



III MCSM

Modelagem Computacional no Sertão Mineiro

PPGMCS
Programa de Pós-Graduação em
Modelagem Computacional e Sistemas

REDE NEURAL MULTICAMADAS PARA CLASSIFICAÇÃO DE SOLDA ROBÓTICA COM BASE EM PARÂMETROS

Geraldo Luiz Souto Neto¹ - geraluizneto@gmail.com

¹Universidade Estadual de Montes Claros, UNIMONTES - Montes Claros, MG, Brasil

Resumo. Este trabalho propõe o desenvolvimento de um modelo computacional baseado em redes neurais artificiais, especificamente Multilayer Perceptron (MLP), para auxiliar na configuração de parâmetros de solda robótica MIG/MAG. Devido à criticidade de variáveis como corrente, tensão e velocidade na qualidade do cordão de solda, busca-se automatizar essa definição para reduzir a necessidade de ajustes empíricos e otimizar a eficiência do processo. Para superar a limitação de um dataset inicial reduzido (37 amostras), foi aplicada a técnica de data augmentation via Conditional Tabular Generative Adversarial Network (CTGAN), gerando dados sintéticos para tornar o aprendizado mais abrangente. O modelo foi desenvolvido em Python, utilizando a biblioteca Sklearn para normalização dos dados. Os resultados indicam uma acurácia satisfatória de 0,818, demonstrando potencial para que empresas definam parâmetros ideais sem a necessidade de um soldador experiente, reduzindo testes físicos e desperdício de material. Trabalhos futuros incluirão a implementação de algoritmos de otimização para os pesos da rede e a validação em ambiente real.

Palavras-chave: Redes neurais artificiais, Multilayer Perceptron (MLP), Solda robótica, Data augmentation.

1. INTRODUÇÃO

Para se obter controle sobre o resultado de uma solda, é necessário controlar as variáveis que a influenciam. Porém, além de serem interdependentes, muitas vezes é difícil perceber apenas por meio de testes quais dessas variáveis têm maior influência e a correlação entre elas. Dos Santos (2022) considerou isso e usou em seu trabalho uma abordagem para reduzir a complexidade de um conjunto de dados de solda. Por meio do método de análise dos componentes principais (PCA), o autor converte os dados de 4 variáveis, corrente, tensão, velocidade de solda e frequência, em um dataset de duas variáveis.

Yang *et al.* (2026, tradução própria) destacam o impacto da deformação causada pelo processo de soldagem em grandes eixos de flange e explora alternativas para uma previsão assertiva baseada nos parâmetros como corrente, tensão e velocidade, que são os principais responsáveis por regular a solda. Rocha *et al.* (2025, tradução própria) também destacam a criticidade dessas variáveis para soldagem, pois afetam diretamente as dimensões do cordão

de solda e, inclusive, apesar de serem comumente escolhidas de maneira empírica por soldadores, isso acaba trazendo resultados de baixa qualidade. Dessa forma, o autor propõe o uso de redes neurais artificiais para previsão de valores ótimos para esses parâmetros, considerando a eficácia dessa técnica em resultados encontrados na literatura.

Zhang *et al.* (2022, tradução própria) defendem que se encontra muita instabilidade e falta de padrão em soldas realizadas manualmente e ainda quando esse processo é usado na indústria ou em construção civil, a exigência em relação à qualidade da solda aumenta ainda mais. A solda manual enfrenta dificuldades não apenas na diferença de habilidade técnica entre os operadores, mas também nos riscos à segurança do trabalho que esses ambientes oferecem. Portanto, os robôs têm substituído operadores humanos nesse processo com o objetivo de aumentar a eficiência, qualidade e escala da produção. Segundo os autores, com o uso de tecnologias como aprendizado de máquina e sistemas especialistas, além de garantir a padronização e a produção em larga escala, os robôs podem se adaptar à dinâmica de ambientes diferentes e parâmetros complexos de soldagem.

Tendo em vista a capacidade dos manipuladores robóticos aplicados aos processos de soldagem e a possibilidade de ampliar isso com aprendizado de máquina, o presente trabalho trata do desenvolvimento de um modelo computacional para auxiliar na configuração de parâmetros de solda robótica.

2. MATERIAIS E MÉTODOS

O objeto desta pesquisa foram as soldas realizadas em placas metálicas unidas por meio de uma solda MIG com arame de 1,2 mm executada por um robô industrial. O gás utilizado foi uma mistura de 80% de argônio e 20% de CO₂.

O robô utilizado foi o Siasun SR12A-12/1.46 configurado para soldagem, mostrado na Figura 1. A trajetória de soldagem do robô foi desenvolvida por meio da interface de controle e programação (*teach pendant*).




Figura 1 - Robô de solda

2.1 Solda MIG/MAG ou GMAW

A solda GMAW (Gas Metal Arc Welding) ou MIG/MAG (Metal Inert Gas/Metal Active Gas) é um processo muito usado na indústria em que a união de dois materiais, geralmente metais, são unidos por meio da fusão deles usando, dentre outros métodos, o curto-circuito usando de um fio de metal em contato com as peças a serem soldadas. À medida que o fio é alimentado pela máquina de solda, ele se funde com a peça. (Yu *et al.*, 2024).

2.2 Redes Neurais Artificiais

Em seu trabalho, Habibkhah e Moallem (2025, tradução própria) descrevem uma rede neural como um modelo de algoritmo inteligente que pode ser composto de múltiplas camadas (Multi-layer Perceptron ou MLP). Uma rede MLP recebe um conjunto de dados na camada de entrada (*input layer*), que são processados pelas camadas seguintes (3 nesse caso) para melhorar a capacidade de seu algoritmo de reconhecer padrões complexos. A rede em questão reconhece os padrões para prever as características do cordão de solda que será realizado. Cada camada é um conjunto de neurônios, que são conectados entre si pelas sinapses. Outro conceito a ser explorado a partir desse exemplo é o de pesos que multiplicam cada valor de entrada da rede, os quais compõem a Equação 1, onde x são os valores de entrada, w são os pesos do nó i ao j , n é o número de nós da camada correspondente e b é o *bias*. Em outras palavras, a Eq. 1 representa cada neurônio da rede, que recebe um estímulo x , que é modificado por um peso sináptico w .

$$f = \sum_{i=1}^n (x_i w_{ij} + b_j) \quad (1)$$

A Figura 2, também extraída do último trabalho citado, ilustra a relação da função de ativação e a função do neurônio (Eq.1) com sua estrutura conceitual.




Figura 2 - Estrutura de um neurônio artificial

Da mesma forma, a arquitetura da rede MLP foi definida com 5 neurônios na entrada, 1 camada escondida de 25 neurônios, com taxa de aprendizagem adaptativa iniciando em 0,05 saída composta de apenas um neurônio, que é ativado por uma função linear conhecida como Rectified Linear Unit (ReLU) e método do gradiente descendente. Os critérios de parada foram erro médio menor ou igual a 1^{-6} e número de iterações igual a 1000. A Figura 3 é uma representação da arquitetura escolhida.




Figura 3 - Representação da rede MLP

Foram selecionados os principais parâmetros usados para programar uma solda como entradas da rede: velocidade linear da tocha (mm/s), corrente elétrica (A), tensão (V), oscilação da tocha (Hz), amplitude da oscilação (mm). Os parâmetros de cada cordão de solda realizado foram registrados em uma planilha e a qualidade avaliada em boa (1) ou ruim (0). A Figura 4 mostra um trecho dessa planilha.

Vel linear (mm/s)	Corrente (A)	Tensão (V)	Oscilação (Hz)	Amplitude (mm)	Qualidade
17	270	5	0	0	1
5	200	0	1	4	1
17	250	5	0	0	1
19	250	5	0	0	1
19	280	5	0	0	1
6	210	0	0	0	1

Figura 4 - Trecho da planilha de registro dos parâmetros de solda

A rede foi desenvolvida em linguagem Python usando o Google Colab como ambiente de desenvolvimento, que facilita o compartilhamento e a documentação e organização do código. Além de permitir a edição em dispositivos diferentes e execução de blocos isolados.

Dos Santos (2022) padronizou parâmetros de soldagem com média igual a 0 e desvio padrão 1 para evitar a influência entre eles em função de suas unidades de medida. A ideia ao padronizar ou normalizar os dados é evitar que os valores maiores tenham um peso maior no aprendizado da rede neural apenas em pela sua escala. Portanto, a função `StandardScaler()` da biblioteca Sklearn do Python foi usada para normalizar os parâmetros de treinamento em um conjunto com média 0 e desvio padrão igual a 1.

As métricas usadas para avaliação da classificação da rede foram a matriz de confusão, acurácia e F1 score.

2.3 Ampliação de dados (*data augmentation*)

Ao considerar alguns trabalhos envolvendo datasets de solda, percebeu-se no presente trabalho a necessidade de se utilizar técnicas para aumento do dataset (*data augmentation*). A CTGAN, disponível na biblioteca SDV do Python foi utilizada para esse fim.

“*Data augmentation* é uma técnica usada para aumentar a quantidade e melhorar a qualidade de dados transformando, aumentando ou sintetizando os dados originais.” (Cao, Zou e Lu, 2025, tradução própria).

Conditional Tabular Generative Adversarial Network (CTGAN). De acordo com Cao, Zou e Lu (2025), o CTGAN é um modelo de rede neural profunda usado para *data augmentation* em cenários com escassez de amostras. Por exemplo, o uso dos dados sintéticos gerados por essas técnicas em pesquisas de expectativa de vida já ajudou a melhorar a capacidade preditiva de modelos de aprendizado de máquina.

3. DESENVOLVIMENTO

Foram registradas as configurações usadas em 37 cordões de solda com sua respectiva classe (0 ou 1). Ou seja, foi elaborado um dataset com 37 valores, que foram salvos como um arquivo csv para serem processados pela rede neural. Entretanto, essa quantidade é muito pequena para os padrões de treinamento de uma rede neural, pois corre-se o risco de a rede aprender apenas esses padrões e não desenvolver a capacidade de generalizar, ou seja, de classificar configurações que não estavam no treinamento.

Apesar da necessidade de se gerar mais padrões, os recursos para realização dos testes são limitados, como as chapas usadas para soldagem, o que dificulta ainda a geração de configurações que vão gerar soldas ruins para diversificar o conjunto de dados. Por isso, com base em exemplos da literatura, como o trabalho de Rocha *et al.* (2025), decidiu-se gerar dados sintéticos para tornar o aprendizado da rede mais abrangente. Dessa forma, o algoritmo foi configurado para gerar 200 novos dados. Entretanto, observou-se que a CTGAN gera valores negativos, que não podem ser usados como parâmetros de solda. Por isso, foi desenvolvido um filtro para o vetor de dados sintéticos que nem sempre vai apresentar um tamanho de 200.

O código também foi programado para receber uma nova configuração dos 5 parâmetros de solda sugerida pelo usuário para ser classificada como boa ou ruim.

4. RESULTADOS

Além dos 37 padrões de entrada coletados por meio dos testes físicos, foram gerados mais 199 valores para treinamento. O código salva os novos padrões em um arquivo csv para análise posterior, caso necessário. Por meio desse arquivo, os dados negativos foram identificados e passaram a ser filtrados.

A rede treinada alcançou uma acurácia de 0,818 em 327 iterações. A Figura 5 mostra a saída do código contendo as métricas estabelecidas.

```
Treinando MLP com dados aumentados...
MLP treinado com dados aumentados com sucesso!

Número de iterações alcançadas (modelo aumentado): 327

Acurácia (modelo aumentado): 0.8181818181818182

Matriz de Confusão (modelo aumentado)
[[2 2]
 [0 7]]
```

	precision	recall	f1-score	support
0	1.00	0.50	0.67	4
1	0.78	1.00	0.88	7
accuracy			0.82	11
macro avg	0.89	0.75	0.77	11
weighted avg	0.86	0.82	0.80	11

Figura 5 - Saída do código

5. CONCLUSÕES

O código pode ser utilizado por empresas ao adquirirem um manipulador robótico de soldagem para possibilitar a definição dos parâmetros ideais sem a necessidade de um soldador experiente. Além disso, o uso desta rede neural pode reduzir a quantidade de testes em ambiente real e consequentemente a quantidade de material gasto no processo de soldagem. Dessa forma, é possível ter uma previsão da qualidade da solda antes de testá-la fisicamente.

A acurácia atingida é satisfatória por estar próxima de 1 e utilizar um número de iterações relativamente baixo em relação ao limite estabelecido de 1000 iterações. Entretanto, a rede neural desenvolvida será testada com outras arquiteturas e variações nos parâmetros para alcançar resultados melhores. Além disso, existem outras ferramentas que podem melhorar a acurácia. O próximo passo do trabalho será a implementação de Algoritmos de otimização para os pesos da rede. Quando se atingir uma acurácia melhor, os parâmetros classificados pela rede serão testados em ambiente real para validação.

Futuramente o projeto também irá se ramificar em outra abordagem que irá tratar da previsão de parâmetros com base em condições de solda desejadas.

Agradecimentos

Os autores agradecem à FAPEMIG (grant n OET-00243-26).

REFERÊNCIAS

- Cao, Zou, e Lu (2025), Augmentation method of fatigue data of welded structures based on physics-informed CTGAN, *Fracture and Structural Integrity*, 19(72), 162-178, <https://doi.org/10.3221/IGF-ESIS.72.12>.
- Dos Santos, Bryan Ferreira Rocha (2022), *Otimização dos parâmetros de soldagem Gmaw automatizada utilizando redes neurais*, Monografia (graduação), Instituto Federal do Espírito Santo, Curso Superior em Engenharia Mecânica, Vitória.
- Habibkhan, Fatemeh e Moallem, Mehrdad (2025), Application of machine learning for seam profile identification in robotic welding, *Machine Learning with Applications*, Volume 20, 100633, ISSN 2666-8270, <https://doi.org/10.1016/j.mlwa.2025.100633>.
- Rocha, V.R.; Lobato, F.S.; de Assis, P.A.Q.; Ribeiro, C.R.; da Cunha, S.S., Jr.; Vilarinho, L.O.; Andrade, J.R.; da Silva, L.R.R.; dos Santos Paes, L.E. (2025), Parametric Optimization of Artificial Neural Networks and Machine Learning Techniques Applied to Small Welding Datasets, *Processes*, 13, 2711, <https://doi.org/10.3390/pr13092711>.
- Yang, C., Xu, Z., Shi, F., Liu, K. e Cao, P. (2026), Study on a Process Parameter-Driven Deep Learning Prediction Model for Multi-Physical Fields in Flange Shaft Welding. *Materials*, 19(5), 995, <https://doi.org/10.3390/ma19050995>.
- Yu, R., Cao, Y., Martin, J., Chiang, O., & Zhang, Y. (2024), Robotizing double-electrode GMAW process through learning from human welders, *Journal of Manufacturing Processes*, 109, 140-150.
- Zhang, Y., Xiao, J., Zhang, Z., & Dong, H. (2022), Intelligent design of robotic welding process parameters using learning-based methods, *Ieee Access*, 10, 13442-13450.