LVI SBPO SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL
DE 04 ATÉ 07 NOVEMBRO 2024
FORTALEZA | CEARÁ

Otimização do Processo de Fresamento de Topo no Aço Inoxidável Duplex por meio de Inteligência Artificial

Matheus Brendon Francisco
Universidade Federal de Itajubá (UNIFEI)
Av. BPS, 1303, Pinheirinho, Itajubá – MG.
matheus_brendon@unifei.edu.br

Deborah Borges da Silva
Universidade Federal de Itajubá (UNIFEI)
Av. BPS, 1303, Pinheirinho, Itajubá – MG.
deborahborgessilva@unifei.edu.br

Guilherme Augusto Vilas Boas Vasconcelos
Universidade Federal de Itajubá (UNIFEI)
Av. BPS, 1303, Pinheirinho, Itajubá – MG.
d2020102469@unifei.edu.br

Giovana Carla da Silva Moraes
Universidade Federal de Itajubá (UNIFEI)
Av. BPS, 1303, Pinheirinho, Itajubá – MG.
giovana.moraes.ismart@gmail.com

Carlos Henrique de Oliveira
Universidade Federal de Itajubá (UNIFEI)
Av. BPS, 1303, Pinheirinho, Itajubá – MG.
carlos.henrique@unifei.edu.br

RESUMO

O fresamento de topo do aço inoxidável duplex UNS S32205 apresenta desafios significativos devido à complexidade de controlar a rugosidade da superfície resultante. Encontrar os parâmetros ideais de usinagem é crucial para garantir a qualidade final das peças e a eficiência do processo. Neste estudo, foi utilizado um Modelo Preditivo baseado em uma Rede Neural Artificial para otimizar os parâmetros de usinagem, como velocidade de corte, avanço por dente, largura fresada e profundidade de corte. A meta-heurística Particles Swarm Optimization foi aplicada para determinar o ponto ótimo do processo, visando a menor rugosidade superficial. A combinação dos parâmetros ótimos resultou em uma rugosidade de Ra = 0.5913637 μm. Além disso, foi realizada uma análise da influência de ruídos no ponto ótimo, revelando que fatores incontroláveis têm um impacto significativo no processo e devem ser considerados durante a análise.

PALAVRAS-CHAVE. Meta-heurística, Particle Swarm Optimization (PSO), Redes Neurais Artificiais, Rugosidade Superficial.

Tópicos. Meta-heurístics, Combinatorial Optimization, Computational Intelligence,

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

ABSTRACT

The milling of duplex stainless steel UNS S32205 presents significant challenges due to the complexity of controlling the resulting surface roughness. Finding the optimal machining parameters is crucial to ensure the final quality of the parts and the efficiency of the process. In this study, a Predictive Model based on an Artificial Neural Network was used to optimize machining parameters such as cutting speed, feed per tooth, milled width, and depth of cut. The Particle Swarm Optimization meta-heuristic was applied to determine the optimal point of the process, aiming for the lowest surface roughness. The combination of optimal parameters resulted in a roughness of Ra = 0.5913637 μm. Additionally, an analysis of the influence of noise at the optimal point was conducted, revealing that uncontrollable factors have a significant impact on the process and should be considered during the analysis.

KEYWORDS. Metaheuristic, Particle Swarm Optimization (PSO), Artificial Neural Networks, Surface Roughness.

Paper topics. Meta-heurístics, Combinatorial Optimization, Computational Intelligence.

1. Introdução

A ascensão da Indústria 4.0 trouxe consigo uma transformação significativa na manufatura, integrando tecnologias avançadas como a Internet das Coisas (IoT), big data, inteligência artificial (IA) e automação para criar fábricas inteligentes [Ferreira *et al*., 2023]. Nesse contexto, a usinagem de precisão se beneficia enormemente dessas inovações, permitindo melhorias substanciais na qualidade e eficiência dos processos. Este trabalho insere-se nesse cenário, explorando a aplicação de redes neurais e metaheurísticas para otimizar o processo de usinagem, com o objetivo específico de minimizar a rugosidade superficial das peças produzidas.

O primeiro passo envolveu a coleta de dados experimentais de usinagem, uma etapa crítica para compreender as variáveis do processo e seus impactos na qualidade do produto final. Esses dados foram então utilizados para treinar um modelo de rede neural, capaz de prever a rugosidade superficial com base nos parâmetros de usinagem. A utilização de redes neurais neste contexto é relevante, pois elas possuem a capacidade de modelar relações complexas e não lineares entre as variáveis, superando as limitações de métodos tradicionais de análise [Parmar *et al*., 2021].

Para potencializar os resultados obtidos com a rede neural, empregou-se a metaheurística Particle Swarm Optimization (PSO) como um método de otimização. A PSO é inspirada no comportamento social de enxames de partículas, como cardumes de peixes ou bandos de pássaros, e é eficaz em encontrar soluções ótimas em espaços de busca complexos [Wang *et al*., 2018]. Neste trabalho, a PSO foi utilizada para ajustar os parâmetros de usinagem de modo a minimizar a rugosidade superficial, utilizando a rede neural como função objetivo para avaliar cada conjunto de parâmetros proposto.

A integração de redes neurais e PSO no processo de usinagem representa um avanço significativo em direção à manufatura inteligente e adaptativa, alinhando-se aos princípios da Indústria 4.0. A capacidade de prever e otimizar a rugosidade superficial das peças em tempo real não apenas melhora a qualidade do produto final, mas também aumenta a eficiência do processo, reduzindo desperdícios e custos operacionais. Este trabalho demonstra como a sinergia entre inteligência artificial e métodos de otimização pode transformar a usinagem tradicional, promovendo inovações que são essenciais para a competitividade industrial na era digital.

2. Fundamentação teórica

2.1 – Redes neurais artificiais

Segundo as redes neurais artificiais (RNAs) são sistemas computacionais inspirados na estrutura e funcionamento do cérebro humano. Elas são compostas por unidades de processamento simples, chamadas neurônios ou nós, que são interconectados de maneira a formar uma rede [Wang et al., 2021] . Cada neurônio processa entradas e gera uma saída que é propagada para outros neurônios na rede, permitindo a modelagem de relações complexas entre os dados [Nasa et al.,

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

2021]. As RNAs são amplamente utilizadas em diversas áreas, como reconhecimento de padrões [Mirbod *et al*., 2023], previsão de séries temporais (Silva *et al*., 2023), classificação de dados [Goswani *et al*., 2023] e, mais recentemente, na otimização de processos industriais [Venkatesan *et al*., 2009].

A estrutura básica de uma rede neural está mostrada na Fig. 1 e consiste em três tipos de camadas: a camada de entrada, uma ou mais camadas ocultas e a camada de saída. A camada de entrada recebe os dados brutos, enquanto a camada de saída produz a previsão ou classificação final. As camadas ocultas, localizadas entre a entrada e a saída, são responsáveis por realizar transformações e extrações de características a partir dos dados de entrada. Cada neurônio em uma camada está conectado a todos os neurônios da camada subsequente, com cada conexão sendo associada a um peso que determina a importância da entrada correspondente.

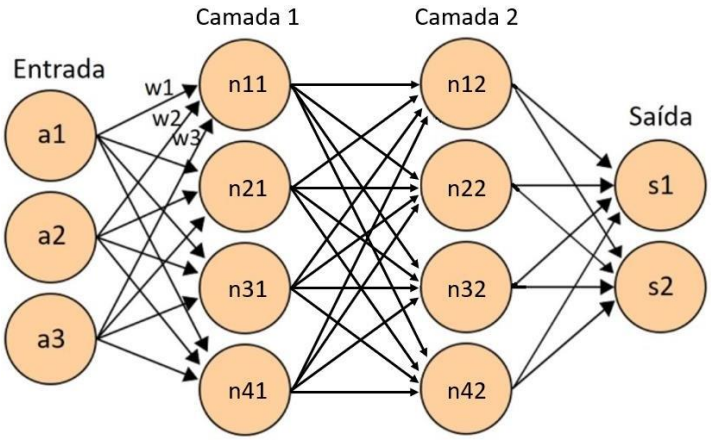


Figura 1*- Estrutura de uma rede neural artificial (fonte: didática tech)*

O aprendizado em redes neurais ocorre por meio de um processo denominado treinamento, onde os pesos das conexões são ajustados para minimizar o erro entre a saída prevista pela rede e o valor real. Este processo é geralmente realizado usando algoritmos de otimização, sendo o mais comum o algoritmo de retropropagação, que ajusta os pesos iterativamente por meio da descida do gradiente (Pontes *et al*., 2010).

Existem vários tipos de redes neurais, cada uma projetada para tarefas específicas. As redes *feedforward*, onde a informação flui em uma única direção, da entrada para a saída, são as mais simples e amplamente utilizadas para tarefas de classificação e regressão. Redes neurais convolucionais são especializadas no processamento de dados estruturados em grades, como imagens, e são amplamente utilizadas em reconhecimento de imagem. Redes neurais recorrentes, que possuem conexões que permitem que a informação persista, são adequadas para tarefas que envolvem dados sequenciais, como processamento de linguagem natural e previsão de séries temporais (Cong *et al*., 2023).

Na era da Indústria 4.0, as redes neurais têm desempenhado um papel crucial na transformação dos processos industriais. Elas são utilizadas para otimizar a produção, prever falhas em equipamentos, melhorar a qualidade dos produtos e reduzir custos operacionais. Por exemplo, em processos de usinagem, as redes neurais podem ser utilizadas para modelar a relação entre os parâmetros de usinagem e a qualidade da superfície da peça, permitindo ajustes precisos que minimizam defeitos e melhoram a eficiência do processo.

2.2 – Otimização por enxame de particulas

A Otimização por Enxame de Partículas (Particle Swarm Optimization - PSO) é uma técnica de otimização baseada na inteligência coletiva de grupos naturais, como enxames de pássaros ou cardumes de peixes. Desenvolvida por Kennedy e Eberhart em 1995, a PSO é um algoritmo inspirado no comportamento social desses grupos, onde a cooperação entre indivíduos (partículas) permite encontrar soluções ótimas em espaços de busca complexos. O PSO tem sido amplamente aplicada em diversas áreas, como otimização de processos industriais, engenharia, finanças e aprendizado de máquina, devido à sua simplicidade, eficiência e capacidade de

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

convergência rápida.

O PSO funciona por meio da interação de partículas dentro de um espaço de busca. Cada partícula representa uma possível solução para o problema de otimização e possui uma posição e uma velocidade que são atualizadas iterativamente com base em duas informações principais: a melhor posição que a própria partícula já encontrou (pBest) e a melhor posição encontrada por qualquer partícula do enxame (gBest).

Matematicamente, a atualização da velocidade e posição de cada partícula é dada pelas seguintes equações:

$$V_k(i+1) = V_k(i) + c_1\, r_1(p^k_{best,i} - X_k\,(i) + c_2\, r_2(g_{best,i} - X_k\,(i)) \quad (1)$$

$$X_k(i+1) = X_k(i) + V_k(i+1)$$

Na qual $V_k(i+1)$ é a velocidade da partícula k na população no número de interações representado por (i+1), c_1 e c_2 são a aceleração do coeficiente que controla o quanto o individual e global afetam a velocidade da partícula, r_1 e r_2 são uniformemente distribuídos aleatoriamente entre 0 e 1, usado para manter a o nível de diversidade na população. $p^k_{best,i}$ é a melhor posição individual da partícula k no número i de interações, $g_{best,i}$ é a melhor posição global de cada partícula no número i de interações, e por fim $X_{k(i)}$ é a posição da partícula k no número i de interações. $X_k(i+1)$ é a posição da partícula k no número (i+1) de interações, $X_k(i)$ é a posição da partícula no número i de interações, e $V_k(i+1)$ é a velocidade da partícula no número (i+1) de interações.

2.3 – Usinagem na era da Indústria 4.0

A usinagem é um processo fundamental na fabricação de componentes metálicos, onde a precisão e a qualidade superficial são essenciais. Tradicionalmente, a otimização dos parâmetros de usinagem, como velocidade de corte, avanço e profundidade de corte, era realizada por meio de métodos empíricos e tentativa e erro. No entanto, com o advento da IA, tornou-se possível modelar de forma precisa e eficiente as relações complexas entre os parâmetros de usinagem e a qualidade das peças produzidas. As redes neurais podem aprender a partir de dados experimentais, permitindo prever a rugosidade superficial e outros aspectos da qualidade com alta precisão.

A integração de meta-heurísticas como a PSO com redes neurais potencia ainda mais a eficiência dos processos de usinagem. A PSO, inspirada no comportamento social de enxames, é uma técnica robusta para a otimização de problemas complexos. Utilizando redes neurais como funções objetivo, a PSO pode ajustar automaticamente os parâmetros de usinagem para minimizar a rugosidade superficial e maximizar a eficiência do processo. Isso resulta em um sistema de otimização adaptativo, capaz de se ajustar dinamicamente às variações nas condições de usinagem e aos requisitos de produção.

No contexto da Indústria 4.0, a aplicação de IA e metaheurísticas na usinagem leva a manufatura inteligente a um novo patamar. Sistemas de usinagem equipados com sensores IoT podem coletar dados em tempo real, fornecendo informações contínuas sobre o desempenho do processo e a qualidade das peças. Esses dados podem ser analisados por algoritmos de IA para detectar padrões, prever falhas e sugerir ajustes nos parâmetros de usinagem. A PSO pode então otimizar esses parâmetros, garantindo que o processo opere de forma ideal em todas as condições.

Além disso, a conectividade e a comunicação entre máquinas e sistemas de gerenciamento centralizados possibilitam uma visão holística do processo de produção, permitindo ajustes em tempo real e a implementação de estratégias de manutenção preditiva. Isso não apenas melhora a qualidade e a consistência das peças usinadas, mas também reduz o tempo de inatividade e os custos operacionais.

Em conclusão, a usinagem no contexto da Indústria 4.0 é significativamente aprimorada pela integração de IA e metaheurísticas. A combinação de redes neurais para modelagem e PSO para otimização proporciona um sistema adaptativo e inteligente que maximiza a eficiência e a qualidade do processo de usinagem. Essa abordagem não só atende às demandas atuais de alta precisão e flexibilidade, mas também prepara o terreno para futuras inovações na manufatura inteligente, solidificando a usinagem como um componente crucial na era da Indústria 4.0.

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

3. Materiais e métodos

3.1 – Levantamento de dados

Os dados utilizados para a construção do modelo de rede neural foram coletados experimentalmente. Foi utilizado um centro de usinagem ROMI D600, utilizando uma operação de fresamento de topo, com potência de 15 kW e rotação máxima de 10000 rpm. A peça a ser usinada é o aço inoxidável duplex UNS S32205, com dimensões de 170 mm x 124 mm x 100 mm, com dureza média de 290 e 330 HV (dureza Vickers). Foi utilizada uma pastilha CoroMill R390-11T308M-MM 2030, feita de metal duro e com dupla camada de Nitreto de Titânio (TiN) e Nitreto de Alumínio e Titânio (TiNAl), revestido pelo processo de deposição física de vapor (PVD), além de um CoroMill® R390-025A25-11M, com diâmetro de 25mm, ângulo de posição χr= 90º, haste cilíndrica, com 3 insertos e fixação mecânica por pinças.

Foi realizado um planejamento experimental, empregando especificamente um arranjo Central Composite Design (CCD). As variáveis de controle selecionadas foram a velocidade de corte (vc), avanço por dente (fz), profundidade de corte (ap) e penetração de trabalho (ae). Ademais, algumas variáveis de ruído como o desgaste do flanco da ferramenta (vb), a vazão de fluido (Q) e o comprimento em balanço (lt0) também foram analisadas. A variável de saída é rugosidade (R_a).

A escolha dos parâmetros de usinagem foi baseada em testes preliminares, pois os valores recomendados pelo catálogo não proporcionaram uma usinagem satisfatória. Durante esses testes, verificou-se que o inserto evoluia para o desgaste de flanco de 0,3 mm após um único passe, comprometendo tanto a eficiência quanto a vida útil da ferramenta. Por esse motivo, foi necessário ajustar os parâmetros de usinagem para garantir a viabilidade do processo e a obtenção de resultados mais consistentes, levando em consideração as especificidades do material e as condições experimentais. A Tab. 1 mostra os níveis de cada variável. Todos os experimentos foram executados no sentido concordante devido a largura fresada (ae) ultrapassar o valor de 60% do diâmetro da fresa. Para a coleta de dados referente a resposta Ra foi utilizado o rugosímetro portátil Mitutoyo Surftest 201, aferido e calibrado antes do início das medições. O parâmetro de cut-off foi ajustado para 0,8 mm em todas as medidas. As medições foram realizadas a cada passe nos pontos extremos e no centro do corpo de prova.

Tabela 1: Condições de contorno para cada variável de entrada (controláveis e incontroláveis)

Parâmetro	Símbolo	Unidade	Máximo	Mínimo
Velocidade de corte	vc	m/min	90	60
Avanço/dente	fz	mm/dente	0,16	0,10
Penetração de trabalho	ae	mm	18	15
Profundidade de corte	ap	mm	1,2	0,8
Desgaste de flanco da ferramenta	vb	mm	0,3	0
Vazão do fluido de corte	Q	l/min	20	0,02
Comprimento em balanço	lt0	mm	50	30

Fonte: Autoria própria

Considerando *k* o número de variáveis no experimento, o arranjo CCD gera 2^k pontos fatoriais, 2*k* pontos axiais e um ponto central. Dessa forma, o presente planejamento experimental gerou 128 pontos fatoriais, 14 pontos axiais e 12 pontos centrais (11 réplicas foram avaliadas no ponto central). Contudo, devido ao alto custo dos experimentos, optou-se por realizar o planejamento fracionado, caindo pela metade o número de experimentos necessários. Dessa forma, foram realizados 77 experimentos, cada um com uma configuração diferente. A Figura 2 mostra uma imagem do experimento realizado.

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

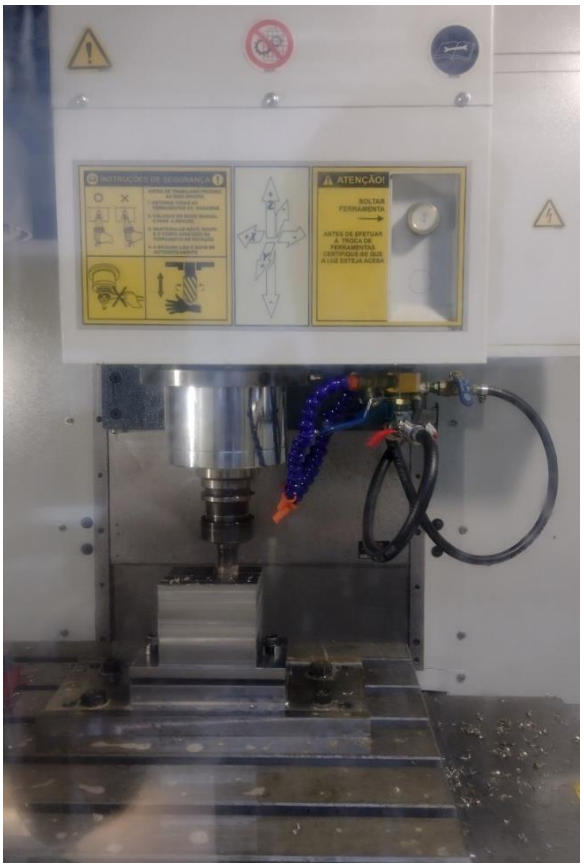


Figura 2*- Configuração experimental realizada.*

3.2 – Metodologia para a integração de redes neurais

Os 77 resultados obtidos experimentalmente foram divididos em dados de treino e teste, na proporção de 80-20%. Assim, 55 resultados foram utilizados para o treinamento da rede neural, enquanto os 22 restantes foram destinados ao teste.

As variáveis de entrada foram normalizadas. Normalizar os dados antes de treinar uma rede neural é crucial por várias razões. Primeiramente, isso facilita o treinamento, evitando problemas como gradientes instáveis que podem surgir devido a escalas discrepantes nos dados. Além disso, a normalização garante a convergência do modelo, mantendo as ativações dentro de intervalos razoáveis durante o treinamento. Essa prática também melhora o desempenho da rede ao permitir que ela aprenda padrões mais relevantes nos dados e reduz a sensibilidade a outliers, tornando o modelo mais robusto. Por fim, dados normalizados são mais fáceis de interpretar, pois estão em uma escala uniforme, facilitando comparações diretas entre eles. Em suma, normalizar os dados é essencial para garantir um treinamento suave, rápido e eficaz, além de melhorar o desempenho e a interpretabilidade do modelo resultante.

Os dados normalizados foram utilizados para treinar o modelo de rede neural artificial como mostrado na Fig. 3. Diversos hiperparâmetros diferentes foram avaliados (Random Search) e os melhores foram selecionados, conforme Tab.2. Métricas como o R^2 e Erro Quadrático Médio foram comparados para diversas configurações de rede neural e o melhor modelo foi escolhido.

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

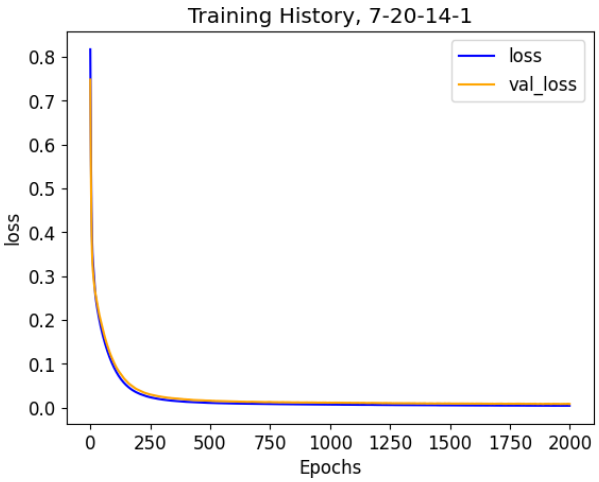


***Figura 3**- Treinamento do modelo de rede neural artificial*

Tabela 2 – Hiperparâmetros para a Rede Neural Artificial

Modelo	**Hiperparâmetros**	**Resultados**
Sequential	Activation hidden layers	RelU
	Activation output	Linear
	Kernel_regularizer	L2
	Optmizer	Adam
	Learning_rate	0.002
	Loss	Mean_squared_error
	Metrics	Mean_absolute_error
	Epochs	2000

3.3 – Otimização de parâmetros utilizando PSO

O grande objetivo do trabalho é achar quais variáveis de entrada que gera a menor rugosidade superficial da peça. O algoritmo de enxame de partículas será utilizado para encontrar o valor ótimo dos parâmetros. A função objetivo a ser otimizada é dada pelo modelo de rede neural artificial, ou seja, queremos otimizar a saída desse modelo a partir dos dados de entrada. Importante ressaltar que para essa otimização as condições de contorno foram as mesmas consideradas para a realização dos ensaios experimentais. A Figura 4 apresenta a metodologia aplicada neste estudo.

No algoritmo PSO, os hiperparâmetros adotados incluem um número padrão de partículas (definido como 20), para garantir uma busca robusta do espaço de solução. O número máximo de iterações foi adotado igual a 1000, avaliando da complexidade do problema e do tempo disponível para execução. Os coeficientes de inércia foram definidos com um valor inicial de 0.5, com fatores

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

cognitivos e sociais iguais a 1.0, mantendo um equilíbrio entre a exploração e a explotação do espaço de busca.

Quanto aos critérios de parada, estabeleceu-se um número máximo de iterações como 1000. A topologia de vizinhança pode seguir um esquema global, onde todas as partículas interagem entre si, ou um esquema de anel, onde cada partícula tem um número fixo de vizinhos. Estes hiperparâmetros personalizados oferecem uma base sólida para a implementação inicial do PSO em uma variedade de problemas de otimização. O programa desenvolvido encontra-se no Apêndice A.

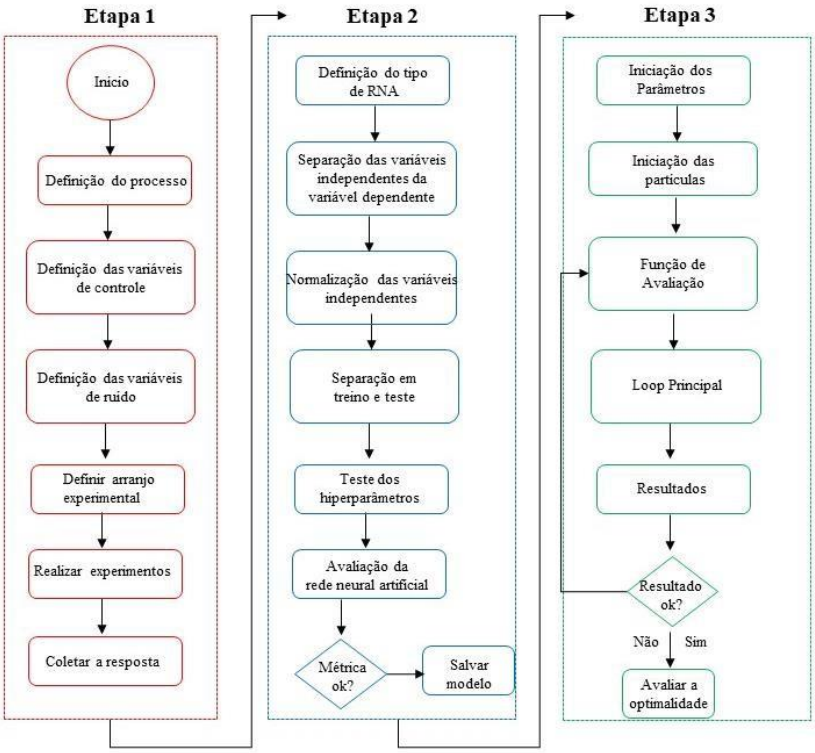


Figura 4 *– Metodologia utilizada no presente trabalho*

4. Discussão de Resultados

Utilizando a metodologia apresentada, obteve-se o resultado ótimo, que está detalhado na Tabela 4. Esta tabela inclui os valores de cada parâmetro e a rugosidade resultante. A rugosidade encontrada está dentro da faixa de parâmetros especificada pela NBR 8404, variando entre as classificações N4 e N6.

Tabela 4: Valores ótimos obtidos

Símbolo	Unidade	Valor
vc	m/mm	61.164616
fz	mm/dente	0.154101
ae	mm	17.84392532
ap	mm	0.94536317
vb	mm	0.18386173
Q	l/min	17.00899035
lt0	mm	32.16936118
Ra	µm	0.5913637

Fonte: Autroria própria.

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

Comparando os valores encontrados pela otimização com os obtidos no trabalho de Vasconcelos (2022), é possível perceber que a velocidade de corte otimizada pelo PSO é menor do que a encontrada pelo autor, que foi de 81,07 m/min. Isso pode indicar uma abordagem mais conservadora do PSO para evitar o desgaste excessivo da ferramenta e aumentar sua vida útil. Já o avanço por dente encontrado pelo autor em sua otimização foi de 0,14 mm/dente. Os valores são próximos, com uma leve diferença que sugere uma pequena variação nas estratégias de otimização. Ambos os estudos mantiveram um avanço relativamente baixo, o que é comum para controlar a qualidade superficial. Vasconcelos (2022) encontrou um valor de profundidade de corte de 1,14 mm, enquanto a otimização neste trabalho obteve o valor de 0,94 mm. Isso pode refletir uma estratégia para reduzir as forças de corte e, consequentemente melhorar a rugosidade superficial.

Portanto, a combinação de redes neurais com a metodologia de otimização PSO mostrou-se eficiente em identificar parâmetros de usinagem que não apenas minimizam a rugosidade superficial, mas também preservam a vida útil da ferramenta. Esta abordagem permite um controle preciso dos parâmetros de fresamento, resultando em superfícies de alta qualidade e processos de usinagem mais sustentáveis e produtivos.

4.1 – Análise gráfica da otimização

A otimização anterior considerou a presença de variáveis de ruído, tais como o desgaste do flanco da ferramenta (*vb*), a vazão de fluido (*Q*) e o comprimento em balanço (*lt0*). Contudo, como a própria classificação indica, não é possível escolher qual valor será gerado para cada uma delas.

Controlamos esses parâmetros em nosso experimento; no entanto, na prática, eles geralmente não podem ser ajustados. Portanto, realizamos o algoritmo de otimização novamente, desta vez considerando apenas as variáveis controláveis. Assumimos que *vb*=0 mm, (o que se refere à ferramenta nova), *Q=20* l/min (a máxima vazão da máquina) e *lt0*=30 mm (a ferramenta fixada a 30 mm). O resultado ótimo obtido está apresentado na Tabela 5.. O resultado ótimo está mostrado na Tabela 5.

Tabela 5: Valores dos parâmetros controláveis

Símbolo	Unidade	Valor
vc	m/mm	60.21
fz	mm/dente	0.14
ae	mm	16.53
ap	mm	0.91
Ra	μm	0.42

Fonte: autoria própria

A Tabela 5 demonstra que a rugosidade foi significativamente influenciada pela eliminação das perdas incontroláveis. Com a presença dos ruídos (valores diferentes de 0 para Q,lt0 e Vb), a rugosidade obtida foi de aproximadamente 0,59 μm. No entanto, ao zerar o valor de Vb, fixar lto e adotar uma vazão de Q=20 l/min, a rugosidade mínima alcançada foi de 0,42 μm. Essa melhoria representa uma redução de 27,62% na rugosidade. Os resultados evidenciam a importância e o impacto dos parâmetros incontroláveis, destacando que o cuidado e controle dessas variáveis são essenciais para alcançar rugosidades baixas no fresamento. As rugosidades obtidas são comparáveis às encontradas em processos de retificação.

Por fim, uma análise gráfica foi feita com o objetivo de avaliar os ruídos no ponto de ótimo (quando não é considerado os ruídos). Para isso, realizou-se a otimização com as variáveis de ruído constantes, ou seja, realizou-se a otimização como se não houvesse ruído no processo. Chegando no ponto de ótimo, avaliou-se como os ruídos influenciam nesse ponto. A Figura 5,6 e 7 mostram os resultados.

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

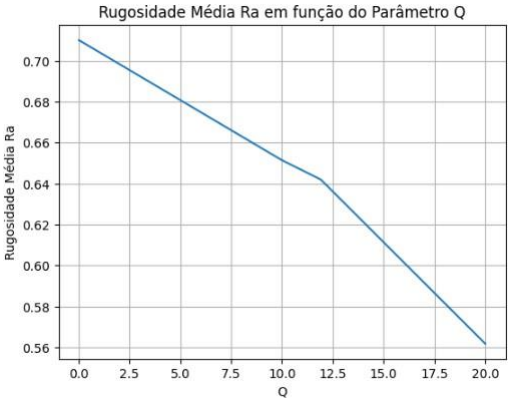


Figura 5: Rugosidade Média em função de Q

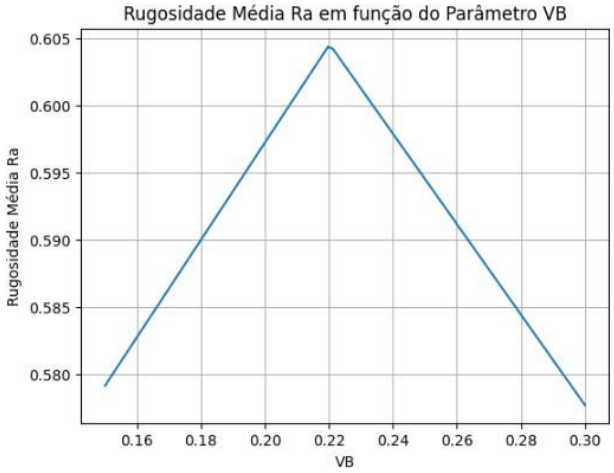


Figura 6: Rugosidade Média em função da vb

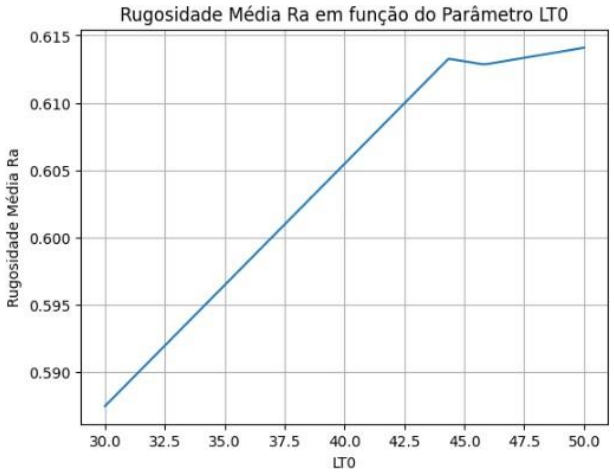


Figura 7: Rugosidade Média em função da lt0

Com relação a Figura 5, conforme se tem o aumento da vazão do fluido de corte, se tem uma melhora na rugosidade, sendo ela apenas 5.01% menor, quando comparada a rugosidade ótima da PSO. Nessa faixa analisada o fluido de corte tem efeito positivo, então reduz a temperatura da superfície e reduz o atrito entre cavaco e ferramenta, resultando em melhor acabamento (MACHADO, 2011). Na Figura 6 percebe-se um comportamento parabólico com a concavidade

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

para baixo relacionado a desgaste de flanco da ferramenta, que pode fazer com que em outros intervalos se obtenha valores melhores de rugosidade, mas nesse caso a diferença da gerada pela otimização é de 2.31% menor, a diferença mais expressiva. Essa diferença maior se dá, pois segundo Vasconcelos (2022) é variável de ruído que mais afeta a rugosidade.

Por fim, na Figura 8 o comprimento em balanço possui um comportamento crescente e seu aumento resulta em uma maior rugosidade, sua variação foi a que gerou menor diferença percentual da rugosidade, sendo ela de apenas 0.31%. Percebe-se que a variação desse parâmetro quase não interferiu no valor da rugosidade.

A menor rugosidade obtida seria com o aumento de Q de 17.01/min para 20 l/min, com isso a diferença refletida na rugosidade seria apenas de aproximadamente 0,59 μm para 0,56 μm. Praticamente 0,03 μm, que representa uma diferença extremamente baixa, considerando que existem fatores que não foram considerados durante a análise e que podem gerar modificações, como o tipo de fluido refrigerante ou as condições de temperatura do local onde a usinagem é realizada.

5. Conclusões

Este trabalho teve o intuito de determinar o valor ótimo dos principais parâmetros (vc, fz, ap, ae, vb, Q, lt0) que envolvem a usinagem de um corpo de prova feito de SDSS UNSS32760, buscando a menor rugosidade possível. Utilizando o método PSO, apresentando o resultado após uma série de interações treinada por uma Rede Neural baseada em dados experimentais.

A melhor rugosidade obtida pela otimização foi de 0,59 μm, considerando parâmetros específicos. Este resultado pode ser considerado bom, uma vez que esse valor se aproxima de rugosidade resultante do processo de retificação, segundo Vasconcelos (2022). Ademais, esse resultado pode ser considerado satisfatório considerando comparações com outros trabalhos utilizando aços similares ao SDSS UNSS32205.

Com relação aos resultados gráficos, pode-se perceber que estão em conformidade com outros estudos também. Vasconcelos (2022) gerou gráficos sobre como vc, fz , vb e Q afetam a rugosidade baseado nos efeitos quadráticos e obteve curvas que nos devidos intervalos apresentam o mesmo comportamento.

Por fim, ao se propor uma otimização que desconsidere as variáveis incontroláveis (Q, VB e lt0) pode-se se comprovar a importância dessas variáveis para os resultados obtidos, uma vez que a rugosidade ótima obtida foi de 0.42797926. Esse resultado é aproximadamente 28% menor do que o obtido pela otimização, por isso o controle sobre esses parâmetros deve ser realizado de forma mais criteriosa possível quando se busca obter rugosidades mínimas.

Referências

Cong, S., & Zhou, Y. (2023). A review of convolutional neural network architectures and their optimizations. *Artificial Intelligence Review*, *56*(3), 1905-1969.

Eberhart; Yuhui Shi. Particle swarm optimization: developments, Applications and resources. *In*: **Proceedings of the 2001 Congress on Evolutionary Computation (IEEE Cat. No.01TH8546)**. Seoul, South Korea: IEEE, 2001, v. 1, p. 81–86.

Goswami, A. D., Bhavekar, G. S., & Chafle, P. V. (2023). Electrocardiogram signal classification using VGGNet: a neural network based classification model. *International Journal of Information Technology*, *15*(1), 119-128.

Ferreira, J. J., Lopes, J. M., Gomes, S., & Rammal, H. G. (2023). Industry 4.0 implementation: Environmental and social sustainability in manufacturing multinational enterprises. *Journal of Cleaner Production*, *404*, 136841.

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br

Mirbod, M., & Shoar, M. (2023). Intelligent concrete surface cracks detection using computer vision, pattern recognition, and artificial neural networks. *Procedia Computer Science*, *217*, 52-61.

Nasir, V., & Sassani, F. (2021). A review on deep learning in machining and tool monitoring: Methods, opportunities, and challenges. *The International Journal of Advanced Manufacturing Technology*, *115*(9), 2683-2709.

Nascimento, c. *et al*. Análise da rugosidade Ra no torneamento do aço inoxidável super duplex uns s32750 utilizando planejamento de experimentos. 10o congresso brasileiro de engenharia de fabricação. anais...abcm, 2019.

Vasconcelos, G. Otimização do fresamento de topo do aço inoxidável duplex uns s32205. 2022. 103 f. Dissertação (Mestrado) - Curso de Engenharia Mecânica, Instituto de Engenharia Mecânica, Universidade Federal de Itajubá, Itajubá, 2022.

Parmar, J. G., Dave, K. G., Gohil, A. V., & Trivedi, H. S. (2021). Prediction of end milling process parameters using artificial neural network. Materials Today: Proceedings, 38, 3168-3176.

Pontes, F. J., Ferreira, J. R., Silva, M. B., Paiva, A. P., & Balestrassi, P. P. (2010). Artificial neural networks for machining processes surface roughness modeling. *The International Journal of Advanced Manufacturing Technology*, *49*, 879-902.

Silva, A. Q. B., Gonçalves, W. N., & Matsubara, E. T. (2023). DESCINet: A hierarchical deep convolutional neural network with skip connection for long time series forecasting. *Expert Systems with Applications*, 120246.

Venkatesan, D., Kannan, K., & Saravanan, R. (2009). A genetic algorithm-based artificial neural network model for the optimization of machining processes. *Neural Computing and Applications*, *18*, 135-140.

Wang, D., Tan, D., & Liu, L. (2018). Particle swarm optimization algorithm: an overview. Soft computing, 22, 387-408.

Wang J, Zou B, Liu M et al (2021) Milling force prediction model based on transfer learning and neural network. J Intell Manuf 32:947–956. https://doi.org/10.1007/s10845-020-01595-w

DOI: 10.59254/sbpo-2024-193808
https://proceedings.science/p/193808?lang=pt-br