



INTEGRAÇÃO DE INTELIGÊNCIA ARTIFICIAL NO ENSINO DE CONTROLE DE PROCESSOS: ESTUDO DE CASO COM PLANTA DIDÁTICA DE TEMPERATURA

DOI: 10.37702/2175-957X.COBENGE.2024.5330

Autores: MARLON JOSÉ DO CARMO, ARTUR MARTINS ALMEIDA

Resumo: Este trabalho explora a utilização de redes neurais para ajustar controladores PI em uma planta didática de temperatura, comparando-os com os métodos tradicionais de Ziegler-Nichols e Cohen-Coon. Os resultados mostraram que a rede neural proporcionou um tempo de subida e de acomodação significativamente menores, além de um máximo sobressinal reduzido. No entanto, foram observadas oscilações de alta frequência no estado estacionário. A pesquisa destaca a eficácia das redes neurais na otimização de controladores PI e sua relevância para o ensino de engenharia, promovendo uma abordagem interdisciplinar no controle de processos.

Palavras-chave: Inteligência artificial, Controle de Processos, Redes Neurais.

INTEGRAÇÃO DE INTELIGÊNCIA ARTIFICIAL NO ENSINO DE CONTROLE DE PROCESSOS: ESTUDO DE CASO COM PLANTA DIDÁTICA DE TEMPERATURA

1 INTRODUÇÃO

A inteligência artificial (IA) tem se tornado uma área de interesse crescente em diversas disciplinas acadêmicas, notadamente na engenharia, onde sua aplicação promete revolucionar tanto o ensino quanto a prática profissional. O impacto da IA nas disciplinas de controle de processos é particularmente significativo, pois possibilita a implementação de técnicas avançadas de controle e automação que são cruciais para o desenvolvimento e otimização de sistemas complexos. A interseção entre IA e controle de processos representa uma oportunidade única para inovar metodologias de ensino, proporcionando aos estudantes uma compreensão mais aprofundada e prática dos conceitos teóricos.

A literatura atual aponta para uma variedade de estudos que exploram a integração de IA no ensino na educação. Por exemplo, Wang et al. (2022) discutem como as redes neurais artificiais podem ser utilizadas para melhorar o desempenho de sistemas de controle, oferecendo uma abordagem mais adaptativa e eficiente em comparação aos métodos tradicionais. Além disso, Rane (2023) ressalta a importância da interdisciplinaridade, argumentando que a combinação de conhecimentos em IA com disciplinas específicas pode resultar em uma aprendizagem mais robusta e relevante para os alunos.

A utilização de plantas didáticas em ambientes educacionais tem se mostrado uma ferramenta eficaz para a aplicação prática dos conceitos teóricos de controle de processos. Plantas didáticas de temperatura, por exemplo, são amplamente utilizadas para demonstrar

o funcionamento de sistemas de controle em um ambiente controlado e seguro. Quando combinadas com técnicas de IA, essas plantas podem oferecer uma plataforma poderosa para experimentação e aprendizado prático. Nesse contexto, diversos estudos têm demonstrado que a aplicação de redes neurais para o ajuste de controladores pode resultar em sistemas de controle mais precisos e adaptativos (BARROS, 2023).

Segundo Scardua (2021), a introdução de IA no currículo de engenharia pode estimular o pensamento crítico e a resolução de problemas, habilidades essenciais para os engenheiros do futuro. Isso é particularmente relevante em disciplinas como controle de processos, em que a aplicação prática dos conhecimentos é fundamental.

O objetivo deste trabalho é mostrar como a interseção entre inteligência artificial e controle de processos pode enriquecer o ensino de engenharia, proporcionando aos estudantes uma compreensão mais profunda e prática dos conceitos abordados. Ao final, espera-se que os resultados deste estudo contribuam para a literatura existente sobre a integração de IA no ensino de engenharia e ofereçam insights valiosos para educadores que buscam implementar abordagens interdisciplinares em seus currículos.

2 REVISÃO DE BIBLIGRAFIA

O avanço da inteligência artificial (IA) tem sido exponencial, impactando diversos setores da sociedade, desde a saúde e transporte até a educação e entretenimento. Segundo Kaufman (2022), a IA está transformando indústrias ao automatizar tarefas rotineiras, melhorar a precisão de diagnósticos médicos e otimizar operações logísticas. Este crescimento é impulsionado pelo aumento da capacidade de processamento computacional e pela disponibilidade de grandes volumes de dados, elementos essenciais para o treinamento de modelos de IA.

O setor educacional não é uma exceção a essa tendência. A IA está sendo integrada em ferramentas de ensino e plataformas de aprendizagem adaptativa que personalizam a experiência do aluno com base em suas necessidades e desempenho individuais (SCARDUA 2019). Além disso, tecnologias como *chatbots* e assistentes virtuais estão sendo utilizadas para fornecer suporte aos alunos fora do horário de aula, respondendo a perguntas e oferecendo orientações personalizadas.

2.1 Utilizando as Redes Neurais no ensino

Ensinar os alunos a utilizarem a IA de maneira eficaz é essencial para prepará-los para um mercado de trabalho em constante evolução. De acordo com Meroto (2024), é crucial que os currículos educacionais incluam não apenas os aspectos técnicos da IA, mas também suas implicações éticas e sociais. Isso prepara os alunos para serem não apenas usuários competentes de tecnologia, mas também cidadãos conscientes de seus impactos.

No contexto da engenharia, isso significa incorporar IA nos programas de estudo de maneira prática e teórica. Os estudantes devem ser expostos a algoritmos de aprendizado de máquina, redes neurais e outras técnicas de IA, além de entender como essas tecnologias podem ser aplicadas em diferentes áreas da engenharia, como controle de processos, robótica e análise de dados (RUSSELL; NORVIG, 2020).

A interdisciplinaridade é uma abordagem educacional que integra diferentes disciplinas para fornecer uma compreensão mais completa e aplicável dos assuntos. No ensino de engenharia, a utilização de IA pode promover essa integração de maneira significativa. Segundo Javaid (2022), a IA pode ser usada como uma ferramenta de apoio

em diversas disciplinas, como eletrônica, mecânica, e controle de processos, permitindo uma visão mais holística dos problemas e soluções.

Por exemplo, uma planta didática de temperatura pode ser utilizada para ensinar princípios de controle de processos enquanto simultaneamente introduz conceitos de IA, como redes neurais para ajuste de controladores (ASTROM; MURRAY, 2021). Essa abordagem interdisciplinar não apenas reforça os conhecimentos específicos de cada disciplina, mas também demonstra a aplicação prática e integrada da IA na resolução de problemas complexos.

2.2 Vantagens e Desvantagens de se utilizar IA no Ensino de Engenharia

As vantagens de utilizar IA no ensino de engenharia são numerosas. A IA pode personalizar a aprendizagem, adaptando-se às necessidades individuais dos alunos e proporcionando feedback em tempo real (CHEN; LIN, 2020). Além disso, pode automatizar tarefas administrativas, permitindo que os professores se concentrem mais no ensino e menos na burocracia.

No entanto, há também desvantagens a serem consideradas. Uma preocupação significativa é a possível dependência excessiva da tecnologia, o que pode levar a uma diminuição na capacidade dos alunos de resolver problemas sem o auxílio de IA. Além disso, há questões éticas relacionadas ao uso de dados dos alunos e à transparência dos algoritmos de IA utilizados (CHEN; LIN, 2020).

Existem diversos exemplos de integração da IA no ensino de engenharia tanto no Brasil quanto no exterior. No Brasil, a Universidade de São Paulo (USP) tem desenvolvido projetos que utilizam IA para personalizar o ensino e otimizar o desempenho dos alunos (GIRAFFA; KHOLS-SANTOS, 2023). A USP implementou plataformas de aprendizagem que utilizam algoritmos de IA para identificar dificuldades específicas dos alunos e oferecer conteúdo personalizados para superá-las.

Internacionalmente, o Instituto de Tecnologia de Massachusetts (MIT) tem sido um líder na utilização de IA no ensino de engenharia. O MIT desenvolveu cursos que integram IA em diversas disciplinas de engenharia, utilizando plataformas de aprendizado adaptativo e simuladores que empregam técnicas de IA para fornecer uma experiência de aprendizagem mais rica e interativa (MEIRA, 2022).

A proposta deste trabalho contribui ao demonstrar a aplicação prática da IA no ensino de engenharia, especificamente através da utilização de uma planta didática de temperatura controlada por um controlador PI ajustado por redes neurais. Este estudo de caso oferece uma visão detalhada de como a IA pode ser integrada em currículos de engenharia de forma interdisciplinar, proporcionando uma experiência de aprendizagem mais envolvente e aplicável.

Além disso, ao documentar o processo de implementação e os resultados obtidos, este trabalho serve como um guia para outros educadores que desejam incorporar IA em suas disciplinas de engenharia, sobretudo em controle de processos. A abordagem prática e teórica descrita aqui não só reforça os conceitos acadêmicos, mas também prepara os alunos para um mercado de trabalho onde a competência em IA será cada vez mais valorizada.


2.3 Introdução às Redes Neurais

Redes neurais artificiais (RNAs) são modelos computacionais inspirados no cérebro humano, projetados para reconhecer padrões complexos e fazer previsões a partir de

dados. Desenvolvidas inicialmente na década de 1940, as redes neurais têm evoluído significativamente, especialmente com o advento da computação moderna e a disponibilidade de grandes conjuntos de dados. Segundo Silva et. al. (2010), as RNAs são essenciais no campo do aprendizado profundo, permitindo a modelagem de relações não-lineares entre entradas e saídas.

A estrutura básica de uma rede neural consiste em nós (ou neurônios) organizados em camadas: a camada de entrada, camadas ocultas, e a camada de saída. Cada neurônio recebe entradas, processa essas entradas através de uma função de ativação e transmite a saída para os neurônios das camadas subsequentes (Figura 1). Esta arquitetura permite que as RNAs aprendam representações hierárquicas dos dados, onde as camadas superiores capturam características mais abstratas.

Figura 1 – Esquema de uma rede neural simples.



Fonte: Adaptado de Silva et al (2010)

Existem diversos tipos de redes neurais, cada uma adequada a diferentes tipos de problemas. As redes neurais *feedforward*, onde as conexões não formam ciclos, são usadas principalmente para problemas de classificação e regressão. Redes neurais convolucionais (CNNs) são especialmente eficazes no processamento de dados com estrutura de grade, como imagens, devido à sua capacidade de capturar padrões espaciais e hierárquicos. Redes neurais recorrentes (RNNs) são adequadas para dados sequenciais, como séries temporais e processamento de linguagem natural, pois podem manter informações contextuais ao longo das sequências (HAYKIN, 1999).

O processo de treinamento de uma rede neural envolve a atualização dos pesos das conexões entre neurônios para minimizar uma função de custo, geralmente através do algoritmo de retropropagação e de métodos de otimização como o gradiente descendente. Durante o treinamento, a rede ajusta seus pesos com base nos erros das previsões, refinando assim sua capacidade de prever ou classificar novos dados.

Neste trabalho, especificamente, utilizar-se-á técnicas de redes neurais para controlar uma planta de temperatura. Especificamente, as técnicas de redes neurais é uma das opções que os desenvolvedores e pesquisadores tem implementado para contornar problemas encontrados utilizando os controladores mais comuns, como o PID, por exemplo, e tem obtido resultados melhores para tal finalidade como investigado por Yu et al. (2006). O fato de não ser necessário um modelo matemático, de poderem ser aplicadas a processos de comportamento complexo e não-lineares, as tornam uma alternativa de aplicação para controle deles aos demais métodos clássicos de controle.

3 MATERIAIS E MÉTODOS


Foi construído um protótipo de uma planta de temperatura do tipo estufa que consiste em uma caixa de isopor com tampa, com ventoinhas instaladas nas laterais. Em uma das paredes perpendiculares às das ventoinhas, está a lâmpada e na outra o sensor de temperatura LM35. A fonte de energia térmica que fica dentro do recipiente é uma lâmpada incandescente de 100 W de potência pelo fato de que 5% da energia dissipada de uma lâmpada deste tipo é convertido em luz e 95% é transferida ao meio por meio do efeito joule. Desejou-se trabalhar com a variação da tensão de alimentação da lâmpada e manter as ventoinhas acionadas, uma como ventilador e outra como exaustor, recebendo sinal de tensão de alimentação constante. A Figuras 2 e 3 ilustram a planta montada.

Figura 2 – Vista lateral da planta com a tampa fechada.



Fonte: autores.

Figura 3 – Vista de cima da planta com a tampa aberta.



Fonte: autores.


O circuito é composto por:

- Uma fonte de tensão que tem saídas para 12 V e 5 V;
- Uma lâmpada incandescente de 60 W;
- Duas ventoinhas de fonte de computador de 12 V, 5 A;
- Um sensor de temperatura LM 35;
- Uma Plataforma de prototipagem TM4C123G LaunchPad Tiva C Series;
- Um circuito de acoplamento Dimmer Shield;
- Cabos de conexão.

A fonte de tensão que fornece energia elétrica para os componentes do circuito é conectada à rede de energia elétrica doméstica. As ventoinhas são alimentadas pela fonte de tensão e a lâmpada é conectada diretamente ao *dimmer shield* por meio das vias de conexão apropriadas. O circuito de acoplamento também é conectado a fonte de tensão. O *dimmer Shield* é conectado à plataforma TM4C123G que receberá também a conexão dos cabos do sensor de temperatura.

O circuito de controle da tensão fornecida para lâmpada utilizado foi o *dimmer shield*, um circuito já desenvolvido para o simples acoplamento a microcontroladores. Este dispositivo permite o controle de acionamento de dispositivos eletroeletrônicos que utilizam a tensão alternada para seu funcionamento. Este controle é realizado por meio da configuração do ângulo de disparo, ou um ângulo dentro do intervalo 0 e 180 graus em que irá iniciar a condução de energia elétrica, de um TRIAC. A Figura 4 mostra o esquema do protótipo.

Figura 4 – Esquema do protótipo.



Fonte: os autores.

Foram feitos dois programas. Um deles contempla as redes neurais, seu desenvolvimento seu treinamento e foi feito utilizando a linguagem Python e a biblioteca Scikit_learn. O outro programa possui a parte de aquisição e tratamento de dados e o algoritmo de controle. A manipulação do *dimmer shield* foi realizada, principalmente, pela utilização de uma interrupção que detectava a passagem do sinal de tensão negativo para positivo. A partir do conhecimento deste evento, um ângulo para disparar o TRIAC, tal que, corresponderia ao valor de tensão desejado, pôde ser configurado. O ângulo foi calculado e convertido em unidade de tempo dentro de um período completo da onda senoidal e, por meio da aplicação de um atraso, tal unidade de tempo calculada, no acionamento do TRIAC, obteve-se o valor de tensão almejado. Esta possibilidade de controle do sinal de tensão alternada permitiu o uso de um controlador e, conseqüentemente, a aplicação de métodos diversos de sintonia: Ziegler-Nichols, CHR0%, CHR20%, Cohen-Coon e Haalman (CARMO, 2006) e análises comparativas entre o controlador neural e o controlador PI.


Inicialmente, foi necessário identificar o sistema para que sejam aplicadas as diferentes formas de controle. Uma das formas de obter o modelo matemático que pode ser aproximado ao modelo de primeira ordem é por meio da análise da resposta do sistema quando ele é excitado por um degrau e observado até sua estabilidade. Denomina-se esta aproximação a como modelo de 1ª ordem a três parâmetros ou primeira ordem mais tempo morto – do inglês *First Order Delay Time* (FODT) (AGUIRRE, 2001), Equação 1. Destaca-se também este método como sendo capaz de representar uma das não linearidades característica da dinâmica dos processos industriais, o atraso de tempo.

$$G(s) = \frac{k}{\tau s + 1} e^{-Ls} \quad (1)$$

Os parâmetros k , τ e L são, respectivamente, ganho do sistema, constante de tempo e tempo morto e podem ser determinados analisando o gráfico disposto na Figura 3.6. A constante de tempo τ , o ganho k ao valor máximo atingido com aplicação do degrau unitário ao sistema e L ao período de tempo em que é perceptível a reação do sistema a excitação. Nesta metodologia, os valores 0,623 e 0,283 são tomados em relação ao valor de K (CARMO, 2006).

Analisando a resposta da planta ao degrau unitário aplicado na Figura 3.7, nota-se a presença de ruídos que são inevitáveis em todo experimento real (AGUIRRE, 2001). Todos os componentes do sistema contribuem com a inserção de ruídos e por assumirem características estocásticas, não podem ser completamente eliminados. No cenário de testes, é notável uma forte intensificação destes sinais indesejados quando a lâmpada incandescente, fonte térmica, é conectada à rede elétrica. Portanto, implementou-se um filtro média móvel de quinta ordem que age como um filtro passa baixa, pode ser implementado de forma simples e obtêm-se resultados satisfatórios em medições de temperatura.

Figura 5 – Resposta ao degrau de 50° na planta de temperatura considerando o filtro de média móvel para levantar o modelo FODT.



Fonte: os autores.

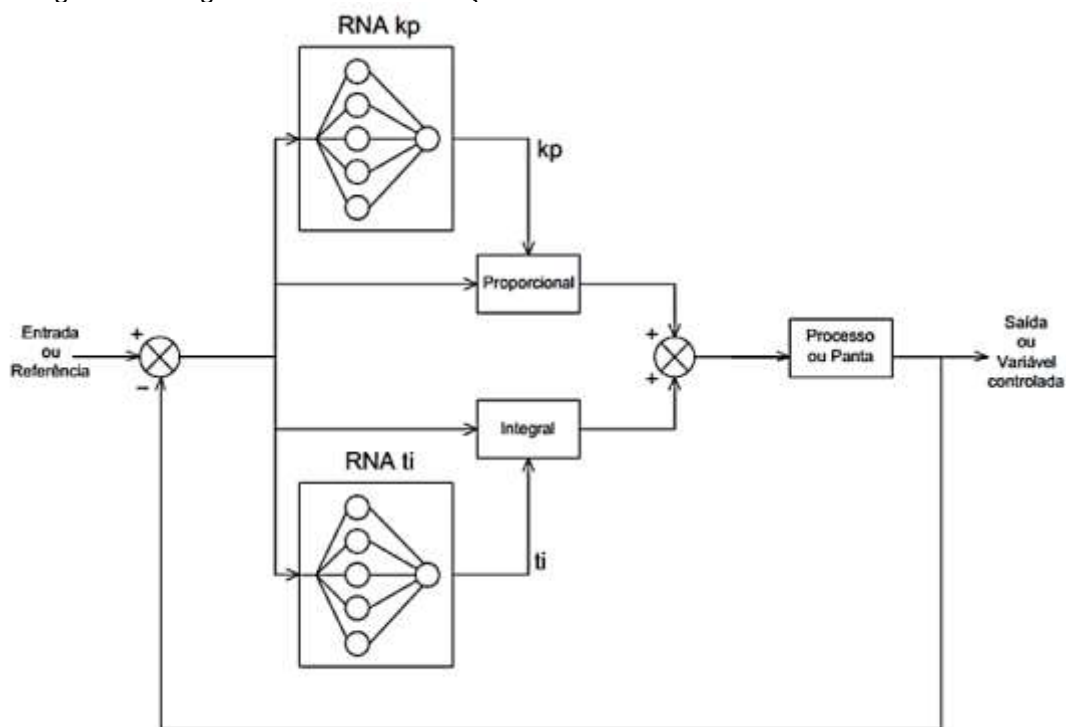
Um degrau de 50 graus Celsius foi aplicado e o modelo de primeira ordem para o processo é expresso na Equação 2.

$$G(s) = \frac{0,9064}{18,75s + 1} e^{-2,25s} \quad (2)$$

3.1 Modelagem das Redes Neurais

Nguyen *et. al* (2003) define este método de controle selecionado para a realização deste trabalho como forma direta. As redes neurais foram implementadas para gerarem as constantes dos ganhos proporcional e integral. Um esquemático é mostrado na Figura 6.

Figura 6 – Diagrama ilustrativo das ações das redes neurais sobre o controlador PI.

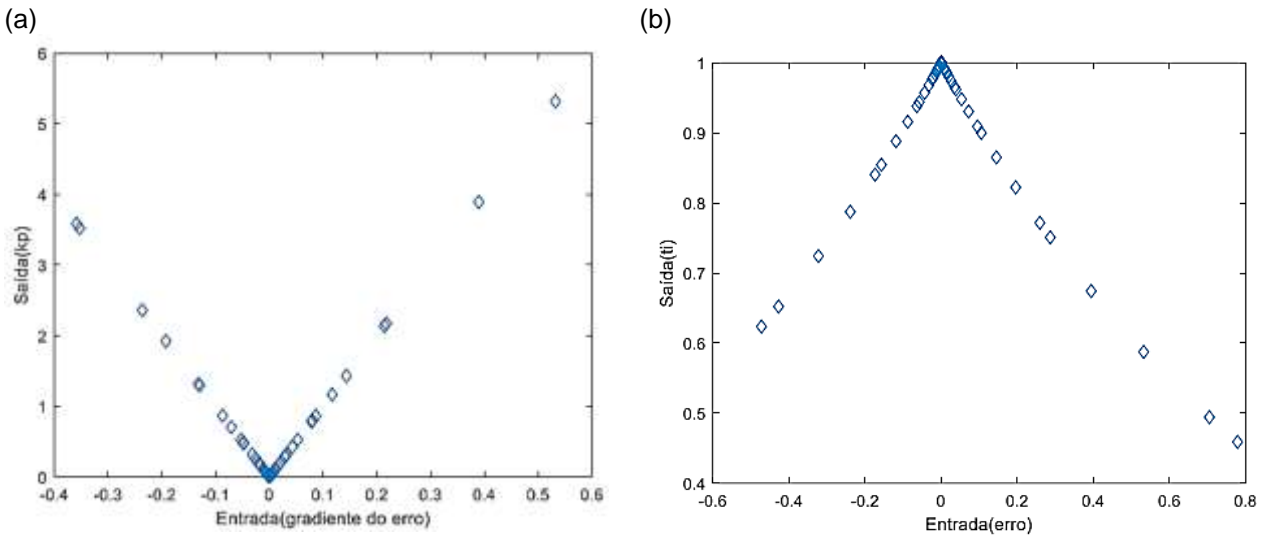


Fonte: os autores.

Neste trabalho, as redes neurais são compostas por duas camadas de neurônios. A primeira camada contém quantos neurônios forem desejados. A segunda camada contém apenas um neurônio que está encarregado de fornecer o valor de saída do controlador. As saídas correspondem aos ganhos proporcional e integral, apenas. Utilizou-se o modelo de rede neural proposto por Nguyen *et al.*, 2003 que sugere que sejam treinadas duas redes neurais, a *Perceptron* multicamadas para fornecerem a função que apresente comportamento semelhante a constante do ganho proporcional e a outra, a constante de um ganho integral, ambas em resposta a entrada que simula o erro. Ainda seguindo tal literatura, o comportamento do erro ao longo do tempo sob a ação controladora é simulado por uma senoide amortecida pois esta apresenta a associação de um padrão de origem oscilatória com algum amortecimento que aumenta em função do tempo. Portanto, este padrão fornece a simulação da diferença entre a saída obtida e a desejada desde o início da excitação do sistema até sua estabilização. Complementarmente, por sua capacidade de generalização, forneceria uma solução que reagisse as demais variações de erro. A

constante do ganho proporcional e a constante do ganho integral tem seus funcionamentos desempenhados pelas curvas da Figura 7a e 7b, respectivamente.

Figura 7 – Comportamento do: (a) – ganho proporcional mediante ao erro de entrada; (b) – ganho integral mediante ao erro de entrada.




Fonte: autores.

4 RESULTADOS


Os resultados do experimento indicam uma performance significativamente superior do ajuste de controladores PI utilizando redes neurais em comparação com os métodos tradicionais de Ziegler-Nichols e Cohen-Coon. No que diz respeito ao tempo de subida (t_r), a rede neural conseguiu um valor de 14,5 segundos, significativamente menor do que os 31 segundos de Ziegler-Nichols e 36 segundos de Cohen-Coon, demonstrando uma resposta mais rápida do sistema. O tempo de acomodação (t_s) também mostrou uma melhoria notável com a rede neural, alcançando 17 segundos, comparado aos 234 segundos de Ziegler-Nichols e 150 segundos de Cohen-Coon, o que evidencia uma estabilização mais rápida do sistema. Além disso, o máximo sobressinal foi drasticamente reduzido para 2,86% com a rede neural, enquanto Ziegler-Nichols e Cohen-Coon apresentaram 17,89% e 13,86%, respectivamente, indicando uma resposta mais controlada e menos oscilatória. Entretanto, foi observado que a rede neural introduziu oscilações de frequências mais altas no estado estacionário, embora essas oscilações permanecessem dentro da margem aceitável de 5% do máximo sobressinal. Essas oscilações podem ser explicadas pela maior sensibilidade da rede neural em ajustar os ganhos K_p e K_i em função do erro em tempo real. A adaptabilidade e a rapidez com que a rede neural responde às variações de erro podem resultar em ajustes mais frequentes e finos, que, por sua vez, geram essas oscilações de alta frequência. Essencialmente, enquanto a rede neural proporciona um controle mais eficiente e rápido, ela também pode introduzir dinâmicas mais complexas devido à sua natureza adaptativa e à resposta sensível às flutuações no erro do sistema, conforme às Figuras 8a, b e c.

Figura 8 – Resposta ao degrau de 38° em malha fechada para o método de Ziegler e Nichols (a); método de Cohen-Coon (b); Ajuste por Redes Neurais (c).



(a)



(b)



(c)



Fonte: os autores

5 CONCLUSÃO

O experimento demonstrou que o ajuste de controladores PI utilizando redes neurais supera significativamente os métodos tradicionais de Ziegler-Nichols e Cohen-Coon em termos de tempo de subida, tempo de acomodação e máximo sobressinal. Com a rede neural, observou-se uma resposta mais rápida e precisa do sistema, refletida em tempos de subida e acomodação substancialmente reduzidos e em um máximo sobressinal drasticamente menor. Esses resultados evidenciam o potencial das redes neurais para otimizar o desempenho dos controladores PI em aplicações de controle de processos.

Apesar das vantagens evidentes, o uso de redes neurais também introduziu oscilações de frequências mais altas no estado estacionário. Embora essas oscilações estivessem dentro da margem aceitável de 5%, elas indicam uma área potencial para melhorias futuras, especialmente no ajuste fino dos parâmetros da rede neural para mitigar essas oscilações sem comprometer a eficiência do controle.

Este estudo contribui para a literatura sobre a aplicação de inteligência artificial em engenharia, demonstrando que técnicas avançadas de IA, como as redes neurais, podem melhorar substancialmente o desempenho dos sistemas de controle de processos. A integração de tais técnicas no ensino de engenharia não só capacita os alunos a lidarem com tecnologias emergentes, mas também promove uma abordagem interdisciplinar, essencial para enfrentar os desafios complexos da engenharia moderna.

AGRADECIMENTOS

Os autores deste trabalho agradecem à FAPEMIG, CAPES, CNPq e CEFET-MG pelo fomento e apoio a este trabalho.

REFERÊNCIAS

AGUIRRE, L. A. **Introdução à Identificação de Sistemas: Técnicas Lineares e NãoLineares Aplicadas a Sistemas Reais**. 2. ed. Belo Horizonte: Editora UFMG, 2004.

ÅSTRÖM, Karl Johan; MURRAY, Richard. **Feedback systems: an introduction for scientists and engineers**. Princeton university press, 2021.

BARROS, Iaci Tucumã Castro de Martins. **Machine learning aplicada à modelagem e ao controle de um pêndulo invertido sobre um carro**. Trabalho de conclusão de curso de graduação. Instituto Federal do Espírito Santo, 2023.

CARMO, Marlon José. **Ambiente educacional multifuncional integrado para sintonia e avaliação do desempenho de malhas industriais de controle**. 2006. Tese de Doutorado. Dissertação de mestrado, Universidade Federal de Juiz de Fora.

CHEN, Lijia; CHEN, Pingping; LIN, Zhijian. Artificial intelligence in education: A review. **Ieee Access**, v. 8, p. 75264-75278, 2020.

GIRAFFA, Lucia; KHOLS-SANTOS, Pricila. Inteligência Artificial e Educação: conceitos, aplicações e implicações no fazer docente. **Educação em Análise**, v. 8, n. 1, p. 116-134, 2023.

HAYKIN, S. **Redes Neurais, Princípios e Práticas**. Porto Alegre: Bookman, 1999.

JAVOID, Mohd et al. Artificial intelligence applications for industry 4.0: A literature-based study. **Journal of Industrial Integration and Management**, v. 7, n. 01, p. 83-111, 2022.

MEIRA, Matheus Carvalho. **Desenvolvimento de um sistema de tutoria inteligente e interativo baseada na metodologia PBL aplicado em ambiente virtual de aprendizagem**. Tese de Doutorado. UNICAMP, Faculdade de Educação, 2022.

MEROTO, Monique Bolonha et al. Desbravando o amanhã: uma exploração profunda das tecnologias digitais da informação. **Caderno Pedagógico**, v. 21, n. 3, p. e3401-e3401, 2024.

KAUFMAN, Dora. **Desmistificando a inteligência artificial**. Autêntica Editora, 2022.

RANE, Nitin; CHOUDHARY, Saurabh; RANE, Jayesh. Education 4.0 and 5.0: Integrating Artificial Intelligence (AI) for personalized and adaptive learning. **Available at SSRN 4638365**, 2023.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático**. São Paulo: Artliber, 2010

RUSSELL, Stuart; NORVIG, Peter. Artificial intelligence: A modern approach, global edition. **Harlow: Pearson**, 2022.

SCARDUA, Leonardo Azevedo; DEVELLY, David Paolini. **Gamificação no ensino de inteligência artificial aplicada à engenharia de controle e automação**. Trabalho de conclusão de curso de graduação. Instituto Federal do Espírito Santo, 2021.

WANG, Xueli et al. Neural-network-based control with dynamic event-triggered mechanisms under DoS attacks and applications in load frequency control. **IEEE Transactions on Circuits and Systems I: Regular Papers**, v. 69, n. 12, p. 5312-5324, 2022.

YU, Z. et al. **Applying Neural Networks to PID Controllers for Time-Delay Systems**. 2006 International Conference on Machine Learning and Cybernetics. INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND CYBERNETICS, 2006.

INTEGRATION OF ARTIFICIAL INTELLIGENCE IN PROCESS CONTROL TEACHING: CASE STUDY WITH TEACHING TEMPERATURE PLANT

Abstract: *This study explores the use of neural networks to tune PI controllers in a didactic temperature plant, comparing them with the traditional Ziegler-Nichols and Cohen-Coon methods. The results showed that the neural network provided significantly lower rise and settling times, as well as a reduced maximum overshoot. However, high-frequency oscillations were observed in the steady state. The research highlights the effectiveness of neural networks in optimizing PI controllers and their relevance to engineering education, promoting an interdisciplinary approach to process control.*

Keywords: *Artificial Intelligence, Control System, Neural Network.*

