruiz-del; CHOWN, E.; PLÖGER, P. G. (Ed.). *RoboCup 2010: Robot Soccer World Cup XIV*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. p. 206–217. Citado na página 18.
- KOHL, M. *Shape Memory Actuators*. [S.l.]: ed. Heidelberg, 2010. Citado na página 18.
- KRIESEL, D. *A Brief Introduction to Neural Networks*. [S.l.]: Bookman, 2005. Citado 2 vezes nas páginas 28 e 33.
- ÖLANDER, A. An electrochemical investigation of solid cadmium-gold alloys. *Journal of the American Chemical Society*, v. 54, n. 10, p. 3819–3833, 1932. Citado na página 17.
- LI, J.; TIAN, H. Position control of sma actuator based on inverse empirical model and smc-rbf compensation. *Mechanical Systems and Signal Processing*, v. 108, p. 203 – 215, 2018. ISSN 0888-3270. Citado na página 15.
- LIAO, G.-H. Design of rigid elastic coupling passive micro-sucker based on sma<xref ref-type="fn"rid="b9789814699143\_0059fn001"ptype="b"citart="citart1"></xref>. In: \_\_\_\_\_. *Mechanics and Mechatronics (ICMM2015)*. [S.l.: s.n.], 2016. p. 470–475. Citado na página 15.
- MA GANGBING SONG, H. J. L. N. *Position control of SMA actuators with internal electrical resistance feedback*. 2003. 5049 - 5049 - 10 p. Disponível em: <<http://dx.doi.org/10.1117/12.484059>>. Citado na página 21.

- MA, N.; SONG, G. Control of shape memory alloy actuator using pulse width modulation. *Smart Materials and Structures*, v. 12, n. 5, p. 712, 2003. Citado na página 36.
- MORGAN, N. Medical shape memory alloy applications—the market and its products. *Materials Science and Engineering: A*, v. 378, n. 1, p. 16 – 23, 2004. ISSN 0921-5093. European Symposium on Martensitic Transformation and Shape-Memory. Citado na página 18.
- NIKDEL, N. et al. 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, March 2014. ISSN 0278-0046. Citado 2 vezes nas páginas 34 e 35.
- NOVÁK, V. et al. Electric resistance variation of niti shape memory alloy wires in thermomechanical tests: Experiments and simulation. *Materials Science and Engineering: A*, v. 481-482, p. 127 – 133, 2008. ISSN 0921-5093. Proceedings of the 7th European Symposium on Martensitic Transformations, ESOMAT 2006. Citado na página 21.
- PAI, A.; RIEPOLD, M.; TRACHTLER, A. A model extended temperature and strain controller modulated with pwm for precision position control of shape memory alloy actuators. In: *2016 IEEE International Conference on Advanced Intelligent Mechatronics (AIM)*. [S.l.: s.n.], 2016. p. 442–447. Citado na página 15.
- PAN, Y. et al. Output-feedback adaptive neural control of a compliant differential sma actuator. *IEEE Transactions on Control Systems Technology*, v. 25, n. 6, p. 2202–2210, Nov 2017. Citado na página 15.
- SCHETKY, L. M. Shape memory alloy applications in space systems. *Materials & Design*, v. 12, n. 1, p. 29 – 32, 1991. ISSN 0261-3069. Citado 2 vezes nas páginas 17 e 18.
- SCHIEDECK, F.; MOJRZISCH, S. Design of a robust control strategy for the heating power of shape memory alloy actuators at full contraction based on electric resistance feedback. *Smart Materials and Structures*, v. 20, n. 4, p. 045002, 2011. Citado na página 21.
- SEBORG, D. E.; EDGAR, T. F.; MELLICHAMP, D. A. *Process Dynamics and Control*. [S.l.]: John Wiley & Sons, 2010. Citado na página 34.
- SHAPE memory actuators for automotive applications. *Materials & Design*, v. 11, n. 6, p. 302 – 307, 1990. ISSN 0261-3069. Citado na página 17.
- SILVA, A. F. C. *Desenvolvimento e Caracterização de uma Mão Robótica Acionada por Atuadores de Liga com Memória de Forma*. Tese (Doutorado) — Universidade Federal de Campina Grande, 2015. Citado 2 vezes nas páginas 15 e 17.
- SREEKUMAR, M. et al. Critical review of current trends in shape memory alloy actuators for intelligent robots. *Industrial Robot: the international journal of robotics research and application*, v. 34, n. 4, p. 285–294, 2007. Citado na página 18.
- SRIVASTAVA, A.; WARD, C.; PATEL, R. V. Adaptive neural preisach model and model predictive control of shape memory alloy actuators. In: *2017 IEEE International Conference on Advanced Intelligent Mechatronics (AIM)*. [S.l.: s.n.], 2017. p. 1179–1184. ISSN 2159-6255. Citado na página 35.

- SUN, L. et al. Stimulus-responsive shape memory materials: A review. *Materials & Design*, v. 33, p. 577 – 640, 2012. ISSN 0261-3069. Citado na página 18.
- WANG, T.; GAO, H.; QIU, J. A combined adaptive neural network and nonlinear model predictive control for multirate networked industrial process control. *IEEE Transactions on Neural Networks and Learning Systems*, v. 27, n. 2, p. 416–425, Feb 2016. ISSN 2162-237X. Citado na página 35.
- WU, M. H.; SHETCKY, L. M. Industrial applications for shape memory alloys. *International conference on shape memory and superelastic technologies*, p. 171–182, 2000. Citado na página 17.
- YOO, S.; PARK, J.; CHOI, Y. Stable predictive control of chaotic systems using self-recurrent wavelet neural network. *International Journal of Control, Automation and Systems*, v. 3, p. 43–55, 03 2005. Citado na página 35.
- YOO, S. J.; CHOI, Y. H.; PARK, J. B. Generalized predictive control based on self-recurrent wavelet neural network for stable path tracking of mobile robots: adaptive learning rates approach. *IEEE Transactions on Circuits and Systems I: Regular Papers*, v. 53, n. 6, p. 1381–1394, June 2006. ISSN 1549-8328. Citado na página 35.
- ZHANG, J.-J.; YIN, Y.-H.; ZHU, J.-Y. Electrical resistivity-based study of self-sensing properties for shape memory alloy-actuated artificial muscle. *Sensors*, v. 13, n. 10, p. 12958–12974, 2013. ISSN 1424-8220. Citado na página 21.
- ZHANG, L.; XU, M.; YANG, H. Research on soft manipulator actuated by shape memory alloy (sma) springs. In: *2017 IEEE International Conference on Real-time Computing and Robotics (RCAR)*. [S.l.: s.n.], 2017. p. 74–78. Citado na página 15.
- R. B. Zider e J. F. Krumme. *Eyeglass frame including shape-memory elements*. 1988. US 4772112. Citado na página 17.