

ARTIGO ORIGINAL

Modelagem matemática da eficiência térmica da soldagem a arco elétrico utilizando redes neurais artificiais

Mathematical modeling of the thermal efficiency of electric arc welding using artificial neural networks

Marcelo Maroski¹, Airam Sausen ¹, Paulo Sausen ¹,
Maurício de Campos ¹, Manuel Binelo ¹, Diego Tolotti de Almeida ²,
Angelica Paola de Oliveira Lopes ², Vagner Braga ²

¹Programa de Pós-Graduação em Modelagem Matemática e Computacional (PPGMMC/UNIJUI), Ijuí (RS) – Brasil,

²Bruning Tecnometal, Panambi (RS) – Brasil

*marcelomaroski@gmail.com; airam@unijui.edu.br; sausen@unijui.edu.br; campos@unijui.edu.br; manuel.binelo@unijui.edu.br; Diegot@bruning.com.br; angelica@bruning.com.br; vagner.braga@bruning.com.br

Recebido: 16/11/2021. Revisado: 24/10/2022. Aceito: 01/11/2022.

Resumo

Neste artigo é abordado o problema da estimativa da eficiência térmica da soldagem a arco elétrico, especialmente em relação ao processo *Gas Metal Arc Welding*. Apesar de ser um parâmetro de grande relevância, a eficiência muitas vezes é determinada a partir de valores tabelados pelas normas técnicas, o que pode acabar prejudicando as análises metalúrgicas, visto que esses valores nem sempre conseguem contemplar todas as variações possíveis nos parâmetros da solda. Nesse contexto, neste artigo é proposto o desenvolvimento de um modelo matemático através de Redes Neurais Artificiais (RNAs) para ser utilizado em conjunto com um calorímetro de fluxo contínuo, a fim de se obter uma estimativa prévia para a eficiência e evitar despesas com ensaios experimentais que produziram resultados abaixo do ideal. Os dados experimentais foram obtidos através de ensaios do processo de soldagem na empresa Bruning Tecnometal Ltda, e as simulações foram realizadas na ferramenta computacional Matlab. O modelo proposto foi validado por meio do método *k-fold cross-validation* e apresentou baixo erro relativo médio.

Palavras-Chave: Soldagem; Eficiência; Aporte Térmico; Rede Neural Artificial.

Abstract

This paper deals with the problem of the estimate of the arc welding thermal efficiency, especially in relation to the Gas Metal Arc Welding process. Despite being a parameter of great importance, the efficiency is determinate, oftentimes, from tabulated values given by the technical standards, which can affect the metallurgical analysis, since these values not always can consider each possible variation in the welding parameters. In this context, this paper proposes the development of a mathematical model through Artificial Neural Networks (ANNs) to be used in conjunction with a continuous flow calorimeter, in order to obtain a preliminary estimate for efficiency and avoid expenses with experimental tests that would produce suboptimal results. The experimental data were obtained through tests of the welding process in the company Bruning Tecnometal Ltda, and the simulations were carried out using the computational tool Matlab. The proposed model was validated using the *k-fold cross-validation* method and presented a low mean relative error.

Keywords: Welding; Efficiency; Heat Input; Artificial Neural Network.

1 Introdução

A soldagem por fusão é um procedimento no qual se emprega uma fonte de calor para unir duas partes metálicas. Nesse processo, é comum a utilização de um consumível, como por exemplo, uma haste ou fio metálico, que ao ser derretido forma a poça de fusão. Esta, por sua vez, quando solidificada constitui a junta que garante a união das peças a serem soldadas (Furbee, 2011).

O processo de soldagem é conhecido desde os tempos remotos, mas começou a se tornar popular no início do século XX, devido à concretização de alguns avanços tecnológicos, tais como o acesso facilitado à energia elétrica (Oliveira et al., 2020). Contudo, os maiores avanços no campo da soldagem por fusão ocorreram somente após a Segunda Guerra Mundial, momento em que surgiu a necessidade da indústria produzir estruturas mais complexas, constituídas por diversos componentes com funcionalidades específicas (Oliveira et al., 2017).

De acordo com Kou (2003), a soldagem por fusão pode ser dividida em três grandes grupos: soldagem a gás, soldagem por feixes de alta energia (elétrons ou laser), e soldagem a arco elétrico que será o foco deste artigo. Neste último grupo, encontram-se os métodos utilizados com maior frequência na manipulação de metais, como é o caso do *Gas Metal Arc Welding* (GMAW) (Komanduri and Hou, 2000; Huang, 2010).

Atualmente, a soldagem a arco elétrico de caráter industrial é realizada por meio de dispositivos automatizados e pode contar com os avanços tecnológicos provenientes da microeletrônica e das tecnologias de informação e comunicação (Oliveira et al., 2017). No entanto, embora muito se tenha avançado nas últimas décadas, persiste ainda a busca por alternativas que possam apresentar melhores resultados para a eficiência desse processo (Dedyukh, 2015).

De fato, a eficiência do arco elétrico, também denominada eficiência térmica, rendimento térmico ou, simplesmente eficiência, é um dos parâmetros comumente utilizados para avaliar a soldagem, sobretudo no que diz respeito à quantidade real de calor transferida para o material que está sendo soldado, uma vez que se admite a existência de perdas de calor inerentes ao processo (Hackenhaar et al., 2016). Dentre outros exemplos, pode-se citar a eficiência como um fator relevante para calcular taxas de refrigeração e analisar as características da fusão (Stenbacka, 2013). Além disso, o conhecimento da eficiência é importante para realizar qualquer modelagem de caráter numérico associada à soldagem (Pépe et al., 2017).

Embora a eficiência tenha a sua importância reconhecida, é recorrente a utilização do seu valor tabelado pelas normas técnicas. Isso pode se tornar um problema, pois as normas determinam a eficiência das variações do processo sem considerar as possíveis alterações nos parâmetros de solda (Haelsing et al., 2017). Nesse sentido, os valores da eficiência apresentados pelas normas técnicas podem acabar se distanciando da realidade.

Diante disso, uma alternativa experimental pode ser utilizada para calcular a eficiência, que são os dispositivos denominados calorímetros, construídos de acordo com o avanço tecnológico da época e a disponibilidade de materiais (Arevalo and Vilarinho, 2012). Na literatura relacionada à soldagem, são três os modelos utilizados com maior

frequência: o calorímetro de caixa fechada, o calorímetro de nitrogênio líquido, e o calorímetro de fluxo contínuo de água.

Em Kuntz et al. (2017) é apresentado um calorímetro que utiliza este último princípio de funcionamento, ele tem sido utilizado pela empresa Bruning Tecnometal Ltda, do município de Panambi, no estado do Rio Grande do Sul (RS), para determinar a eficiência da soldagem a arco elétrico. Por meio de uma parceria estabelecida com o Grupo de Automação Industrial e Controle (GAIC), da Universidade Regional do Noroeste do Estado do Rio Grande do Sul (Unijui), foi possível utilizar os dados experimentais obtidos pela Bruning no processo de soldagem para a proposição de um modelo matemático que, mediante parâmetros de entrada característicos da soldagem a arco elétrico, estima a eficiência do processo de soldagem.

Neste contexto, este artigo objetiva desenvolver um modelo matemático baseado em Redes Neurais Artificiais (RNAs) que forneça, de forma prática e rápida, uma boa estimativa para a eficiência térmica do processo de soldagem a arco elétrico. Na literatura consultada, não foram localizados trabalhos que tratassem da modelagem matemática da eficiência térmica da soldagem a arco elétrico a partir dos parâmetros da solda, portanto, uma das principais contribuições desse artigo é o próprio desenvolvimento do modelo que se configura como algo inovador para o campo da soldagem. Além disso, a utilização desse modelo pela Bruning poderá resultar em ganho de tempo, redução de custos financeiros e economia de recursos humanos, uma vez que o modelo fará a estimativa da eficiência do processo de soldagem em etapa anterior ao ensaio experimental com o calorímetro, evitando que sejam realizados ensaios cujas eficiências tendem a apresentar valores inferiores aos adequados.

O restante deste artigo está organizado como segue. Na Seção 2 é apresentada a revisão bibliográfica. Na Seção 3 são descritos os procedimentos experimentais, ou seja, o processo de aquisição de dados e o método de Taguchi. Na Seção 4 são apresentadas a modelagem matemática via RNAs e a metodologia de validação. Na Seção 5 são apresentados os resultados das simulações e análises. E por fim, na Seção 6 são apresentadas as conclusões e possibilidade de trabalhos futuros.

2 Revisão Bibliográfica

Segundo Jorge et al. (2017) a soldagem a arco elétrico é um método que utiliza energia derivada da potência elétrica, ou seja, a fusão é obtida a partir da transferência da energia produzida pelo arco elétrico para o material que está sendo soldado. Compreendida como um dos principais métodos empregados na manufatura de juntas metálicas, a soldagem a arco elétrico é encontrada em uma grande variedade de aplicações, incluindo pontes, carros, trens, implementos agrícolas e reatores nucleares (Huang, 2010; Komanduri and Hou, 2000).

Conforme Kou (2003), a soldagem a arco elétrico pode ser dividida em seis variações: *Shielded Metal Arc Welding* (SMAW), *Gas Tungsten Arc Welding* (GTAW), *Plasma Arc Welding* (PAW), *Flux-Cored Arc Welding* (FCAW), *Submerged Arc Welding* (SAW) e *Gas Metal Arc Welding* (GMAW).

Esta última é a utilizada nesse artigo, visto que esse é o método de soldagem a arco elétrico utilizado pela Bruning Tecnometal nos ensaios com o calorímetro de fluxo contínuo de água.

A seguir são apresentadas as principais características do processo GMAW; na sequência é abordado sobre o parâmetro da eficiência no processo de soldagem destacando a sua relevância para a metalurgia; e por fim são apresentados os métodos tradicionais utilizados na literatura para a definição da eficiência.

2.1 Gas Metal Arc Welding

Durante os anos de 1940, observou-se uma série de avanços no campo da soldagem. Dentre eles, a utilização de um arame alimentado a partir de um rolo, como eletrodo consumível, o que contribuiu para o aumento do ritmo de produção em processos automatizados (Oliveira et al., 2020). Nesse cenário, foi desenvolvido o processo de soldagem GMAW, que assim como outros métodos semelhantes, utiliza um arco elétrico estabelecido entre o eletrodo e o material a ser soldado (Kou, 2003).

Durante a segunda metade do século XX, o processo GMAW adquiriu popularidade e, atualmente, é um dos mais utilizados pela indústria, tanto em soldagens manuais, quanto automatizadas, (Oliveira et al., 2020; Kou, 2003; Arevalo and Vilarinho, 2012; Pépe et al., 2017; Liskevych and Scotti, 2015). Um exemplo de um mecanismo que realiza a soldagem pelo método GMAW, de forma automatizada, pode ser observado na Fig. 1 (a), já na Fig. 1 (b) são apresentados maiores detalhes do processo nas proximidades da peça de metal que recebe a solda.




Figura 1: Processo GMAW, (Kou, 2003)

O derretimento do eletrodo gera as gotículas de metal representadas na Fig. 1 (b), que são direcionadas para a

poça de solda por uma combinação de forças que se devem a: efeitos eletromagnéticos, gravidade, tensão de superfície e vaporização. Os fatores que influenciam na ação dessas forças são: o tipo de gás, o diâmetro do arame, a velocidade de alimentação do arame e o *stick-out*, (Oliveira et al., 2020). Este último é compreendido como o comprimento de arame não derretido localizado entre o bico de gás e o ponto em que o eletrodo começa a ser consumido, (AWS, 2020).

O gás de proteção utilizado no processo GMAW, conforme Fig. 1 (b), forma uma atmosfera que tem a função de proteger tanto o arco elétrico quanto a poça de solda, evitando que esta passe por um processo de oxidação. Os gases utilizados são inertes, ou seja, não reagem quimicamente em condições normais de temperatura e pressão. Para metais não-ferrosos, ligas de aço e aço inoxidável, utiliza-se Argônio, Hélio e suas misturas. Para metais ferrosos, costuma-se adicionar oxigênio ou gás carbônico ao argônio, a fim de minimizar problemas que possam surgir durante a soldagem, (Kou, 2003).

Uma das principais vantagens do processo GMAW é a alta taxa de deposição, o que permite que peças de metal com maior espessura sejam soldadas com velocidades mais altas (Kou, 2003). Outras vantagens incluem pouca deformação da peça, boa proteção da poça de solda, e alta eficiência (ThaoNgo et al., 2019). Como desvantagens, pode-se citar a eventual dificuldade que a tocha de solda apresenta para atingir pequenas áreas ou cantos (Kou, 2003), e os defeitos que podem surgir nas peças após a realização da soldagem como efeito das altas temperaturas (ThaoNgo et al., 2019).

2.2 Eficiência

A eficiência é um parâmetro de grande relevância no contexto da soldagem a arco elétrico (Stenbacka, 2013). De forma sucinta, ela é definida como a razão entre a quantidade de calor transferida para a peça de metal e a energia nominal produzida pela fonte para gerar o arco elétrico (Essers and Walter, 1981; Kou, 2003), ou seja:

$$\eta = \frac{\text{calor transferido para o metal}}{\text{energia nominal}}$$

Um dos motivos que justifica a importância de η é sua aplicabilidade na estimativa de outro parâmetro, o calor imposto pelo arco elétrico, compreendido como a quantidade de calor, por unidade de comprimento do cordão de solda, imposta pelo arco elétrico ao material que está sendo soldado (Malin and Sciammarella, 2006; Oliveira et al., 2020). Este parâmetro é bastante significativo para a definição das características da junta, interferindo nas propriedades mecânicas, nas transformações metalúrgicas e na formação do cordão de solda, além de influenciar nas distorções características do metal e em aspectos econômicos (Haelsig and Mayr, 2013; Jorge et al., 2017; Liskevych et al., 2013). O calor imposto pelo arco elétrico é dado por:

$$H_e = \frac{\eta \cdot P}{v} \quad (1)$$

com

$$P = U \cdot I \quad (2)$$

onde: H_e é o calor imposto pelo arco elétrico (J/mm), v é a velocidade de soldagem (mm/s), P é a potência (W), U é a tensão (V) e I é a corrente (A), (Malin and Sciammarella, 2006; Haelsig et al., 2016).

Assim, compreendendo H_e como um parâmetro relevante e observando, na Eq. (1), que é necessário conhecer η para calcular H_e , conclui-se que η possui igual relevância e necessita ser estimado com a maior precisão possível. No entanto, os valores de η comumente utilizados são oriundos da literatura, ou das normas técnicas da soldagem que acabam fixando um valor global de η para cada uma das variações do processo de soldagem a arco elétrico, sem levar em consideração as condições que podem ser ajustadas de uma execução do processo, para outra (Haelsig et al., 2015).

Por exemplo, a norma técnica BS EN 1011-1:1998 (BSI, 2004) sugere que para o processo GMAW se assuma $\eta = 0,8$. No entanto, Haelsig et al. (2017) indicam que, na realidade, η pode variar de 0,65 a 0,9. Em seus estudos, Arevalo and Vilarinho (2012) verificaram um intervalo semelhante, com η variando de 0,66 a 0,82. Diante disso, torna-se imprescindível a busca por um método que forneça uma estimativa confiável para η , substituindo, assim, o valor tabelado encontrado nas normas técnicas. De acordo com Haelsig et al. (2012) uma relação válida para a soldagem a arco elétrico é:

$$Q = P \cdot t_w \cdot \eta \quad (3)$$

onde: Q é o aporte térmico (J), compreendido como a quantidade real de calor transferida para a peça de metal, já com as perdas descontadas conforme Hackenhaar et al. (2016), e t_w é o tempo de soldagem (s). É imediato, a partir da Eq. (3), que seja possível obter uma expressão para η , dada por:

$$\eta = \frac{Q}{P \cdot t_w}, \quad (4)$$

onde: η é um coeficiente adimensional, tal que $0 \leq \eta \leq 1$.

No entanto, apenas uma parte da energia produzida no processo é efetivamente transferida ao material que está sendo soldado. A outra parte se dissipa no ambiente, essa perda é inerente ao processo. Nesse sentido, deve-se considerar, para todos os efeitos $\eta < 1$ (Kou, 2003).

Para determinar o valor de Q e, consequentemente, estimar η , diversos métodos têm sido desenvolvidos, tanto analíticos quanto experimentais. Uma possibilidade seria a utilização de modelos baseados no fluxo de calor, mas estes se mostram limitados por não conseguirem contemplar todas as variáveis de um sistema de soldagem. Nesse contexto, a calorimetria surge como uma alternativa para determinar Q de forma experimental, apresentando bons resultados (Arevalo and Vilarinho, 2012).

2.3 Calorímetro de Fluxo Contínuo

Os calorímetros que utilizam fluxo contínuo de água são empregados com maior frequência na soldagem a arco elétrico. Para este princípio de funcionamento, é notável a existência de uma ampla variedade de modelos, que surgem a partir das alterações propostas pelos pesquisadores com o intuito de aperfeiçoar o desempenho dos dispositivos.

A ideia de utilizar um calorímetro com um fluxo contínuo de água não é algo relativamente novo, visto que este modelo de calorímetro já apareceu em artigos da década de 80, como é o caso de Kou and Le (1984) e Lu and Kou (1989). Na Fig. 2 é apresentada uma ilustração da configuração mais elementar de um calorímetro de fluxo contínuo de água.




Figura 2: Representação de um calorímetro de fluxo contínuo de água (adaptado de (Lu and Kou, 1989))

Conforme pode ser observado na Fig. 2, o dispositivo é constituído, basicamente, por um compartimento retangular, dito corpo do calorímetro, no qual são escavados dois canais: um para entrada e outro para saída de água. Sobre o compartimento, dispõe-se o corpo de prova, no qual será realizada a soldagem. Além disso, termopares são instalados para medir a temperatura da água tanto na entrada quanto na saída do calorímetro.

O corpo do calorímetro utilizado por Lu and Kou (1989) é fabricado em aço inoxidável, com 30cm de comprimento, 7,5cm de largura e 5cm de altura. O corpo de prova é uma chapa de alumínio, com 34cm de comprimento e 11cm de largura, funcionando, também, como tampa para o dispositivo. Outros materiais também podem ser utilizados na construção desse tipo de calorímetro, como, por exemplo, policloreto de vinila (PVC) (Nasiri et al., 2014), e cobre-fósforo (Silva et al., 2018).

Para a manutenção do fluxo contínuo de água, Lu and Kou (1989) utilizaram um sistema de abastecimento através de um tanque de água. Antes do início do experimento, é necessário completar o tanque com água, esperar que ele atinja a temperatura ambiente e, em seguida, preencher o corpo do calorímetro. Só então, o sistema de soldagem é posto em funcionamento.

O princípio de funcionamento do calorímetro de fluxo contínuo de água baseia-se na transferência de calor da chapa de metal que está sendo soldada para a água que

passa embaixo dela. Mantendo-se um fluxo com vazão controlada e constante no corpo do calorímetro, é possível extrair o calor da chapa, fazendo a temperatura da água se elevar. Então, conhecendo-se a diferença entre as temperaturas de entrada e saída da água, pode-se estimar a quantidade de calor que foi transferida da chapa para a água e, consequentemente, da tocha de solda para a chapa (Hackenhaar et al., 2016; Nasiri et al., 2014).

As curvas características para as temperaturas de entrada e saída da água, ao longo do tempo de execução do ensaio experimental com o calorímetro de fluxo contínuo de água, podem ser observadas na Fig. 3. Destaca-se que a curva referente à temperatura de entrada é constante, ou praticamente constante, uma vez que a água se encontra em temperatura ambiente ao entrar no calorímetro. Em relação à curva da temperatura de saída, percebe-se que ela cresce até um ponto de máximo, decresce logo em seguida e tende a estabilizar.




Figura 3: Curvas características para as temperaturas de entrada e saída da água (adaptado de (Kou and Le, 1984))

De acordo com Kou (2003), quando se utiliza um calorímetro de fluxo contínuo de água, Q pode ser calculado a partir de:

$$Q = \int_0^{\tau} V_a \cdot \rho \cdot C_p \cdot \Delta T(t) dt \quad (5)$$

onde: V_a é a vazão de água no calorímetro (m^3/s), ρ é a massa específica da água (kg/m^3), C_p é o calor específico da água ($J/kg \cdot ^\circ C$), τ é o tempo de duração do ensaio (s) e $\Delta T(t)$ é a função que descreve o comportamento da diferença de temperatura no tempo.

Considerando V_a , ρ e C_p constantes, e escrevendo $\Delta T(t)$ como $T_{out} - T_{in}$, obtém-se:

$$Q = V_a \cdot \rho \cdot C_p \cdot \int_0^{\tau} (T_{out} - T_{in}) dt \quad (6)$$

onde: T_{in} é a temperatura de entrada da água ($^\circ C$) e T_{out} é a temperatura de saída da água ($^\circ C$) do calorímetro. Nessas condições, a integral que aparece na Eq. (6) corresponde à

área entre as curvas da Fig. 3 (Kou, 2003).

Utilizando termopares para aquistar dados de T_{in} e T_{out} , com um intervalo de ΔT segundos entre uma leitura e outra, após τ segundos é obtida uma quantidade q de dados. Visto que são conhecidos esses q dados, mas não se conhece a função $\Delta T(t)$, então é conveniente calcular a integral da Eq. (6) a partir da Soma de Riemann, como proposto por Hackenhaar et al. (2016) dada por:

$$Q = V_a \cdot \rho \cdot C_p \cdot \sum_{i=1}^q (T_{out_i} - T_{in_i}) \cdot \Delta t. \quad (7)$$

Por fim, destaca-se que o calorímetro de fluxo contínuo de água merece atenção especial, pois é esse o princípio de funcionamento do dispositivo calorímetro construído pela Bruning Technometal Ltda.

3 Procedimentos Experimentais

Uma das etapas mais importantes de uma pesquisa científica é a definição dos procedimentos experimentais. No caso deste artigo, essa etapa foi executada pela empresa Bruning, dada a necessidade de equipamentos específicos e experiência para operá-los. A partir disso, foram realizadas soldagens de caráter experimental, nas quais utilizou-se um calorímetro de fluxo contínuo de água para aquistar os dados necessários para a determinação do aporte térmico (Q), que é fundamental para o cálculo da eficiência (η). Em seguida, esses dados foram tratados, para fins de remoção do calor residual, e finalmente, a influência de cada parâmetro do processo de soldagem (i.e., fator) foi analisada por meio do Método Taguchi.

3.1 Aquisição de Dados

O calorímetro de fluxo contínuo, construído pela Bruning, encontra-se em suas dependências, no município de Panambi, local onde os ensaios foram realizados. O corpo do calorímetro é feito de polioximetileno, possui duas divisórias, conforme Fig. 4, o que permite uma melhor troca de calor entre o corpo de prova e a água (Hackenhaar et al., 2016). As dimensões do corpo do calorímetro são: 475mm de comprimento, 150mm de largura, e 70mm de altura.

Acoplado ao calorímetro, há um registro conectado a uma mangueira. Antes do início da soldagem, o registro é aberto e o calorímetro é preenchido com água. Quando esta sair pela mangueira, significa que o ar que havia no interior do dispositivo foi eliminado, entretanto, mesmo com a utilização do registro, é necessário inclinar o calorímetro por alguns instantes, a fim de garantir que não fiquem bolhas de ar no corpo do dispositivo. O calorímetro da Bruning não conta com sistema de abastecimento, de modo que a água é utilizada diretamente do encanamento da empresa. Para controlar a vazão de entrada, é utilizado um medidor digital.

Para aferir a temperatura da água no decorrer do ensaio, são utilizados dois termopares, um na entrada e outro na saída do calorímetro. O erro máximo dos termopares é 0,3°C mais 0,5% da temperatura registrada. Após a realização da soldagem, é necessário aguardar o equilíbrio




Figura 4: Corpo do calorímetro utilizado pela Bruning

térmico entre a água e o corpo de prova para encerrar o experimento. Nesse sentido, foi adotado como critério a diferença de $0,5^{\circ}\text{C}$ entre a temperatura registrada pelo termopar da saída do calorímetro e a primeira leitura realizada pelo termopar de entrada da água.

O corpo de prova utilizado foi uma chapa de aço com 330mm de comprimento, 130mm de largura e $6,3\text{mm}$ de espessura. Além de ser a peça na qual a soldagem é realizada, o corpo de prova funciona também como tampa para o calorímetro. Na Fig. 5 são destacados os principais componentes desse dispositivo. No caso da Bruning, a soldagem é realizada por um robô sinérgico, ou seja, que tem a funcionalidade de adequar a energia aplicada no processo de acordo com os parâmetros de solda previamente definidos.




Figura 5: Componentes do calorímetro utilizado pela Bruning

Antes do início do experimento, é necessário ajustar na máquina de solda informando: o tipo de gás de proteção, a vazão do gás, a velocidade de soldagem, a velocidade de alimentação do arame e o *stick-out*. A partir da combina-

ção desses cinco parâmetros, o robô de solda determina a tensão e a corrente, e por consequência, a potência a serem aplicadas no decorrer do processo. Além desses, há alguns parâmetros que não são alterados de um ensaio para outro, conforme apresentado na ()reftab:parâmetros.

Tabela 1: Parâmetros invariáveis para os diferentes ensaios experimentais

Parâmetro	Valor adotado
Intervalo de amostragem (s)	0,01
Vazão de água (l/min)	2,3
Massa específica da água (kg/m^3)	997
Calor específico da água ($\text{J}/\text{kg} \cdot ^{\circ}\text{C}$)	4187

As temperaturas registradas pelos termopares são gravadas em um arquivo com a extensão *.xlsx*, que possui quatro colunas: a primeira deles corresponde ao instante de tempo t , a segunda apresenta a temperatura de entrada T_{in} da água, na terceira encontra-se a temperatura de saída T_{out} da água e a última coluna à diferença ΔT entre T_{out} e T_{in} . Cada um desses arquivos possui milhares de linhas, devido ao intervalo de amostragem considerado.

3.2 Método Taguchi

O planejamento experimental é amplamente utilizado para analisar a influência de vários fatores em um mesmo processo, bem como as interações entre eles (Roy, 2010; Rosa et al., 2009). Em um planejamento fatorial completo, o número N de experimentos a serem realizados é dado por:

$$N = K^r \quad (8)$$

onde: K é o número de níveis (i.e., valor atribuído nos experimentos) de cada fator, e r é a quantidade de fatores.

Para o caso dos ensaios realizados pela Bruning, têm-se 5 parâmetros de solda, ou seja, 5 fatores. Substituindo, na Eq. (8), r por 5 e K por 2, 3, 4, etc., obtém-se um total de, respectivamente, 32, 243, 1024, etc., experimentos. Visto que N cresce rapidamente à medida em que se incrementa o número de níveis por fator, surge a necessidade de buscar uma alternativa mais viável ao planejamento experimental, uma vez que seria inconveniente realizar, por exemplo, 243 ou mais soldagens em corpos de prova, por questões óbvias relacionadas a tempo e custo financeiro. Além disso, com apenas 32 experimentos, a análise ficaria restrita a, somente, 2 níveis por fator.

Nesse contexto, a Bruning optou por realizar o planejamento experimental por meio do Método Taguchi que permite analisar a influência dos vários parâmetros de uma maneira simplificada, reduzindo significativamente a quantidade de experimentos, por meio da utilização de arranjos ortogonais (Moita, 2007; Pimenta et al., 2012). Cada um desses arranjos é indicado pelo símbolo L_N , em que N é o número de experimentos (Roy, 2010). Os mais utilizados são L_4 , L_8 , L_9 , L_{12} , L_{16} , L_{18} , L_{27} e L_{32} , para fatores com 2 e 3 níveis (Pimenta et al., 2012).

Para realizar uma avaliação dos resultados dos experimentos, o Método Taguchi utiliza o quociente Sinal-Ruído

(S/N), que é uma função de otimização que representa a relação entre a sensibilidade e a variabilidade de um sistema (Pimenta et al., 2012). De acordo com Roy (2010), a função S/N é dada por:

$$S/N = -10 \log(\text{MSD}), \quad (9)$$

onde: MSD é o desvio quadrático médio.

Segundo Roy (2010), existem três possibilidades para determinar MSD, cuja escolha deve partir da intenção do pesquisador. São elas:

- menor é melhor; ou seja, quanto menor o valor da variável resposta, melhor para o processo. Nesse caso, tem-se:

$$\text{MSD} = \frac{1}{n} \sum_{i=1}^n (y_i)^2, \quad (10)$$

onde: y_i é cada observação da variável resposta;

- maior é melhor; ou seja, quanto maior o valor da variável resposta, melhor para o processo. Nesse caso, tem-se:

$$\text{MSD} = \frac{1}{n} \sum_{i=1}^n \frac{1}{(y_i)^2}, \quad (11)$$

- nominal é melhor; ou seja, quanto mais próxima a variável resposta estiver de um valor x determinado pelo pesquisador, melhor para o processo, nesse caso tem-se:

$$\text{MSD} = \frac{1}{n} \sum_{i=1}^n (y_i - x)^2. \quad (12)$$

Para a aplicação do Método Taguchi, conforme Tabela 2, a Bruning considerou como fatores os cinco parâmetros de solda, a quantidade de níveis variando entre dois ou três valores para cada um deles. Os níveis relativos ao tipo de gás, indicados pelas abreviaturas C10, C25 e F36, apresentam as seguintes composições:

- C10: 10% de gás carbônico (CO_2) e 90% de argônio (Ar);
- C25: 25% de CO_2 e 75% de Ar;
- F36: 5% de oxigênio (O_2) e 95% de Ar.

Tabela 2: Fatores e respectivos níveis considerados pela Bruning nos ensaios

Fatores	QN	V
Vazão do gás (l/min)	2	20, 15
Tipo de gás	3	C10, C25, F36
Vel. de soldagem (mm/min)	3	250, 300, 350
Vel. de alimentação do arame (m/min)	3	7, 9, 11
Stick-out (mm)	3	15, 20, 25

QN = Quantidade de Nível.
V = Valores.

Nessas condições, foi utilizado para o planejamento ex-

perimental um arranjo ortogonal do tipo L_{18} , portanto, sendo necessária a realização de 18 ensaios conforme apresentado no quadro da Fig. 6. No entanto, para se obter repetitividade do experimento e, consequentemente, aprimorar a qualidade da análise estatística, cada uma das combinações apresentadas na Fig. 6 foi repetida 3 vezes, gerando, assim, um total de 54 ensaios. Visto que o objetivo da Bruning é obter o maior valor possível para η , a função S/N escolhida foi a maior é melhor, que corresponde à Eq. (11).

Como ferramenta para aplicar o método e realizar os respectivos cálculos foi utilizado o software estatístico Minitab, que possui recursos específicos para elaboração de planejamento experimental, incluindo o Método Taguchi. Por meio da utilização desse software, é possível classificar os fatores por ordem de influência e encontrar a melhor combinação entre os mesmos. Os resultados obtidos indicaram que a ordem dos parâmetros de solda, daquele com maior influência para o com menor influência no valor de η , foi a seguinte: 1. Tipo de Gás; 2. Velocidade de Alimentação do Arame; 3. Stick-Out; 4. Vazão de Gás; 5. Velocidade de Soldagem. Além dessa classificação por ordem de influência, a análise realizada com o auxílio do software Minitab apontou a melhor combinação entre eles. Esse resultado é apresentado na Tabela 3.

Tabela 3: Melhor combinação para os parâmetros de solda via Método Taguchi

Parâmetro	1. TG	2. VAA	3. SO	4. VG	5. VS
Valor	C10	7	20	15	350

TG = Tipo de Gás.

VAA = Velocidade de Alimentação do Arame.

SO = Stick-Out.

VG = Vazão de Gás.

VS = Velocidade de Soldagem.

Para validar se a combinação de parâmetros sugerida pelo software Minitab realmente confere altos valores de η ao processo de soldagem, a Bruning realizou mais 24 ensaios, gerados a partir de 8 combinações entre os parâmetros de solda com 3 repetições para cada um deles. Como pode ser observado na Tabela 4, na primeira linha a combinação é justamente aquela apontada como melhor possível pelo Método Taguchi, as demais foram obtidas a partir da combinação entre as variações dos parâmetros, que se encontram numerados de 1. a 5., tal como antes.

Da observação dos resultados apresentados na Tabela 4, conclui-se que a melhor combinação apontada pelo Método Taguchi foi aquela que apresentou um melhor resultado para Eficiência Média (EM), ou seja, $\eta = 0,6257$, considerando os três ensaios realizados para cada combinação entre os parâmetros. Destaca-se, também, que o Desvio Padrão (DP) é baixo para todos os valores médios da Tabela 4.

4 Modelagem Matemática

Vazão de gás (l/min)	Tipo de gás	Velocidade de soldagem (mm/min)	Velocidade de alimentação do arame (m/min)	Stick-out (mm)
15	C10	250	7	15
15	C10	300	9	20
15	C10	350	11	25
15	C25	250	7	20
15	C25	300	9	25
15	C25	350	11	15
15	F36	250	9	15
15	F36	300	11	20
15	F36	350	7	25
20	C10	250	11	25
20	C10	300	7	15
20	C10	350	9	20
20	C25	250	9	25
20	C25	300	11	15
20	C25	350	7	20
20	F36	250	11	20
20	F36	300	7	25
20	F36	350	9	15

Figura 6: Arranjo ortogonal L_{18} utilizado pela Bruning

Tabela 4: Ensaios realizados para validar o resultado do Método Taguchi

Parâmetros						
1. TG	2. VAA	3. SO	4. VG	5. VS	EM	DP
C10	7	20	15	350	0,6257	0,027
C10	7	20	15	300	0,5050	0,02
C10	7	20	15	250	0,4874	0,015
C10	7	20	20	350	0,4234	0,013
C10	7	15	15	350	0,4184	0,028
C10	7	25	15	350	0,3655	0,02
C10	9	20	15	350	0,3403	0,018
C10	11	20	15	350	0,3159	0,054

TG = Tipo de Gás.

VAA = Velocidade de Alimentação do Arame.

SO = Stick-Out.

VG = Vazão de Gás.

VS = Velocidade de Soldagem.

4.1 Redes Neurais Artificiais

Uma Rede Neural Artificial (RNA) é um modelo matemático que procura simular a estrutura e a funcionalidade de uma rede neural biológica, (Krenker et al., 2011). Ela é composta por unidades fundamentais de processamento

de informação densamente interligadas entre si denominadas neurônios, (Furtado, 2019).

Cada neurônio de uma RNA realiza o processamento de forma isolada e envia o resultado para os demais, por meio das conexões existentes entre eles. A estas conexões atribui-se um determinado valor chamado peso sináptico, que estabelece o grau de conectividade entre um neurônio e outro. É por meio delas que a RNA é capaz de resolver problemas altamente complexos, (Furtado, 2019).

A estrutura de um neurônio de uma RNA é apresentada na Fig. 7, onde é possível identificar que o valor da entrada p sofre uma alteração inicial, determinada pelo peso sináptico w . Em seguida, adiciona-se um termo linear b , dito bias, definido por Furtado (2019) como uma excitação provocada por uma polarização constante. Finalmente, uma função de ativação F é utilizada para gerar o valor de saída a . De acordo com Krenker et al. (2011), F pode ser qualquer função matemática. No entanto, as mais utilizadas são: função degrau unitário, função linear e função sigmoide, (Furtado, 2019).

Matematicamente, o processamento de um neurônio de uma RNA pode ser expresso por:

$$a = F(w \cdot p + b) \quad (13)$$




Figura 7: Neurônio de uma RNA, (Finocchio, 2014)

onde: p é o valor de entrada, w é o peso sináptico, b é o bias, F é a função de ativação e a é o valor de saída. Destaca-se que w e b são parâmetros ajustáveis de acordo com a necessidade do usuário da RNA.

Na Fig. 7, o neurônio representado possui apenas um valor de entrada. No entanto, um neurônio artificial pode receber inúmeras entradas, e cada uma das p entradas é multiplicada por um peso sináptico diferente e combinada com as demais antes de passar pela função de ativação, (Finocchio, 2014). Em termos matemáticos, a saída associada a um neurônio que recebe p sinais de entrada, é dada por:

$$a = F\left(\sum_{i=1}^R (w_i \cdot p_i) + b\right). \quad (14)$$

Obviamente, uma RNA não é formada por apenas um neurônio, mas uma determinada quantidade deles, que se organizam em camadas. Além de uma camada de entrada, que recebe os sinais a serem processados, e uma camada de saída, que apresenta o resultado pós-processamento, a RNA possui uma ou mais camadas intermediárias, geralmente denominadas camadas ocultas, nas quais a maior parte do processamento é realizada pelos neurônios, (Furtado, 2019).

Em relação à quantidade ideal de neurônios em cada camada, pode-se dizer que essa é uma questão intuitiva, que varia de um problema para outro. No entanto, (Haykin, 2009) aponta que a utilização de um grande número de neurônios permite um alto grau de acurácia e maior tolerância a falhas. Outro aspecto importante de uma RNA é a sua arquitetura, que corresponde à maneira como os neurônios são estruturados. Basicamente, as arquiteturas podem ser classificadas em: *feedforward* de uma camada, *feedforward* multicamadas ou recorrentes. Destas, destaca-se a arquitetura *feedforward* multicamadas, que será utilizada nas simulações desse artigo.

Elegida uma arquitetura e construída a RNA, é necessário treiná-la para que ela aprenda a resolver o problema em questão. No caso deste artigo, será utilizada a metodologia de treinamento supervisionado, na qual é necessário fornecer a resposta desejada para o padrão de entrada. Assim, os parâmetros da RNA são ajustados para que o erro, ou seja, a diferença entre os valores obtidos e os valores esperados, seja mínimo ou satisfatório, (Furtado, 2019). Para o treinamento é empregado o algoritmo *backpropagation*, que é amplamente aplicado em redes multicamadas e utiliza um processo iterativo para ajustar os parâmetros da RNA, com o objetivo de minimizar a soma dos erros quadráticos por

meio de uma técnica de gradiente descendente, (Sibi et al., 2013). Destaca-se que nesse artigo a ferramenta computacional *nnTool* do Matlab foi selecionada para criar e treinar as RNAs a partir dos dados experimentais produzidos pela Bruning.

4.2 Metodologia das Simulações

Para a realização das simulações, inicialmente, as variáveis de entrada e saída da RNA foram determinadas. Dos cinco parâmetros com influência testada via Método Taguchi o tipo de gás foi desconsiderado, visto que o C10 é o gás amplamente utilizado pela Bruning antes de ser apontado pelo Método Taguchi como o melhor tipo de gás entre os três testados. Portanto, as variáveis de entrada do modelo são: Velocidade de Alimentação do Arame (m/min); *Stick-Out* (m); Vazão de Gás (m^3/min), e Velocidade de Soldagem (m/min). Em relação à saída, a escolha óbvia é a eficiência do processo, pois este é o parâmetro que se deseja estimar por meio do modelo.

A partir da fixação do tipo de gás C10, foi possível selecionar um conjunto de 42 ensaios experimentais apresentados na Tabela 5. Os dados desses ensaios estão organizados da seguinte maneira, os 18 primeiros ensaios realizados pela Bruning são as combinações apontadas pelo Método Taguchi na Fig. 6 para o gás C10, repetidas 3 vezes; os 24 ensaios restantes são os utilizados para validar método Taguchi, apresentados na Tabela 4, também repetidos 3 vezes.

Para calcular η em relação a esses 42 ensaios, a Bruning fez uso de um *software*, desenvolvido pelo GAIC em linguagem Python. Os valores de η foram obtidos através da implementação das Eq. (4) e Eq. (7). Antes de dar início às simulações com as RNA, as variáveis de entrada passaram por um processo de normalização. Nesse sentido, todas as unidades de comprimento foram convertidas para metro (m), de tempo para minuto (min), e de volume para metro cúbico (m^3).

Em seguida, o conjunto de dados experimentais foi duplicado, ou seja, repetiu-se uma vez as informações de cada um dos ensaios, gerando um conjunto com 84 ensaios. Na sequência, definiu-se que diversas RNAs seriam criadas e treinadas, variando, de uma para outra, as seguintes propriedades: número de camadas ocultas, quantidade de neurônios em cada camada, e função de ativação.

Nas RNAs com duas camadas ocultas, foram utilizados 40 e 60 neurônios em cada uma delas. Para as RNAs com três camadas ocultas, as quantidades de neurônios utilizadas foram 20 e 30. Em ambos os casos, as funções de ativação testadas foram: linear pura (PURELIN), sigmoide tangente (TANSIG) e sigmoide logarítmica (LOGSIG).

Destaca-se também que as redes que foram treinadas com as funções de ativação PURELIN e LOGSIG em todas as camadas, tanto ocultas quanto de saída, apresentaram resultados bastante inferiores àqueles obtidos com a função TANSIG.

No entanto, observou-se que mantendo as funções PURELIN ou LOGSIG nas camadas ocultas e alterando a função de ativação da camada de saída para TANSIG, os resultados apresentaram uma melhora significativa. Portanto, de agora em diante quando indicado que uma RNA possui funções de ativação dos tipos PURELIN ou LOGSIG, deve-

se subentender que a função da camada de saída é TANSIG.

Após a etapa de treinamento, cada uma das RNAs foi exportada para a *workspace* do MatLab, a fim de que fosse calculado o erro relativo médio dado por:

Tabela 5: Dados experimentais utilizados na simulação.

Ensaio	VAA	SO	VG	VS	Eficiência
1	7	0,015	0,015	0,25	0,6702
2	7	0,015	0,015	0,25	0,6364
3	7	0,015	0,015	0,25	0,6736
4	9	0,020	0,015	0,30	0,5874
5	9	0,020	0,015	0,30	0,6508
6	9	0,020	0,015	0,30	0,6799
7	11	0,025	0,015	0,35	0,6576
8	11	0,025	0,015	0,35	0,6273
9	11	0,025	0,015	0,35	0,5440
10	11	0,025	0,020	0,25	0,5052
11	11	0,025	0,020	0,25	0,5918
12	11	0,025	0,020	0,25	0,6073
13	7	0,015	0,020	0,30	0,6905
14	7	0,015	0,020	0,30	0,6515
15	7	0,015	0,020	0,30	0,6302
16	9	0,020	0,020	0,35	0,6545
17	9	0,020	0,020	0,35	0,6287
18	9	0,020	0,020	0,35	0,6019
19	7	0,020	0,015	0,35	0,6509
20	7	0,020	0,015	0,35	0,6286
21	7	0,020	0,015	0,35	0,5976
22	7	0,020	0,015	0,30	0,5174
23	7	0,020	0,015	0,30	0,5158
24	7	0,020	0,015	0,30	0,4818
25	7	0,020	0,015	0,25	0,4986
26	7	0,020	0,015	0,25	0,4932
27	7	0,020	0,015	0,25	0,4705
28	7	0,020	0,020	0,35	0,4107
29	7	0,020	0,020	0,35	0,4363
30	7	0,020	0,020	0,35	0,4233
31	7	0,015	0,015	0,35	0,4304
32	7	0,015	0,015	0,35	0,3868
33	7	0,015	0,015	0,35	0,4380
34	7	0,025	0,015	0,35	0,3545
35	7	0,025	0,015	0,35	0,3535
36	7	0,025	0,015	0,35	0,3884
37	9	0,020	0,015	0,35	0,3503
38	9	0,020	0,015	0,35	0,3194
39	9	0,020	0,015	0,35	0,3510
40	11	0,020	0,015	0,35	0,3677
41	11	0,020	0,015	0,35	0,2602
42	11	0,020	0,015	0,35	0,3198

TG = Tipo de Gás.

VAA = Velocidade de Alimentação do Arame.

SO = *Stick-Out*.

VG = Vazão de Gás.

VS = Velocidade de Soldagem.

$$\bar{\varepsilon} = \frac{1}{q} \cdot \sum_{i=1}^q \frac{|\bar{a}_i - \bar{t}_i|}{\bar{t}_i} \quad (15)$$

onde: $\bar{a}$ é o vetor de saídas calculado pela RNA, $\bar{t}$ é o vetor *target* (i.e., alvo), q é a quantidade de elementos nos vetores $\bar{a}$ e $\bar{t}$, e $\bar{\varepsilon}$ é o erro relativo médio da RNA.

Uma vez determinado o valor de $\bar{\varepsilon}$ para cada uma das RNAs criadas, utilizou-se esse parâmetro para decidir qual a combinação entre as propriedades da RNA seria utilizada na etapa de validação. Ou seja, definiu-se que o modelo a ser validado deveria ter a mesma quantidade de camadas ocultas, o mesmo número de neurônios em cada camada e a mesma função de ativação da RNA que apresentou menor valor de $\bar{\varepsilon}$, dentre aquelas treinadas nesta etapa de simulação.

4.3 Metodologia de Validação

Para realizar a validação das RNAs foi utilizado o método *k-fold cross-validation*. Esse método consiste em dividir o conjunto de dados D em k subconjuntos $F_1, F_2, \dots, F_k$, de modo que $F_i \cap F_j = \emptyset, \forall i \neq j$, (Jiang and Wang, 2017). Em outras palavras, o conjunto D é dividido em k subconjuntos de mesmo tamanho ou de tamanhos aproximados, (Xu et al., 2018). Em seguida, deve-se treinar o modelo com $k - 1$ subconjuntos, usando o remanescente para posterior validação. Esse processo é repetido k vezes, até que todos os k subconjuntos tenham sido utilizados para validar o modelo, (Jiang and Chen, 2016).

No caso deste artigo, o conjunto D com 42 ensaios foi dividido em $k = 6$ subconjuntos com 7 ensaios em cada; desses 7 ensaios, 6 são utilizados para o treinamento e 1 para validação das RNAs. Então, 6 novas RNAs foram criadas e treinadas com a ferramenta *nnTool*, nesse treinamento estiveram envolvidos 35 ensaios, que duplicados, geraram um conjunto com 70 ensaios experimentais.

O erro referente a cada um dos k modelos validados pelo método *k-fold cross-validation* foi calculado fazendo uso da equação:

$$\bar{\varepsilon}_k = \frac{1}{q} \cdot \sum_{i=1}^q \frac{|\hat{y}_i - y_i|}{y_i} \quad (16)$$

onde: cada $\hat{y}_i$ é um valor de η calculado pela RNA, cada y_i é o valor de η dado pelo k -ésimo conjunto selecionado para validação, e $\bar{\varepsilon}_k$ é o erro relativo médio referente ao k -ésimo modelo.

Ao final do processo de validação, obteve-se o valor de $\bar{\varepsilon}$ para cada uma das 6 RNAs criadas, todas diferentes entre si, pois mesmo que não se alterem as propriedades da RNA, ela tende a retornar resultados distintos quando treinada com conjuntos de dados diferentes. Nessas condições, analisou-se cada um dos 6 modelos de RNA e elegeu-se como melhor dentre eles aquele que apresentou menor valor para $\bar{\varepsilon}$.

5 Resultados das Simulações e Discussões

Nesta seção são apresentados os resultados obtidos das RNAs desenvolvidas a partir da ferramenta computacional *nntool* do Matlab, e os procedimentos metodológicos adotados nessa pesquisa. Nas análises procurou-se comparar o desempenho dos diferentes modelos obtidos, sobretudo no que diz respeito ao erro relativo médio ($\bar{\varepsilon}$) dos mesmos, a fim de identificar aquele que tende a apresentar maior assertividade.

Em um primeiro momento são apresentados os resultados das RNAs com duas camadas ocultas e, posteriormente, os resultados das RNAs com três camadas ocultas. Em ambos os casos foram criadas e treinadas 6 RNAs, a fim de contemplar todas as possibilidades de combinações entre as duas quantidades de neurônios por camada, ou seja, 40 ou 60 neurônios para as RNAs com duas camadas ocultas; e 20 ou 30 para as RNAs com três camadas ocultas; e as três funções de ativação PURELIN, TANSIG e LOGSIG que foram utilizadas para cada quantidade de camadas ocultas.

Na **Tabela 6** são apresentados os resultados referentes às RNAs com duas camadas ocultas, com destaque para o valor de $\bar{\varepsilon}$ aqui apresentado na forma percentual, e o respectivo desvio padrão. Os modelos estão identificados por letras maiúsculas do alfabeto latino. A partir dos resultados percebe-se que as RNAs com as funções de ativação TANSIG e LOGSIG, para ambas as quantidades de neurônios, tiveram desempenho semelhante, com $\bar{\varepsilon}$ em torno de 4, 5%. Por outro lado, as redes com a função PURELIN apresentaram um desempenho bastante inferior às demais.

Tabela 6: Resultados das RNAs com 2 camadas ocultas.

RNA	NC	FA	ERM (%)	DP
A	40	TANSIG	4,55	3,95
B	60	TANSIG	4,56	4,05
C	40	LOGSIG	4,56	3,76
D	60	LOGSIG	4,52	3,85
E	40	PURELIN	17,10	12,40
F	60	PURELIN	18,67	12,370

NC = Neurônio por Camada.

FA= Função de Ativação.

ERM = Erro Relativo Médio.

DP = Desvio Padrão.

Na **Tabela 7**, por sua vez, são apresentados os resultados referentes às RNAs com três camadas ocultas, destacando-se novamente os valores de $\bar{\varepsilon}$ e os respectivos desvios padrão. Observa-se que as RNAs com a função TANSIG apresentaram leve melhora no valor de $\bar{\varepsilon}$, sem alterações significativas no desvio padrão, quando comparadas às RNAs com duas camadas ocultas. Por esse motivo, definiu-se a RNA H como a melhor dentre as doze testadas. De posse desse resultado, procedeu-se para a validação das RNAs a partir da aplicação do método *k-fold cross-validation*, onde foram consideradas as mesmas propriedades da RNA H, ou seja, três camadas ocultas, 30 neurônios por camada e a função de ativação TANSIG, conforme **Fig. 8**.

Na **Tabela 8**, são apresentados os resultados da validação das RNAs numeradas de 1 a 6, que correspondem aos 6

Tabela 7: Resultados das RNAs com 3 camadas ocultas.

RNA	NC	FA	ERM (%)	DP
G	20	TANSIG	4,48	4,05
H	30	TANSIG	4,47	3,71
I	20	LOGSIG	4,67	3,49
J	30	LOGSIG	4,53	3,6859
K	20	PURELIN	17,85	12,43
L	30	PURELIN	32,70	25,74

NC = Neurônio por Camada.

FA= Função de Ativação.

ERM = Erro Relativo Médio.

DP = Desvio Padrão.

subconjuntos criados pelo método *k-fold cross-validation* com destaque para o valor de $\bar{\varepsilon}$ e o respectivo desvio padrão. Além disso, a **Tabela 8** contém, para cada RNA, o maior e o menor erro relativo observados dentre os 7 calculados, que correspondem aos 7 ensaios dispostos em cada um dos 6 subconjuntos.

Tabela 8: Resultados do método *k-fold cross-validation*.

RNA	ERM (%)	DP	Ma ER (%)	Me ER (%)
1	10,01	9,22	29,07	2,17
2	6,83	5,90	16,83	1,57
3	3,13	2,72	7,45	0,26
4	8,92	6,45	19,15	2,12
5	5,84	2,83	10,34	3,59
6	10,34	7,22	18,45	2,54

ERM = Erro Relativo Médio.

DP = Desvio Padrão.

Ma ER = Maior Erro Relativo.

Me ER = Menor Erro Relativo.

Analisando a **Tabela 8**, percebe-se que os modelos nº 1, 4 e 6 apresentaram os piores desempenhos, com $\bar{\varepsilon}$ variando de 8, 92% a 10, 34%. Além disso, para esses modelos, observou-se uma diferença considerável entre o maior e o menor erro relativo observados, especialmente para o modelo nº 1, o que indica a existência de uma certa instabilidade, visto que, para determinados parâmetros de entrada, a RNA apresenta uma saída próxima ao ideal, ou seja, com baixo erro, e, para outros, o valor calculado se distancia muito do valor de η esperado.

Prosseguindo com a análise da **Tabela 8**, pode-se afirmar que o modelo nº 2 apresentou um desempenho intermediário, ou seja, o valor de $\bar{\varepsilon}$ não é elevado, mas ainda há uma diferença significativa entre o maior e o menor erro relativo observados. Por fim, destaca-se que os modelos nº 3 e 5 foram os dois que apresentaram melhor desempenho. Nessas condições, conclui-se que o modelo de RNA mais adequado para a estimativa da eficiência térmica da soldagem a arco elétrico é o nº 3, pois ele possui o menor dentre os seis valores de $\bar{\varepsilon}$ apresentados na **Tabela 8**, além de uma diferença não tão elevada entre o maior e o menor erro relativo calculado. Assim, pode-se afirmar que o modelo nº 3, tende a estimar valores de eficiência mais próximos daqueles obtidos por meio dos ensaios experimentais.

Em relação à avaliação do método *k-fold cross validation* como um todo, **Jiang and Wang (2017)** destacam que é




Figura 8: Diagrama genérico das RNAs criadas para validação

possível obter o erro total do processo de validação a partir da média aritmética entre os erros médios de cada um dos k modelos obtidos. Para o caso deste artigo, obteve-se 7,51% como média dos valores de $\bar{\varepsilon}$ apresentados na Tabela 8, com desvio padrão de 2,78. Uma vez que este erro relativo médio total não assume um valor demasiadamente alto, pode-se concluir que o método k -fold cross validation foi executado de maneira satisfatória, apresentando resultados confiáveis.

6 Conclusões

A eficiência térmica é um dos principais parâmetros de avaliação do processo de soldagem a arco elétrico. No entanto, determiná-la da maneira adequada pode ser um problema, visto que os valores da eficiência tabelados pelas normas técnicas nem sempre condizem com a realidade, pois não conseguem contemplar todas as variações possíveis nos parâmetros de solda. Neste contexto, neste artigo é desenvolvida a modelagem matemática, através de RNAs, com o objetivo de se obter uma estimativa prévia da eficiência no processo de soldagem a arco elétrico e evitar despesas com ensaios experimentais que produzem resultados abaixo do ideal.

A partir dos modelos obtidos, o de nº 3 apresentou erro médio relativo de pouco mais de 3% na estimativa da eficiência, o que permite apontá-lo como o modelo que melhor representa o conjunto de dados disponível. Além disso, o erro relativo médio total do método de validação utilizado também apresentou baixo percentual, indicando que as RNAs conseguiram estimar a eficiência de maneira satisfatória. Assim, por meio desse resultado, valida-se também a configuração de RNA selecionada para determinar a eficiência a partir dos parâmetros de solda considerados.

De posse de um modelo matemático devidamente validado e que apresenta boa assertividade, pode-se pensar em empregá-lo no âmbito da indústria, uma vez que a sua utilização pode trazer benefícios para a empresa que faz uso da soldagem a arco elétrico na confecção de seus produtos. Mais especificamente, o emprego do modelo matemático removeria a necessidade de realizar um novo ensaio experimental a cada alteração nos parâmetros de solda.

Como trabalhos futuros, considera-se válida a tentativa de obter modelos a partir da variação de outras propriedades das RNAs ou da inclusão de variáveis de entrada que aqui não foram consideradas, como, por exemplo, o tipo de gás de proteção e a potência elétrica aplicada ao processo. Entretanto, acredita-se que não seja necessário tornar o modelo mais complexo em relação ao número de camadas ocultas e à quantidade de neurônios em cada uma delas.

Agradecimentos

Os autores agradecem a empresa Bruning Tecnometal pelo apoio e colaboração no desenvolvimento desse projeto. Esta pesquisa foi financiada em parte pela was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES).

Referências

- Arevalo, H. D. H. and Vilarinho, L. O. (2012). Desenvolvimento e avaliação de calorímetros por nitrogênio líquido e fluxo contínuo para medição de aporte térmico, *Soldagem & Inspeção* 17: 236–250. <https://doi.org/10.1590/S0104-92242012000300008>.
- AWS (2020). *Standard Welding Terms and Definitions*. Disponível em https://pubs.aws.org/Download_PDFS/1__A3_OM_A3_0_2020-PV.pdf.
- BSI (2004). *Recommendations for Welding of Metallic Materials – Part 1: general guidance for arc welding*. Disponível em <https://www.iso.org/obp/ui/#iso:std:iso:tr:17671:-1:ed-1:v1:en>.
- Dedyukh, R. I. (2015). Special features of consumable electrode plasma welding (review), *Welding International* 29: 397–401. <https://doi.org/10.1080/09507116.2014.934541>.
- Essers, W. G. and Walter, R. (1981). Heat transfer and penetration mechanisms with gma and plasma-gma welding), *Welding Journal* 60: 37s–42s. http://files.aws.org/wj/supplement/WJ_1981_02_s37.pdf.
- Finocchio, M. A. F. (2014). *Noções de Redes Neurais Artificiais*. Disponível em <http://paginapessoal.utfpr.edu.br/mafinocchio/labsi-laboratorio-de-seguranca-e-iluminacao/redes-neurais-artificiais/NOCa0%20DE%20REDES%20NEURAI%20ARTIFICIAIS.pdf/view>.
- Furbee, B. (2011). Welding and parkinsonism, *Neurologic Clinics* 29: 623–640. <https://doi.org/10.1016/j.ncl.2011.05.007>.
- Furtado, M. I. V. (2019). *Redes Neurais Artificiais: uma Abordagem para Sala de Aula*, 1 edn, Atena Editora, Ponta Grossa.
- Hackenhaar, W., Mazzaferro, J. A. E., Gonzalez, A. R. and Machado, I. G. (2016). Influência da vazão e geometria da região de entrada sobre a eficiência térmica medida por um calorímetro de fluxo contínuo de água, *Soldagem & Inspeção* 21: 269–281. <https://doi.org/10.1590/0104-9224/SI2103.03>.

- Haelsig, A., Kusch, M. and Mayr, P. (2012). New findings on the efficiency of gas shielded arc welding, *Welding in the World* **56**: 98–104. <https://doi.org/10.1007/BF03321400>.
- Haelsig, A., Kusch, M. and Mayr, P. (2015). Calorimetric analyses of the comprehensive heat flow for gas metal arc welding, *Welding in the World* **59**: 191–199. <https://doi.org/10.1007/s40194-014-0193-0>.
- Haelsig, A. and Mayr, P. (2013). Energy balance study of gas-shielded arc welding process, *Welding in the World* **57**: 727–734. <https://doi.org/10.1007/s40194-013-0073-z>.
- Haelsig, A., Mayr, P. and Kusch, M. (2016). Determination of energy flows for welding processes, *Welding in the World* **60**: 259–266. <https://doi.org/10.1007/s40194-016-0297-9>.
- Haelsig, A., Pehle, S., Kusch, M. and Mayr, P. (2017). Reducing potential errors in the calculation of cooling rates for typical arc welding processes, *Welding in the World* **61**: 745–754. <https://doi.org/10.1007/s40194-017-0462-9>.
- Haykin, S. (2009). *Neural Networks and Learning Machines*, 3 edn, Pearson Prentice Hall, Canada.
- Huang, H. Y. (2010). Research on the activating flux gas tungsten arc welding and plasma arc welding for stainless steel, *Metals and Materials International* **16**: 819–825. <https://doi.org/10.1007/s12540-010-1020-9>.
- Jiang, G. and Wang, W. (2017). Error estimation based on variance analysis of k-fold cross-validation, *Pattern Recognition* **69**: 94–106. <https://doi.org/10.1016/j.patcog.2017.03.025>.
- Jiang, P. and Chen, J. (2016). Displacement prediction of landslide based on generalized regression neural networks with k-fold cross-validation, *Neurocomputing* **198**: 40–476. <https://doi.org/10.1016/j.neucom.2015.08.118>.
- Jorge, V. L., Gohrs, R. and Scotti, A. (2017). Active power measurement in arc welding and its role in heat transfer to the plate, *Welding in the World* **61**: 847–856. <https://doi.org/10.1007/s40194-017-0470-9>.
- Komanduri, R. and Hou, Z. B. (2000). Thermal analysis of the arc welding process: Part i. general solutions, *Metalurgical and Materials Transactions B* **31**: 1353–1370. <https://doi.org/10.1007/s11663-000-0022-2>.
- Kou, S. (2003). *Welding metallurgy*, 2 edn, Wiley-Interscience, New Jersey.
- Kou, S. and Le, Y. (1984). Heat flow during the autogenous gta welding of pipes, *Metalurgical and Materials Transactions A* **15A**: 1165–1171. <https://doi.org/10.1007/BF02644711>.
- Krenker, A., Bester, J. and Kos, A. (2011). *Artificial neural networks: methodological advances and biomedical applications*, 1 edn, InTechOpen, London.
- Kuntz, A. A. K., de Almeida, D. T., de Souza, J. H. C. and Hoffmann, R. (2017). Simulação numérica e verificação experimental de um calorímetro para medição da eficiência térmica nos processos de soldagem, *Conso-sul - 2o Congresso de Simulação e Otimização do Sul*, Universidade de PF, Passo Fundo. Disponível em <http://www.consosul.upf.br/index.php/v-1-2017/anaais>.
- Liskevych, O. and Scotti, A. (2015). Determination of the gross heat input in arc welding, *Journal of Materials Processing Technology* **225**: 139–150. <https://doi.org/10.1016/j.jmatprotec.2015.06.005>.
- Liskevych, O. et al. (2013). Intrinsic errors on cryogenic calorimetry applied to arc welding, *Welding in the World* **57**: 349–357. <https://doi.org/10.1007/s40194-013-0035-5>.
- Lu, M. J. and Kou, S. (1989). Power inputs in gas metal arc welding of aluminum – part 2, *Welding Journal* **60**: 452s–456s. [s.aws.org/wj/supplement/WJ_1989_11_s452.pdf](http://www.aws.org/wj/supplement/WJ_1989_11_s452.pdf).
- Malin, V. and Sciammarella, F. (2006). Controlling heat input by measuring net power, *Welding Journal* **85**: 44–50. <http://www.arcrafterplasma.com/welding/Controlling-heat-input-by-measuring-net-power.pdf>.
- Moita, N. F. V. C. (2007). *Implementação do método taguchi e análise de experiências na fase de testes de moldes para injeção de plásticos*, Mestrado em engenharia mecânica, Programa de Pós-Graduação em Engenharia Mecânica. Disponível em [http://Downloads/Tese_NunoMoitaN%20\(1\).pdf](http://Downloads/Tese_NunoMoitaN%20(1).pdf).
- Nasiri, M. B. et al. (2014). Investigation on the influence of various welding parameters on the arc thermal efficiency of the gtaw process by calorimetric method, *Journal of Mechanical Science and Technology* **28**: 3255–3261. <https://doi.org/10.1007/s12206-014-0736-8>.
- Oliveira, J. P., Miranda, R. M. and Fernandes, F. M. B. (2017). Welding and joining of niti shape memory alloys: a review, *Progress in Materials Science* **88**: 412–466. <https://doi.org/10.1016/j.pmatsci.2017.04.008>.
- Oliveira, J. P., Santos, T. G. and Miranda, R. M. (2020). Revisiting fundamental welding concepts to improve additive manufacturing: from theory to practice, *Progress in Materials Science* **107**: 100590. <https://doi.org/10.1016/j.pmatsci.2019.100590>.
- Pépe, N., Engerland, S., Colegrove, P. A. and Yapp, D. (2017). Measuring the process efficiency of controlled gas metal arc welding processes, *Science and Technology of Welding and Joining* **16**: 412–417. <https://doi.org/10.1179/1362171810Y.0000000029>.
- Pimenta, C. D., Silva, M. B., Claro, F. A. E. and Ribeiro, R. B. (2012). Método taguchi aplicado na identificação dos fatores causadores da descarbonetização do arame de aço sae 51b35, durante tratamento térmico de esferoidização, *GEPROS. Gestão da Produção, Operações e Sistemas* **7**: 97–108. <https://doi.org/10.15675/gepros.v0i2.800>.
- Rosa, J. L., Robin, A., Silva, M. B., C.A.Baldan and M.P.Peres (2009). Electrodeposition of copper on titanium wires: Taguchi experimental design approach, *Journal of*

- Materials Processing Technology* **209**: 1181–1188. <https://doi.org/10.1016/j.jmatprotec.2008.03.021>.
- Roy, R. K. (2010). *A primer on the Taguchi Method*, 1 edn, Society of Manufacturing Engineers, Michigan.
- Sibi, P., Jones, S. A. and Siddarth, P. (2013). Analysis of different activation functions using back propagation neural networks, *Journal of Theoretical and Applied Information Technology* **47**: 1264–1268. <https://www.jatit.org/volumes/Vol47No3/61Vol47No3.pdf>.
- Silva, N. N., Moreno, A. M., Arias, A. R. and Bracarense, A. Q. (2018). Study on the electric arc of gtaw process, *Journal of Physics: Conference Series* **1126**: 012013. <https://doi.org/10.1088/1742-6596/1126/1/012013>.
- Stenbacka, N. (2013). On arc efficiency in gas tungsten arc welding, *Soldagem & Inspeção* **18**: 380–390. <https://doi.org/10.1590/S0104-92242013000400010>.
- ThaoNgo, T., Wang, C. C., H.Huang, J. and Than, V. T. (2019). Estimating heat generation and welding temperature for gas metal arc welding process, *Applied Thermal Engineering* **160**: 114056. <https://doi.org/10.1016/j.applthermaleng.2019.114056>.
- Xu, L., Fu, H. Y., Goodarzi, M., Cai, C. B., Yin, Q. B., Wu, Y., Tang, B. C. and She, Y. B. (2018). Stochastic cross validation, *Chemometrics and Intelligent Laboratory Systems* **175**: 74–81. <https://doi.org/10.1016/j.chemolab.2018.02.008>.