

UNIVERSIDADE DE PASSO FUNDO – Engenharia Mecânica
Disciplina MEC041 - Trabalho Final de Graduação II

ANÁLISE DE REDES NEURAIS ARTIFICIAIS NO COMPORTAMENTO DA VIDA EM FADIGA DE JUNTA SOLDADA DO AÇO LN-700

Luiz André Fortuna Menegaz
luizandremenegaz@hotmail.com

Prof. Dr. Charles Leonardo Israel
israel@upf.br

Comissão Examinadora – Prof. Dr. Luiz Airton Consalter, Prof. Dr. William Haupt

RESUMO

O conhecimento do comportamento de um material quando é solicitado em diferentes condições de carregamentos se torna uma das principais etapas para se entender a sua utilidade, pois possibilita o seu dimensionamento correto para diversas aplicações, visando que não falhe e apresente uma vida útil apropriada. No momento em que um material é submetido a tensões cíclicas, efeitos indesejáveis podem acontecer, como o início e a propagação de trincas e falhas por fadiga e, com isso a probabilidade de falhar catastróficamente. O presente trabalho consiste na avaliação numérica do ensaio de fadiga de uma junta soldada do aço LN-700 via redes neurais artificiais dividida em duas etapas: a primeira é comparar o ensaio de fadiga do material base soldado com o não soldado e a segunda é definir qual energia de soldagem e material de adição foi mais efetivo para ser usado no material base LN-700 em comparação com as propriedades mecânicas do aço LN-700 não soldado. Com os resultados do trabalho, foi possível validar o modelo de redes neurais artificiais utilizado, correlacionando as análises encontradas com as análises da literatura. A rede neural artificial foi treinada com exatidão, obtendo nesse caso 100% dos dados acertados em sua previsão, definindo o metal de adição ER90S-D2 e a energia de soldagem de 0,44 (KJ/mm) como os que mais se adequaram no ensaio de fadiga as propriedades mecânicas do metal base.

Palavras chave: fadiga; aço LN-700; redes neurais artificiais; soldagem.

1 INTRODUÇÃO

A Inteligência Artificial é um tópico que vem se tornando muito popular nesses últimos anos quando o assunto abordado é a Indústria 4.0. Com o passar dos anos, as máquinas inventadas pelos homens vêm substituindo o trabalho braçal realizado para facilitar o processo do trabalho.

As Redes Neurais Artificiais (RNA) são muito presentes na Inteligência Artificial, uma vez que em quase todos os métodos agregados se usam as redes neurais.

As RNA têm por sua lógica de funcionamento os neurônios biológicos dos seres humanos, buscado copiar o processamento de informações que um neurônio biológico tem para a sua

autoaprendizagem. As RNAs vêm sendo muito usadas pela sua praticidade em aplicar qualquer tipo de informação para prever soluções de problemas. Devido a essa praticidade o seu uso se torna muito atraente, pelo fato de reduzir drasticamente o tempo que se levaria para realizar na forma física, obtendo assim, através do treinamento correto da RNA, os mesmos resultados. (ARANCIBIA, 2008)

O uso das RNAs na Indústria metalmeccânica vêm se tornando assíduo por ter uma aplicação muito versátil, através de um *software*, sendo capaz de solucionar problemas de forma mais rápida e com a mesma eficiência que na prática.

A ideia do presente estudo se assemelha ao de Maleki e Reza (2017) com a modelagem do comportamento de fadiga do aço CK45 dos efeitos do revestimento de níquel, onde se usa as RNAs em seu estudo.

O foco de estudo é obter através da RNA uma comparação do ensaio de fadiga do aço LN-700 soldado com o não soldado, diferenciando os ensaios de fadiga realizados em ambos e indicando qual energia de soldagem e material de adição realizada na solda teve melhor performance em comparação com as propriedades mecânicas no material.

Para uma boa soldagem, espera-se que as propriedades mecânicas da junta soldada continuem semelhantes ao do metal base. Para isso acontecer, optou-se pela escolha da menor energia de soldagem. O metal de adição foi escolhido de acordo com os já utilizados na indústria (ER70S6, ER90S-D2), por conta de seu baixo custo e de ser coerente ao material que tenha as propriedades mecânicas próximas às do metal base, obtendo assim uma melhor soldabilidade e atuação na curva S-N. (ESMELINDRO, 2015)

Com o tratamento dos dados e a realização do treinamento e dos testes para validação da RNA, se obterá os elementos encontrados através da rede onde por fim será feita a correlação com o que já se conhece na literatura, a fim de validar as previsões feitas pela RNA. O *software* utilizado para implementação da RNA foi o *R Studio*.

1.1 Objetivo Geral

Correlacionar os resultados numéricos obtidos pela rede neural artificial com os dados da literatura, quanto ao comportamento do ensaio de fadiga do aço LN-700 soldado e sem solda.

1.2 Objetivos Específicos

- Comparar através de dados já conhecidos o ensaio de fadiga no aço LN-700 com solda e sem solda;
- Analisar o comportamento das diferentes energias de soldagem utilizadas no material base;
- Analisar o comportamento dos diferentes materiais de adição utilizados no material base;
- Realizar uma análise pelas redes neurais artificiais, para avaliar o ensaio de fadiga do aço LN-700 soldado;
- Realizar o treinamento e o teste nas redes neurais artificiais.

2 REVISÃO BIBLIOGRÁFICA

Os itens a seguir apresentam a fundamentação teórica utilizada para o desenvolvimento do presente estudo. Os tópicos abordados são: estado da arte já experimentados na Rede Neural Artificial, aços de resistência elevada e sua aplicação, soldabilidade de aços e zona termicamente afetada, ensaio de fadiga, redes neurais e redes neurais artificiais.

2.1 Estado da arte de estudos já experimentados na Rede Neural Artificial

Importantes estudos mostram que o uso de redes neurais artificiais traz bons resultados quando o assunto se trata de confiabilidade e rapidez em realizar o processo a ser executado.

Gorni e Silva (2013) estudaram a comparação entre os modelos para o cálculo de carga na laminação a quente industrial aplicando redes neurais artificiais, tendo afirmado que o cálculo de carga de laminação por redes neurais se destacou por ser preciso, tornando-se muito boa a adoção desse recurso.

Santos e Bonventi Jr. (2020) avaliaram o controle de sistemas eletro-mecânicos por redes neurais artificiais recorrentes e afirmaram que a resposta do treinamento da rede possui convergência rápida, porém, devido a isso são necessárias várias seções de treinamento em uma rede neural.

No estudo de Maleki e Reza (2017) foi aplicado o método de elementos finitos e redes neurais artificiais para modelar os efeitos do revestimento de níquel endurecido no comportamento a fadiga do aço CK45 utilizando a base de algoritmo de erro de propagação reserva (BP). Realizaram uma comparação entre essas duas análises e concluíram que o método de redes neurais artificiais é o mais preciso para analisar o comportamento da vida em fadiga do aço CK45 em relação ao método de elementos finitos, porém ressaltam que com o método de elementos finitos se consegue realizar essa mesma modelagem para outros tipos de revestimentos no aço CK45. Já para as redes neurais é necessário realizar outros treinamentos envolvendo mudanças na estrutura da rede para poder prever a vida em fadiga com outro revestimento.

2.2 Aços de resistência elevada e sua aplicação (ARBL)

Os aços de alta resistência e baixa liga (ARBL) vem se destacando muito, pois sem o seu desenvolvimento a resistência era adquirida através de manganês e carbono, procedendo uma baixa tenacidade e soldabilidade. Com a adição de valores pequenos de elementos de liga nos aços ARBL se obtém boas tensões de escoamento (acima de 276 MPa), com um teor de carbono reduzido proporcionando uma boa soldabilidade. (MELLO JR et al., 2013)

Os aços ARBL são microligados e se compõem de um grupo específico de aços, possuindo elevadas propriedades mecânicas com o desenvolvimento de sua composição química. (ESMELINDRO, 2015)

2.3 Soldabilidade de aços e Zona Termicamente Afetada (ZTA)

A soldabilidade em aços é a eficácia com que um metal de acordo com as circunstâncias propostas pelo processo de fabricação tem de se deixar soldar, desempenhando adequadamente com uma boa estrutura aos trabalhos que serão empregados. (QUITES, 2008)

O objetivo de se realizar uma soldagem é procurar um material de adição que se adeque melhor as propriedades mecânicas do material base, para que após a soldagem não diminua as propriedades mecânica ao ponto de prejudicar o seu uso na indústria.

A ZTA é classificada como o local do metal base com a qual não foi fundida durante a soldagem por fusão. Esta, sofre alterações nas propriedades mecânicas e em sua microestrutura por decorrência do aporte térmico, através da intervenção da dissipação perto do metal de adição, por conta da fusão local e ao resfriamento rápido na junta soldada. Na Figura 1 tem-se um exemplo da ZTA, onde o calor criado perante o processo de soldagem muda as características do material criando as ZTA próximas a região do metal de adição. (QUITES, 2008)

A finalidade de uma solda boa é diminuir a região da ZTA, pois as trincas por fadiga se iniciam em seu interior. (JUNIOR, 2006 apud VURAL et al. 2011)




Figura 1 - Zona afetada pelo calor
(Fonte: Emelindro, 2015)

2.4 Ensaio de Fadiga

O fenômeno fadiga estima 90% das falhas que acontecem nos aços. O rompimento por fadiga acontece no emprego de esforços cíclicos na condição dinâmica com tensões muito menores com as obtidas em ensaios de tração e compressão. Isto ocorre após um tempo, por conta de esforços dinâmicos e vibratórios frequentes por meio desse ensaio. (GARCIA, 2000)

O responsável pelos primeiros dados que informavam o comportamento de materiais metálicos sujeitos a esforços alternados e repetitivos foi o Augusto Wohler. Os dados obtidos através desses ensaios normalmente se adequam em um gráfico, o qual relaciona tensão e número de ciclos até a fratura.

A avaliação da fadiga aperfeiçoada na tensão foi o primeiro método utilizado para a previsão da vida em fadiga. A curva S-N se encontra por meio de em um ensaio obtido através de um corpo de prova que é submetido a um carregamento de amplitude constante até a sua falha.

A Figura 2 mostra como exemplo de curva S-N as respostas naturais do ensaio de fadiga do aço UNS G41 300 normalizado, podendo ser analisado a sua vida finita, infinita.




Figura 2 - Curva característica do ensaio de fadiga
(Fonte: Budynas; Nisbeth, 2011)

2.5 Redes Neurais

O ser humano realiza diversas atividades no decorrer do seu dia, e para poder desenvolvê-las primeiro pensa no que precisa fazer para depois realizar sua tarefa, tendo como exemplo caminhar, realizar atividades físicas, entre várias outras coisas. O responsável por transmitir as informações pensadas do cérebro para o resto do corpo humano é chamado de rede neural.

O sistema nervoso humano é agrupado por uma rede de neurônios responsável por ações como emoção, pensamento e realização de funções autônomas. Essas informações são compartilhadas com diversas outras células, que são capazes de captar essas informações e transmiti-las para outras células, através de sinais eletroquímicos, chamados de sistema de comunicação cerebral. Na Figura 3 é mostrado um neurônio biológico, que é unido com diversos outros neurônios por meio do axônio e dos dendritos, onde os neurônios são o que o cérebro usa

para processar informações e o axônio é o que transmite o sinal de um neurônio para o outro. (ARANCIBIA, 2008)

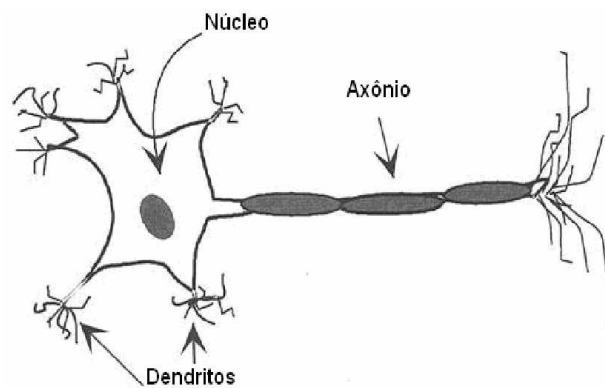


Figura 3 – Neurônio
(Fonte: Arancibia, 2008)

2.6 Redes Neurais Artificiais

Inspirado em uma rede neural biológica, as Redes Neurais Artificiais foram desenvolvidas com o intuito de imitar a performance do cérebro humano. Comparando-a com um computador o cérebro humano age de uma forma diferente, por ser um “computador” muito complexo, paralelizado e não linear, realizando alguns cálculos muitas vezes mais rápido que um computador. (HAYKIN, 2001)

Haykin (2001) mostra que uma Rede Neural Artificial possui uma capacidade extremamente grande de aprender e generalizar, derivando seu poder computacional de uma estrutura distribuída paralelamente. A generalização está interligada com a capacidade da Redes Neurais Artificiais produzir saídas para as entradas não encontradas durante o treinamento (aprendizagem), resolvendo problemas extremamente difíceis, promovendo as seguintes propriedades e capacidades essenciais:

- Uniformidade de análise;
- Tolerância com relação ao erro;
- Não linearidade;
- Mapeamento de entrada-saída;
- Adaptatividade;
- Resposta congruente.

Segundo Melo (2018), as Redes Neurais Artificiais são utilizadas em diversos tipos de problemas, tendo como aplicação: mineração dos dados, controle, otimização, reconhecimento de padrões, processamento de dados e previsões de séries temporais.

2.6.1 Execução de uma Rede Neural Artificial

Os algoritmos pensados para realizar uma rede neural artificial são feitos através de trabalhos com uma certa finalidade. A Redes Neural Artificial se compara ao cérebro humano em

duas fases: a primeira é o conhecimento encontrado por meio de processos de aprendizagem e a segunda são os pesos sinápticos (união existente entre os neurônios), que são utilizados para armazenar o conhecimento. A Figura 4 refere uma rede de neurônios artificiais, formando uma rede de processamento. (KOVÁCS, 2002)

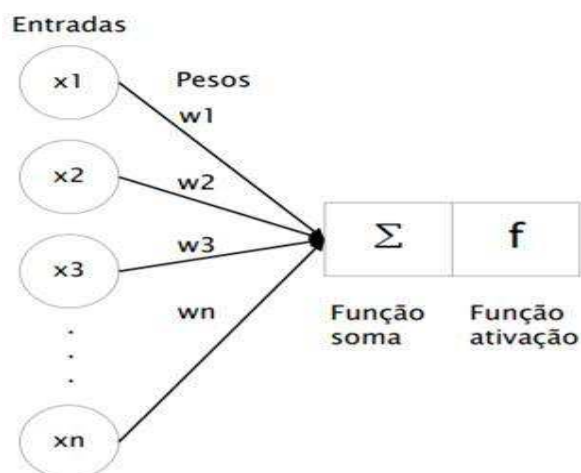


Figura 4 – Representação de um neurônio artificial
(Fonte: Adaptado de Granatyr, 2021)¹

Para a execução de uma Rede Neural Artificial, como visto na Figura 4, é necessária uma aquisição de dados de entrada que são comparadas aos neurônios de uma rede neural, para assim interliga-las com uma linha até a função soma e a função de ativação, onde cada linha é chamada de peso (axônio) que possui um valor chamado de w , onde a função soma será o somatório de cada dado de entrada multiplicado com o peso correspondente, como visto na Equação 1.

$$soma = \sum_{i=1}^n x_i * w_i \quad (1)$$

Há diversos meios de construir uma rede neural, que deve ser executada de acordo com os problemas a serem solucionados. Na sua arquitetura é encontrado vários parâmetros, como o número de camadas, os neurônios de cada camada e o tipo de peso empregado.

2.6.2 Aprendizagem de máquina

O método em que uma rede neural aprende é processado quando acontece diversas modificações significativas nos pesos dos neurônios, isso ocorre conforme for a ativação do neurônio. Se algumas ligações na Redes Neural Artificial são mais usadas entre todas, estas são reforçadas, enquanto as outras são enfraquecidas. Por conta disso, quando uma Redes Neural Artificial é implantada para uma certa aplicação, é preciso um tempo para que seja treinada para poder entender e realizar o problema proposto com sucesso.

Entre todas as formas de se executar uma Redes Neural Artificial, o que mais interessa entre elas é a sua forma de aprendizado, que acontece por meio de treinamentos da rede de questões às suas unidades visíveis.

¹ Figura adaptada das notas de aula do curso – Redes Neurais Artificiais em R, ministrada pelo Jones Granatyr em 2021 através da plataforma online udemy.com.

Nesse contexto, Arancibia 2008, mostra que em especial existem três formas de aprendizado em uma RNA:

- **Não-supervisionado:** A rede neural trabalha com seus dados de entrada sem ter informações sobre seus dados de saída, ou seja, ela emprega os dados de forma a determinar algumas propriedades do agrupamento de dados. Por meio dessas propriedades o aprendizado ocorre de forma contínua até chegar ao resultado esperado;
- **Supervisionado:** Nessa forma de aprendizagem, as Redes Neurais Artificiais recebem um agrupamento de dados de entrada e suas correspondentes saídas, onde conforme for o aprendizado da rede neural ocorrem ajustes nos pesos, de forma que o erro gerado com relação aos padrões de saída seja o menor possível, obtendo assim um valor desejável;
- **Híbrido:** Nessa forma acontece uma combinação dos tipos não-supervisionados e supervisionados, trabalhando em uma camada de uma forma, enquanto outra trabalha com outra.

2.6.3 Arquiteturas de Redes Neurais Artificiais

A forma com que uma Redes Neural Artificial é construída tem um significado muito importante, pois está interligado com a forma com que irá solucionar seu problema. Braga (2000, *apud* MELO, 2018) mostra que alguns padrões são levados em consideração para a definição da arquitetura de uma rede neural, sendo eles:

- Tipos de conexão entre os nós;
- Número de camadas;
- Número de camadas por nós;
- Topografia da rede.

Segundo Arancibia 2008, identifica-se três formas de construção de uma Redes Neural Artificial: redes *feed-forward* de uma única camada, redes *feed-forward* de múltiplas camadas e redes recorrentes.

Redes *feed-forward* de camada única: Se relaciona apenas a um nó com entrada e saída, sendo sua propagação unidirecional, visto na Figura 5.




Figura 5 – Rede Neural Artificial do tipo *feed-forward* de única camada
(Fonte: Arancibia, 2008)

Redes *feed-forward* de camadas múltiplas: Nesta forma, existem mais de um neurônio (camadas) entre a entrada e a saída vista na Figura 4(a), sendo normalmente treinadas com o algoritmo de retro propagação do erro (*backpropagation*) Figura 4(b), conforme Figura 6.

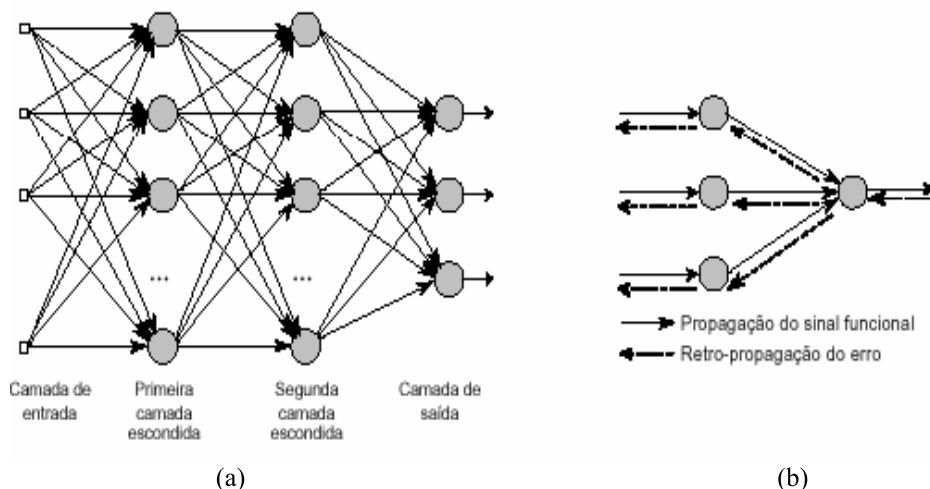


Figura 6 – Rede Neural Artificial de camada múltipla
(Fonte: Arancibia, 2008)

Redes recorrentes: Se difere das redes *feed-forward* pela existência de no mínimo um laço de recorrência (*feed-back*). Uma rede recorrente pode partir de apenas uma camada de neurônios com cada um alimentando seu sinal de saída para voltar ao começo de todos os neurônios. O laço possui um enorme impacto na forma com que a rede irá aprender, resultando em um comportamento dinâmico não-linear, mostrado na Figura 7.




Figura 7 – Rede Neural Artificial recorrente sem nenhuma camada intermediária
(Fonte: Arancibia, 2008)

2.6.4 O algoritmo *Back-Propagation* em Redes Neurais Multicamadas

A forma de treinamento mais empregada em Redes Neurais Multicamadas é o algoritmo *back-propagation*. Viveros (2018), afirma que este método recebe esse nome pois começa na última camada e retorna ajustando os pesos até a camada inicial. Esse algoritmo se divide em duas partes, como se confere na Figura 8:

- **Propagação:** Após definir os padrões de entrada a resposta de um neurônio é propagada como entrada para as uniões na camada posterior até a camada de saída, adquirindo a resposta da rede e calculando o erro;

- **Retro propagação:** Iniciando na camada de saída, são realizadas as modificações nos pesos até atingir a camada de entrada.




Figura 8 – Representação do algoritmo *back-propagation*
(Fonte: Adaptado de Viveros, 2018)

A Rede Neural de Multicamadas, observada na Figura 9, é caracterizada por possuir múltiplas camadas de unidades básicas do processamento do tipo *Perceptron*. Acrescentando-se mais camadas em suas redes neurais resulta na capacidade do processamento não linear e ampliação da rede neural. As Redes Neurais Multicamadas possuem treinamento de máquina supervisionado, buscando melhorar os pesos da rede por meio de dados de entradas conhecidos, para obter assim um conjunto de dados planejados de saída. (AGUIAR, 2010)

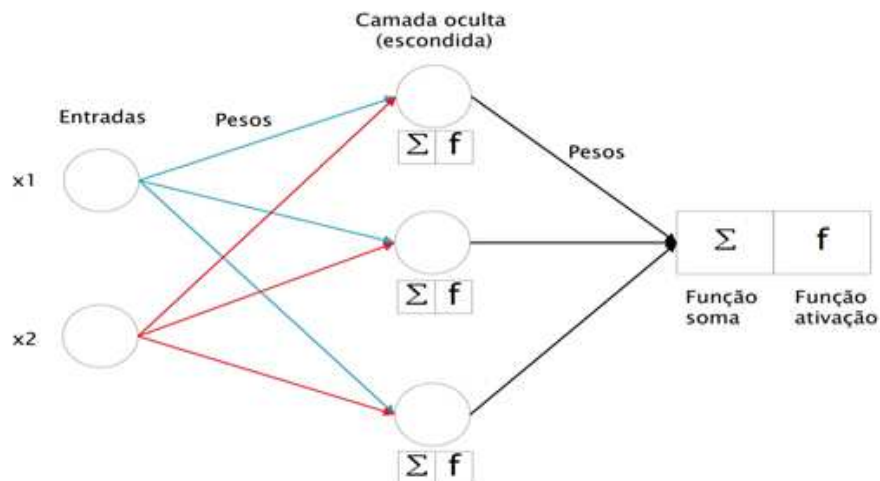


Figura 9 – Rede Neural de Multicamadas
(Fonte: Adaptado de Granatyr, 2021)²

² Figura adaptada das notas de aula do curso – Redes Neurais Artificiais em R, ministrada pelo Jones Granatyr em 2021 através da plataforma online udemy.com.

Como visto na Figura 9 o andamento do processo de cada neurônio é diretamente influenciado pelo executado nas unidades das camadas anteriores. Cada camada desempenha um cargo específico, como por exemplo na Figura 9, com uma rede de 3 camadas, onde se tem:

- **Camada de entrada:** Camada receptora dos dados;
- **Camada oculta:** Cada neurônio define uma reta no espaço de decisão, definindo as propriedades dos padrões apresentados;
- **Camada de saída:** Ajusta as regiões desenvolvidas pela camada anterior, definindo o espaço de saída da rede neural.

A forma mais simples para determinar a quantidade de neurônios necessários para uma Rede Neural de Multicamadas é vista na Equação 2. Mas a relação para definir as camadas ocultas não é tão aparente. Recomenda-se aplicar a menor quantidade possível de camadas ocultas para que a generalização da rede não se torne difícil. Se o número de neurônios em uma camada oculta for extremamente grande, a rede neural acaba memorizando as propostas apresentadas no treinamento, mas se a estrutura das camadas ocultas possuir quantidades de processamento inferior ao que precisa, o algoritmo *back-propagation* bloqueará a convergência para uma resposta, podendo não conseguir ajustar os pesos. (AGUIAR, 2010)

$$\text{Neurônios} = \frac{\text{Entradas} + \text{Saídas}}{2} \quad (2)$$

2.6.5 Ajustes dos pesos e cálculo do erro

Ao se iniciar o treinamento de uma rede neural, os pesos que se interligam com as camadas de uma rede são iniciados com valores pequenos e aleatórios, evitando a saturação da função de ativação e a incapacidade de realizar o algoritmo de aprendizagem. Conforme o treinamento evolui, os pesos podem passar a adotar valores maiores, pressionando a operação dos neurônios na região onde é muito baixa a derivada da função. Como a derivada é proporcional ao erro retro-propagado, o treino tende a se instabilizar, parando a rede sem encontrar uma solução. Para isso ser resolvido, deve-se aplicar uma taxa de aprendizagem menor. (ARANCIBIA, 2008)

Uma das formas mais simples de se aplicar um algoritmo para calcular o erro dos pesos da rede neural é vista na Equação 3, onde se aplica a resposta correta que se deseja para esse erro juntamente com a resposta calculada.

$$\text{erro} = \text{respostaCorreta} - \text{respostaCalculada} \quad (3)$$

2.6.6 Funções de ativação

Os valores de saída dos neurônios são essencialmente fornecidos pela função de ativação, satisfazendo a um limiar que condiciona a propagação do impulso nervoso a adaptação de uma atividade, mapeando a unidade do processamento para um intervalo de saída. (RAUBER, 2005)

O mesmo estudo do Autor supra referido mostra também que as funções de ativações mais utilizadas em redes neurais são:

- Sigmóide:
$$y = \frac{1}{1 + e^{-x}} \quad (4)$$

- Tangente Hiperbólica:
$$y = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

- Função degrau:
$$\begin{cases} 0 & \text{se } x < 0 \\ 1 & \text{se } x \geq 0 \end{cases} \quad (6)$$

- ReLU
$$y = \max \{0, x\} \quad (7)$$

3 METODOLOGIA

Neste capítulo será abordado o desenvolvimento metodológico do trabalho para a conclusão dos objetivos propostos, os quais visam correlacionar os resultados obtidos pela rede neural artificial quanto ao ensaio de fadiga do aço LN-700 soldado e não soldado. Para melhorar o entendimento, a Figura 10 mostrará um fluxograma genérico das etapas do desenvolvimento do trabalho, e na sequência será esclarecida cada uma dessas etapas.

No presente estudo, para a construção dos dados de entrada da rede neural foram utilizados dados fornecidos pela dissertação de mestrado de Oséias Matias de Oliveira Esmelindro.

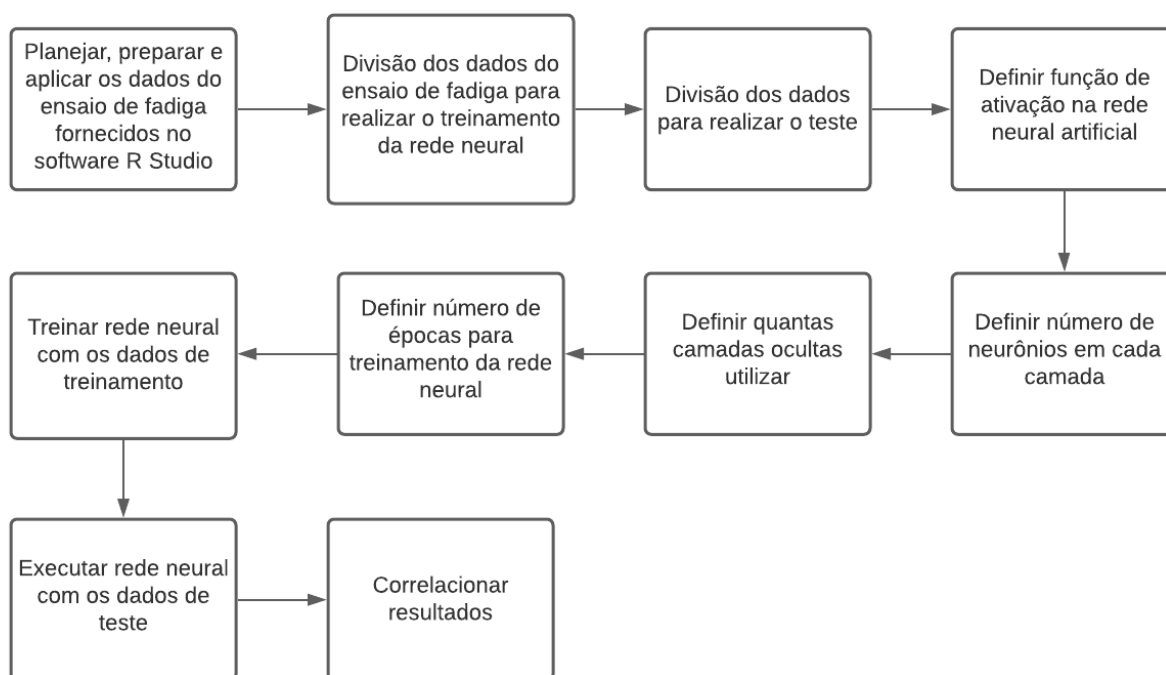


Figura 10 – Fluxograma de desenvolvimento do trabalho
(Fonte: O autor, 2021)

3.1 Material base utilizado

O material base utilizado foi o aço ARBL USI-LN-700 produzido pela USIMINAS segundo sua norma interna. Os dados encontrados na avaliação química da amostra são expressos na Tabela 1.

Tabela 1 - Composição química do aço USI-LN-700 em estudo (% em peso)

Elemento	C	Si	Mn	P	S	AL	Cu	Nb	V	Ti	Cr	Ni	Mo	Sn	Ni	B	Ca	Pb
USI-LN-700	0,090	0,030	1,560	0,021	0,004	0,062	0,020	0,044	0,007	0,114	0,440	0,020	0,010	0,002	0,006	0,000	0,001	0,001
Amostra	0,097	0,034	1,510	0,028	0,004	0,058	0,016	0,042	0,004	0,136	0,538	0,007	0,003	0,001	0,007	0,001	0,003	0,013

(Fonte: Adaptado de Esmelindro, 2015)

A caracterização das propriedades mecânicas do metal base do fornecedor, juntamente com ensaios de tração da amostra são abordados na Tabela 2.

Tabela 2 – Propriedades Mecânicas do aço USI-LN-700

Descrição	Tensão de Escoamento (MPa)	Tensão Máxima (MPa)	Alongamento Ruptura (%)
USI-LN-700	714,4	758,5	18
Amostra	736,9	780,5	7,8

(Fonte: Adaptado de Esmelindro, 2015)

3.2 Metais de adição

Na Tabela 3 é apresentada as propriedades mecânicas de dois metais de adição utilizadas como material de adição para a soldagem do material base. O ER70S6 - AWS 5.18-05, sendo o mais utilizado na indústria, não tendo um grande impacto no custo para a realização da soldagem e o ER90S-D2 - AWS A5.28, o que possui as propriedades químicas e mecânicas mais idênticas ao metal base, mas com um custo maior.

Tabela 3 - Propriedades Mecânicas dos Metais de Adição

Material de adição	Limite de Escoamento (MPa)	Resistência à Tração (MPa)	Alongamento (%)
ER90S-D2	620	705	26
ER70S-6	440	550	30

(Fonte: Adaptado Esmelindro, 2015)

Os parâmetros de energia de soldagem para os ensaios foram abordados por meio de testes em laboratório de soldagem, apresentado na Tabela 4.

Tabela 4 – Parâmetros de energia de soldagem

PARÂMETROS	VALORES
Energia_1	0,44 kJ/mm
Energia_2	0,54 kJ/mm
Energia_3	0,58 kJ/mm

(Fonte: Adaptado de Esmelindro, 2015)

3.3 Ensaio de fadiga

Os experimentos foram realizados variando três energias de soldagens e dois materiais de adição com o objetivo de determinar a melhor configuração de soldagem para o aço USI-LN-700, aplicando a curva S-N do metal soldado para avaliação da vida em fadiga do material. Na Tabela 5 é visto os resultados do número de ciclos encontrados no ensaio de fadiga para cada condição.

Tabela 5 – Ensaio de fadiga para o aço USI-LN-700 com os materiais de adição

BLOCOS	TRATAMENTOS		
	Energia_2	Energia_3	Energia_1
METAL BASE - ER 70S6 ø 1,2 - AWS 5.18-05	CP_01 36940	CP_04 58480	CP_07 38000
	CP_02 81000	CP_05 55290	CP_08 80425
	CP_03 33480	CP_06 51440	CP_09 81240
METAL BASE - ER 90S-D2 ø 1,1 - AWS A5.28	CP_10 70819	CP_13 18854	CP_16 62890
	CP_11 56130	CP_14 38660	CP_17 65430
	CP_12 54570	CP_15 60550	CP_18 82820

(Fonte: Adaptado de Esmelindro, 2015)

3.3.1 Curva S-N do aço USI-LN-700 sem solda e com solda

O ensaio de fadiga foi realizado em quatro níveis de tensão para ocorrer o estrago em cada corpo de prova ensaiado, quando o valor aplicado se iniciou a partir de 80% da tensão de escoamento, baixando até que o corpo de prova passa-se de 2×10^6 números de ciclos, considerado por este estudo vida infinita. A Figura 11 apresenta os dados do ensaio de fadiga realizado com os corpos de prova do material base sem solda e a Figura 12 mostra os dados do ensaio de fadiga com solda.

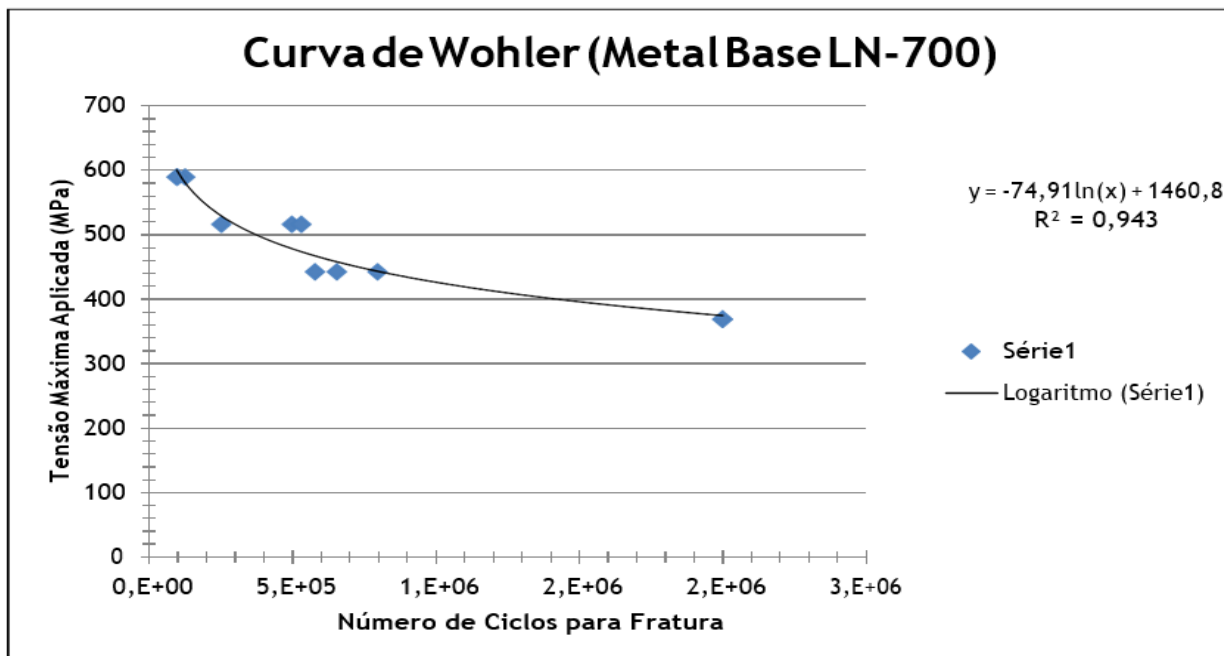


Figura 11 - Curva S-N do material base ARBL USI-LN-700
(Fonte: Lamef (URGS, apud Esmelindro, 2015))

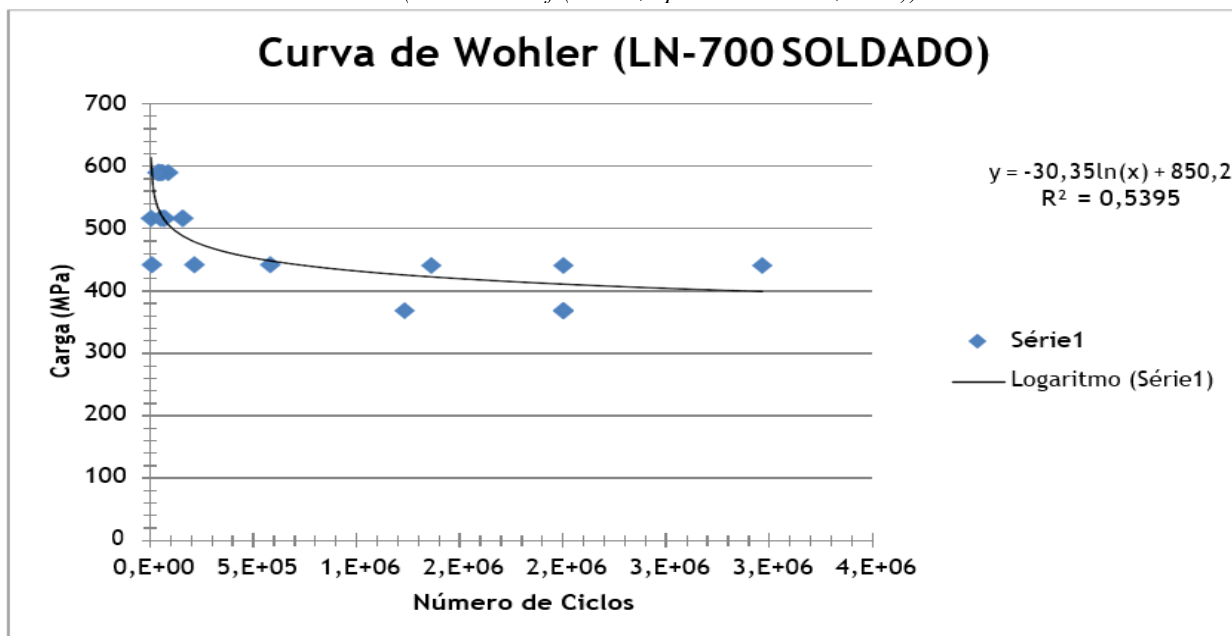


Figura 12 - Curva S-N do material base ARBL USI-LN-700 soldado
(Fonte: Esmelindro, 2015)

3.4 Aplicação das Redes Neurais Artificiais (RNA)

O uso da RNA, nesse estudo, tem por objetivo simular um ensaio de fadiga do aço USI-LN-700 soldado. Se variar a energia de soldagem e o material de adição aplicado para se comparar os dados com o ensaio de fadiga do aço USI-LN-700 sem solda, pode-se avaliar o material de adição e a energia de soldagem que se aproxima as condições ideais das propriedades mecânicas do aço LN-700 sem solda.

A aplicação da RNA foi utilizada para definir dois parâmetros e o primeiro deles é indicar através do ensaio de fadiga realizado com o aço LN-700 soldado se os materiais de adição, que foram empregados no material base assemelham-se às propriedades mecânicas do material base. Já a segunda aplicação tem por finalidade indicar quais dos materiais de adição e energia de soldagem desempenham uma melhor performance para comparação.

Para ambas aplicações da RNA foram utilizadas as mesmas informações para a construção dos dados de entrada, que serão explicados na sequência, ou seja, os dados de entrada utilizados na RNA foram os mesmos e treinados de duas formas diferentes para assim obter os dois resultados desejados.

3.4.1 Software para utilização da RNA

O *software* utilizado foi o *R Studio*, o qual é de fácil operacionalização e instalação. Encontra-se na internet gratuitamente. A linguagem é acessível e possibilita entendimento e manuseio para aplicação numa rede neural artificial com o *deep-learnig*, sendo esses os pontos principais que foram utilizados nesse experimento.

3.4.2 Parâmetros utilizados para a construção da RNA

Para executar uma RNA é necessário entender e aplicar uma série de fatores que serão explicados na sequência, que são importantes para que a rede seja executada corretamente. Os passos mostrados na Figura 10 citada anteriormente foram utilizados como base para a construção da RNA.

- **Função de ativação:** A função de ativação utilizada foi a função *Rectifier* (ReLU) sendo a mais indicada para ser utilizada pela sua eficiência em correlacionar os resultados corretamente. A função compara os resultados encontrados de forma binária, ou seja, os resultados adquiridos na RNA são números muito próximo de 0 ou 1.

- **RNA *feed-forward* Multicamada:** A arquitetura implementada foi a rede *feed-forward* de multicamada, o qual avalia seu erro através do algoritmo *backpropagation*. A Figura 13 representa um fluxograma para o entendimento de como o erro irá operar nos neurônios da RNA.

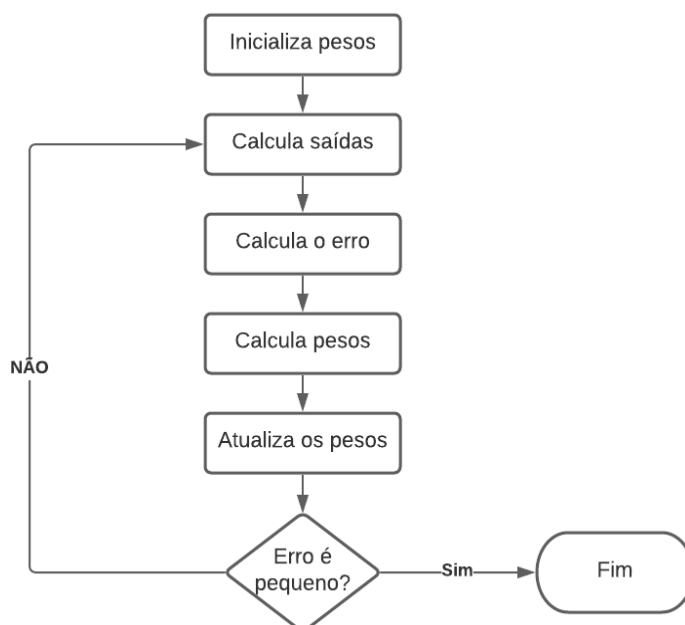


Figura 13 – Fluxograma de desenvolvimento do erro da RNA
(Fonte: O Autor, 2021)

Na RNA multicamadas se encontra a camada oculta que é outra variável que tem extrema importância para o seu funcionamento, a qual tem como função resolver problemas mais complexos. O número de camadas ocultas utilizadas foi de apenas 1, possuindo 8 neurônios na camada de entrada, 5 na camada oculta e 1 na camada de saída, apresentado na Figura 14.

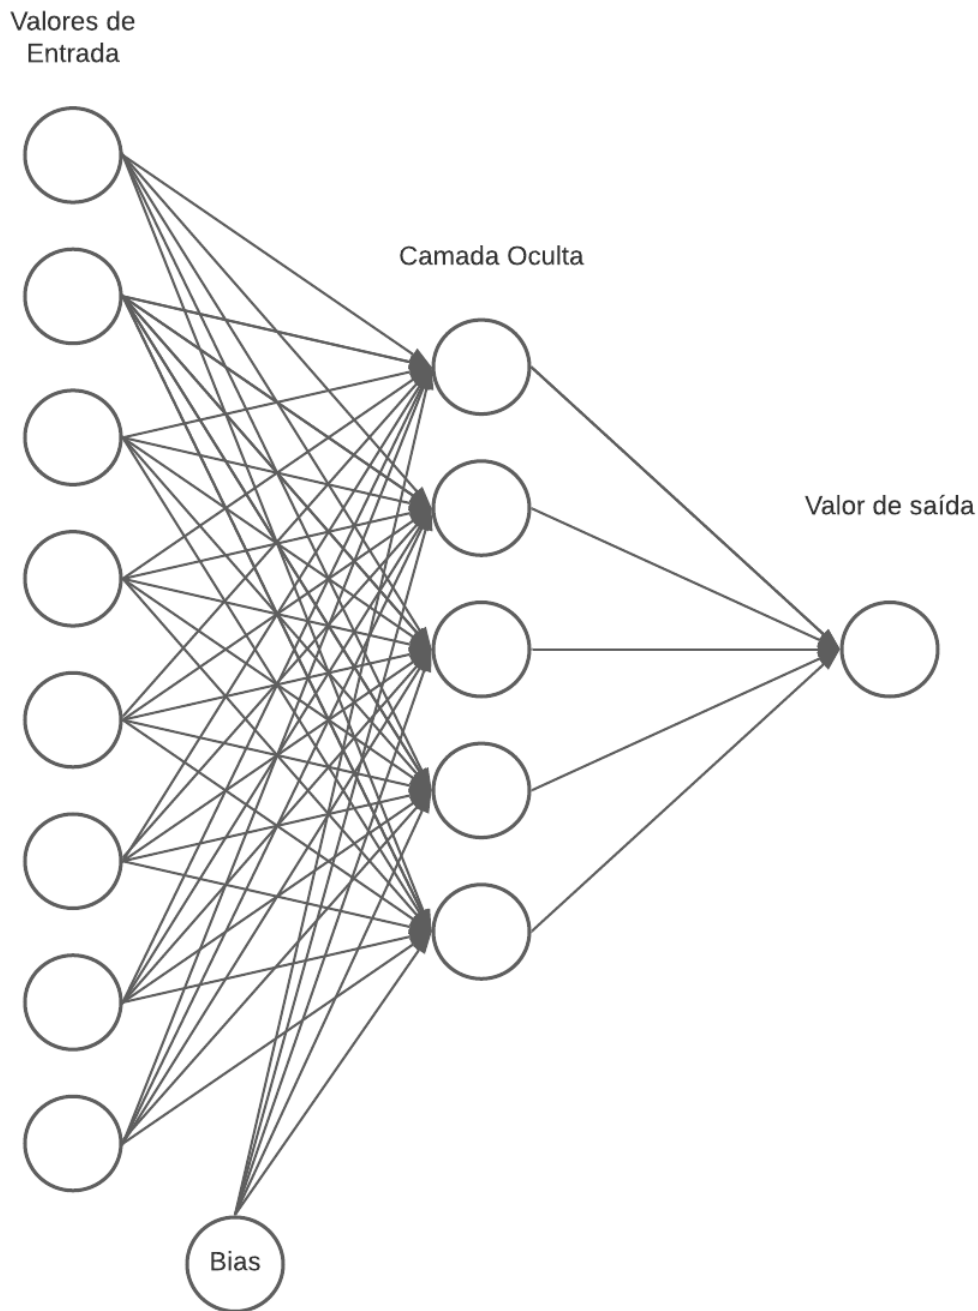


Figura 14 – Esquema da rede neural utilizada no trabalho
 (Fonte: O Autor, 2021)

- **Bias:** Quando uma rede neural é muito complexa e não consegue convergir os resultados para o desejado, existe uma opção que pode ser usada, a qual ajuda a facilitar o treinamento da RNA chamado *Bias*. O *Bias* é um neurônio artificial implantado em uma rede neural possibilitando ao usuário acrescentar um neurônio a mais em sua rede, podendo definir o seu valor, para assim convergir o resultado esperado. Devido a aleatoriedade dos dados de entrada na rede neural implementada no trabalho, o *bias* foi utilizado para garantir o funcionamento correto da rede.

- **Aprendizagem de máquina:** A aprendizagem de máquina utilizada no estudo foi a supervisionada, ocasião em que o operador da RNA realiza o treinamento com os dados de entrada, já fornecendo os dados de saída, correlacionando-os. Proporcionando assim que através de uma nova previsão com diferentes dados de entradas, mas sem fornecer os dados de saída, a rede correlacione e entregue os resultados desejados.
- **Épocas:** O número de épocas define quantas vezes a RNA vai realizar o treinamento até chegar ao resultado esperado. O número de épocas utilizado para esse ensaio foi de 1.000.000.

3.5 Aplicação dos dados no *R Studio*

Após efetivar o tratamento dos dados, é feita a criação das tabelas para executar no *R Studio* de forma que o *software* entenda a aplicação para executar na RNA. Na Tabela 6 é mostrado os dados de entrada e de saída utilizados para a rede neural. Objetiva prever o ensaio de fadiga realizado com os materiais de adição no aço usado de material base LN-700 para comparar ao ensaio de fadiga realizado no material base. E na Tabela 7 observa-se os mesmos dados de entrada utilizado na Tabela 6 com diferentes dados de saídas, tendo por finalidade comparar e prever com qual material de adição e energia de soldagem se obtém mais proximidade nos dados do ensaio de fadiga com o material base sem solda.

Em ambas as tabelas foram utilizados como dados de entrada a carga aplicada no ensaio de fadiga, a energia de soldagem, bem como o limite de escoamento, a resistência à tração e o alongamento do material de adição (MA). Ainda, a tensão de escoamento, a tensão máxima e o alongamento à ruptura do material base (MB) e o neurônio artificial bias. E como saída da rede neural foram utilizados os ciclos do ensaio de fadiga, sendo que para a Tabela 6 ele representa como resposta o número 0 como não comparável ao ensaio de fadiga do MB e 1 sendo como comparável. Na Tabela 7 apresenta-se 0 como o MA não comparável ao MB e 1 como comparável ao MB.

Tabela 6 – Dados de entrada para análise comparativa do ensaio de fadiga do MB soldado com não soldado

Carga (MPa)	Energia (KJ/mm)	Limite de Escoamento MA (MPa)	Resistencia a tração MA (MPa)	Alongamento Ruptura MA (%)	Tensão de Escoamento MB (MPa)	Tensão Máxima MB (MPa)	Alongamento Ruptura MB (%)	Bias	Ciclos
531,01	0,54	440	550	30	736,9	780,5	7,8	0	0
507,18	0,54	440	550	30	736,9	780,5	7,8	0	0
533,99	0,54	440	550	30	736,9	780,5	7,8	0	0
511,25	0,54	620	705	26	736,9	780,5	7,8	0	0
518,31	0,54	620	705	26	736,9	780,5	7,8	0	0
519,17	0,54	620	705	26	736,9	780,5	7,8	0	0
517,07	0,58	440	550	30	736,9	780,5	7,8	0	0
518,77	0,58	440	550	30	736,9	780,5	7,8	0	0
520,96	0,58	440	550	30	736,9	780,5	7,8	0	0
551,42	0,58	620	705	26	736,9	780,5	7,8	0	0
529,67	0,58	620	705	26	736,9	780,5	7,8	0	0
516,01	0,58	620	705	26	736,9	780,5	7,8	0	0
530,15	0,44	440	550	30	736,9	780,5	7,8	0	0
507,39	0,44	440	550	30	736,9	780,5	7,8	0	0
507,09	0,44	440	550	30	736,9	780,5	7,8	0	0
514,86	0,44	620	705	26	736,9	780,5	7,8	0	0
513,66	0,44	620	705	26	736,9	780,5	7,8	0	0
506,50	0,44	620	705	26	736,9	780,5	7,8	0	0
500,78	0,44	440	550	30	736,9	780,5	7,8	0	0
467,44	0,44	440	550	30	736,9	780,5	7,8	1	1
451,94	0,44	440	550	30	736,9	780,5	7,8	1	1
437,67	0,44	620	705	26	736,9	780,5	7,8	1	1
430,90	0,44	620	705	26	736,9	780,5	7,8	1	1
418,59	0,44	620	705	26	736,9	780,5	7,8	1	1
409,86	0,44	440	550	30	736,9	780,5	7,8	1	1
397,56	0,44	440	550	30	736,9	780,5	7,8	1	1

(Fonte: O Autor, 2021)

Tabela 7 – Dados de entrada para análise comparativa dos MA e energia de soldagem utilizados com o MB soldado

Carga (MPa)	Energia (KJ/mm)	Limite de Escoamento MA (MPa)	Resistencia a tração MA (MPa)	Alongamento Ruptura MA (%)	Tensão de Escoamento MB (MPa)	Tensão Máxima MB (MPa)	Alongamento Ruptura MB (%)	Bias	Ciclos
531,01	0,54	440	550	30	736,9	780,5	7,8	0	0
507,18	0,54	440	550	30	736,9	780,5	7,8	0	0
533,99	0,54	440	550	30	736,9	780,5	7,8	0	0
511,25	0,54	620	705	26	736,9	780,5	7,8	0	0
518,31	0,54	620	705	26	736,9	780,5	7,8	0	0
519,17	0,54	620	705	26	736,9	780,5	7,8	0	0
517,07	0,58	440	550	30	736,9	780,5	7,8	0	0
518,77	0,58	440	550	30	736,9	780,5	7,8	0	0
520,96	0,58	440	550	30	736,9	780,5	7,8	0	0
551,42	0,58	620	705	26	736,9	780,5	7,8	0	0
529,67	0,58	620	705	26	736,9	780,5	7,8	0	0
516,01	0,58	620	705	26	736,9	780,5	7,8	0	0
530,15	0,44	440	550	30	736,9	780,5	7,8	0	0
507,39	0,44	440	550	30	736,9	780,5	7,8	0	0
507,09	0,44	440	550	30	736,9	780,5	7,8	0	0
514,86	0,44	620	705	26	736,9	780,5	7,8	1	1
513,66	0,44	620	705	26	736,9	780,5	7,8	1	1
506,50	0,44	620	705	26	736,9	780,5	7,8	1	1
500,78	0,44	440	550	30	736,9	780,5	7,8	0	0
467,44	0,44	440	550	30	736,9	780,5	7,8	0	0
451,94	0,44	440	550	30	736,9	780,5	7,8	0	0
437,67	0,44	620	705	26	736,9	780,5	7,8	1	1
430,90	0,44	620	705	26	736,9	780,5	7,8	1	1
418,59	0,44	620	705	26	736,9	780,5	7,8	1	1
409,86	0,44	440	550	30	736,9	780,5	7,8	0	0
397,56	0,44	440	550	30	736,9	780,5	7,8	0	0

(Fonte: O Autor, 2021)

3.6 Etapa Conclusiva

Depois de implementar os dados no *software R Studio* e definir todas as variáveis para execução da RNA foi abordada a utilização da biblioteca *h2o* encontrada no *software*. Para isso, foi necessário dividir os dados de entrada em duas partes: a primeira foi chamada base de treinamento onde a rede realizou seu treinamento; a segunda foi chamada de base de teste, onde a rede realizou as previsões. Após isso, foi feita a verificação do funcionamento da RNA. Caso os dados fornecidos pela rede não fossem satisfatórios, seria necessário investigar e realizar novos treinamentos da rede modificando o número de épocas, de neurônios na camada oculta e da quantidade de camadas ocultas para convergência dos dados.

4 RESULTADOS E DISCUSSÃO

Neste tópico são apresentados os resultados obtidos conforme os objetivos propostos para o trabalho. A sequência de apresentação dos resultados segue a ordem que foi realizada cada etapa, visto que foi necessário adquirir alguns resultados para poder avançar em uma nova etapa, principalmente a divisão dos dados para realizar o treinamento e o teste da RNA.

Primeiramente, são exibidos os dados de treinamento para a rede neural, em seguida é feito a previsão com os dados de teste para a rede neural. Posteriormente, são apresentados os resultados da RNA para os dados de previsão do ensaio de fadiga comparativo entre o MB soldado e o não soldado e o resultados da previsão do MA que mais se aproximou as propriedades mecânicas do MB.

4.1 Treinamento da RNA

O treinamento realizado na rede neural, como visto anteriormente, foi dividido em duas partes: uma para comparar o ensaio de fadiga do MB com ou sem solda e a outra para comparar as energias de soldagens e os MA utilizados, para definir qual se aproximou mais das propriedades mecânicas do MB. A divisão dos dados foi feita através do *software R Studio* dividindo 75% dos dados da Tabela 6 e da Tabela 7 de forma aleatória para realizar o treinamento da RNA, sendo os outros 25% foram usados para realizar o teste da RNA.

4.1.1 Análise comparativa do ensaio de fadiga do MB soldado com o MB não soldado

A Tabela 8 apresenta 75% dos dados de entrada referidos na Tabela 6 utilizados na realização do treinamento da RNA. Nesta, compara-se o ensaio de fadiga do MB soldado com o não soldado, visto que os resultados apresentados na rede neural são de forma binária, ou seja, os resultados que apresentam o valor 0 significa que o ensaio de fadiga do MB soldado não foi satisfatório em comparação ao MB não soldado, e o valor 1 representa resultado satisfatório.

Tabela 8 – Base de treinamento da RNA do ensaio de fadiga do MB soldado e o não soldado

Carga (MPa)	Energia (KJ/mm)	Limite de Escoamento MA (MPa)	Resistencia a tração MA (MPa)	Alongamento Ruptura MA (%)	Tensão de Escoamento MB (MPa)	Tensão Máxima MB (MPa)	Alongamento Ruptura MB (%)	Bias	Ciclos
531,01	0,54	440	550	30	736,9	780,5	7,8	0	0
507,18	0,54	440	550	30	736,9	780,5	7,8	0	0
533,99	0,54	440	550	30	736,9	780,5	7,8	0	0
511,25	0,54	620	705	26	736,9	780,5	7,8	0	0
519,17	0,54	620	705	26	736,9	780,5	7,8	0	0
517,07	0,58	440	550	30	736,9	780,5	7,8	0	0
520,96	0,58	440	550	30	736,9	780,5	7,8	0	0
551,42	0,58	620	705	26	736,9	780,5	7,8	0	0
529,67	0,58	620	705	26	736,9	780,5	7,8	0	0
516,01	0,58	620	705	26	736,9	780,5	7,8	0	0
507,39	0,44	440	550	30	736,9	780,5	7,8	0	0
507,09	0,44	440	550	30	736,9	780,5	7,8	0	0
514,86	0,44	620	705	26	736,9	780,5	7,8	0	0
513,66	0,44	620	705	26	736,9	780,5	7,8	0	0
467,44	0,44	440	550	30	736,9	780,5	7,8	1	1
437,67	0,44	620	705	26	736,9	780,5	7,8	1	1
418,59	0,44	620	705	26	736,9	780,5	7,8	1	1
409,86	0,44	440	550	30	736,9	780,5	7,8	1	1
397,56	0,44	440	550	30	736,9	780,5	7,8	1	1

(Fonte: O Autor, 2021)

Após feito o treinamento da RNA foi realizado o teste com os outros 25% dos dados de entrada. É importante citar que nessa etapa do processo a RNA já está treinada, o *software R Studio* realizou a previsão dos dados sem o neurônio auxiliar *Bias* e sem os dados de saída que é representado pela coluna ciclos. Estes foram utilizados para melhorar a precisão da RNA, podendo assim ser avaliado se a rede foi treinada com sucesso ou não. A Tabela 9 apresenta os dados utilizados para o teste da rede.

Tabela 9 – Base de teste da RNA do ensaio de fadiga do MB soldado e o não soldado

Carga (MPa)	Energia (KJ/mm)	Limite de Escoamento MA (MPa)	Resistencia a tração MA (MPa)	Alongamento Ruptura MA (%)	Tensão de Escoamento MB (MPa)	Tensão Máxima MB (MPa)	Alongamento Ruptura MB (%)
518,31	0,54	620	705	26	736,9	780,5	7,8
518,77	0,58	440	550	30	736,9	780,5	7,8
530,15	0,44	440	550	30	736,9	780,5	7,8
506,5	0,44	620	705	26	736,9	780,5	7,8
500,78	0,44	440	550	30	736,9	780,5	7,8
451,94	0,44	440	550	30	736,9	780,5	7,8
430,9	0,44	620	705	26	736,9	780,5	7,8

(Fonte: O Autor, 2021)

Por fim, a Tabela 10 demonstra a resposta que a RNA encontra através da Tabela 9 juntamente com a Tabela 11, a qual é chamada de matriz confusão. Esta compara os resultados encontrados através de rede com os resultados que eram esperados.

Tabela 10 – Resultado da precisão da RNA

Carga (MPa)	Energia (KJ/mm)	Limite de Escoamento MA (MPa)	Resistencia a tração MA (MPa)	Alongamento Ruptura MA (%)	Tensão de Escoamento MB (MPa)	Tensão Máxima MB (MPa)	Alongamento Ruptura MB (%)	Resposta (Ciclos)
518,31	0,54	620	705	26	736,9	780,5	7,8	0
518,77	0,58	440	550	30	736,9	780,5	7,8	0
530,15	0,44	440	550	30	736,9	780,5	7,8	0
506,5	0,44	620	705	26	736,9	780,5	7,8	0
500,78	0,44	440	550	30	736,9	780,5	7,8	0
451,94	0,44	440	550	30	736,9	780,5	7,8	1
430,9	0,44	620	705	26	736,9	780,5	7,8	1

(Fonte: O Autor, 2021)

Tabela 11 – Matriz confusão da comparação do ensaio de fadiga do MB soldado e o não soldado

Dados de saídas	Previsões	
	0	1
0	5	0
1	0	2

(Fonte: O Autor, 2021)

Através da Tabela 11 se avalia que a RNA representou todos os resultados corretamente. Os representados como 0 são os não comparáveis ao ensaio de fadiga do MB soldado com o não soldado. Os representados como 1 são os comparáveis ao ensaio de fadiga do MB sem solda. Tanto os representados como o 0 quando o 1 foram lidos corretamente pela RNA.

4.1.2 Análise comparativa da energia de soldagem e do material de adição

Seguindo a mesma ideia do item anterior foi feita uma nova análise, sendo comparados as energias de soldagem e os MA utilizados no MB para verificar qual obteve um melhor desempenho no ensaio de fadiga, com a finalidade de comparar com o MB não soldado.

A Tabela 12 apresenta 75% dos dados de entrada distribuídos de forma aleatória, que foram empregados para realizar o treinamento da RNA. Nesta Tabela já se fornece os dados de resposta possibilitando que a rede faça o treinamento, sendo que 0 indica uma baixa performance no ensaio de fadiga e 1 como uma boa performance, definindo qual energia de soldagem e MA são os melhores para se usar no MB.

A Tabela 13 apresenta os outros 25% dos dados distribuídos de forma aleatória para a rede realizar um teste, podendo assim analisar se o treinamento foi executado com sucesso. Ressalta-se que os dados da Tabela 13 não apresentam os neurônios *Bias* e o de saída.

Tabela 12 – Base de treinamento da RNA do ensaio de fadiga do MB soldado com diferentes energias de soldagem e diferentes MA

Carga (MPa)	Energia (KJ/mm)	Limite de Escoamento MA (MPa)	Resistencia a tração MA (MPa)	Alongamento Ruptura MA (%)	Tensão de Escoamento MB (MPa)	Tensão Máxima MB (MPa)	Alongamento Ruptura MB (%)	Bias	Ciclos
531,01	0,54	440	550	30	736,9	780,5	7,8	0	0
507,18	0,54	440	550	30	736,9	780,5	7,8	0	0
533,99	0,54	440	550	30	736,9	780,5	7,8	0	0
518,31	0,54	620	705	26	736,9	780,5	7,8	0	0
519,17	0,54	620	705	26	736,9	780,5	7,8	0	0
517,07	0,58	440	550	30	736,9	780,5	7,8	0	0
518,77	0,58	440	550	30	736,9	780,5	7,8	0	0
520,96	0,58	440	550	30	736,9	780,5	7,8	0	0
551,42	0,58	620	705	26	736,9	780,5	7,8	0	0
529,67	0,58	620	705	26	736,9	780,5	7,8	0	0
507,09	0,44	440	550	30	736,9	780,5	7,8	0	0
514,86	0,44	620	705	26	736,9	780,5	7,8	1	1
513,66	0,44	620	705	26	736,9	780,5	7,8	1	1
506,5	0,44	620	705	26	736,9	780,5	7,8	1	1
467,44	0,44	440	550	30	736,9	780,5	7,8	0	0
451,94	0,44	440	550	30	736,9	780,5	7,8	0	0
430,9	0,44	620	705	26	736,9	780,5	7,8	1	1
409,86	0,44	440	550	30	736,9	780,5	7,8	0	0
397,56	0,44	440	550	30	736,9	780,5	7,8	0	0

(Fonte: O Autor, 2021)

Tabela 13 – Base de teste da RNA do ensaio de fadiga do MB soldado do ensaio de fadiga do MB soldado com diferentes energias de soldagem e diferentes MA

Carga (MPa)	Energia (KJ/mm)	Limite de Escoamento MA (MPa)	Resistencia a tração MA (MPa)	Alongamento Ruptura MA (%)	Tensão de Escoamento MB (MPa)	Tensão Máxima MB (MPa)	Alongamento Ruptura MB (%)
511,25	0,54	620	705	26	736,9	780,5	7,8
516,01	0,58	620	705	26	736,9	780,5	7,8
530,15	0,44	440	550	30	736,9	780,5	7,8
507,39	0,44	440	550	30	736,9	780,5	7,8
500,78	0,44	440	550	30	736,9	780,5	7,8
437,67	0,44	620	705	26	736,9	780,5	7,8
418,59	0,44	620	705	26	736,9	780,5	7,8

(Fonte: O Autor, 2021)

Após feito o teste a Tabela 14 e a Tabela 15 referem os resultados obtidos da RNA. Na Tabela 15 observa-se a matriz confusão dos dados que compara os resultados encontrados através da rede com os resultados que eram esperados.

Tabela 14 – Resultado da precisão da RNA

Carga (MPa)	Energia (KJ/mm)	Limite de Escoamento MA (MPa)	Resistencia a tração MA (MPa)	Alongamento Ruptura MA (%)	Tensão de Escoamento MB (MPa)	Tensão Máxima MB (MPa)	Alongamento Ruptura MB (%)	Ciclos
511,25	0,54	620	705	26	736,9	780,5	7,8	0
516,01	0,58	620	705	26	736,9	780,5	7,8	0
530,15	0,44	440	550	30	736,9	780,5	7,8	0
507,39	0,44	440	550	30	736,9	780,5	7,8	0
500,78	0,44	440	550	30	736,9	780,5	7,8	0
437,67	0,44	620	705	26	736,9	780,5	7,8	1
418,59	0,44	620	705	26	736,9	780,5	7,8	1

(Fonte: O Autor, 2021)

Tabela 15 – Matriz confusão da comparação do ensaio de fadiga do MB soldado com as diferentes energias de soldagem e MA utilizados

Dados de saídas	Previsões	
	0	1
0	5	0
1	0	2

(Fonte: O Autor, 2021)

Através da Tabela 11 se nota que a RNA representou novamente todos os resultados de forma correta. Os dados apresentados como 0 indicam as diferentes energias de soldagem e os diferentes MA utilizados no ensaio de fadiga do MB soldado, sendo não comparáveis com o ensaio de fadiga do MB sem solda. Os dados representados como 1 indicam que são comparáveis com o ensaio de fadiga do MB sem solda. Ambos foram lidos de forma precisa pela RNA.

4.2 Correlação do ensaio de fadiga do MB soldado e não soldado com as análises da RNA

Os dados encontrados por Esmelindro (2015), no ensaio de fadiga do MB soldado realizado experimentalmente em laboratório indicam que o padrão do ensaio de fadiga que mais se aproximou com as propriedades mecânicas do MB sem solda foi o que utilizou a energia de soldagem de 0,44 (KJ/mm) com o MA ER90S-D2.

A Tabela 16 indica os resultados entre os dados experimentais do estudo acima referido com os encontrados na RNA. Os principais dados de entrada empregados para o treinamento da rede foram a energia de soldagem e o MA utilizados na soldagem do MB, visando encontrar a energia de soldagem e o MA que obtiveram o melhor desempenho no ensaio de fadiga para comparação das propriedades mecânicas do material base.

Tabela 16 – Análise dos resultados experimentais com os numéricos

Dados de entrada	Resultados	
	Experimental	RNA
Energia de soldagem	0,44 (KJ/mm)	0,44 (KJ/mm)
Material de adição	ER90S-D2	ER90S-D2

(Fonte: O Autor, 2021)

Por meio da Tabela 16, avaliou-se que a RNA foi treinada com sucesso, por ter encontrado os mesmos padrões no ensaio de fadiga realizado em laboratório. Em especial, por indicar quais foram os dados de entrada que se aproximaram das propriedades mecânicas do MB.

5 CONCLUSÕES

Através dos dados obtidos na primeira etapa feita pela RNA foram abordados os dados do ensaio de fadiga encontrados com o MB soldado para comparar com os dados do MB não soldado.

Notou-se que a rede indicou a comparação entre os dois ensaios quando se diminuiu a carga aplicada no ensaio de fadiga, chegando a 50% da tensão de escoamento, bem como quando o MB soldado começou a chegar na sua vida infinita determinada como 10^6 ciclos. Isso aconteceu pelo fato de o MB soldado perder propriedades mecânicas com a solda, o qual no início do ensaio não restou comparável ao MB não soldado, pois sendo utilizada a mesma carga em ambos os testes acabou se rompendo antes que o MB sem solda. Esse fato comprova com o que está na literatura, concluindo que a primeira etapa realizada pela RNA foi feita com exatidão, acertando 100% dos testes realizados nesse caso.

Por fim, obteve-se os dados do segundo treinamento da RNA indicando qual foi o melhor MA utilizado para o ensaio de fadiga e a melhor energia de soldagem. Através da previsão é notado que a rede indica a energia de soldagem de 0,44 KJ/mm a melhor para se utilizar no material base LN-700 juntamente com o material de adição ER90S-D2. A ideia da rede é confirmada com a literatura, onde indica a energia de soldagem de 0,44 KJ/mm como a melhor a se utilizar, pelo fato de ser a que menos altera as propriedades mecânicas durante a soldagem do MB e o material de adição ER90S-D2 também como o material mais indicado que se aproxima das propriedades mecânicas do aço LN-700.

Por meio desses dois testes realizados através da RNA, concluiu-se que a rede foi treinada com sucesso, podendo ser usada como um parâmetro auxiliar nas definições que se desejam encontrar através do ensaio de fadiga.

6 ETAPAS FUTURAS

Como sugestões e demandas para trabalhos futuros:

- Avaliação do ensaio de fadiga do aço LN-700 por meio da RNA indicando o número de ciclos encontrados no ensaio através da rede.
- Abordar outras formas de construção de RNA para avaliar o mesmo funcionamento testado nesse trabalho.
- Criação de uma RNA que simule um ensaio de fadiga para o aço LN-700.
- Criação de uma RNA que simule um ensaio de fadiga para qualquer tipo de aço.

REFERÊNCIAS

- AGUIAR, F. G. **Utilização de redes neurais artificiais para detecção de padrões de vazamento em oleodutos**. Dissertação de Mestrado em Engenharia Mecânica – Escola de Engenharia de São Carlos – Universidade de São Paulo. 2010.
- ARANCIBIA, E. P. M. F. **Avaliação de configuração de rede neural para previsão do consumo de energia de sistemas de climatização**. Trabalho de Formatura – Escola Politécnica da Universidade de São Paulo. 2008. 57p.4
- BUDYNAS, Richard G.; NISBETH, J. Keith. **Elementos de Máquinas de Shigley-8ª Edição**. McGraw Hill Brasil, 2011.
- DE ASSIS SANTOS, Diego; BONVENTI JR, Waldemar. **Controle de sistemas eletro-mecânicos por redes neurais artificiais recorrentes**. Brazilian Applied Science Review, v. 4, n. 3, p. 1591-1606, 2020.
- ESMELINDRO, Oséias Matias de Oliveira et al. **Comportamento da vida em fadiga de junta soldada do aço LN-700**. Tese (Mestrado) – Universidade de Passo Fundo. 2015.
- GARCIA, Amauri; SPIM, Jaime Alvares; SANTOS, Carlos Alexandre dos. **Ensaaios dos Materiais**. Rio de Janeiro: LTC, 2000.
- GORNI, A. A.; SILVA, M. R. S. **Comparação entre os modelos para o cálculo de carga na laminação a quente industrial**. Tecnologia em Metalurgia, Materiais e Mineração, v. 9, n. 3, p. 197-203, 2013.
- HAYKIN, S. **Redes Neurais: Principio e Pratica**. 2ª ed. Bookman. 2001.
- JR, Antonio Gonsalves de MELLO e all, et. 2013. **Influência do jateamento com granalhas no comportamento mecânico de uma junta sobreposta soldada pelo processo MIG/MAG em aços de tipo Dual Phase**. VII Congresso Brasileiro de Engenharia de Fabricação. 2013.
- KOVÁCS, Z. L. **Redes neurais artificiais**. Editora Livraria da Física, 2002.
- MACIEL JUNIOR, Helio. **Uso do planejamento e análise de experimentos no desenvolvimento de um processo de solda por resistência elétrica de pequena escala**. Dissertação (Mestrado em Ciências em Engenharia de Produção) – Universidade Federal de Itajubá, Outubro, 2011.
- MALEKI, E.; REZA KASHYZADEH, K. **Effects of the hardened nickel coating on the fatigue behavior of CK45 steel: experimental, finite element method, and artificial neural network modeling**. Iranian Journal of Materials Science and Engineering, v. 14, n. 4, p. 81-99, 2017.
- MELO, J. F. **Desenvolvimento de técnica de predição de defeitos em máquinas rotativas por meio de redes neurais artificiais**. Tese (Doutorado) – Universidade Federal de Pernambuco. 2018. 120p.
- QUITES, Almir Monteiro. **Metalurgia na soldagem dos aços**. Florianópolis: Solda Soft, 2008.
- RAUBER, T. W. **Redes neurais artificiais**. Universidade Federal do Espírito Santo, p. 29, 2005.
- VIVEROS, H. P. **Aplicação de algoritmo de controle preditivo neural NNMPC em mancal híbrido ativo**. Tese (Doutorado) – Escola de Engenharia de São Carlos – Universidade de São Paulo. 2018.

APÊNDICE A – LINGUAGEM UTILIZADA NA RNA

No texto a seguir é apresentado a linguagem utilizada para aplicação da RNA para leitura do *software R Studio*.

```
base1 = read.csv("tfg2q.csv")
#install.packages("caTools")
library(caTools)
divisao = sample.split(base1$Ciclos, SplitRatio = 0.75)
base_treinamento1 = subset(base1, divisao == TRUE)
base_teste1 = subset(base1, divisao == FALSE)

#install.packages("h2o")
library(h2o)
h2o.init(nthreads = -1)

redeneuraul = h2o.deeplearning(y = "Ciclos", training_frame = as.h2o(base_treinamento1),
activation = "Rectifier", hidden = c(5), epochs = 1000000)
previsoes = h2o.predict(redeneuraul, newdata = as.h2o(base_teste1[-9,-10]))
previsoes = (previsoes > 0.5)
previsoes = as.vector(previsoes)
matriz_confusao = table(base_teste1[,10], previsoes)
```